

# Manual do usuário

Versão digital  
Portable Document File

**Introdução**  
**Exercícios tutoriais**

**J. Ronald Eastman**

**Centro de Recursos Idrisi, Brasil**



**Idrisi**

for Windows  
Versão 2

# Idrisi

*for Windows*  
*versão 2*

## **Manual do usuário**

**Introdução**  
**Exercícios tutoriais**

**J. Ronald Eastman**  
Clark Labs for Cartographic  
Technology and Analysis

Editores da versão em português:

**Heinrich Hasenack**  
**Eliseu Weber**

Porto Alegre  
1998

©1998 by Graduate School of Geography, Clark University.

Este texto é parte integrante de:

EASTMAN, J. R. 1997. *IDRISI for Windows Users's Guide version 2.0. Introduction*. Worcester-MA, Graduate School of Geography, Clark University. p. 1-1 to 3-19.

EASTMAN, J. R. 1997. *IDRISI for Windows Users's Guide version 2.0. Tutorial Exercises*. Worcester-MA, Graduate School of Geography, Clark University. 192 p.

**Tradução:**

Eliseu Weber

Élvio Giasson

Fernando José de França

Heinrich Hasenack

Rodrigo Agra Balbuena

**Revisão técnica e editoração:**

Heinrich Hasenack

Eliseu Weber

**Agradecimentos:**

Ao Prof. Robin Thomas Clarke, do Instituto de Pesquisas Hidráulicas da UFRGS, pelo auxílio na tradução e adaptação para o português de termos relativos à estatística de dados espaciais.

**Realização:**

Universidade Federal do Rio Grande do Sul

Instituto de Biociências - Centro de Ecologia

Centro de Recursos Idrisi

**Solicitações:**

UFRGS Centro de Ecologia

Centro de Recursos Idrisi

Caixa postal, 15007

CEP 91.501-970 Porto Alegre RS Brasil

Tel.: (051) 316 6909

Fax: +55 (51) 319 1568

E-mail: [cridrissi@ecologia.ufrgs.br](mailto:cridrissi@ecologia.ufrgs.br)

<http://www.ecologia.ufrgs.br/~cridrissi>

---

**Eastman, J. R.**

IDRISI for Windows: Introdução e Exercícios tutoriais. J. Ronald Eastman. Editores da versão em português, Heinrich Hasenack e Eliseu Weber. Porto Alegre, UFRGS Centro de Recursos Idrisi, 1998.

**240p.: 45 figuras, 10 tabelas**

Palavras-chave: 1. Sistemas de informação geográfica; 2. Geoprocessamento; 3. GIS; 4. SIG; I. Eastman, J.R. II. Título

Todos os direitos reservados. Reprodução, mesmo parcial, proibida sob qualquer forma ou meio, sem autorização por escrito do editor.

IMPRESSO NO BRASIL

PRINTED IN BRAZIL

Centro de Recursos Idrisi, Brasil

O *software* descrito neste documento é fornecido sob licença e pode ser usado ou copiado somente de acordo com os termos desta licença (veja os termos da licença no **Guia de instalação**). O IDRISI pretende ser basicamente um veículo de baixo custo para o ensino e a pesquisa acadêmica. Em conformidade com esta intenção, um grande número de licenças para pesquisa, acadêmicas e para estudantes já estão disponíveis.

## **GARANTIA**

Este *software* é vendido “tal qual” e a informação contida neste manual está sujeita a modificações sem prévia notificação. Além disso, a *Graduate School of Geography* da Clark University não assume responsabilidade por quaisquer erros que possam aparecer neste documento ou no *software* que ele descreve.

A *Graduate School of Geography* da Clark University dá uma garantia pelo período de 30 dias a partir da data da compra sobre os disquetes ou CD-ROM através dos quais este *software* é distribuído de que eles estão livres de defeitos no material ou na mão-de-obra. No caso de notificação e devolução dos disquetes ou CD-ROM defeituosos no período de garantia, a *Graduate School of Geography* da Clark University os substitui. Em nenhuma outra circunstância haverá reposição ou devolução.

A GRADUATE SCHOOL OF GEOGRAPHY - CLARK UNIVERSITY DESCONSIDERA QUALQUER OUTRA GARANTIA EXPLÍCITA OU IMPLÍCITA, INCLUINDO MAS NÃO LIMITADA A GARANTIAS IMPLÍCITAS DE MERCABILIDADE E AJUSTE PARA FINS PARTICULARES, COM RELAÇÃO A DEFEITOS NOS DISQUETES E/OU NA DOCUMENTAÇÃO, E A LICENÇA DO PROGRAMA CONCEDIDA AQUI EM PARTICULAR E SEM OPERAÇÃO LIMITANTE DO PROGRAMA LICENCIADO. COM RESPEITO A QUALQUER APLICAÇÃO, USO OU PROPÓSITO PARTICULAR. EM NENHUM CASO A GRADUATE SCHOOL OF GEOGRAPHY - CLARK UNIVERSITY DEVE SER RESPONSÁVEL POR QUALQUER PERDA DE LUCRO OU QUALQUER OUTRO DANO COMERCIAL, INCLUINDO E NÃO RESTRINGINDO-SE APENAS A DANOS ESPECIAIS, ACIDENTAIS, CONSEQÜENTES OU OUTROS PREJUÍZOS.

## **MARCA REGISTRADA**

O Windows é uma marca registrada da Microsoft Corporation. Todos os outros nomes mencionados neste volume podem ser marcas registradas ou marcas registradas em suas respectivas companhias e recebem aqui os nossos agradecimentos.

## **GRATOS POR ADQUIRIREM O IDRISI FOR WINDOWS**

Bem vindo à versão 2.0 do Sistema de Análise Geográfica IDRISI for Windows.

Veja no **Guia de instalação** uma lista dos conteúdos do pacote bem como os termos da licença.

O seu cartão de registro incluído nestes materiais deve ser preenchido e enviado de volta ao nosso escritório. Ele assegurará a você o envio da revista bi-anual do IDRISI e de informação sobre atualizações.

Após findos seus 60 dias de assistência técnica gratuita, sugerimos que você faça um “contrato de assistência técnica”. Um formulário do contrato de assistência técnica acompanha seu *software*. Quando necessitar assistência técnica, por favor fique com o número de série de sua licença à mão, uma vez que a Clark University não fornece serviço sem este número.

Nós do projeto IDRISI esperamos satisfazê-lo com este *software*. Sugestões que vocês tenham para desenvolvimento futuro são sempre bem vindas.

## A CAPA DO MANUAL

A “árvore” apresentada na capa do Manual do usuário do IDRISI for Windows é parte de uma fotografia aérea de um sistema fluvial na Tanzânia. Árvores individuais nesta foto compreendem o que aparenta serem folhas, enquanto o padrão de drenagem forma os galhos e o tronco. A colocação da árvore do IDRISI como uma janela sob forma de vitral anuncia o lançamento do IDRISI for Windows.

## Contatos com o Projeto IDRISI

Para contactar o projeto IDRISI o endereço é:

The IDRISI Project  
The Clark Labs for Cartographic  
Technology and Geographic Analysis  
Clark University  
950, Main Street  
Worcester, MA 01610-1477  
U S A

Para contatos por telefone, fax ou correio eletrônico, ou para visitar-nos na Internet:

Vendas e solicitações em geral	(1) 508-793-7526
Assistência técnica	(1) 508-793-7528
Fax	(1) 508-793-8842
Bitnet	Idrisi@clarku
Internet	Idrisi@vax.clarku.edu
Web site	www.idrisi.clarku.edu

Nosso horário de funcionamento vai das 9h às 17h no horário da Costa Atlântica dos Estados Unidos (-5 horas GMT no inverno e -4 horas GMT no verão) de segundas a sextas-feiras. As mensagens fora deste horário são recebidas por secretária eletrônica.

## Agradecimentos

Este produto é resultado do esforço coletivo de um time de profissionais sérios. O *software* e a documentação foram concebidos e definidos por Ron Eastman. O time de programadores foi composto por Ron Eastman, Tammy Woodard, Diane Denner, Jim Hagan, Hong Jiang e Kristin Schneider. O time de documentação foi composto por Ron Eastman, Michele Fulk, Laurie Canavan, Karen Lehrach, Chris Allen e Kelly Davis. O sistema de Ajuda foi desenvolvido por Laurie Canavan. O design gráfico foi feito por Anne Gibson. O desenvolvimento de novos exercícios tutoriais e a conversão dos exercícios existentes foi feito por Ron Eastman, Michele Fulk, John Auble, Kevin St. Martin e Gary Votour. Testes locais foram coordenados por James Toledano com contribuição substancial de Stephanie Hulina, Mahadevan Ramachandran, Maggie Robertson, Mathilde Snel, Assaf Anyamba, Rhonda Davis, Nick Haan, Sandra Johnson, Dmitry Varlyguin, Amadou Thiam, Sarah Williams e Rita Young.

## Os laboratórios da Clark University

O projeto IDRISI é uma das várias atividades de **Clark Labs for Cartographic Technology and Analysis**, um dos quatro centros localizados no George Perkins Marsh Institute da Graduate School of Geography na Clark University. Em 1º de maio de 1997, a equipe do Clark Labs era composta pelas seguintes pessoas:

Anne Gibson (USA), Gerente do laboratório de cartografia  
Assaf Anyamba (Quênia), Pesquisador associado  
Chris Allen (USA), Analista de assistência técnica  
Diane Denner (USA), Programador  
Garry Votour (USA), Analista de assistência técnica  
Hong Jiang (China), Analista de pesquisa  
James Toledano (USA), Diretor assistente para o desenvolvimento de produtos  
Jessica Hilyard (USA), Assistente de serviço ao cliente  
Jim Hagan (USA), Programador  
John Auble (USA), Pesquisador associado Senior  
Karen Lehrach (USA), Vice-coordenadora dos Centros de Recursos/especialista de serviço ao cliente  
Kelly Davis (USA), Coordenador de marketing e de produção  
Kelly Harvey (USA), Serviço ao cliente e agente de arquivo  
Kevin St. Martin (USA), Coordenador dos Centros de Recursos  
Korey Darling (USA), Assistente estudante de serviço ao cliente  
Kristin Schneider (USA), Analista de pesquisa  
Laurie Canavan (USA), Diretor assistente de operações  
Maggie Parry (USA), Assistente de pesquisa K-12  
Maggie Robertson (USA), Especialista em assistência técnica  
Mahadevan Ramachandran (Índia), Pesquisador associado  
Marianna Pavlovskaya (Rússia), Assistente de pesquisa  
Mathilde Snel (Holanda), Vice-coordenador de treinamento  
Michele Fulk (USA), Diretor assistente para programas  
Nancie Consolie (USA), Assistente de serviço ao cliente  
Nick Haan (USA), Vice-coordenador de treinamento  
Rita Young (USA), Assistente de serviço ao cliente  
Rhonda Davis (USA), Testes  
Ron Eastman (Canadá), Diretor/programador  
Sandra Johnson (USA), Testes  
Sarah Williams (USA), Assistente de serviço ao cliente estudante  
Srinivas Emani (Índia), Pesquisador associado  
Stephanie Hulina (USA), Assistente de pesquisa  
Stephanie Wood (USA), Assistente de pesquisa  
Tammy Woodard (USA), Programadora/gerente do laboratório de desenvolvimento de sistemas  
Thomas Gabrielle (USA), Analista de sistemas de informação  
Ying Li (China), Assistente de pesquisa  
Yelena Ogneva-Himmelberger (Rússia), Assistente de pesquisa

## Os Centros de Recursos IDRISI

### Áustria

Salzburg University  
Dept. of Geography, Hellbrunnerstrasse 34, A-5020 Salzburg  
Contato: Drs. Josef Strobl, Eric J. Lorup  
Email: [Idrisi@geo.sbg.ac.at](mailto:Idrisi@geo.sbg.ac.at) <http://www.edvz.sbg.ac.at/geo/idrisi/irchome/htm>  
Fax: (+43) 662 8044 525

### Brasil

Universidade Federal do Rio Grande do Sul  
Centro de Ecologia, Caixa Postal 15.007, 91.501-970 Porto Alegre  
Contato: MSc Heinrich Hasenack, MSc Eliseu Weber  
Email: [cridrisi@ecologia.ufrgs.br](mailto:cridrisi@ecologia.ufrgs.br)  
<http://www.ecologia.ufrgs.br/idrisi>  
Fax: (+55) 51 319 1568

**China**

Beijing Normal University  
College of Resource & Environmental Science, N° 19 Xijiekouwai St., 100875 Beijing  
Contato: Dr. Yang Ming Chuan, Dr. Peng Wanglu, Dr. Shi Peijun  
Email: idrisi@ns.bnu.edu.cn  
Fax: (+86) 10 6220 0667

**Costa Rica**

Universidad Nacional  
Escuela de Ciencias Geográficas  
Email: robinson@irazu.una.ac.cr  
[http://www.una.ac.cr/geog/Isigae/frames/irc\\_cr/index.html](http://www.una.ac.cr/geog/Isigae/frames/irc_cr/index.html)  
Fax: (+506) 261 0028

**Eslováquia**

(administrado em conjunto com o centro de recursos da República Tcheca)  
Technicka Univerzita vo Zvolene Lesnicka Fakulta  
Email: tucek@vsld.tuzvo.sk  
Fax: (+42) 855 22654

**Espanha**

Universitat de Girona  
Servei de SIG, Place Ferrater Mora, 1, 17071 Girona  
Contato: Mr. David Comas, Ms. Irene Compte  
Email: idrisi@skywalker.udg.es  
<http://www.sigte.udg.es>  
Fax: (+34) 72 418230

administrado em conjunto com

Universidad de Alcalá  
Departamento de Geografía, C/. Colegios, 2, Alcalá  
Contato: Dr. Emilio Chuvieco, Dr. Javier Salas  
Email: ggecs@geogra.alcala.es

**Hungria**

University of Sopron  
College of Surveying & Land Management, P.O. Box 52, Pirosalma u. 1-3, H-8000 Szek-esfehervar  
Contato: Dr. Bela Markus, Mr. Andras Dioszegi  
Email: mb@geo.cslm.hu  
<http://geo.cslm.hu/geoinfo.idrisi.htm>  
Fax: (+36) 22 327 697

**Polônia**

Jagiellonian University  
Institute of Geography  
GIS laboratory  
31-044, Krakow  
Email: jkosak@arsenal.geo.uj.edu.pl

**Reino Unido**

Manchester Metropolitan University  
Dept. of Environmental & Geographic Sciences, John Dalton Building, Chester St., M15GD Manchester  
Contato: Dr. Ian Heywood, Mr. Bruce Carlisle, Mr. Bruce Carlisle, Mr. Simon Kenton  
Email: idrisi@mmu.ac.uk  
<http://ehlana.mmu.ac.uk/docs/Idrisi/index.html>  
Fax: (+44) 0161 247 6344

### **República Tcheca**

(administrado em conjunto com o centro de recursos da Eslováquia)  
Mendel University of Agriculture and Forestry  
Dept. of Geomatics  
Email: idrisi@mendelu.cz  
Fax: (+42) 5 4521 1422

### **Rússia**

Russian Academy of Sciences  
Institute of Geography  
Coastal Systems Laboratory, Staromonetny per. 29, 109017 Moscow  
Contato: Dr. Anatoly Mandych, Mr. Andrei Ptichnikov  
Email: idrisi.rc@g23.relcom.ru  
Fax: (+7) 095 487 6301

### **Suíça**

École Polytechnique Fédérale de Lausanne  
Chaire de Systèmes d'Information à Référence Spatiale  
GR-Ecublens, CH-1015, Lausanne  
Contato: Dr. Guillemette Willemin  
Email: Guillemette.Willemin@dgr.epfl.ch  
[http://dgrwww.epfl.ch/sirs/documents/idrisi\\_fr.html](http://dgrwww.epfl.ch/sirs/documents/idrisi_fr.html)  
Fax: (+41) 21 693 57 40

administrado em conjunto com

University of Fribourg  
Dept. of Geography, Perolles, Fribourg  
Contato: Dr. Claude Collet  
Email: Claude.Collet@unifr.ch  
Fax: (+41) 37 29 97 46

## **Nota especial**

O corpo deste material é dedicado a uma série de tópicos avançados. O tratamento dado aqui é necessariamente mais acadêmico e temos tentado oferecer a você um conjunto genérico de referências para estabelecer o contexto adequado à pesquisa. Caso seja iniciante em SIG, você poderá achar estes materiais um tanto desafiadores. Entretanto, a maior parte dos temas cobertos tornar-se-ão muito significativos quando você tiver adquirido uma maior familiaridade no uso de SIG como ferramenta de desenvolvimento de bancos de dados analíticos e espaciais. Como sempre, os comentários sobre este produto e a respeito da direção de nossa pesquisa são bem vindos. Esperamos que o sistema IDRISI for Windows represente um acréscimo produtivo ao seu conjunto de ferramentas para a exploração e o gerenciamento de fenômenos geográficos.





## **Prefácio**

É com satisfação que apresentamos a você a tradução da **Introdução** do Manual do usuário e dos **Exercícios tutoriais introdutórios** e **Exercícios tutoriais avançados** do IDRISI for Windows v.2.0.

Sempre no intuito de acompanhar a evolução do *software*, o Centro de Recursos Idrisi sente-se gratificado pela crescente procura do material em português. Isto deve-se ao aumento do número de usuários de geoprocessamento em países de língua portuguesa mas também evidencia o quanto é importante haver material disponível na língua mãe, possibilitando aplicações mais efetivas aos propósitos de seu idealizador, o professor Ron Eastman: o ensino e a pesquisa de geoprocessamento de qualidade e com preços acessíveis.

A inclusão da introdução do manual do usuário deve-se em grande parte às solicitações daqueles que já fizeram uso dos Exercícios tutoriais da versão 1.0, para que estes fossem acompanhados de alguns conceitos básicos de geoprocessamento. A bibliografia em português também não é muito ampla.

Muito interessantes sobretudo são os Exercícios tutoriais avançados. Através deles é possível avançar sobre temas bastante novos na área do geoprocessamento. Os conceitos existem há algum tempo, mas sua implementação como módulos de programa é pioneira no IDRISI.

Os nomes originais dos arquivos foram mantidos no texto traduzido para não criar confusão com relação a versões do programa e, em especial, de dados dos exercícios. É importante lembrar também que no texto em português o separador decimal é a vírgula, mas ao introduzir dados no IDRISI o separador decimal a usar deve ser o ponto.

Esperamos satisfazer a comunidade usuária desta ferramenta desejando a todos bons frutos em seu trabalho. Continuem a nos estimular, contactando-nos sobre dúvidas e trazendo-nos sugestões. O Centro de Recursos Idrisi para os países de língua portuguesa procurará atendê-los da melhor maneira possível.

Cordialmente,

Heinrich Hasenack  
Eliseu Weber

Editores



# Índice

<b><u>INTRODUÇÃO</u></b>	<b>1</b>
O PROJETO IDRISI	1
ESTRUTURA DO MANUAL DO IDRISI FOR WINDOWS	2
<b><u>INTRODUÇÃO A SISTEMAS DE INFORMAÇÃO GEOGRÁFICA (SIG)</u></b>	<b>4</b>
DEFINIÇÃO DE SIG	4
COMPONENTES DE UM SIG	5
BANCO DE DADOS ESPACIAL E DE ATRIBUTOS	5
SISTEMA DE VISUALIZAÇÃO CARTOGRÁFICA	5
SISTEMA DE DIGITALIZAÇÃO DE MAPAS	5
SISTEMA DE GERENCIAMENTO DE BANCO DE DADOS	6
SISTEMA DE ANÁLISE GEOGRÁFICA	7
SISTEMA DE PROCESSAMENTO DE IMAGENS	8
SISTEMA DE ANÁLISE ESTATÍSTICA	8
SISTEMA DE APOIO À DECISÃO	8
REPRESENTAÇÃO DE DADOS EM MAPAS	8
VETORIAL	8
RASTER	9
RASTER VERSUS VETORIAL	10
CONCEITOS GEOGRÁFICOS DE BANCO DE DADOS	10
ORGANIZAÇÃO	10
GEORREFERENCIAMENTO	12
ANÁLISE EM SIG	12
FERRAMENTAS ANALÍTICAS	12
OPERAÇÕES ANALÍTICAS	16
<b><u>INTRODUÇÃO AO SENSORIAMENTO REMOTO E AO PROCESSAMENTO DE IMAGENS</u></b>	<b>18</b>
DEFINIÇÃO	18
CONSIDERAÇÕES FUNDAMENTAIS	19
FONTE DE ENERGIA	19

COMPRIMENTO DE ONDA	19
MECANISMOS DE INTERAÇÃO	20
PADRÕES DE RESPOSTA ESPECTRAL	21
SENSORIAMENTO REMOTO MULTIESPECTRAL	23
SISTEMAS DE SENSORES MULTIESPECTRAIS	24
<b>SISTEMAS PLATAFORMA/SENSOR</b>	<b>26</b>
FOTOGRAFIA AÉREA	26
SISTEMAS DE SATÉLITES	27
<b>GEORREFERENCIAMENTO DE IMAGENS E FOTOGRAMETRIA</b>	<b>29</b>
<b>PROCESSAMENTO DIGITAL DE IMAGENS</b>	<b>29</b>
CORREÇÃO DE IMAGENS	30
REALCE DE IMAGENS	31
CLASSIFICAÇÃO DE IMAGENS	31
TRANSFORMAÇÃO DE IMAGENS	33
<b>CONCLUSÕES</b>	<b>35</b>
<b><u>EXERCÍCIOS TUTORIAIS INTRODUTÓRIOS</u></b>	<b>35</b>
<b><u>1. O AMBIENTE DO IDRISI FOR WINDOWS</u></b>	<b>37</b>
<b><u>2. O SISTEMA DE VISUALIZAÇÃO</u></b>	<b>41</b>
CONHECENDO AS IMAGENS DISPONÍVEIS: LIST E DESCRIBE	41
VISUALIZAÇÃO BÁSICA DE IMAGEM: LANÇADOR DE VISUALIZAÇÃO	42
UMA INTRODUÇÃO À COMPOSIÇÃO DE MAPAS	43
TABELAS DE CORES	43
LEGENDAS	45
DIMENSIONANDO A LEGENDA E A MOLDURA DO MAPA	45
FATORES DE EXPANSÃO / ZOOM / JANELA	46
OUTROS ELEMENTOS INTERATIVOS DE VISUALIZAÇÃO	47
VISUALIZAÇÃO DE VETOR BÁSICO	48
VISUALIZAÇÃO DE RELEVO EM PERSPECTIVA E IMAGENS DE COBERTURA	49
PREFERÊNCIAS DE VISUALIZAÇÃO	50
<b><u>3. COMPOSIÇÃO DE MAPAS</u></b>	<b>53</b>
<b><u>4. TABELAS DE CORES, SÍMBOLOS E AUTOESCALONAMENTO</u></b>	<b>57</b>
OFICINA DE TABELAS DE CORES	57
OFICINA DE SÍMBOLOS	59
CRIANDO PLANOS DE TEXTO E ARQUIVOS DE SÍMBOLOS DE TEXTO	59
AUTOESCALONAMENTO	62
<b><u>INTRODUÇÃO À MODELAGEM CARTOGRÁFICA</u></b>	<b>65</b>

<i>Introdução</i>	3
<b><u>5. CONSULTA AO BANCO DE DADOS</u></b>	<b>67</b>
<b><u>6. OPERADORES DE DISTÂNCIA E DE CONTEXTO</u></b>	<b>79</b>
<b><u>7. AUTOMAÇÃO DE ANÁLISES COM MACROS</u></b>	<b>85</b>
<b><u>8. DISTÂNCIAS DE CUSTO E CAMINHOS DE MENOR CUSTO</u></b>	<b>89</b>
<b><u>9. ÁLGEBRA COM MAPAS</u></b>	<b>105</b>
<b><u>10. OFICINA DE BANCO DE DADOS</u></b>	<b>104</b>
PARTE 1: EXPLORAÇÃO DOS DADOS	105
PARTE 2: CONSULTA AO BANCO DE DADOS POR LOCALIZAÇÃO	106
PARTE 3: VISUALIZAÇÃO DE ATRIBUTOS DO BANCO DE DADOS	107
PARTE 4: CONSULTA AO BANCO DE DADOS POR ATRIBUTO - FILTRO	109
PARTE 5: ÁLGEBRA COM MAPAS - CALCULAR	110
<b><u>11. EXPLORAÇÃO DE IMAGENS</u></b>	<b>115</b>
<b><u>12. CLASSIFICAÇÃO SUPERVISIONADA</u></b>	<b>131</b>
<b><u>13. ANÁLISE DE COMPONENTES PRINCIPAIS</u></b>	<b>130</b>
<b><u>14. CLASSIFICAÇÃO NÃO SUPERVISIONADA</u></b>	<b>133</b>
<b><u>15. GEORREFERENCIAMENTO DE IMAGENS USANDO REAMOSTRAGEM</u></b>	<b>136</b>
<b><u>16. BASES DE DADOS CARTOGRÁFICOS DIGITAIS</u></b>	<b>144</b>
<b><u>17. ALTERAÇÃO DO SISTEMA DE REFERÊNCIA COM PROJECT</u></b>	<b>148</b>

<b><u>EXERCÍCIOS TUTORIAIS AVANÇADOS</u></b>	<b>151</b>
<b><u>1. TEOREMA DE BAYES E CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA</u></b>	<b>152</b>
<b><u>2. DESENVOLVIMENTO DE ASSINATURAS FUZZY</u></b>	<b>155</b>
<b><u>3. CLASSIFICADORES RELATIVOS I: BAYCLASS</u></b>	<b>159</b>
<b><u>4. DISCRETIZADORES</u></b>	<b>162</b>
<b><u>5. CLASSIFICADORES RELATIVOS II: BELCLASS</u></b>	<b>164</b>
<b><u>6. DEMPSTER-SHAFFER MODIFICADO</u></b>	<b>166</b>
<b><u>7. ANÁLISE DE VEGETAÇÃO EM AMBIENTES ÁRIDOS</u></b>	<b>169</b>
<b><u>8. AVALIAÇÃO POR CRITÉRIOS MÚLTIPLOS -- ANÁLISE BOOLEANA</u></b>	<b>174</b>
DESENVOLVIMENTO DE DADOS E CRITÉRIOS	175
MCE USANDO OPERADORES BOOLEANOS	179
<b><u>9. AVALIAÇÃO POR CRITÉRIOS MÚLTIPLOS -- COMBINAÇÃO LINEAR PONDERADA</u></b>	<b>183</b>
<b><u>10. AVALIAÇÃO POR CRITÉRIOS MÚLTIPLOS -- MÉDIA PONDERADA ORDENADA</u></b>	<b>191</b>
<b><u>11. TOMADA DE DECISÃO COM OBJETIVOS MÚLTIPLOS</u></b>	<b>199</b>
<b><u>12. MODELAGEM DE PESO DE EVIDÊNCIA COM BELIEF</u></b>	<b>202</b>

<i>Introdução</i>	5
<b><u>13. INCERTEZA NO BANCO DE DADOS E RISCO NA DECISÃO</u></b>	<b>209</b>
<b><u>14. REGRESSÃO MÚLTIPLA EM SIG</u></b>	<b>213</b>
<b><u>15. VARIÁVEIS DICOTÔMICAS E REGRESSÃO LOGÍSTICA</u></b>	<b>218</b>





# INTRODUÇÃO

## O Projeto IDRISI

O IDRISI<sup>1</sup> é um sistema de informação geográfica e um *software* para processamento de imagens desenvolvido pela Graduate School of Geography da Clark University. Ele foi projetado para ser um instrumento para pesquisa geográfica profissional baseado no baixo custo e sem fins lucrativos. Desde sua introdução em 1987, o IDRISI vem crescendo e se tornando o SIG raster e de processamento de imagens para microcomputadores de maior difusão no mercado. Este sistema vem sendo usado em cerca de 120 países em todo o mundo em uma ampla gama de pesquisas, em órgãos públicos, no planejamento local, como fonte de gerenciamento e em instituições educacionais. Hoje o IDRISI é sustentado por uma equipe dedicada em tempo integral ao seu desenvolvimento, ao apoio técnico e ao atendimento ao usuário profissional, nos Clark Labs for Cartographic Technology and Geographic Analysis, George Perkins Marsh Institute, Clark University.

Durante seu desenvolvimento inicial, houve apoio parcial do Programa das Nações Unidas para o Meio Ambiente - Banco de Dados sobre Recursos Globais (UNEP-GRID), do Instituto das Nações Unidas para Treinamento e Pesquisa (UNITAR) e da Agência para Desenvolvimento Internacional dos Estados Unidos (USAID). Hoje, todo o apoio vem da venda do *software*, mas relações estreitas com estas e outras agências de desenvolvimento ainda são mantidas, na tentativa de prover um custo acessível aos instrumentos de análise geográfica.

O IDRISI é líder na funcionalidade analítica raster, cobrindo todo o espectro de necessidades de SIG e de sensoriamento remoto, desde consulta a banco de dados e modelagem espacial até realce e classificação de imagens. Facilidades especiais estão incluídas para monitoramento ambiental e gerenciamento de recursos naturais, incluindo análise de séries temporais/mudanças, apoio à decisão por critérios múltiplos e por objetivos múltiplos; análise de incerteza (incluindo análises *Bayesianas*, *Dempster Shafer* e de conjuntos *fuzzy*) e modelagem de simulação (incluindo modelagem de força e análise de atrito anisotrópico). Apesar da natureza altamente sofisticada destas funções, o sistema é muito fácil de usar.

Hoje, o IDRISI está disponível nas versões para MS-DOS e Windows<sup>2</sup>. Embora as duas versões sejam muito similares em sua funcionalidade analítica, o IDRISI for Windows oferece amplos recursos de análise em Bancos de dados. Este manual descreve a versão 2.0 for Windows. O IDRISI for Windows consiste de uma programa de interface principal (contendo o menu e o sistema de barra de ferramentas) e uma coleção de mais de 150 módulos de programas que oferecem funções para a entrada, a exibição e a análise de dados geográficos. Veja o capítulo *Módulos do IDRISI for Windows* para uma visão geral da estrutura de menus e uma listagem de todos os módulos e suas capacidades. Informações detalhadas sobre cada módulo, assim como uma variedade de outras informações técnicas, podem ser encontradas no Sistema de ajuda on-line.

---

<sup>1</sup> IDRISI é uma marca registrada da Clark University

<sup>2</sup> MS-DOS e Windows são marcas registradas da Microsoft Corporation

## **Estrutura do Manual do IDRISI for Windows**

A instalação do sistema de *software* IDRISI for Windows está descrita em detalhes em um *Guia de Instalação* que vem em separado. Uma vez instalado, a mais rápida introdução ao IDRISI for Windows pode ser feita com os *Exercícios Tutoriais*. Em paralelo ao trabalho de exercícios você deveria ler o restante do manual (especialmente a seção **FUNDAMENTOS DO SISTEMA**).

A **INTRODUÇÃO** deste manual contém uma visão geral do IDRISI for Windows, Sistemas de Informação Geográfica, sensoriamento remoto e processamento de imagens.

A parte de **FUNDAMENTOS DO SISTEMA**, como é denominada a parte introdutória deste programa, fornece instruções específicas quanto ao uso do IDRISI for Windows e oferece um resumo de toda a estrutura dos menus. O capítulo *Uso do IDRISI for Windows* é especialmente importante, uma vez que descreve a natureza do uso da interface, a estrutura do IDRISI for Windows em arquivos de dados e edições relacionadas à exibição de dados geográficos. O capítulo *Módulos do IDRISI for Windows* dá um resumo das suas habilidades e usos mais comuns. Este capítulo também resume a lógica da estrutura dos menus. A *Oficina de banco de dados* é um capítulo que descreve o sistema de gerenciamento de banco de dados, dando informação detalhada em todas as suas funções, incluindo a possibilidade de ligar-se o banco de dados a um mapa e sua habilidade de usar uma linguagem estruturada.

A seção **TÓPICOS ESPECIAIS** contém informações sobre uma série de tópicos específicos. O capítulo de *georreferenciamento* é especialmente importante, já que muitos projetos de utilização de SIG e processamento de imagens requerem georreferenciamento para um sistema geodésico e integração de dados com mapeamento de governos locais e nacionais. O capítulo que se refere a *Apoio à decisão* será de particular interesse para aqueles envolvidos com a distribuição de recursos e com o planejamento. Ele cobre os procedimentos específicos solicitados para experimentar critérios múltiplos/análise por objetivos múltiplos, assim como tomada de decisão na presença de incerteza. O capítulo relacionado à *Análise de séries temporais/mudança* trata de um aumento importante no conjunto de instrumentos para o monitoramento ambiental. Alguns tópicos incluem comparações, procedimentos para distinguir uma mudança real da variabilidade natural, perfil temporal e séries temporais através de análise de componentes principais. No capítulo sobre *Análise anisotrópica de custo* faz-se uma breve discussão dos procedimentos abordados na seção **FUNDAMENTOS DO SISTEMA** para considerar o caso dos atritos e forças (isto é, forças e atritos que atuam de forma distinta em diferentes direções). Estas ferramentas são experimentais, mas oferecem oportunidades para a modelagem de fenômenos dinâmicos como o fluxo de água subterrânea, o deslocamento do fogo nas florestas, o derramamento de óleo e assim por diante. No capítulo de *Produção cartográfica*, uma consideração especial é feita aos procedimentos de produção cartográfica e acerca do trabalho de “pré-impressão”. O capítulo *Criação de macros* é especialmente útil para aqueles que repetidamente usam seqüências de comandos. A macro é um procedimento que pode ser chamado para recriar uma seqüência. Este capítulo contém informações sobre a estrutura do arquivo macro, a criação e a execução de comandos macro.

Os *Exercícios tutoriais* são destinados ao aprendizado do IDRISI for Windows, dos instrumentos básicos usados em SIG e no processamento de imagens. Eles foram desenhados em formato adequado para sala de aula, assim como para a instrução auto-didática. Temos literalmente milhares de usuários que têm aprendido os conceitos básicos de SIG por meio destes exercícios.

A seção *Apêndices* contém informação detalhada dos tópicos apresentados nos capítulos preliminares. Os mais importantes são aqueles com as tabelas contendo as constantes usadas para transformação entre *datums* de mapas (sim, em geodésia, o plural de *datum* é *datums*, e não *data*). Nesta seção você também encontrará o *Glossário*.

Como parte adicional do volume impresso, o IDRISI for Windows também possui um *Sistema de ajuda* on-line. Isto não duplica a informação contida no **Manual do usuário**, mas funciona como um suplemento muito importante dele. Especificamente, o sistema de ajuda contém informação detalhada sobre o uso de cada módulo do IDRISI. Isto inclui informação sobre operações, notas especiais, explicações sobre erros e assim por diante. Para cada finalidade, o módulo tem um botão que pode ser

acionado para obter-se ajuda para o módulo desejado. O sistema de ajuda também pode ser acessado acionando o item respectivo no menu de ajuda. Você encontrará uma lista geral dos conteúdos, bem como uma palavra-chave para a busca de funções. O sistema de ajuda também contém um glossário básico assim como os fundamentos de como operar o sistema.

# ***Introdução a Sistemas de Informação Geográfica (SIG)***

A tecnologia SIG tem tido um enorme impacto em virtualmente todos os campos que gerenciam e analisam dados espacialmente distribuídos. Para aqueles que não estão familiarizados com a tecnologia é fácil vê-la como uma “caixa mágica”. A velocidade, consistência e precisão com a qual ela opera é realmente impressionante e é difícil resistir à sua forte característica gráfica. Entretanto, para analistas experimentados, a filosofia de SIG é muito diferente, pois com a experiência o SIG torna-se uma simples extensão do pensamento analítico. O sistema não tem respostas inerentes, apenas aquelas do analista. É somente uma ferramenta, assim como a estatística é uma ferramenta. É uma ferramenta para pensar.

Investir em SIG requer mais que um investimento em *hardware* e *software*. De fato, em muitos momentos este é o último item a se pensar. A maioria das pessoas lembra também que um investimento substancial necessita ser direcionado para o desenvolvimento da base de dados. Entretanto, um dos investimentos menos considerados, embora dos mais importantes, relaciona-se aos analistas que irão usar o sistema. O sistema e o analista não podem ser separados -- um é simplesmente uma extensão para o outro. Além disso, o processo de incorporação de um SIG em uma instituição requer um investimento em educação e treinamento a longo prazo e envolvendo toda a organização.

Em muitos casos aprender SIG envolve aprender a pensar -- aprender a pensar sobre padrões, sobre espaço e sobre processos que atuam no espaço. Como você aprendeu sobre procedimentos específicos, eles irão frequentemente ser encontrados no contexto de exemplos específicos. Eles também frequentemente terão nomes que sugerem sua aplicação típica. Mas atenção, resista à tentação de categorizar essas rotinas. A maioria dos procedimentos tem aplicações muito mais gerais e pode ser usada de muitas formas novas e inesperadas. Explore! Desafie o que você vê! O que você aprenderá vai muito além do que este ou qualquer pacote de *software* pode oferecer.

## ***Definição de SIG***

Um SIG é um sistema auxiliado por computador para a aquisição, armazenamento, análise e visualização de dados geográficos. Atualmente uma variedade de ferramentas de *software* está disponível para auxiliar nesta atividade, muitas das quais definem a si próprias como um SIG. Entretanto, elas podem diferir significativamente umas das outras, em parte pela maneira como representam e trabalham com dados geográficos, em parte pela ênfase dada às várias operações. Neste capítulo estudaremos estas diferenças para entender as características especiais do sistema IDRISI for Windows.

## Componentes de um SIG

Embora imaginemos um SIG como uma peça de *software* única, ele é composto de uma variedade de elementos distintos. A figura 2-1 dá uma visão geral dos componentes encontrados num SIG. Nem todos os sistemas têm todos esses elementos, mas para ser um verdadeiro SIG, um grupo essencial deve estar presente.

### *Banco de dados espacial e de atributos*

No centro do sistema está o banco de dados -- uma coleção de mapas e informações associadas na forma digital. Como o banco de dados trata feições da superfície terrestre, ele compreende dois elementos -- um banco de dados espacial descrevendo a geografia (forma e posição) das feições e um banco de dados de atributos descrevendo as características ou qualidades dessas feições. Podemos, por exemplo, ter uma propriedade rural definida no banco de dados espacial e qualidades como seu uso do solo, proprietário, avaliação e outros no banco de dados de atributos.

Em alguns sistemas, os bancos de dados espacial e de atributos são rigidamente separados um do outro, enquanto em outros estão integrados em uma única entidade -- por isso a linha se estendendo apenas meio caminho através do círculo central da figura 2-1. O IDRISI for Windows é do tipo que integra estes dois componentes em um. Entretanto, ele também oferece a opção de manter separados alguns elementos do banco de dados de atributos. Isto será explorado mais adiante quando examinarmos técnicas para a representação digital de dados de mapas.

### *Sistema de visualização cartográfica*

Circundando o banco de dados central temos uma série de componentes de *software*. O mais básico deles é o sistema de visualização cartográfica. O sistema de visualização cartográfica permite, a partir de elementos selecionados do banco de dados, produzir mapas de saída na tela ou em alguns dispositivos de saída em meio sólido como uma impressora ou plotter. A variação de possibilidades de produção cartográfica entre *software* SIG é bastante grande. A maioria oferece apenas uma saída cartográfica muito básica, e recomenda o uso de *software* de editoração de alta qualidade para satisfazer necessidades de produção mais sofisticadas, como a separação de cores.

O IDRISI for Windows permite composição cartográfica na tela altamente interativa e flexível, incluindo a especificação de múltiplos planos de dados, o dimensionamento e posicionamento de elementos do mapa como título, texto, barra de escala, imagens secundárias e outros, bem como configurações de símbolos e cores. As composições de mapa do IDRISI for Windows podem ser gravadas para visualização posterior, impressas em dispositivos compatíveis com Windows e exportadas em vários formatos *desktop publishing* comuns.

Sistemas de *software* que oferecem apenas a possibilidade de acessar e visualizar elementos de um banco de dados são freqüentemente citados como "Atlas eletrônicos".

### *Sistema de digitalização de mapas*

Após a visualização cartográfica, o próximo elemento mais essencial é o sistema de digitalização de mapas. Com um sistema de digitalização de mapas pode-se converter mapas existentes em papel para uma forma digital, desenvolvendo mais o banco de dados. No método de digitalização mais comum o mapa em papel é fixado sobre uma mesa digitalizadora, traçando-se depois as feições de interesse com um cursor, de acordo com os procedimentos exigidos pelo *software*. Muitos sistemas de digitalização de mapas também permitem alguma edição dos dados digitalizados. Existem vários pacotes de *software* de digitalização independentes que são compatíveis com o formato do IDRISI.

Os *scanners* também podem ser usados para digitalizar dados, como fotografias aéreas, por exemplo. O resultado é uma imagem gráfica, ao contrário das linhas de contorno de feições que são criadas com uma

mesa digitalizadora. O *software* para escanear normalmente oferece aos usuários uma variedade de formatos padrão de arquivos gráficos para exportação. Estes arquivos podem ser importados para um SIG. O IDRISI for Windows permite a entrada de formatos de arquivos gráficos TIF e BMP.

Os *software* do tipo *Computer Assisted Design* (CAD) e *Coordinate Geometry* (COGO) são dois exemplos de programas que possibilitam adicionar informação digitalizada de mapas ao banco de dados, além de oferecerem possibilidades de visualização cartográfica.

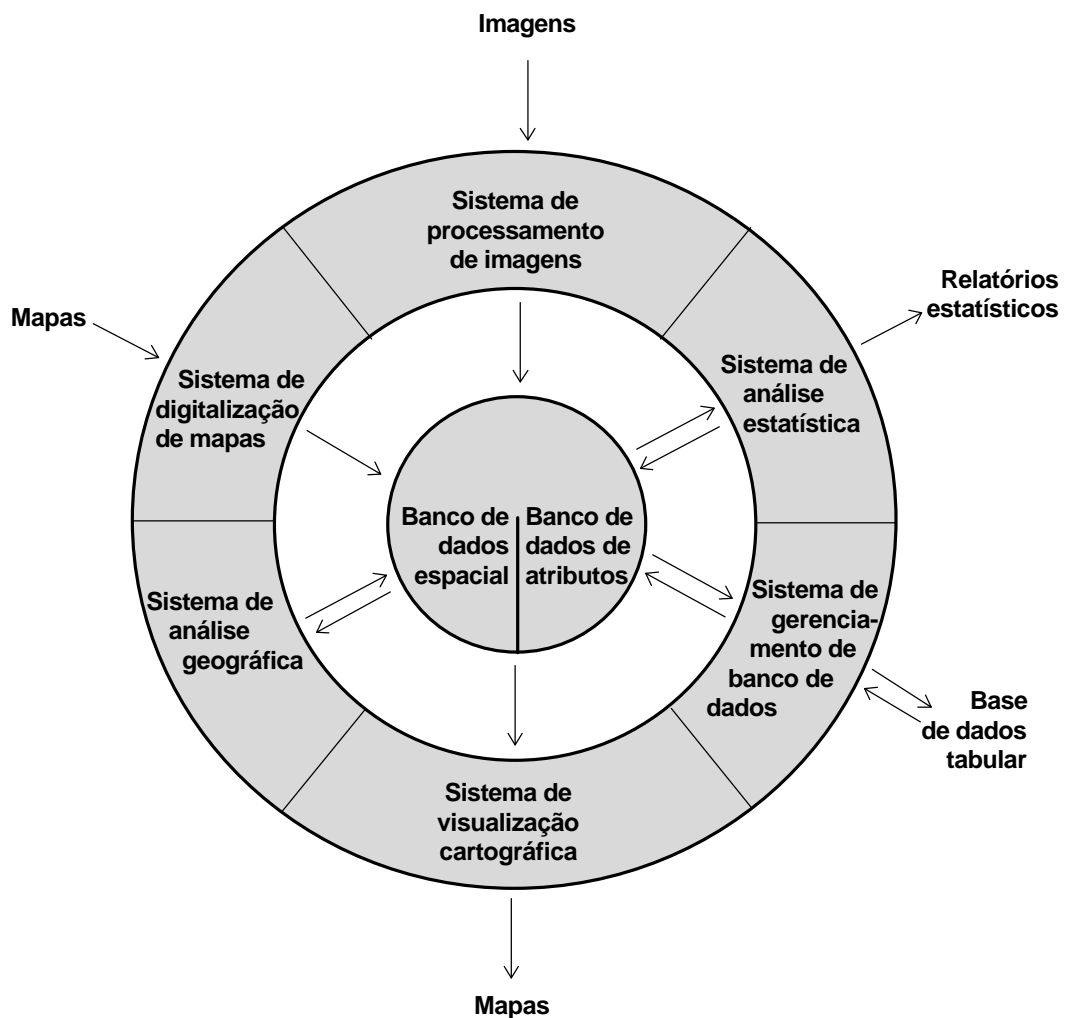


Figura 2-1. Componentes de um SIG

### *Sistema de gerenciamento de banco de dados*

O próximo componente lógico de um SIG é um sistema de gerenciamento de banco de dados (SGBD). Tradicionalmente, este termo se refere a um tipo de *software* que é usado para entrada, gerenciamento e análise de dados de atributo. Ele também é usado neste sentido aqui, embora necessitemos reconhecer que também se faz necessário o gerenciamento de dados espaciais. Assim, um SIG usualmente incorpora não apenas um SGBD tradicional, mas também uma variedade de utilitários para gerenciar os componentes espaciais e de atributos dos dados geográficos armazenados.

Com um SGBD, é possível introduzir dados de atributo como informação tabular e estatística e subsequentemente extrair tabulações especializadas e sumários estatísticos para gerar novos relatórios tabulares. Entretanto, mais importante é o fato de que um sistema de gerenciamento de banco de dados nos permite analisar dados de atributo. Muitas análises de mapas não têm um componente espacial verdadeiro, e para elas um SGBD freqüentemente funciona muito bem. Por exemplo, podemos solicitar ao sistema para encontrar todas as parcelas onde o chefe de família é solteiro, mas com uma ou mais crianças dependentes, e produzir um mapa com o resultado. O produto final (um mapa) é certamente espacial, mas a análise em si não tem qualidades espaciais. Dessa forma, as setas duplas entre o SGBD e o banco de dados de atributos na figura 2-1 significam essa forma distintamente não espacial de análise de dados.

No IDRISI for Windows, um SGBD é provido pela Oficina de banco de dados. Um extenso conjunto de módulos de programas também está disponível para o gerenciamento de dados espaciais e de atributo. É possível realizar análises na Oficina de banco de dados e então imediatamente aplicar os resultados ao dado espacial correspondente, visualizando os resultados na forma de um mapa.

Os *software* que oferecem visualização cartográfica, digitalização de mapas e capacidades de consulta ao banco de dados são freqüentemente chamados de sistemas AM/FM (*Automated Mapping and Facilities Management*).

### Sistema de análise geográfica

Até este ponto, descrevemos um conjunto abrangente de funções -- a digitalização de dados espaciais e a ligação de atributos às feições armazenadas, a análise de dados baseados nestes atributos e a visualização dos resultados na forma de mapa. Existe no mercado uma gama de sistemas que têm exatamente estas possibilidades, muitos dos quais nós denominamos de SIG. Embora estas funções sejam úteis, tal conjunto de funções não constitui necessariamente um SIG. O componente que falta é a possibilidade de analisar dados baseado em suas características espaciais reais. Para isso necessitamos de um Sistema de análise geográfica.

Com um sistema de análise geográfica, ampliamos as possibilidades de consulta a bancos de dados tradicionais para incluir a possibilidade de analisar dados baseados em sua posição geográfica. Talvez o exemplo mais simples disto é considerar o que acontece quando estamos envolvidos com a ocorrência concomitante de feições com distribuição espacial diferente. Por exemplo, suponha que desejamos encontrar todas as áreas residenciais sobre tipos de rocha associados com altos níveis de gás radônio. Este é um problema que um SGBD tradicional não pode solucionar porque tipos de rocha e divisões do uso do solo não compartilham os mesmos limites geográficos. As consultas aos SGBD tradicionais funcionam bem enquanto tratamos de atributos associados às mesmas feições. Quando as feições são diferentes isso não é possível. Para tal necessitamos um SIG. De fato, a possibilidade de comparar feições diferentes baseadas em sua ocorrência espacial comum é a marca registrada dos SIG. Esta análise é realizada pelo processo de *overlay* (sobreposição), assim denominada por ser idêntica em caráter à sobreposição de mapas transparentes dos dois tipos de entidades.

Assim como o SGBD, o Sistema de análise geográfica é visto (Fig. 2-1) como tendo duas formas de interação com o banco de dados -- o processo é distinto analiticamente e quanto ao caráter. Assim, enquanto ele acessa dados do banco de dados, ele pode contribuir de modo a oferecer os resultados desta análise como um novo acréscimo ao banco de dados. Por exemplo, podemos ter como objetivo determinar áreas que simultaneamente tenham declividades acentuadas e solos suscetíveis à erosão sob uso agrícola e denominar o resultado como um mapa de risco de erosão do solo. Este mapa de risco não existia no banco de dados original, mas foi derivado com base nos dados existentes e num conjunto de relacionamentos especificados. Assim o potencial analítico de um Sistema de análise geográfica e de um SGBD têm um papel importante em ampliar o banco de dados através da adição de conhecimento dos relacionamentos entre feições.

Enquanto *overlay* é a marca registrada de um SIG, a análise geográfica em computador amadureceu enormemente durante a última década. Um capítulo em separado explorará isso com maior detalhe.



Entretanto, por enquanto, estas observações são suficientes para verificar que é este componente geográfico distinto que dá ao SIG sua identidade. No IDRISI for Windows, estas funções são amplas e são a razão da criação deste sistema de *software*.

### **Sistema de processamento de imagens**

Em adição a esses elementos essenciais a um SIG -- um sistema de visualização cartográfica, um sistema de digitalização de mapas, um sistema de gerenciamento de banco de dados e um sistema de análise geográfica -- alguns sistemas de *software* incluem também a possibilidade de analisar imagens de sensoriamento remoto e oferecem análises estatísticas específicas. O IDRISI for Windows é um sistema deste tipo. *Software* de processamento de imagens permitem tomar uma imagem de sensoriamento remoto (tal como imagens de satélite LANDSAT ou SPOT) e convertê-las em dados interpretados na forma de mapa de acordo com vários procedimentos de classificação. O IDRISI for Windows oferece um amplo conjunto de ferramentas para a interpretação de dados de sensoriamento remoto com o computador, da maior importância como técnica de aquisição de dados, particularmente nos países em desenvolvimento.

### **Sistema de análise estatística**

Para a análise estatística, o IDRISI for Windows oferece procedimentos estatísticos tradicionais como também algumas rotinas específicas para a descrição de dados espaciais, em parte pelo caráter especial dos dados espaciais, mas também porque os dados espaciais colocam problemas especiais com relação a inferências descritas a partir de procedimentos estatísticos.

### **Sistema de apoio à decisão**

Enquanto o apoio à decisão é uma das mais importantes funções de um SIG, as ferramentas desenhadas especialmente para este fim existem em número relativamente pequeno na maior parte dos *software* de SIG. Contudo, o IDRISI for Windows inclui vários módulos especialmente desenvolvidos para auxiliar no processo de tomada de decisão. São módulos que incorporam o erro no processo, ajudam na construção de mapas de aptidão através de critérios múltiplos e atendem decisões sobre localização quando objetivos múltiplos estão envolvidos. Usados em conjunto com outros componentes do sistema, estes módulos oferecem uma ferramenta poderosa para tomadores de decisão na alocação de recursos.

## **Representação de dados em mapas**

Um aspecto que diferencia os vários sistemas de informação geográfica existentes é a forma com a qual os componentes de *software* mencionados acima são combinados. Entretanto, uma distinção ainda mais fundamental se refere a como eles representam dados de mapas em forma digital.

Um sistema de informação geográfica armazena dois tipos de dados que são encontrados em um mapa -- as definições geográficas das feições da superfície da Terra e os atributos ou qualidades que essas feições possuem. Nem todos os sistemas usam a mesma lógica para fazer isto, mas quase todos usam uma ou a combinação das duas técnicas fundamentais de representação de mapas: *vetorial* e *raster*.

### **Vetorial**

Com a representação vetorial, os limites ou o curso das feições são definidos por uma série de pontos que, quando unidos com linhas retas, formam a representação gráfica de cada feição. Os próprios pontos são codificados com um par de números representando as coordenadas X e Y em sistemas como latitude/longitude ou a grade de coordenadas Universal Transversa de Mercator. Os atributos das feições são então armazenadas num *software* de gerenciamento de banco de dados tradicional (SGBD). Por exemplo, um mapa vetorial de parcelas de propriedades rurais pode ser vinculado a um banco de dados

de atributos de informações contendo o endereço, nome do proprietário, avaliação da propriedade e uso da terra. A ligação entre estes dois arquivos de dados pode ser um simples número identificador que é dado a cada feição no mapa (figura 2-2).

### Raster

A segunda maior forma de representação é conhecida como *raster*. Com sistemas raster, a representação gráfica das feições e os atributos que elas possuem são fundidas em arquivos de dados unificados. Na verdade, nós não definimos feições de fato. Ao contrário, a área de estudo é subdividida em uma fina malha de células de grade, nas quais registramos a condição ou o atributo da superfície terrestre naquele ponto (figura 2-2). A cada célula é dado um valor numérico que pode representar tanto um identificador da feição quanto um código de atributo qualitativo ou um valor de atributo quantitativo. Por exemplo, uma célula pode ter o valor “6” para indicar que ela pertence ao distrito 6 (identificador de feição), que é coberta por tipo de solo 6 (atributo qualitativo) ou que está 6 metros acima do nível do mar (valor de atributo quantitativo).

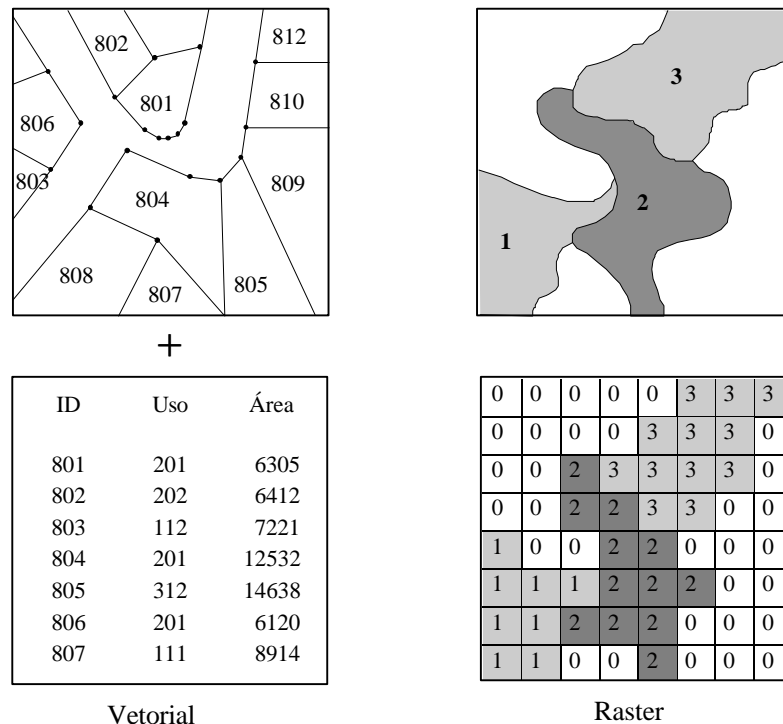


Figura 2-2. Representação de dados nos formatos vetorial e raster.

Embora os dados que armazenamos nestas células de grade não necessariamente correspondam a um fenômeno que possa ser visto no ambiente, as grades de dados podem ser pensadas elas próprias como *imagens* - imagens de algum aspecto do ambiente -- ou como *planos* -- cada um dos quais armazenando um tipo de informação sobre a região mapeada -- que podem ser feitos visíveis através do uso de um dispositivo de visualização raster. Num dispositivo raster, como a tela de seu computador, há também uma grade de pequenas células chamadas *pixels*. A palavra *pixel* é uma contração do termo *picture element*. Os *pixels* podem ser submetidos à uma variação em suas cores, forma ou tons de cinza. Para formar uma imagem visível, os valores das células são usados para regular diretamente a aparência de seus *pixels* correspondentes no dispositivo de visualização. Assim, em um sistema raster, o dado armazenado controla diretamente a forma visível que vemos.

### *Raster versus vetorial*

Os sistemas raster são tipicamente intensos em dados (embora existam boas técnicas de compactação de dados) uma vez que eles precisam registrar dados em cada posição de célula independentemente da célula ter ou não informação de interesse. Entretanto, a vantagem é que o espaço geográfico é uniformemente definido em uma forma simples e previsível. Como resultado, sistemas raster têm substancialmente maior poder analítico do que os sistemas vetoriais na análise do espaço contínuo<sup>3</sup> e são mais aptos para o estudo de dados que variam continuamente no espaço, como o relevo, a biomassa vegetal e a pluviosidade, por exemplo. A segunda vantagem de sistemas raster é que a sua estrutura se aproxima muito da arquitetura dos computadores digitais. Como resultado, sistemas raster tendem a ser muito rápidos na avaliação de problemas que envolvem várias combinações matemáticas de dados em múltiplos planos. Por isso eles são excelentes para a avaliação de modelos ambientais como a erosão potencial do solo e o manejo de florestas. Adicionalmente, como as imagens de satélite empregam uma estrutura raster, a maioria dos sistemas raster pode facilmente incorporar esses dados e alguns oferecem plena capacidade de processamento de imagens.

Enquanto sistemas raster são predominantemente orientados para a análise, os sistemas vetoriais tendem a ser mais orientados para o gerenciamento de bancos de dados. Sistemas vetoriais são muito eficientes no armazenamento de dados de mapas porque armazenam apenas os limites das feições e não o que está dentro desses limites. Em função da representação gráfica das feições estar diretamente ligada ao banco de dados de atributos, os sistemas vetoriais geralmente permitem o deslocamento em torno do visualizador gráfico com o mouse e a consulta dos atributos associados à feição visualizada, tais como a distância entre pontos ou ao longo de linhas, as áreas de regiões definidas na tela e assim por diante. Além disso, eles podem produzir mapas temáticos simples de consultas a banco de dados, como todas as seções de linhas de esgoto com mais de um metro de diâmetro instaladas antes de 1940.

Comparado com seus similares raster, os sistemas vetoriais não têm uma ampla gama de funções para análise sobre um espaço contínuo. Eles levam vantagem, entretanto, em problemas que envolvem movimentos sobre uma rede e podem empreender a mais fundamental das operações de SIG que será esboçada abaixo. Para muitos, é a simples função de gerenciamento de banco de dados e as excelentes possibilidades de mapeamento que tornam sistemas vetoriais atraentes. Por causa da forte afinidade entre a lógica da representação vetorial e a produção tradicional de mapas, um *plotter* de pena pode ser usado para produzir um mapa muito parecido com aqueles produzidos por meios tradicionais. Como resultado, sistemas vetoriais são muito populares em aplicações municipais onde predominam questões de produção de mapas para engenharia e gerenciamento de bancos de dados.

Sistemas raster e vetoriais têm cada um seus pontos fortes. O IDRISI for Windows incorpora elementos de ambas as técnicas de representação. Embora seja um sistema analítico raster, o IDRISI for Windows emprega a estrutura de dados vetorial como uma das principais formas de visualização e intercâmbio de dados de mapas. Aspectos fundamentais de gerenciamento de banco de dados vetorial estão também presentes no IDRISI.

## **Conceitos geográficos de banco de dados**

### *Organização*

Independente da lógica usada para a representação espacial, raster ou vetorial, começamos a ver que um banco de dados geográfico -- um banco de dados completo para uma dada região -- é organizado de maneira similar a uma coleção de mapas (figura 2-3). Sistemas vetoriais podem chegar mais próximo desta lógica, com o que é conhecido como *Coverages* -- coleções similares a mapas que contêm as definições geográficas de um conjunto de feições e suas tabelas de atributos associadas. Entretanto, eles

---

<sup>3</sup> A estrutura básica de dados de sistemas vetoriais pode ser melhor descrita como uma rede. Como resultado, não é surpresa o fato de sistemas vetoriais terem excelente capacidade para a análise de redes. Assim a diferença entre raster e vetorial é menor em termos de habilidades inerentes do que nos tipos de espaço que eles descrevem.

diferem dos mapas em duas coisas. Primeiro, cada uma conterá informação de apenas um único tipo de feição, como parcelas de propriedades, polígonos de solos e outros temas. Segundo, eles podem conter um conjunto completo de atributos que pertencem a essas feições, como um conjunto de informações de censo para vários setores da cidade.




Figura 2-3

Sistemas raster também usam essa lógica parecida com a de um mapa, mas geralmente dividem os conjuntos de dados em planos unitários. Um plano contém todos os dados para um único atributo. Dessa maneira, pode haver um plano de solos, um plano de estradas e um plano de uso da terra. Em alguns sistemas raster, como no IDRISI for Windows, também é possível ligar um plano identificador de feições (um plano que contém os identificadores das feições localizadas em cada célula de grade) com tabelas de atributos. Mais comumente, existirão planos separados para cada atributo a partir dos quais, isolados ou em combinação, serão feitas visualizações em tela ou mapas em papel.

Embora haja diferenças sutis, para todas as tentativas e propósitos, planos raster e *coverages* vetoriais podem ser entendidas simplesmente como diferentes manifestações do mesmo conceito -- a organização do banco de dados em mapas temáticos elementares. Planos e *coverages* diferem dos mapas comuns e tradicionais em um aspecto importante. Quando dados de um mapa são codificados em forma digital (digitalização) diferenças de escala são removidas. O dado digital pode ser visualizado ou impresso em qualquer escala. Mais importante ainda, planos de dados digitais derivados de mapas de papel de diferentes escalas, mas cobrindo a mesma área geográfica, podem ser combinados.

Adicionalmente, muitos SIG, incluindo o IDRISI for Windows, oferecem utilitários para mudar o sistema de projeção cartográfica e de referência de planos digitais. Isto permite que múltiplos planos, digitalizados a partir de mapas com várias projeções e sistemas de referência, sejam convertidos a um sistema comum.

Com a possibilidade de gerenciar diferenças de escala, projeção e sistema de referência, os planos podem ser fundidos com facilidade, eliminando um problema que tem tradicionalmente dificultado o planejamento de atividades com mapas em papel. É importante observar, entretanto, que a questão da **resolução** da informação nos planos de dados permanece. Embora feições digitalizadas de um mapa mundial em escala pequena possam ser combinadas em um SIG com feições digitalizadas a partir de um mapa local de escala grande, como um mapa de ruas de uma cidade, isto normalmente não deveria ser feito. O nível de exatidão e detalhe do dado digital pode ser apenas tão bom quanto o dos mapas originais.

### Georreferenciamento

Todos os arquivos de dados espaciais em um SIG são georreferenciados. O georreferenciamento refere-se à localização de um plano ou *coverage* no espaço definida por um sistema referenciamento de coordenadas. Com imagens raster, uma forma comum de georreferenciamento é indicar o sistema de referência (p.ex. latitude/longitude), as unidades de referência (p. ex.; graus) e as coordenadas das bordas esquerda, direita, superior e inferior da imagem. O mesmo é válido para os arquivos de dados vetoriais, embora as bordas esquerda, direita, superior e inferior se refiram ao que é comumente chamado de *Retângulo envolvente* da *coverage* -- um retângulo que define os limites da área mapeada<sup>4</sup>. Esta informação é particularmente importante num SIG integrado como o IDRISI for Windows, uma vez que isto permite que arquivos raster e vetoriais sejam relacionados um ao outro de uma maneira significativa e segura. Também é vital para o referenciamento de valores de dados às posições reais no terreno.

O Georreferenciamento é uma consideração extremamente importante no uso de SIG. Por isso, um capítulo separado a respeito de **Georreferenciamento** na seção **TÓPICOS ESPECIAIS** trata detalhadamente este tópico.

## Análise em SIG

A organização dos bancos de dados em planos não é feita simplesmente por razões de clareza organizacional, mas para prover acesso rápido aos elementos de dados requeridos para análise geográfica. De fato, a *raison d'être*<sup>5</sup> do SIG é prover um instrumento para a análise geográfica. As características analíticas de um SIG podem ser vistas de duas formas. Primeiro, do ponto de vista das ferramentas que o SIG oferece. Segundo, dos tipos de operação que o SIG executa. Independente de usarmos sistemas raster ou vetoriais, podemos agrupar as ferramentas em quatro grupos básicos e as operações efetuadas em três.

### Ferramentas analíticas

#### Consulta ao banco de dados

As mais fundamentais de todas as ferramentas oferecidas por um SIG são aquelas envolvidas com consulta ao banco de dados. A consulta ao banco de dados simplesmente solicita para ver a informação armazenada. Em alguns casos nós consultamos pela localização -- *que tipo de uso da terra existe neste local?* Em outros casos consultamos por atributo -- *que áreas possuem alto nível de gás radônio?*

<sup>4</sup> Convém explicar aqui que o *retângulo envolvente* é definido pela região de estudo de interesse e não se refere às coordenadas mínimas e máximas reais no arquivo de dados.

<sup>5</sup> *Raison d'être*, do francês: a própria razão de ser ou existir, expressão emprestada do francês para reforçar certas afirmações e usado com regularidade no inglês.

Algumas vezes efetuamos consultas simples como estas que acabamos de ilustrar, e outras vezes fazemos uma combinação complexa de condições -- *mostre-me todas as áreas sujeitas à inundação maiores que 1 hectare e que estejam próximas a áreas industriais.*

Na maioria dos sistemas, incluindo o IDRISI for Windows, essas operações de consulta são efetuadas em dois passos. O primeiro passo, chamado de *reclassificação*, cria um novo plano *para cada condição individual de interesse* (figura 2-4). Por exemplo, se alguém estivesse procurando por áreas residenciais sobre rochas associadas a altos níveis de gás radônio, o primeiro passo seria criar um plano de áreas residenciais reclassificando todos os códigos de uso da terra em apenas dois - um código 1 para áreas residenciais e um código 0 para todos os outros casos. O plano resultante é conhecido como plano *Booleano*, uma vez que mostra apenas aquelas áreas que preenchem a condição (1 = verdadeiro, residencial) e aquelas que não preenchem (0 = falso, não residencial). Planos *Booleanos* são também chamados planos *lógicos*, uma vez que eles mostram apenas a relação verdadeiro/falso. Eles são algumas vezes chamados binários, pois contêm apenas zeros e uns, mas evitaremos usar este termo porque ele também descreve um tipo particular de formato armazenamento de dados. Neste texto nós chamaremos estes planos de planos *Booleanos*.

Uma vez tendo sido criado o plano residencial, um plano de geologia é então também reclassificado para criar um plano *Boleano* mostrando áreas com rochas associadas com altos níveis de gás radônio. A partir deste ponto podemos combinar as duas condições usando uma operação de sobreposição, também chamada de *overlay* (figura 2-4). Como mencionado anteriormente, sobreposição é a marca registrada dos SIG na qual somente um SIG pode combinar condições como estas que envolvem feições com diferentes geografias. Tipicamente, uma operação de sobreposição em SIG permitirá a produção de novos planos com base em algumas combinações lógicas ou matemáticas de dois ou mais planos de entrada. No caso de consulta ao banco de dados, as operações lógicas principais de maior interesse são os operadores relacionais *AND* e *OR*, também conhecidos respectivamente como as operações de *INTERSECÇÃO* e *UNIÃO*. Aqui estamos procurando por casos de áreas residenciais *AND* (e) alto nível de gás radônio -- a intersecção lógica de nossos dois planos *Booleanos*.

### Álgebra com mapas

O segundo conjunto de ferramentas que um SIG geralmente oferece destina-se a combinar matematicamente planos de mapas. A modelagem requer a possibilidade de combinar planos de acordo com várias equações matemáticas. Por exemplo, podemos ter uma equação que prediz a temperatura média anual em função da altitude. Como outro exemplo, temos também a possibilidade de criar um mapa de erosão potencial do solo com base em fatores de erodibilidade do solo, de gradiente de declividade e de intensidade pluviométrica. Para isso necessitamos modificar os valores dos dados em nossos planos de mapa através de várias operações e transformações matemáticas e combinar fatores matematicamente para produzir o resultado final.

As ferramentas de álgebra com mapas geralmente possibilitam três diferentes tipos de operações:

1. modificar aritmeticamente valores de dados de atributos sobre o espaço por uma constante (isto é, aritmética escalar);
2. transformar matematicamente valores de dados de atributos por uma operação padrão. (como funções trigonométricas, transformações logarítmicas e assim por diante);
3. combinar matematicamente (como adicionar, subtrair, multiplicar, dividir) diferentes planos de dados pra produzir um resultado composto.

Esta terceira operação é simplesmente outra forma de sobreposição - sobreposição matemática, diferente da sobreposição lógica de consulta ao banco de dados.

Para ilustrar isso, considere um modelo para derretimento da neve em áreas densamente florestadas<sup>6</sup>

$$M = (0.19T + 0.17D)$$

onde M é a taxa de derretimento em cm/dia, T é a temperatura do ar e D é a temperatura do ponto de

<sup>6</sup> Equação tomada de Dune, T.; Leopold, L. B. 1978. *Water in Environmental Planning*. W.H. Freeman and Co. San Francisco. 480p.

orvalho. Tendo planos de temperatura do ar e ponto de orvalho para uma região desse tipo, poderíamos facilmente produzir um mapa de taxa de derretimento da neve. Para tanto seria necessário multiplicar o plano de temperatura por 0,19 (uma operação escalar), o plano do ponto de orvalho por 0,17 (outra operação escalar) e então empregar uma operação de sobreposição para adicionar aos dois resultados. Apesar de simples em conceito, esta possibilidade de tratar planos de mapas como variáveis em fórmulas algébricas é extremamente poderosa.

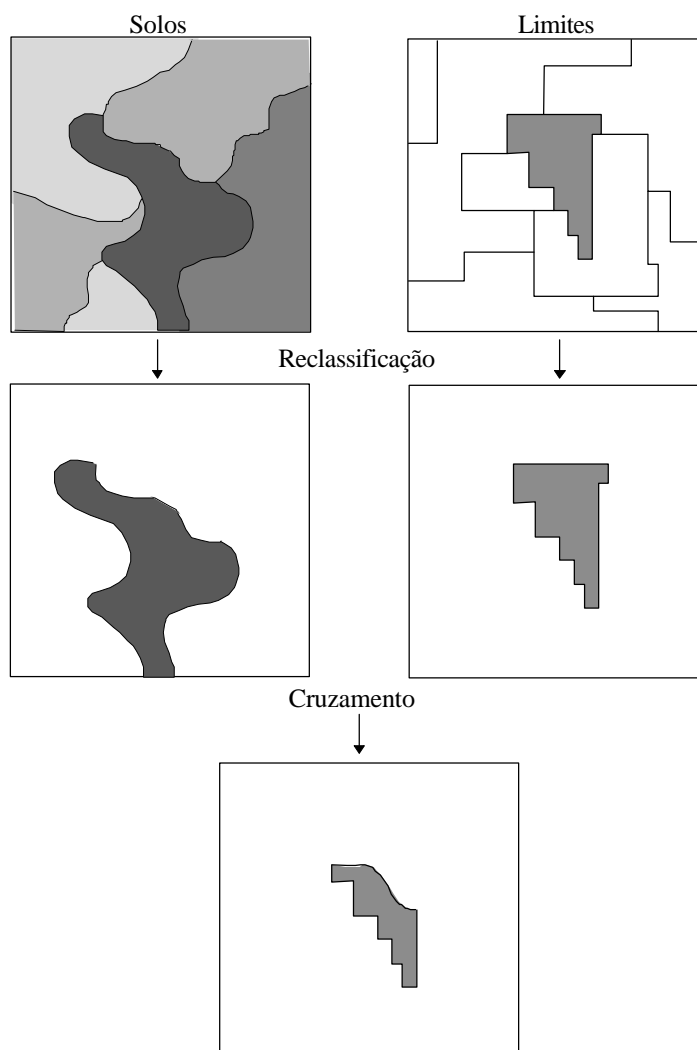


Figura 2-4

### Operadores de distância

O terceiro grupo de ferramentas oferecidas por um SIG consiste de Operadores de distância. Como o nome sugere, eles são um conjunto de técnicas onde a distância desempenha um papel fundamental na análise. Virtualmente todos os sistemas provêm ferramentas para criar faixas tampão -- áreas dentro de uma distância a partir de um tipo de feição determinado (figura 2-5). Alguns podem também avaliar a distância de todos os locais à feição de um conjunto mais próxima (figura 2-6), enquanto outras podem incorporar efeitos de atrito (figura 2-7) e barreiras (figura 2-8) nas distâncias calculadas.

Quando efeitos de atrito são incorporados, a distância calculada é freqüentemente referida como *distância de custo*. Este nome é usado porque o movimento através do espaço é considerado estar sujeito a custos, medidos em dinheiro, tempo ou esforço. Os atritos aumentam estes custos. Quando os custos de movimento de um ou mais locais são avaliados para uma região inteira, freqüentemente nos referimos ao resultado como uma *superfície de custo* (figura 2-7). Neste caso, áreas de baixo custo (presumivelmente

próximas ao ponto de partida da análise) podem ser vistas como vales, e áreas de alto custo podem ser vistas como elevações. Uma superfície de custo tem seus pontos mais baixos no local ou locais de partida da análise e seus pontos mais altos nos locais que estão mais afastados (no sentido do maior custo acumulado)<sup>7</sup>.

Podem haver casos em que os atritos não afetem o custo do movimento da mesma forma em todas as direções. Em outras palavras, eles atuam anisotropicamente. Um exemplo disso é o movimento através de uma paisagem onde os atritos dependem da declividade. Subir uma rampa íngreme resultaria em um custo mais alto do que descer esta mesma rampa. A direção do movimento através do atrito é importante e deve ser levado em conta no desenvolvimento da superfície de custo. O IDRISI for Windows provê módulos para modelar esse tipo de superfície de custo que está explicada em detalhe no capítulo *Análise anisotrópica de custo* na seção *TÓPICOS ESPECIAIS* do Manual do usuário.

Dado o conceito de uma superfície de custo, os sistemas de informação geográfica usualmente também oferecem *análise de caminho de menor custo* -- outra importante operação de distância. Como o nome sugere, nosso objetivo é avaliar o caminho de menor custo entre dois locais. É a superfície de custo que dá a informação necessária a essa avaliação (figura 2-8).



Figura 2-5




Figura 2-6




Figura 2-7




Figura 2-8

<sup>7</sup> Convém esclarecer aqui que uma superfície de custo somente pode ser avaliada com um sistema raster. Para sistemas vetoriais, o equivalente mais próximo poderia ser as distâncias avaliadas sobre uma rede. Nós vimos uma simples mas eficaz ilustração das diferenças entre sistemas raster e vetoriais quanto à maneira como eles concebem o espaço.



Independente da forma como a distância é avaliada, por distância em linha reta ou por distância de custo, outra ferramenta geralmente disponível é a *distribuição*. Com a distribuição, nós atribuímos locais à mais próxima de um conjunto de feições determinadas. Por exemplo, devemos estabelecer um conjunto de postos de saúde e então distribuir residentes seu posto mais próximo, onde “próximo” pode ser expresso em distância linear ou distância de custo, como tempo de viagem, por exemplo.

### Operadores de contexto

Finalmente, a maioria dos sistemas de informação geográfica provê uma variedade de operadores de contexto (também conhecidos como *operadores de vizinhança* ou *operadores locais*). Com os operadores de contexto é possível criar novos planos com base na informação de um mapa existente e no contexto no qual ele se encontra. Um dos exemplos mais simples disso é a *análise de superfície*, onde um modelo digital de elevação é usado para produzir um plano de declividades através da avaliação da altitude de um local em comparação com a altitude dos locais vizinhos. De forma similar, a orientação (ou aspecto -- a direção da máxima declividade) também pode ser avaliada.

Um segundo bom exemplo de operador de contexto é um *filtro digital*. Filtros digitais operam mudando os valores de acordo com o caráter dos valores vizinhos. Por exemplo, uma superfície de altitudes do terreno pode ser suavizada substituindo os valores pela média da altitude original e da altitudes vizinhas. Filtros digitais têm um grande número de aplicações em SIG e sensoriamento remoto, desde a remoção de ruído até o realce visual de imagens.

Por causa da sua estrutura de dados simples e uniforme, sistemas raster tendem a oferecer um rico conjunto de operadores de contexto. No IDRISI for Windows, por exemplo, isso inclui análise de superfícies e filtragem digital, identificação de áreas contíguas, análises de bacias hidrográficas, análises de áreas visíveis (uma análise de todas as áreas visíveis a partir de uma ou mais feições determinadas) e um procedimento especial de modelagem de suprimento/demanda onde as demandas são satisfeitas através da tomada de suprimentos de uma forma radial a partir dos locais vizinhos.

## Operações analíticas

Dadas as ferramentas básicas, uma grande variedade de operações analíticas podem ser efetuadas. A maior parte delas pode ser classificada em três grupos básicos, quais sejam a consulta ao banco de dados, o mapeamento derivativo e a modelagem de processos.

### Consulta ao banco de dados

Com consulta ao banco de dados nós estamos simplesmente selecionando combinações de variáveis para exame. As ferramentas que usamos são em grande parte as ferramentas de consulta ao banco de dados que discutimos anteriormente (por isso o nome), mas também incluem vários procedimentos de medição e análise estatística. A principal característica que distingue esse tipo de análise é que não conseguimos obter do sistema nada além do que colocamos nele. Apesar de podermos extrair combinações que nunca examinamos antes, o sistema não nos fornece nova informação -- estamos simplesmente fazendo uma retirada de um banco de dados que previamente construímos.

Uma das principais atividades na consulta ao banco de dados é a procura de padrões. Geralmente estamos procurando padrões espaciais nos dados que podem nos levar a criar hipóteses sobre relacionamentos entre variáveis.

### Mapeamento derivativo

Com mapeamento derivativo nós combinamos componentes selecionados de nosso banco de dados para construir novos planos derivados. Por exemplo, podemos tomar nossos dados de elevação digital para derivar gradientes de declividade, e então tomar nossos dados de declividade e combiná-los com informação do tipo de solo e regime pluviométrico para produzir um novo mapa de potencial de erosão. Esse novo mapa se torna um acréscimo ao nosso crescente banco de dados.

Como podemos criar novos dados a partir de dados já existentes? Diferente da consulta ao banco de dados onde simplesmente extraímos informação que já estava no banco de dados, com mapeamento

derivativo nós tomamos informação existente e a ela adicionamos algo novo -- *conhecimento de relacionamentos* entre elementos do banco de dados. Podemos criar um mapa de potencial de erosão do solo usando um plano com um modelo digital de elevação, um plano de solos e um plano de regime pluviométrico, mas somente se conhecermos o relacionamento entre esses fatores e o novo mapa que estamos criando. Em alguns casos, esses relacionamentos devem ser especificados em termos lógicos (como a criação de um mapa de aptidão para localização de uma indústria, com a condição de que ela deve estar em áreas de floresta, fora de áreas de proteção em torno de banhados e em baixas declividades), onde usamos nossas ferramentas de consulta ao banco de dados. Em outros casos, entretanto, esses relacionamentos são especificados em termos matemáticos, onde necessitamos empregar intensamente as ferramentas de álgebra com mapas. Da mesma forma, os relacionamentos que formam o modelo necessitam ser conhecidos.

Em alguns casos, os modelos de relacionamento podem ser derivados de fundamentos lógicos ou teóricos. Entretanto, em muitos momentos, é necessário que os relacionamentos sejam determinados por estudos empíricos. A análise de regressão, por exemplo, é uma forma muito comum de usar testes empíricos para desenvolver um relacionamento matemático entre variáveis. Seguindo o exemplo da erosão do solo, podemos levantar uma série de locais de teste nos quais a erosão é medida juntamente com dados de declividade, tipo de solo e precipitação. Esses pontos de amostragem são então usados para desenvolver uma equação relacionando a erosão do solo a essas variáveis. A equação pode depois ser usada para avaliar o potencial de erosão do solo sobre uma região muito maior.

### Modelagem de processos

Consulta ao banco de dados e mapeamento derivativo formam o conjunto das análises de SIG efetuadas atualmente. Entretanto, há uma terceira área que oferece incrível potencial -- modelagem de processos e simulação.

Com a modelagem de processos nós também trazemos algo novo para o banco de dados -- *conhecimento dos processos*. O termo processo refere-se à corrente causal pela qual algum evento acontece. Por exemplo, um modelo simples para satisfazer a demanda de madeira para combustível pode funcionar do seguinte modo:

1. tome toda a madeira que você necessita (ou pode) da sua localização atual;
2. se sua demanda foi satisfeita ou se você andou mais de 10km de casa, vá para o passo 4;
3. se sua demanda não foi satisfeita, mova-se para um local imediatamente adjacente ainda não visitado e repita o passo 1;
4. pare.

A modelagem de processos é uma perspectiva particularmente estimulante para SIG. Ela se baseia na noção de que num SIG, nosso banco de dados não apenas representa um ambiente, *ele é um ambiente!* É um ambiente possível de ser medido, manipulado e sobre o qual agem processos espaciais e temporais. Nosso banco de dados atua como um laboratório para o estudo de processos em um ambiente complexo. Tradicionalmente, na ciência, tínhamos de remover essa complexidade para entender processos isoladamente. Essa estratégia foi muito eficaz e nos possibilitou aprender muito. Entretanto, tecnologias como os SIG oferecem agora as ferramentas para reunir esses entendimentos simples para gerar um entendimento e um reconhecimento sobre como eles atuam na complexidade de uma situação ambiental real. Frequentemente entendimentos muito simples resultam em padrões complexos quando postos a interagir no ambiente.

Um tipo diferente de processo é o processo de tomada de decisão, que pode também ser apoiado e de algumas formas modelado com o uso de SIG. A tecnologia de SIG está se tornando muito importante como ferramenta para apoio à decisão. De fato, mesmo os resultados da mais simples consulta ao banco de dados podem ter valor inestimável para o tomador de decisão. Entretanto, o *processo* mais complexo de tomada de decisão, no qual tomadores de decisão frequentemente pensam em termos de critérios múltiplos, limites relativos (não *Booleano*) e níveis de risco aceitáveis, também pode ser modelado usando SIG. O IDRISI for Windows oferece um conjunto de módulos de apoio à decisão para ajudar tomadores de decisão a desenvolver decisões mais explicitamente racionais e bem informadas. O capítulo *Apoio à decisão* da seção **TÓPICOS ESPECIAIS** do manual discute em detalhe esse

importante uso de SIG e fornece exemplos ilustrativos de casos de aplicação.

A despeito de sua evidente atração, a modelagem de processos, tanto em processos ambientais quanto de tomada de decisão, é uma atividade ainda bastante nova e pouco comum em SIG. A razão é muito simples. Apesar de mais e mais ferramentas de modelagem estarem sendo disponibilizadas em diversos *software* de SIG, não é incomum constatar-se que o processo de interesse requer uma capacidade não introduzida no sistema. Esses casos requerem a criação de um novo módulo de programa. Muitos sistemas não estão muito bem estruturados para a incorporação de rotinas desenvolvidas pelos usuários, mas o IDRISI for Windows foi desenhado para possibilitar essa incorporação. Programas em qualquer linguagem de computador podem ser incluídos no sistema e acionados a partir da interface do IDRISI for Windows.



# ***Introdução ao sensoriamento remoto e ao processamento de imagens***

Das várias fontes de dados usadas em SIG, uma das mais importantes é indubitavelmente representada pelo sensoriamento remoto. Através do uso de satélites, existem programas de aquisição contínua de dados para o mundo inteiro, com intervalos de tempo que abrangem desde de semanas até uma questão de horas. Também muito importante é o fato de que temos acesso a imagens de sensores remotos na forma digital, permitindo uma rápida integração dos resultados de análises de sensoriamento remoto em um SIG.

O desenvolvimento de técnicas digitais para a correção, realce e interpretação de imagens de sensoriamento remoto auxiliada por computador ocorreu inicialmente de forma independente e um pouco à frente do desenvolvimento de SIG. Contudo, a estrutura de dados raster e muitos dos procedimentos envolvidos nestes sistemas de processamento de imagens (*Image Processing Systems - IPS*) eram idênticos àqueles envolvidos em SIG com estrutura raster. Como resultado, tem se tornado comum ver pacotes de processamento de imagens adicionados às capacidades mais gerais de análise de SIG, e *software* SIG incluírem ao menos um conjunto fundamental de ferramentas de processamento de imagens. O IDRISI for Windows é um sistema avançado combinando SIG e processamento de imagens.

Devido à grande importância do sensoriamento remoto como entrada de dados para SIG, tem se tornado necessário aos analistas de SIG (particularmente aqueles envolvidos na utilização de recursos naturais) adquirir uma boa familiaridade com sistemas de processamento de imagens. Por causa disso, este capítulo dá uma visão geral desta importante tecnologia e da sua integração com SIG.

## ***Definição***

Sensoriamento remoto pode ser definido como qualquer processo através do qual é coletada informação a respeito de um objeto, área ou fenômeno, sem entrar em contato com ele. Nossos olhos são um excelente exemplo de um dispositivo de sensoriamento remoto. Somos capazes de reunir informações sobre o que nos rodeia julgando a quantidade e a natureza da reflectância da energia da luz visível (proveniente de alguma fonte externa, como o Sol ou uma lâmpada) conforme ela reflete de objetos em nosso campo visual. Um exemplo do contrário disto é um termômetro, que precisa estar em contato com o fenômeno que ele está medindo e por isso não é um dispositivo de sensoriamento remoto.

Dadas estas definições mais gerais, o termo sensoriamento remoto vem sendo associado mais especificamente com a indicação de interações entre os materiais da superfície terrestre e a energia eletromagnética. Contudo, qualquer tentativa de uma definição mais específica se torna difícil, uma vez que não é sempre o ambiente natural que é analisado (p. ex., aplicações na conservação de arte); o tipo

de energia não é sempre eletromagnética (p. ex., sonar) e alguns métodos medem emissão de energia natural (p. ex., infravermelho termal) em vez de interações de energia proveniente de uma fonte independente.

## Considerações fundamentais

### Fonte de energia

Os sensores podem ser divididos em dois grandes grupos - *passivos* e *ativos*. Sensores passivos medem níveis de fontes de energia existentes, enquanto os sensores ativos têm sua própria fonte de energia. A maior parte do sensoriamento remoto usa sensores passivos, para os quais o Sol é a principal fonte de energia. O exemplo mais antigo destes sensores é a fotografia. Temos sido capazes de medir e registrar a reflexão da luz pelos elementos da superfície terrestre há bastante tempo através de câmeras fotográficas aerotransportadas. Apesar da fotografia aérea ainda ser uma das principais formas de sensoriamento remoto, tecnologias de estado sólido mais novas têm expandido a capacidade para enxergar nos comprimentos de onda do visível e do infravermelho próximo, incluindo assim comprimentos de onda maiores da radiação solar. Entretanto, nem todos os sensores passivos usam a energia do Sol. Sensores no infravermelho termal e sensores de microondas passivos medem emissões de energia natural da Terra. Portanto, sensores passivos são simplesmente aqueles que não fornecem a eles próprios a energia detectada.

Os sensores ativos, por outro lado, possuem sua própria fonte de energia. O exemplo mais familiar desta fonte de energia é o *flash* fotográfico. Em aplicações ambientais e de mapeamento o melhor exemplo é constituído pelo Radar. Sistemas de Radar emitem energia na região do espectro eletromagnético das microondas (figura 3-1). A reflexão dessa energia pelos materiais na superfície da Terra é então medida para produzir uma imagem da área recoberta pelo sensor.




Figura 3-1. O espectro eletromagnético (Lillesand & Kiefer, 1987, adaptado<sup>8</sup>).

### Comprimento de onda

Como já mencionado, a maior parte dos dispositivos de sensoriamento remoto fazem uso de energia eletromagnética. Entretanto, o espectro eletromagnético é muito amplo e nem todos os comprimentos de onda são igualmente efetivos para propósitos de sensoriamento remoto. Além disso, nem todos têm interações significativas com os materiais da superfície da Terra que nos interessam. A figura 3.1 ilustra o espectro eletromagnético. A própria atmosfera causa absorção e/ou espalhamento significativo dos comprimentos de onda mais curtos. Além disso, as lentes de vidro de muitos sensores também causam absorção significativa dos comprimentos de onda mais curtos como os do ultravioleta (UV). Como resultado, a primeira janela significativa (i.e., uma região na qual a energia pode significativamente

<sup>8</sup> Lillesand, T. & Kiefer, R. 1987. *Remote Sensing and Image interpretation*. New York. Wiley.

atravessar a atmosfera) localiza-se nos comprimentos de onda do visível. Os comprimentos de onda do azul sofrem substancial atenuação pelo espalhamento atmosférico e por esse motivo são freqüentemente preteridos nas imagens de sensoriamento remoto. Entretanto, os comprimentos de onda do verde, do vermelho e do infravermelho próximo proporcionam boas oportunidades para medir interações da superfície terrestre sem interferência relevante por parte da atmosfera. Adicionalmente, estas regiões fornecem indícios importantes a respeito da natureza de muitos materiais da superfície terrestre. Os comprimentos de onda do vermelho visível, por exemplo, são fortemente absorvidos pela clorofila, enquanto os comprimentos de onda do infravermelho próximo fornecem indícios importantes da estrutura das folhas das plantas. Como resultado, o maior volume de imagens de sensoriamento remoto usadas em tarefas relacionadas a SIG são adquiridas nessas regiões.

Nas regiões do infravermelho médio e termal, várias boas janelas podem ser encontradas. Os comprimentos de onda mais longos do infravermelho médio mostraram grande utilidade em aplicações geológicas, enquanto as regiões do termal provaram ser muito úteis para o monitoramento não somente dos casos óbvios de distribuição espacial do calor da atividade industrial, mas de um amplo conjunto de aplicações desde o monitoramento do fogo e estudos de distribuição animal até as condições de umidade do solo.

Depois do infravermelho termal, a próxima área de maior importância no sensoriamento remoto ambiental está na região das microondas. Existem várias janelas importantes nesta região, que são de particular interesse para o uso do imageamento ativo por Radar. A textura dos materiais da superfície da Terra causa interações significativas com vários comprimentos de onda na região das microondas. Isto pode ser usado como um complemento às informações obtidas em outros comprimentos de onda, e também oferece a vantagem de ser utilizável à noite (sendo um sistema ativo, ele independe da radiação solar) e em regiões com cobertura de nuvens persistente (os comprimentos de onda do Radar são pouco afetados por nuvens).

### *Mecanismos de interação*

Quando a energia eletromagnética atinge um material, três tipos de interações podem ocorrer: reflexão, absorção e transmissão (Figura 3-2). Nosso principal interesse reside na porção da energia que é refletida pois é geralmente esta a que retorna ao sistema sensor. A quantidade refletida varia de acordo com a natureza do material e com a região do espectro magnético na qual a medida é feita. Como resultado, se examinarmos o comportamento da componente refletida ao longo de um intervalo de comprimentos de onda, podemos caracterizar o resultado como um *padrão de resposta espectral*.




Figura 3-2. Mecanismo de interação entre energia eletromagnética e materiais.

### Padrões de resposta espectral

Um padrão de resposta espectral é algumas vezes chamado de *assinatura*. É uma descrição (frequentemente na forma de um gráfico) do grau com o qual a energia é refletida em diferentes regiões do espectro. A maioria das pessoas está muito familiarizada com padrões de resposta espectral, uma vez que eles equivalem ao conceito humano de cor! Por exemplo, a figura 3-3 mostra padrões de resposta espectral típicos para algumas cores na porção visível de espectro eletromagnético, assim como para branco e cinza escuro. O padrão de reflectância vermelho claro, por exemplo, pode ser aquele produzido por um papel impresso com tinta vermelha. Aqui, a tinta é pensada para alterar a luz branca que brilha sobre ela e absorver os comprimentos de onda do azul e do verde. Restam, então, os comprimentos de onda do vermelho que refletem da superfície do papel para o sistema sensor (o olho). O alto retorno de comprimentos de onda do vermelho indica um vermelho claro, enquanto o baixo retorno de comprimentos de onda do verde, no segundo exemplo, sugere que ele aparecerá bastante escuro.

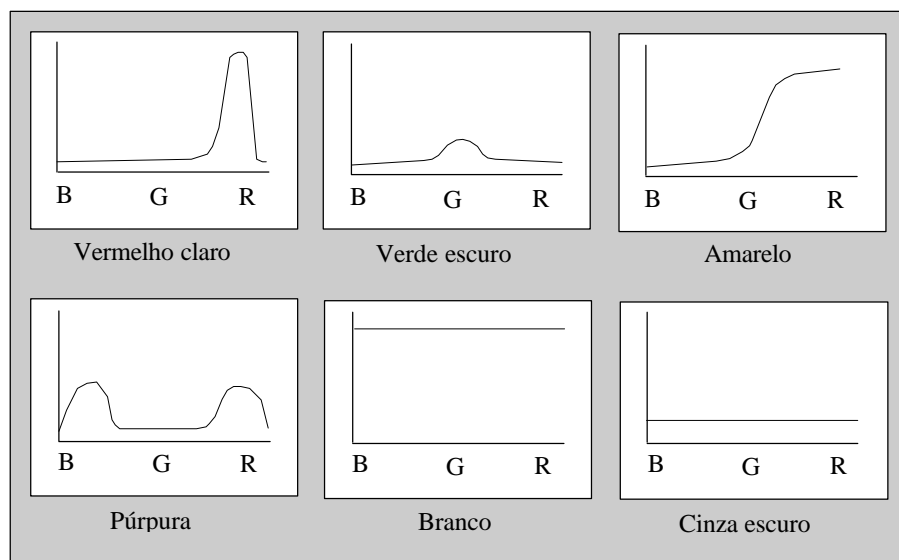


Figura 3-3. Padrões de resposta espectral para discos selecionados

O olho é capaz de perceber padrões de resposta espectral porque ele é um verdadeiro sensor multiespectral (isto é, ele tem percepção em mais de um local no espectro). Embora o verdadeiro funcionamento do olho seja muito complexo, ele de fato tem três tipos de detectores separados que podem ser considerados como capazes de responder às regiões de comprimento de onda do verde, vermelho e azul. Estas são as *cores primárias aditivas* e o olho responde à sua misturas para produzir uma sensação de outros tons. Por exemplo, a cor percebida pelo terceiro padrão de resposta espectral na figura 3-3 seria um amarelo -- resultado da mistura do vermelho e do verde. Entretanto, é importante reconhecer que esta é simplesmente nossa percepção fenomenológica de um padrão de resposta espectral. Considere, por exemplo, a quarta curva. Aqui nós temos reflectância em ambas as regiões do azul e do vermelho do espectro visível. Esta é uma distribuição bimodal, tecnicamente não é um tom específico no espectro. Todavia, perceberíamos isto visualmente como sendo púrpura! Púrpura não existe na natureza (isto é, como tom de cor -- um comprimento de onda dominante). É muito real em nossa percepção, mas púrpura é simplesmente nossa percepção de um padrão bimodal envolvendo um par de tons primários não adjacentes.

No início das pesquisas com sensoriamento remoto, acreditava-se (na verdade esperava-se) que cada material da superfície da Terra tivesse um padrão de resposta espectral distinto que lhe permitiria ser detectado com segurança por meios visuais ou digitais. Entretanto, como nossa experiência simples com cores sugere, na realidade isto não é freqüente. Por exemplo, duas espécies de árvores podem ter uma coloração bastante diferente em uma época do ano e muito similar em outra.



Encontrar padrões de resposta espectral distintos é a chave para a maior parte dos procedimentos de interpretação de imagens de sensoriamento remoto auxiliada por computador. Esta tarefa não é trivial. Além do mais, o analista precisa encontrar a combinação de bandas espectrais e a época do ano em que padrões distintos possam ser encontrados para cada uma das classes de informação de interesse.

Por exemplo, a figura 3-4 mostra um padrão de resposta espectral típico para vegetação, juntamente com os de água e de solo exposto seco. A forte absorção pelos pigmentos da folha (particularmente clorofila) nas regiões do azul e do vermelho da porção visível do espectro conduz à aparência verde característica da vegetação saudável. Entretanto, enquanto esta *assinatura* é bem diferente das superfícies sem vegetação, ela não é muito capaz de distinguir entre espécies -- a maioria terá uma cor verde similar na idade madura. No infravermelho próximo, todavia, nós encontramos um retorno muito maior das superfícies com vegetação devido ao espalhamento dentro da camada mesofílica das folhas. Os pigmentos das plantas não absorvem energia nesta região, de forma que a dispersão, combinada com o efeito multiplicador de um dossel completo de folhas, induz à alta "reflectância" nesta região do espectro. Esta reflectância é fortemente dependente da estrutura interna das folhas. Como resultado, diferenças significativas entre espécies podem ser freqüentemente detectadas nesta região. Da mesma forma, na região do infravermelho médio, vemos uma inclinação significativa no padrão de resposta espectral que está associada à umidade da folha. Esta é outra área onde diferenças significativas podem surgir entre espécies maduras. Como resultado, aplicações que buscam uma diferenciação ótima entre espécies envolvem geralmente tanto a região do infravermelho próximo quanto do infravermelho médio e usam imagens obtidas ao longo do ciclo de desenvolvimento.




Figura 3-4. Assinaturas típicas de solo descoberto, vegetação verde e água limpa (Lillesand & Kiefer, 1987, adaptado<sup>9</sup>).

Algumas tecnologias de sensoriamento remoto recentes (como o AVIRIS) produzem imagens hiperespectrais - dados adquiridos em dezenas ou centenas de bandas muito estreitas. Assinaturas desenvolvidas usando esses dados são potencialmente muito precisas. Além disso, bibliotecas de assinaturas hiperespectrais foram criadas em condições de laboratório, contendo centenas de assinaturas para diferentes tipos de cobertura do solo, incluindo muitos minerais e outros materiais. Essas bibliotecas de curvas espectrais estão disponíveis a partir de vários sites na *World Wide Web*, como o do *United States Geological Survey (USGS) Spectroscopy Lab* (<http://spclab.cr.usgs.gov>). Veja o capítulo **Classificação de imagens de sensoriamento remoto** na seção **TÓPICOS ESPECIAIS** do Manual do usuário para mais detalhes sobre análise de dados hiperespectrais.

<sup>9</sup> Lillesand, T. & Kiefer, R. 1987. *Remote Sensing and Image interpretation*. New York. Wiley.

### Sensoriamento remoto multiespectral

Na interpretação visual de imagens de sensoriamento remoto, várias características das imagens são levadas em consideração, como a cor (ou tom, no caso de imagens pancromáticas), textura, tamanho, forma, padrão, contexto e a semelhança. Entretanto, na interpretação auxiliada por computador é usada com mais frequência simplesmente a cor (isto é, o padrão de resposta espectral). É por esta razão que uma forte ênfase é dada ao uso de sensores multiespectrais (sensores que, como o olho humano, vêm mais do que um local no espectro e por isso são capazes de captar padrões de resposta espectral), bem como ao número e à localização específica das bandas espectrais desses sensores.




Figura 3-5

A figura 3-5 ilustra as bandas espectrais do sensor *Thematic Mapper* (TM) do LANDSAT. O satélite LANDSAT é um sistema comercial que fornece imageamento multiespectral em sete bandas espectrais com uma resolução espacial de 30 metros.

É possível demonstrar através de técnicas analíticas como a análise de componentes principais, que na maioria dos ambientes as bandas que carregam a maior parte da informação sobre o ambiente natural são as dos comprimentos de onda do infravermelho próximo e do vermelho. A água absorve fortemente o infravermelho, o que a torna fácil de distinguir nessa região do espectro. Além disso, as espécies de plantas apresentam as maiores diferenças nesta região. A região do vermelho também é muito importante porque é a principal região de absorção de energia pela clorofila para a fotossíntese. Esta banda é a que melhor permite distinguir entre superfícies com vegetação e sem vegetação.

Dada a importância das bandas do vermelho e do infravermelho próximo, não é surpresa que os sistemas de sensores projetados para o monitoramento de recursos naturais invariavelmente as incluam em qualquer sistema multiespectral particular. A inclusão de outras bandas depende da gama de aplicações pretendidas. Muitos sistemas incluem a banda do verde visível porque ele pode ser usado, juntamente com outros dois, para produzir uma composição falsa cor tradicional -- uma imagem em cor plena derivada das bandas do verde, vermelho e infravermelho em oposição às bandas do azul, verde e vermelho de imagens em cor natural. Este formato tornou-se comum com o advento da fotografia infravermelha colorida, e é conhecida de muitos especialistas do campo do sensoriamento remoto. Além disso, a combinação destas três bandas funciona bem na interpretação da paisagem alterada e de superfícies naturais e com vegetação. Contudo, é cada vez mais comum incluir outras bandas especificadamente direcionadas para a diferenciação dos materiais da superfície. Por exemplo, a banda 5 LANDSAT TM está colocada entre duas bandas de absorção da água e tem sido muito útil na determinação de diferenças de umidade do solo e das folhas. De forma similar, a Banda 7 LANDSAT TM está direcionada para a detecção de zonas de alteração hidrotermal em superfícies de rocha exposta. Ao contrário do sistema LANDSAT, o sistema AVHRR, da série de satélites NOAA, inclui vários canais termais para o sensoriamento da temperatura de nuvens.

Em adição às imagens multiespectrais tradicionais, alguns novos sistemas experimentais como AVIRIS e EOS-MODIS têm a capacidade de adquirir dados hiperespectrais. Esses sistemas cobrem um intervalo de comprimentos de onda similar mas em bandas muito mais estreitas, o que aumenta sensivelmente o número de bandas disponíveis para a classificação de imagens. O grande potencial de detectar assinaturas distintas ao longo de um grande número de bandas torna possível classificar dados usando bibliotecas de curvas espectrais de diferentes materiais da Terra.

### **Sistemas de sensores multiespectrais**

Como é feito o sensoriamento multiespectral? A forma mais antiga é a fotografia colorida, que é ainda muito usada atualmente. Entretanto, para fins de interpretação auxiliada por computador, os sistemas de imageamento de estado sólido são agora mais comumente usados.

### **Fotografia colorida**

As fotografias normais são produzidas a partir de uma composição de três camadas do filme com filtros intercalados que atuam isolando os comprimentos de onda do vermelho, do verde e do azul. Com o filme infravermelho colorido, estes comprimentos de onda são deslocados para os comprimentos de onda mais longos para produzir uma composição que isola os comprimentos de onda das regiões do verde, vermelho e infravermelho próximo. Todavia, como o olho humano não enxerga o infravermelho, uma composição em falsa cor é produzida fazendo os comprimentos de onda do verde aparecerem em azul, do vermelho aparecerem em verde e do infravermelho em vermelho.

Uma alternativa para o uso do filme colorido é agrupar várias câmeras em uma mesma instalação numa aeronave, cada uma com filme preto e branco e um filtro específico para isolar um intervalo específico de comprimentos de onda. A vantagem deste arranjo é que as bandas ficam acessíveis de forma independente e podem ser fotograficamente realçadas. Se uma composição colorida for desejada, é possível criá-la mais tarde a partir das bandas individuais.

É evidente que as fotografias não estão em um formato que pode ser imediatamente usado em análise digital. Entretanto, é possível escanear fotografias com um *scanner* de mesa comum e criar conjuntos de

dados multiespectrais, tanto pelo escaneamento das imagens em bandas individuais quanto de uma imagem colorida e posterior separação e suas bandas. Vários sistemas SIG e/ou de processamento de imagens oferecem essa possibilidade. Adicionalmente, também pode ser adquirido um *software* especial para retificar imagens de baixa altitude através de técnicas fotogramétricas.

## Vídeo

Gravadores videocassete em formato Super VHS podem ser usados com pequenas câmeras de vídeo CCD para produzir vídeos aéreos coloridos de alta qualidade. Usando várias câmeras simultaneamente, cada uma com um filtro para isolar um intervalo específico de comprimentos de onda, é possível isolar imagens de bandas multiespectrais, que podem ser usadas individualmente ou combinadas na forma de uma composição colorida. Para uso em análise digital, placas gráficas especiais conhecidas como *frame grabbers* podem ser usadas para congelar qualquer quadro de uma seqüência contínua de vídeo e convertê-lo para formato digital, geralmente em um dos mais populares formatos de intercâmbio como TIF ou TARGA.

## Scanners multiespectrais

A fotografia provou ser um importante dispositivo para a interpretação visual e para a produção de mapas analógicos. Entretanto, o desenvolvimento de plataformas em satélites e a necessidade de telemetrar imagens na forma digital, assim como o desejo por imagens altamente consistentes, deram impulso ao desenvolvimento de *scanners* de estado sólido como formato principal para a captação de dados de sensoriamento remoto. Os aspectos específicos dos diferentes sistemas variam. Na discussão que segue é apresentado um esquema representativo dos sistemas atualmente em uso.




Figura 3-6. Configurações operacionais do sistema Landsat TM (Lillesand & Kiefer, 1987, adaptado<sup>10</sup>)

A lógica básica de um sensor de escaneamento é o uso de um mecanismo para varrer um pequeno campo de visada (conhecido como *instantaneous field of view* -- IFOV, ou campo de visada instantâneo) na direção oeste para leste ao mesmo tempo em que o satélite está se movendo de norte para sul. Este movimento combinado permite compor uma imagem raster completa do ambiente.

Uma técnica simples de escaneamento é usar um espelho rotativo que possa varrer o campo de visada na direção oeste para leste de forma consistente. O campo de visada é interceptado com um prisma que pode dispersar a energia oriunda do IFOV em seus componentes espectrais. Detectores fotoelétricos (da mesma natureza que aqueles encontrados em medidores de exposição luminosa comumente disponíveis

<sup>10</sup> Lillesand, T. & Kiefer, R. 1987. *Remote Sensing and Image interpretation*. New York. Wiley.

em câmeras fotográficas) são então dispostos no caminho deste espectro para fornecer medições elétricas da quantidade de energia detectada em várias partes do espectro eletromagnético. Conforme a varredura vai de oeste para leste, estes detectores coletam um conjunto de leituras ao longo da mesma. Essas leituras formam as colunas ao longo de uma linha de um conjunto de imagens raster -- uma para cada detector. O movimento do satélite de norte para sul posiciona então o sistema para detectar a próxima linha, processo cujo final resulta na produção de um conjunto de imagens raster com um registro da reflectância ao longo de um intervalo de bandas espectrais.

## **Sistemas plataforma/sensor**

Em função dos recentes desenvolvimentos em sensores, existem atualmente várias plataformas disponíveis para a captação de dados de sensoriamento remoto. Nós revisamos algumas das principais combinações plataforma/sensor normalmente disponíveis para a comunidade de usuários de SIG.

### **Fotografia aérea**

A fotografia aérea é o método de sensoriamento remoto mais antigo e mais amplamente usado. Câmeras montadas em aeronaves leves voando em altitudes entre 200 e 15.000 m captam uma grande quantidade de informação detalhada. Fotos aéreas fornecem um inventário visual instantâneo de uma porção da superfície terrestre e podem ser usadas para criar mapas detalhados. Fotografias aéreas são frequentemente produzidas por empresas comerciais especializadas, que possuem e operam aeronaves especialmente modificadas, equipadas com câmeras de grande formato (23cmx23cm) e de alta qualidade. Fotos aéreas também podem ser obtidas a partir de câmeras de pequeno formato (35 mm e 70 mm), manuais ou acopladas em uma aeronave leve não modificada.

As configurações de câmera e plataforma podem ser agrupadas em verticais e oblíquas. As plataformas configuradas e a câmera podem ser agrupadas em termos verticais e oblíquos. A fotografia aérea oblíqua é obtida a partir de um determinado ângulo em relação ao terreno. As imagens resultantes dão uma visão semelhante à de um observador olhando pela janela do avião. Estas imagens são bem mais fáceis de interpretar do que fotografias verticais, mas é difícil localizar e medir feições neste tipo de foto para propósitos de mapeamento.

A fotografia aérea vertical é adquirida olhando diretamente para baixo. As imagens resultantes mostram feições do terreno em forma plana e são facilmente comparadas com mapas. As fotos aéreas verticais são sempre altamente desejáveis, mas são particularmente úteis para levantamentos de recursos em áreas onde não há mapa disponíveis. Fotos aéreas mostram feições como padrões de campo e vegetação que são frequentemente omitidas em mapas. Comparações entre fotos aéreas antigas e mais recentes podem também evidenciar as mudanças dentro de uma área ao longo do tempo.

Fotos aéreas verticais contêm deslocamentos sutis devido ao relevo, inclinação e balanço da aeronave e distorções das lentes. As imagens verticais podem ser tomadas com sobreposição, geralmente com cerca de 60 por cento ao longo da linha de vôo e pelo menos de 20 por cento entre linhas. A sobreposição de imagens pode ser vista com um estereoscópio para criar uma visão tridimensional, chamada de modelo estereoscópico.

### **Fotografia de grande formato**

Empresas comerciais de levantamentos aéreos usam aeronaves mono ou bimotores equipadas com câmeras de grande formato para mapeamento. As câmeras de grande formato, como a WILD RC-10, usam filme de 23cm x 23cm que está disponível em cartuchos. A companhia Kodak, entre outras, fabrica vários tipos de películas de filmes especialmente destinadas ao uso em fotografias aéreas. Um filme negativo é empregado quando o produto desejado é um material impresso, enquanto filme positivo é empregado quando o produto desejado são transparências. Filmes para impressão permitem ampliações de detalhes, como a produção de posters de grandes dimensões. O uso de filme para impressão é útil também quando muitas cópias necessitam ser distribuídas e usadas no campo.

## Fotografia de pequeno formato

Câmeras de pequeno formato transportadas em aeronaves alugadas são uma alternativa de baixo custo para substituir fotos aéreas de grande formato. São necessários uma câmera de 35mm ou 70mm, uma aeronave simples e um piloto, além de alguns meios para processar o filme. Devido à existência de laboratórios comerciais de processamento praticamente no mundo todo, os sistemas de 35mm são especialmente convenientes.

Fotografias oblíquas podem ser tiradas com uma câmera sustentada pela mão em qualquer aeronave simples, mas fotografias verticais requerem alguma forma de montagem especial, direcionada através de uma pequena abertura na parte inferior do avião ou estendida para fora de uma porta ou de uma janela.

As fotografias aéreas de pequeno formato apresentam várias limitações. As aeronaves leves não pressurizadas são limitadas a altitudes abaixo de 4.000m e o tamanho do filme é pequeno, de forma que sacrifícios devem ser feitos na resolução ou na área coberta por cada foto. Por causa das distorções no sistema da câmera, fotografias de pequeno formato não podem ser usadas quando há a necessidade de um mapeamento preciso. Além disso, impressões ampliadas de boa qualidade não podem ser feitas a partir de negativos pequenos. Apesar disso, fotografias de pequeno formato podem ser muito úteis para levantamentos de reconhecimento e podem ser usadas como pontos amostrais.

## Videografia

Videocâmeras e gravadores leves, portáteis e de baixo custo podem ser carregadas em vôos alugados. Algumas companhias de mapeamento aéreo oferecem a videografia como uma opção de produto de aerolevanteamento, a qual consiste em nada menos do que imagens em composição falsa cor numa gravação contínua em vídeo tape. Da mesma forma que a fotografia de pequeno formato, o vídeo aéreo não pode ser usado para mapeamento detalhado, mas propicia uma visão geral útil para levantamentos de reconhecimento, e pode ser usado juntamente com amostragem em campo.

## Sistemas de satélites

Existem atualmente vários sistemas em operação que coletam imagens subseqüentemente distribuídas aos usuários. Alguns dos sistemas mais comuns são descritos abaixo. Cada tipo de dado de satélite oferece características específicas que o tornam mais ou menos apropriado para uma aplicação em particular.

Em geral, existem duas características que podem ajudar você na escolha do dado do satélite: a *resolução espacial* e a *resolução espectral*. A resolução espacial refere-se ao tamanho da área no terreno que é resumida por cada valor de dado nas imagens. Trata-se do campo de visada instantâneo (IFOV) descrito anteriormente. A resolução espectral refere-se ao número e à largura das bandas espectrais que o sensor do satélite detecta. Adicionalmente, questões referentes ao custo e disponibilidade das imagens também devem ser consideradas na escolha.

## LANDSAT

O sistema LANDSAT de satélites para sensoriamento remoto é operado pela *Earth Observation Satellite Company* (EOSAT), que vende dados digitais e fotográficos. Cenas inteiras ou um quarto delas são disponibilizadas através de vários meios de distribuição, como os produtos fotográficos de cenas MSS e TM em falsa cor e em preto e branco.

Existem seis satélites LANDSAT, o primeiro deles lançado em 1972. O LANDSAT 6 foi perdido no lançamento, mas o LANDSAT 5 continua em operação.

O LANDSAT carrega dois sensores multiespectrais. O primeiro deles é o *scanner* multiespectral (*multispectral scanner* -- MSS), que obtém as imagens em quatro bandas espectrais: azul, verde, vermelho e infravermelho próximo. O segundo é o mapeador temático (*Thematic mapper* -- TM), que coleta 7 bandas: azul, verde, vermelho, infravermelho próximo, duas no infravermelho médio e uma no infravermelho termal. O MSS tem uma redução espacial de 80 metros e o TM de 30 metros. Ambos os sensores recobrem uma área de 185km x 185km, e o satélite passa às 09:45 da hora local e retorna à mesma área a cada 16 dias.

## SPOT

O SPOT (*Système Pour L'Observation de la Terre*) foi lançado e vem sendo operado por um consórcio francês desde 1985. O SPOT carrega dois sensores de varredura *High Resolution Visible* -- HRV<sup>11</sup>, que operam em modo multiespectral ou pancromático. No modo multiespectral, o sensor coleta três bandas, uma banda verde, uma banda vermelha e uma banda no infravermelho próximo, com uma resolução espacial de 20 metros. No modo pancromático, o sensor coleta uma única imagem com uma resolução espacial de 10 metros. Ambos os modos cobrem uma faixa de 60km de largura. O sensor SPOT pode ser direcionado para imagear ao longo de faixas de varredura adjacentes. Isto permite ao instrumento adquirir imagens repetidas de qualquer área até 12 vezes durante seu período orbital de 26 dias. A capacidade de direcionamento faz do SPOT o único sistema de satélite que pode adquirir imagens estereoscópicas.

A *SPOT Image Inc.* comercializa vários produtos, incluindo imagens digitais e produtos fotográficos. Imagens existentes podem ser compradas, mas a aquisição de novas imagens necessita ser solicitada. Os clientes podem solicitar que o satélite seja apontado para uma direção particular para as novas aquisições.

## NOAA - AVHRR

O *Advanced Very High Resolution Radiometer* -- AVHRR encontra-se a bordo de uma série de satélites operados pela *U.S. National Oceanic and Atmospheric Administration* -- NOAA. Ele adquire dados ao longo de uma faixa de 2400km diariamente. O AVHRR coleta cinco bandas, uma no vermelho, duas no infravermelho próximo, uma no infravermelho médio e uma no infravermelho termal. A resolução espacial do sensor é 1,1 km e este dado é chamado de cobertura de área local (*Local Area Coverage* -- LAC). Para o estudo de áreas muito grandes, também está disponível uma versão reamostrada com resolução de aproximadamente 4 km, denominado cobertura de área global (*Global Area Coverage* -- GAC).

O AVHRR pode ter alta resolução para aplicações meteorológicas, mas as imagens retratam apenas os padrões mais extensos e apresentam pouco detalhe para uso em estudos terrestres. Todavia, eles têm uma alta resolução temporal, mostrando grandes áreas em uma base diária. O AVHRR tem se tornado uma escolha popular para o monitoramento de grandes áreas. As imagens AVHRR são usadas por várias organizações engajadas com a previsão da fome e é uma parte importante de muitas atividades de alerta de risco. As imagens do AVHRR estão disponíveis na NOAA a menos de 100 dólares por imagem.

## ERS-1

O *European Remote Sensing Satellite* -- ERS- 1 é um novo sistema desenvolvido pela agência espacial européia. Até o momento desta publicação, ela ainda estava operando em modo experimental. O sistema propicia complemento interessante para os outros produtos de imagens comerciais, oferecendo vários formatos de saída de imagens de Radar. Para aplicações de SIG, a principal saída de interesse é o Radar de visada lateral (*side-looking airborne Radar* -- SAR), saída que provê faixas de 100 km de largura com uma resolução espacial de 30m. Isto é de considerável interesse numa variedade de aplicações, incluindo estudos de vegetação e projetos de mapeamento, onde a cobertura de nuvens é um problema persistente.

## RADARSAT

O RADARSAT é um satélite de observação da Terra lançado em novembro de 1995 pela *Canadian Space Agency*. Os dados são distribuídos pela *RADARSAT International* (RSI) a partir de Richmond, Colúmbia Britânica, Canadá. A resolução espacial das imagens varia de 3 a 100 metros e o intervalo de repetição de cobertura do terreno é de 24 dias. Os sensores podem ser direcionados para o local de interesse, o que possibilita a coleta de imagens estereoscópicas. O sinal de Radar também penetra a cobertura de nuvens, atingindo áreas não visíveis para outros sistemas de sensoriamento remoto. Ao contrário dos outros sistemas, o sinal de Radar retornado é afetado mais pelas características elétricas e

<sup>11</sup> Os sensores de varredura produzem uma saída semelhante à de um *scanner*. Entretanto, não há movimento de escaneamento como nos mesmos. Ao contrário, o sensor consiste de um denso arranjo de detectores -- um para cada célula raster na linha de varredura -- que é movido através da cena.

físicas (principalmente a textura) do alvo do que pela sua reflexão e padrão espectral, necessitando por isso de técnicas especiais de interpretação e georreferenciamento. Comparado a outros tipos de imagens de sensoriamento remoto, o uso de dados de Radar ainda está no início, mas tem um enorme potencial.

## AVIRIS

O AVIRIS é um sistema experimental que produz dados hiperespectrais. Ele coleta dados em 224 bandas ao longo do mesmo intervalo de comprimentos de onda do LANDSAT. Está previsto para 1998 o lançamento de outro sistema, o EOS-MODIS, para coletar dados em 36 bandas que cobrem o mesmo intervalo do sistema AVHRR.

## Georreferenciamento de imagens e fotogrametria

Para propósitos de mapeamento, é essencial que quaisquer formas de imagens de sensoriamento remoto sejam referenciadas com exatidão ao mapa proposto como base. Com as imagens de satélite, a grande altitude das plataformas resulta num deslocamento mínimo devido ao relevo, sendo o georreferenciamento normalmente feito através do uso de um processo de transformação sistemática que suavemente “empena” a imagem (através de equações polinomiais) com base nas posições conhecidas de um conjunto de pontos de controle dispersos. Esta capacidade está disponível no IDRISI for Windows através do módulo RESAMPLE.

Com fotografias aéreas o processo é mais complexo. Não existem somente distorções sistemáticas relacionadas ao balanço e à variação de altitude da aeronave. A variação topográfica do relevo leva a distorções muito irregulares que não podem ser removidas através de procedimentos de transformação do tipo *rubber sheet* como os usados nas imagens orbitais. Nestas condições, é necessário usar restituição fotogramétrica para remover estas distorções e propiciar medidas de mapa mais exatas.

Fotogrametria é a ciência de fazer medições espaciais a partir de fotografias aéreas. Para obter uma restituição plena é necessário ter imagens estereoscópicas, fotografias que se sobrepõem o suficiente (p. ex., 60% na direção da linha e 10% entre as linhas de vôo) para proporcionar duas imagens independentes de cada parte da paisagem. Usando estes pares estereoscópicos e pontos de controle no terreno com posição e altitude conhecidas, é possível recriar inteiramente a geometria das condições de visada e, através disso, não apenas retificar medidas dessas imagens como também derivar medidas de altitude do terreno. As fotografias retificadas são chamadas de *ortofotos*. As medidas de altitude podem ser usadas para produzir modelos digitais de elevação.

A retificação fotogramétrica requer *hardware* e *software* especializados que são tradicionalmente muito caros. Todavia, existem atualmente alguns produtos fotogramétricos de custo relativamente baixo entrando no mercado e que podem propiciar retificação de alta qualidade com investimentos menores. Apesar disso, a retificação permanece sendo uma atividade especializada e requer a experiência de um profissional adequadamente treinado.

## Processamento digital de imagens

Como resultado de *scanners* multiespectrais de estado sólido e de outros dispositivos raster temos atualmente disponíveis imagens raster digitais com dados de reflectância espectral. A grande vantagem de ter estes dados na forma digital é a possibilidade de utilizar as técnicas de análise em computador para os dados das imagens -- um campo de estudo chamado de *processamento digital de imagens*.

O processamento digital de imagens está fortemente direcionado a quatro operações básicas:

- correção das imagens
- realce das imagens
- classificação das imagens
- transformação das imagens



A *correção* diz respeito à correção e calibração das imagens de forma a obter uma representação da superfície da Terra o mais fiel possível à realidade -- uma consideração fundamental para todas as aplicações. O *realce* está predominantemente voltado à modificação das imagens para otimizar sua aparência para o sistema visual. A análise visual é um elemento chave, mesmo no processamento digital de imagens, e os efeitos das técnicas de realce podem ser significativos. A *classificação* refere-se à interpretação de imagens auxiliada por computador -- uma operação vital para uso em SIG. Finalmente, a *transformação* de imagens refere-se à derivação de novas imagens através de algum tratamento matemático das bandas das imagens brutas.

Para compreender as operações listadas nesta seção é necessário ter acesso a um *software* de processamento de imagens. Entretanto, como já foi afirmado anteriormente, muitos sistemas raster oferecem atualmente uma mistura de ferramentas de SIG e de processamento de imagens. No IDRISI for Windows, os módulos encontrados no menu de Análise/Processamento de imagens permitirão a você realizar todos os procedimentos descritos a seguir.

### Correção de imagens

Imagens de sensoriamento remoto do meio ambiente são usualmente captadas a grande distância da superfície da Terra. Como consequência, há um percurso atmosférico substancial que a energia eletromagnética precisa atravessar antes de chegar ao sensor. Dependendo dos comprimentos de onda envolvidos e das condições atmosféricas, a energia que atinge o sensor pode ser substancialmente modificada. O próprio sensor pode interferir, uma vez que pode combinar uma variedade de componentes mecânicos, óticos e elétricos que servem para modificar ou mascarar a energia radiante medida. Além disso, durante o período em que a imagem está sendo adquirida, o satélite segue uma faixa que está sujeita a pequenas variações ao mesmo tempo em que a Terra se move abaixo dele. A geometria da imagem está, portanto, constantemente sofrendo alterações. Finalmente, o sinal necessita ser telemetrado de volta à Terra e subsequentemente recebido e processado para produzir os dados finais que recebemos. Conseqüentemente, uma variedade de distúrbios sistemáticos e aparentemente aleatórios podem se combinar para degradar a qualidade da imagem que recebemos no final. A correção de imagens procura remover estes efeitos de degradação.

A correção de imagens pode ser subdividida nas sub-áreas de correção geométrica e de correção radiométrica.

### Correção radiométrica

A correção radiométrica refere-se à remoção ou diminuição de distorções no grau nível de energia eletromagnética registrado por cada detector. Vários agentes podem causar distorções nos valores registrados para as células de uma imagem. Algumas das distorções mais comuns, para as quais existem procedimentos de correção, incluem:

- **valores elevados uniformemente**, devido à nebulosidade da atmosfera, que espalha principalmente bandas de comprimento de onda curto (particularmente os comprimentos de onda do azul);
- **listras/faixas**, devido à descalibração dos detectores;
- **ruídos aleatórios**, devido à imprevisibilidade e à performance não sistemática do sensor ou da transmissão dos dados;
- **perda de linhas de varredura**, devido à perda de sinal de detectores específicos.

Convém também incluir aqui procedimentos que são usados para converter os valores brutos de reflectância relativa das bandas originais, sem unidades, para medidas reais de potência reflexiva.

Veja o capítulo *Correção de imagens* na seção **TÓPICOS ESPECIAIS** do Manual do usuário para uma discussão mais detalhada sobre correção radiométrica e como ela pode ser implementada no IDRISI for Windows.

### Correção geométrica

Com imagens de satélite comerciais como as do LANDSAT e do SPOT, a maior parte dos elementos de distorção geométrica associados à aquisição das imagens são corrigidos pelos distribuidores das imagens. Esses elementos incluem:

- **correção de skew (deformação)** - para considerar o fato de que a Terra se move enquanto uma imagem é adquirida;
- **correção das distorções do scanner** - para explicar o fato de que o campo de visada instantâneo (IFOV) cobre mais território no final das linhas de varredura (onde o ângulo de visão é mais oblíquo) do que no meio.

Parece lógico que deveríamos incluir a transformação do tipo *rubber sheet* e outros procedimentos de georreferenciamento nesta seção. Entretanto, com georreferenciamento, a questão não é restaurar as características *originais* dos dados, mas modificá-las através de uma reorientação e retroprojeção da imagem para encontrar as características  *finais* desejadas.

Veja o capítulo *Georreferenciamento* na seção **TÓPICOS ESPECIAIS** do manual para acompanhar uma discussão mais aprofundada sobre como isso está implementado no IDRISI for Windows.

### Realce de imagens

O realce de imagens diz respeito à modificação de imagens para torná-las mais apropriadas às capacidades da visão humana. Independente da extensão da intervenção digital, a análise visual invariavelmente desempenha um papel muito importante em todos os aspectos do sensoriamento remoto. Embora a gama das técnicas de realce de imagens seja ampla, as seguintes questões fundamentais formam a espinha dorsal nesta área:

#### Ampliação de contraste

Os sensores digitais têm um amplo intervalo de valores de saída para acomodar os valores altamente variáveis de reflectância que podem ser encontrados em diferentes ambientes. Entretanto, em qualquer ambiente simples, freqüentemente apenas um intervalo estreito de valores ocorre na maior parte das áreas e a distribuição dos níveis de cinza tende a ser muito distorcida. Procedimentos de manipulação de contraste são então essenciais para a maior parte das análises visuais.

#### Geração de composições

Para análise visual, as composições coloridas fazem melhor uso das capacidades do olho humano. Dependendo dos sistemas gráficos em uso, a geração de composições varia da simples seleção das bandas a serem usadas a procedimentos mais avançados de combinação de bandas e ampliação de contraste.

#### Filtragem digital

Uma das possibilidades mais intrigantes da análise digital é a de aplicar filtros digitais. Os filtros podem ser usados para promover o realce de bordas (algumas vezes também chamado *crispening* na literatura), para remover a névoa (falta de definição) da imagem e para isolar lineamentos e tendências direcionais, para mencionar apenas algumas aplicações.

### Classificação de imagens

A classificação de imagens refere-se à interpretação de imagens de sensoriamento remoto auxiliada por computador. Embora alguns procedimentos permitam incorporar informações acerca de características das imagens, como textura e contexto, a maior parte da classificação de imagens baseia-se

exclusivamente na detecção de assinaturas espectrais (isto é, padrões de resposta espectral) de classes de cobertura do solo. O sucesso com o qual isto pode ser feito depende de duas coisas: 1) da presença de assinaturas distintas para as categorias de cobertura do solo de interesse no conjunto de bandas a ser usado; e 2) da habilidade para distinguir com segurança estas assinaturas de outros padrões de resposta espectral que possam estar presentes.

Um passo vital no processo de classificação é a avaliação da exatidão das imagens finais produzidas. Isto envolve a identificação de um conjunto de locais amostrais que são visitados no campo. A classe de cobertura do solo encontrada no campo é então comparada à que foi mapeada na imagem para os mesmos locais. As avaliações estatísticas de exatidão podem então ser derivadas para a área de estudo inteira, assim como para as classes individuais.

A classificação de imagens pode ser dividida em *supervisionada* e *não supervisionada*, de acordo com a forma como a classificação é conduzida. No caso da classificação supervisionada, a tarefa consiste em detectar tipos específicos de cobertura do solo já conhecidos, enquanto que na classificação não supervisionada o analista busca definir todas as categorias de cobertura do solo existentes na imagem em certos níveis de generalização. Para ambos os tipos de classificação, o IDRISI for Windows oferece classificadores rígidos e relativos que são únicos no tipo de resultado produzido pela classificação. No caso de classificadores rígidos (tradicionais), uma decisão definida é feita sobre a associação de um *pixel* a uma classe determinada. Os classificadores relativos, ao contrário, adotam uma abordagem *fuzzy* para a avaliação dessa associação e do grau com que um *pixel* pertence a todas as classes envolvidas, incluindo as classes desconhecidas. Adicionalmente, o IDRISI for Windows oferece classificadores que reconhecem explicitamente a presença de classes mistas de cobertura do solo em um único *pixel*. Ele ainda oferece a técnica para o desenvolvimento de assinaturas *fuzzy*, que também leva em conta a mistura de classes. Todas essas técnicas acrescentam maior controle da incerteza no desenvolvimento de cada assinatura ou no estágio de final classificação. Todas as técnicas de classificação relativa produzem uma superfície de incerteza na classificação para auxiliar o usuário na determinação de fontes e tipos de incerteza que ocorrem durante o processo de classificação.

### Classificação supervisionada

Com a classificação supervisionada nós identificamos exemplos das classes de informação (isto é, tipos de cobertura do solo) de interesse na imagem. Estes exemplos são chamados *áreas de treinamento*. O sistema de processamento de imagens é então usado para desenvolver uma caracterização estatística das reflectâncias para cada classe de informação. Este estágio é freqüentemente chamado *análise de assinaturas* e pode envolver o desenvolvimento de uma caracterização tão simples quanto a média ou o intervalo de reflectâncias em cada banda, ou tão complexo como análises detalhadas da média, variâncias e covariâncias em todas as bandas.

Uma vez que a caracterização estatística tiver sido obtida para cada classe de informação, a imagem é então classificada através do exame das reflectâncias de cada píxel para decidir com qual das assinaturas ele mais se parece. Há várias técnicas para tomar estas decisões, e elas são com freqüência denominadas de *classificadores*. A maior parte dos *software* de processamento de imagens oferece mais de um classificador. O IDRISI for Windows oferece três classificadores rígidos supervisionados comumente usados: por paralelepípedo, mínima distância às médias e por máxima verossimilhança. Cada um deles emprega uma lógica diferente para atribuir *pixels* a classes. Adicionalmente, um novo grupo de classificadores rígidos foi incluído especificamente para o processamento de imagens hiperespectrais. Eles incluem os classificadores por mapeamento de ângulo espectral e por distância mínima às médias hiperespectrais.

### Classificação não supervisionada

Em contraste com a classificação supervisionada, onde informamos ao sistema o caráter (isto é, assinatura) das classes de informação pelas quais estamos procurando, a classificação não supervisionada não requer qualquer informação prévia sobre as classes de interesse. Ela examina os dados e os divide nos agrupamentos espectrais naturais predominantes presentes na imagem. O analista então identifica esses agrupamentos como classes de cobertura do solo, através de uma combinação de sua familiaridade com a região estudada e visitas para levantamento de verdade de campo.

A lógica com a qual a classificação não supervisionada trabalha é conhecida como *análise de agrupamento* (ou *cluster*) e é fornecida pelo IDRISI for Windows através do módulo CLUSTER. CLUSTER efetua a classificação de imagens compostas que combinam as bandas de informação mais úteis. É importante reconhecer, entretanto, que os agrupamentos que a classificação não supervisionada produz não são classes de informação, mas categorias espectrais (isto é, eles agrupam feições (*pixels*) com padrões de reflectância similares). Geralmente o analista necessita reclassificar as classes espectrais em classes de informação. Por exemplo, o sistema pode identificar classes diferentes para asfalto e cimento, que o analista deve agrupar posteriormente para criar uma classe de informação chamada de pavimento.

A classificação não supervisionada está se tornando muito popular em agências envolvidas na manutenção de bases de dados de longo período para SIG, principalmente por que atualmente há sistemas que usam procedimentos de agrupamento extremamente rápidos e que necessitam poucos parâmetros operacionais. Dessa forma, tem sido possível treinar analistas de SIG com pouca familiaridade com o sensoriamento remoto a executar classificações que satisfazem os padrões de exatidão típicos de mapas. Com procedimentos adequados de trabalho de campo e avaliação de exatidão, essa ferramenta pode representar uma maneira rápida e eficaz de produzir dados confiáveis de cobertura do solo de forma contínua.

Além das duas técnicas mencionadas acima, dois módulos unem as classificações supervisionada e não supervisionada. O módulo ISOCLUST usa análise de agrupamento auto-organizativa para classificar até 7 bandas brutas com o número de agrupamentos especificado pelo usuário. O módulo MAXSET usa assinaturas para criar um resultado que inclui tanto classes definidas por essas assinaturas quanto as classes para suas possíveis combinações. Ele reconhece explicitamente a existência de *pixels* mistura (classificação sub-*pixel*) e pode atribuir um *pixel* a uma classe para a qual não foram fornecidos dados de treinamento exclusivos.

Todos esses tipos de classificação pertencem ao grupo de classificadores rígidos porque, de acordo com sua lógica intrínseca, eles fazem um julgamento final sobre a classe ou grupo de classes ao qual cada *pixel* deve ser atribuído (ou *pixels* são deixados como não classificados).

### Classificações rígidas e relativas

Diferente dos classificadores rígidos, os classificadores relativos protelam uma decisão definitiva sobre a associação de qualquer *pixel* a uma classe. Em vez de uma imagem de saída final, eles produzem um conjunto de imagens, cujo número depende do número de assinaturas envolvido na classificação. As imagens resultantes avaliam o grau com o qual um *pixel* pertence a uma classe ou combinação de classes. Vários métodos de classificação relativa são oferecidos, incluindo aqueles baseados na teoria de probabilidade *Bayesiana*, teoria *Dempster-Shafer* e teoria de conjuntos *Fuzzy*. Eles tratam várias questões da maior significância para o processamento de imagens em computador, como a análise de misturas, avaliação de evidência em suporte às classes envolvidas, reconhecimento de conhecimento incompleto e presença de classes desconhecidas.

Veja o capítulo *Classificação de imagens de sensoriamento remoto* na seção **TÓPICOS ESPECIAIS** para acompanhar uma discussão detalhada das técnicas tradicionais versus novas técnicas de classificação.

### Transformação de imagens

O processamento digital de imagem oferece uma gama ilimitada de possíveis transformações em dados de sensoriamento remoto. São mencionadas aqui especificamente duas, por causa de sua importância em aplicações em monitoramento ambiental.

### Índices de vegetação

Há uma variedade de índices de vegetação que têm sido desenvolvidos para auxiliar no monitoramento da vegetação. A maior parte está baseada em interações entre a vegetação e a energia eletromagnética

nos comprimentos de onda do vermelho e do infravermelho próximo. Vamos voltar temporariamente à ilustração 3-4, que inclui um padrão de resposta espectral mais geral para vegetação verde de folhas grandes. Como pode ser visto, a reflectância na região do vermelho (cerca de 0,6 - 0,7 $\mu$ ) é baixa devido à absorção pelos pigmentos das folhas (principalmente clorofila). A região do infravermelho (aproximadamente 0,8 - 0,9  $\mu$ ), entretanto, mostra caracteristicamente alta reflectância por causa do espalhamento por parte da estrutura das células das folhas. Um índice de vegetação muito simples pode ser obtido dividindo a medida da reflectância no infravermelho pela reflectância no vermelho. Áreas de vegetação densa terão como resultado um valor de índice muito alto.

Embora um razoável número de variantes desta lógica básica tenha sido experimentada, a única que recebeu mais atenção é a do *índice de vegetação de diferença normalizada* (NDVI). Ele é calculado da seguinte maneira:

$$\text{NDVI} = (\text{NIR} - \text{R}) / (\text{NIR} + \text{R})$$

onde NIR = Infravermelho próximo  
e R = Vermelho

Este tipo de cálculo é bastante simples para um SIG raster ou um sistema de processamento de imagens, e o resultado tem mostrado boa correlação com as medidas de biomassa no terreno. Embora necessite calibração específica para ser usado como uma medida real de biomassa, muitas agências acharam o índice útil como uma medida relativa para fins de monitoramento. Por exemplo, a Organização das Nações Unidas para Alimentação e Agricultura (*United Nations Food and Agricultural Organization -- FAO*), o Sistema em Tempo Real de Informação da África (*Africa Real Time Information System -- ARTEMIS*) e o Sistema de Alerta Contra a Fome do USAID (*Famine Early Warning System -- FEWS*), usam imagens NDVI em escala continental derivadas do sistema NOAA - AVHRR para produzir imagens de índice de vegetação para todo o continente africano a cada dez dias.

Veja o capítulo *Índices de vegetação* na seção *TÓPICOS ESPECIAIS* para uma discussão detalhada de uma variedade de cálculos potenciais.

### Análise de componentes principais

A análise de componentes principais (PCA) é uma técnica de transformação linear relacionada com análise fatorial. Para um conjunto de bandas de imagem, a técnica PCA produz um novo conjunto de imagens, conhecidas como componentes, que estão decorrelacionadas umas com as outras e que são ordenadas em termos da variância do conjunto de bandas original que explicam.

A PCA tem sido tradicionalmente usada no sensoriamento remoto como um meio de compactação de dados. Para um conjunto típico de bandas de imagem multiespectral, é comum descobrir que as primeiras duas ou três componentes são capazes de explicar virtualmente toda a variabilidade original nos valores de reflectância. As últimas componentes tendem a ser dominadas por efeitos de ruído. Rejeitando estas últimas componentes, o volume de dados é reduzido sem perda apreciável de informação.

Recentemente, a PCA tem mostrado ter aplicação especial para o monitoramento ambiental. Nos casos onde imagens multiespectrais estão disponíveis para duas datas, as bandas de ambas as imagens são submetidas à PCA como se todas elas viessem da mesma imagem. Nestes casos, mudanças entre as duas datas tendem a aparecer nos últimos componentes. Mais nitidamente, se uma série temporal de imagens NDVI (ou um índice similar) é submetida à análise; uma visão muito detalhada das mudanças ambientais e tendências pode ser obtida. Neste caso, a primeira componente mostrará o NDVI típico sobre a série completa, enquanto cada componente sucessiva irá ilustrar eventos de mudança em uma seqüência com importância ordenada. Examinando-se estas imagens, juntamente com gráficos da sua correlação com as bandas individuais na séries original, pode ser obtida uma percepção importante da natureza das mudanças e tendências sobre a série temporal.

## **Conclusões**

Dados de sensoriamento remoto são importantes para uma grande variedade de disciplinas. Essa importância certamente aumentará com a maior disponibilidade de dados prometida por um crescente número de sistemas operacionais. A disponibilidade destes dados, associada ao *software* necessário para analisá-los, oferece oportunidades para planejadores e estudantes da área ambiental, particularmente nas áreas de mapeamento de uso do solo e detecção de mudanças, das quais não se ouvia falar há poucas décadas atrás.

A estrutura raster inerente aos dados de sensoriamento remoto os torna prontamente compatíveis com os SIG raster, e vários, incluindo o IDRISI for Windows, são projetados para desempenharem tarefas de processamento de imagens e para facilitar a incorporação dos resultados em análises de SIG. O IDRISI for Windows é excepcional pelo fato de que oferece técnicas avançadas de classificação de imagens em adição a um avançado sistema de análise geográfica.



# ***EXERCÍCIOS TUTORIAIS INTRODUTÓRIOS***

Estes exercícios estão organizados para possibilitar de forma estruturada a compreensão de sistemas de informação geográfica, de processamento de imagens e de outras técnicas de análise geográfica disponíveis no sistema IDRISI for Windows. Os exercícios estão divididos da seguinte forma:

## **Introdução ao Sistema IDRISI for Windows**

1. O ambiente do IDRISI for Windows
2. O sistema de visualização
3. Composição de mapas
4. Tabelas de cores, símbolos e autoescalamento

## **Introdução à modelagem cartográfica**

### **Análise em sistemas de informação geográfica**

5. Consulta ao banco de dados
6. Operadores de distância e de contexto
7. Automação de análises com macros
8. Distâncias de custo e caminhos de menor custo
9. Álgebra com mapas
10. Oficina de banco de dados

### **Processamento de imagem**

11. Exploração de imagens
12. Classificação supervisionada
13. Análise de componentes principais
14. Classificação não supervisionada

### **Importação de dados e georreferenciamento**

15. Georreferenciamento de imagens usando reamostragem
16. Bases de dados cartográficos digitais
17. Alteração do sistema de referência com PROJECT



Enquanto estiver trabalhando nestes exercícios, você poderá acessar a seção **MÓDULOS DO PROGRAMA** no *Sistema de ajuda* sempre que encontrar um novo módulo. Você poderá consultar o **GLOSSÁRIO**, sempre que encontrar termos que não lhe são familiares.

Os exercícios devem ser seguidos em ordem: o conhecimento dos conceitos apresentados no início será considerado sob domínio nos exercícios posteriores, e os exercícios posteriores às vezes dependem de imagens produzidas em exercícios anteriores. No final de cada exercício você será informado sobre as imagens que deverão ser guardadas para os exercícios seguintes. Quaisquer outras imagens criadas durante o exercício podem ser excluídas para liberar espaço no disco rígido.

Em cada exercício, as seções nas quais é requerida uma ação no computador são indicadas com letras do alfabeto. Ao longo do exercício também aparecerão questões numeradas. Para um instrutor, as respostas a estas questões numeradas, juntamente com algum material impresso relevante, pode servir como base para revisão.

Antes de começar, observe o seguinte:

1. Ao usar procedimentos analíticos que requerem mais do que uma imagem de entrada, as imagens devem ter exatamente as mesmas dimensões (i.e., linhas e colunas). Isto é um elemento inerente ao IDRISI for Windows - imagens devem descrever exatamente a mesma área quando usadas em combinação.
2. Examine cada resultado (mesmo intermediário) usando o Lançador de visualização. Caso não esteja correto, pare e repense sobre o que você fez. A análise geográfica pode estar ligada a operações em cascata, cada qual dependendo da anterior. Como resultado, podem haver becos sem saída, similar ao que acontece nos jogos de aventura. Além disso, os erros acumulam-se rapidamente. Seu maior seguro contra isso é pensar cuidadosamente sobre o resultado esperado e então examinar cada produto para ver se ele preenche suas expectativas.

Exercícios tutoriais ilustrando uma seleção de aplicativos avançados do sistema IDRISI for Windows podem ser encontrados nos **Exercícios tutoriais avançados** deste manual.

# 1. O ambiente do IDRISI for Windows

Para iniciar o IDRISI for Windows clique sobre o ícone do aplicativo IDRISI no grupo de programas do IDRISI for Windows. Com isso será carregado o sistema do IDRISI for Windows. O sistema oferece um ambiente de trabalho completo e roda normalmente em estado maximizado (i.e., ele ocupa a tela toda).

- a) Uma vez carregado o sistema, note que a tela possui quatro componentes distintos. No topo, nós temos o menu principal, abaixo do qual aparece a barra de ferramentas com ícones para acesso rápido aos módulos mais comuns. Abaixo desta está a área de trabalho principal e, mais abaixo, a barra de status.

A barra de status fornece mensagens úteis sobre a operação e a performance do sistema. A título de exemplo, mova o mouse sobre os ícones da barra de ferramentas e observe a barra de status, na parte inferior esquerda do seu vídeo. Ainda que deseje memorizar o mais depressa possível o que cada um desses ícones representa, você pode conseguir saber isso simplesmente posicionando o cursor do mouse sobre o ícone em questão. Observe que alguns dos ícones aparecem em cor cinza. Eles estão desligados porque só podem ser usados em certas circunstâncias (tal como quando um mapa está sendo visualizado) mas aparecerão coloridos quando estiverem ativos.

- b) Mova agora o cursor para o ícone mais à esquerda da barra de ferramentas e clique sobre o mesmo com o botão esquerdo do mouse. Como a barra de status informa, isso abre o módulo ENVIRON. ENVIRON é o mais básico dos módulos, no qual é definido o diretório de trabalho. Normalmente os usuários do IDRISI for Windows criam diferentes subdiretórios para os diversos projetos em que trabalham, necessitando, por isso, trocar de diretório frequentemente. Este é o propósito do módulo ENVIRON, motivo pelo qual é o primeiro ícone da barra de ferramentas.

Caso isso ainda não tenha sido feito, defina o diretório de trabalho como aquele onde estão armazenados os dados dos exercícios tutoriais (p. ex., c:\exercise). Observe que você tem duas maneiras de fazer isso. Uma é digitar o nome do diretório dentro da caixa de diálogo e pressionar o botão OK. Todavia, você pode também selecionar o drive e o diretório diretamente da lista abaixo da caixa de diálogo. Para mudar o drive, clique no botão de troca de drive e dê um clique simples sobre o drive desejado. Para alterar o subdiretório você necessita dar um clique duplo sobre o subdiretório desejado, na lista de subdiretórios. Fazendo isso, o nome do subdiretório escolhido vai automaticamente para a caixa de diálogo acima da lista. Veja que você pode clicar no diretório ao topo da lista (o diretório raiz -- p. ex., "c:\") para ver a lista dos subdiretórios principais no drive escolhido. Quando a caixa de diálogo no topo da janela do

ENVIRON estiver corretamente definida, clique no botão OK para que as mudanças escolhidas sejam implementadas. A caixa de diálogo também será fechada neste momento.

Ao longo deste tutorial, sempre que uma opção não for mencionada, deixe os valores padrão como estão. Por exemplo, na caixa de diálogo de ENVIRON, você pode indicar suas unidades de referência padrão e as extensões de arquivo padrão. Como estas opções não são mencionadas nas instruções, deixe-as com seus valores padrão originais.

- c) Agora mova o cursor sobre o menu principal do sistema. Observe que isso também permite uma explanação mais detalhada na barra de status. Selecione o menu Ambiente e escolha o primeiro item neste menu -- ENVIRON. Como você pode ver, isto o leva ao mesmo módulo descrito acima. A barra de ferramentas oferece uma opção mais rápida de acesso aos módulos mais utilizados com maior frequência, mas o menu é a forma principal de fazer isso.

Enquanto voltamos ao item ENVIRON do menu Ambiente, aproveite para observar algumas de suas demais características. Primeiro, veja que ele ilustra qual é o seu ícone correspondente na barra de ferramentas. Todos os módulos que têm ícones os ilustram na sua caixa de diálogo. Em seguida, observe que aparece um botão de Ajuda. Clique sobre ele.

O Sistema de ajuda do IDRISI for Windows é bastante extenso. Ele propicia uma referência técnica completa, que é seu recurso primário para esclarecer detalhes no uso de cada módulo. Você pode notar que, para cada módulo, é dada uma descrição do seu propósito, seguido das chaves para as seções *Operação*, *Notas*, *Mensagens de erro* e *Comandos macro* (se aplicável). Veja que estas chaves aparecem coloridas e sublinhadas. Clique sobre a chave *Operação*, que levará você para a seção sobre como operar o módulo ENVIRON. Para retornar para onde você estava anteriormente, clique sobre o botão Voltar. Observe também que há um botão denominado Localizar. Clique sobre ele e digite "IDRISI". Essa opção de busca permite a você não apenas encontrar informação sobre qualquer módulo do IDRISI, mas também sobre qualquer outro tópico. O Sistema de ajuda possui um glossário completo dos termos que você pode encontrar no uso do seu sistema IDRISI for Windows.

Para sair do sistema de ajuda use o procedimento normal de saída de qualquer janela do Windows (no Windows 3.1 ou Windows NT 3.5 dê um clique duplo no botão do canto superior esquerdo; no Windows 95 clique no botão "X" na barra superior da janela; você pode também usar a opção Arquivo/Sair.

Uma vez que definimos nosso diretório de trabalho e não desejamos fazer mais nenhuma alteração, podemos sair do ENVIRON de três formas. A mais comumente usada é clicar no botão Cancelar. Você também pode usar as formas descritas acima para sair do sistema de ajuda. Entretanto, no IDRISI for Windows, você pode pressionar a tecla "Esc" do seu teclado. Use a forma que você preferir e saia agora do ENVIRON.

- d) Retorne agora para o menu Ambiente e escolha a opção Atalho. Essa é a terceira forma (além da barra de ferramentas e da seleção a partir do menu principal) pela qual os módulos do IDRISI for Windows podem ser acessados. O Atalho é projetado para aqueles que preferem digitar ou selecionar nomes dos módulos, como fazem muitos usuários das versões do IDRISI for DOS. Tente digitar a palavra ENVIRON e observe o que acontece durante a digitação de cada caracter. Veja que ele continuamente procura descobrir o módulo que você deseja. Neste caso em particular, ele sabe após a digitação de apenas dois caracteres ("EN"). A partir deste ponto você pode continuar digitando se quiser, embora não seja mais necessário. Tão logo tenha visto o módulo desejado selecionado na lista, você pode pressionar a tecla *Enter* (ou *Return*) do seu teclado ou clicar no botão OK Experimente apertar a tecla *Enter*. Saia do ENVIRON e clique no botão Cancelar do Atalho. Isso remove o Atalho da tela. Se você acha que vai usar bastante este recurso durante seu trabalho, deixe-o aberto na tela durante o tempo que desejar.
- e) Retorne mais uma vez ao menu Ambiente. Observe que abaixo do Atalho há mais uma série de itens. Cada item define se uma propriedade fica ligada ou desligada. Como você pode ver a

Proteção de escrita, a Barra de ferramentas e a Barra de status estão ligadas enquanto Exibir recursos está desligado. Para ver o que cada um desses ítems faz, clique no item da barra de status e da barra de ferramentas. Normalmente eles são deixados ligados, mas poderá acontecer de você desejar uma área de visualização maior. Esse item permite remover esses itens para liberar espaço. A proteção contra sobrescrita irá avisá-lo sempre que você estiver gravando um arquivo com o mesmo nome de algum arquivo já existente em seu diretório de dados. Esta é uma precaução de segurança que nós aconselhamos seja deixada ligada. Entretanto, você está livre para removê-la, se desejar. Finalmente, o item Mostrar recursos pode ajudá-lo a diagnosticar problemas no uso do sistema Windows. Com Windows 3.1 (e bem menos em Windows 95), um conjunto de *buffers* especiais de memória são utilizados para controlar os elementos do Windows. Esses *buffers* surpreendentemente pequenos (chamados de *System*, *Graphics Device Interface* e *User Resource buffer*) podem ficar sobrecarregados e levar a comportamentos muito incomuns e instáveis, levando no final a um erro de falta de memória (*Out of memory*). Isto é ilusório já que há memória abundante, somente insuficiente nesses buffers específicos. Caso você estiver tendo problemas como esse, tente ligar o item Mostrar recursos -- ele substituirá o relógio e mostrará a porcentagem do *System* (s), *Graphics Device Interface* (g) e *User Resource buffer* (u) que estão disponíveis<sup>12</sup>.

Antes de continuar, ligue tanto a barra de ferramentas quanto a barra de status.

Isso completa nossa exploração do ambiente do IDRISI for Windows. Você irá perceber que existe mais uma entrada no menu Ambiente -- Preferências. Iremos estudá-la apenas para saber que serve para definir as características padrão do sistema de visualização (o qual veremos no próximo exercício) e o idioma<sup>13</sup> a ser utilizado. Aplicações específicas criadas pelo usuário e especificadas nas Preferências aparecem e podem ser executadas a partir do menu Arquivo. Assim, é possível executar qualquer outra aplicação a partir do menu principal do IDRISI for Windows.

Como você pode ver no menu principal, o menu Ambiente é apenas um dos vários grupos de módulos. Esse agrupamento de módulos pode ser útil, mais tarde, para você explorar o sistema de menus, olhando na barra de status para obter informações genéricas ou utilizando o sistema de ajuda *on-line* para saber detalhes específicos de cada módulo.

Imediatamente à direita do menu Ambiente está o menu Arquivo. Este menu contém uma série de opções para o manuseio de arquivos como Listar, Documentar e Descrever e para a Manutenção de arquivos (excluir, renomear, copiar e mover). Ele também contém uma Oficina de impressão e uma série de rotinas para a importação e exportação de arquivos. Próximo à base do menu Arquivo você verá uma opção que executa arquivos macro. Arquivos macro são arquivos que contém seqüências de operações do IDRISI for Windows. Todas as opções do menu mostradas em **letras maiúsculas** podem ser executadas em modo macro. Finalmente, caso haja algum aplicativo definido pelo usuário indicado nas Preferências, o nome deste aplicativo aparecerá na base do menu Arquivo.

O menu Visualização acessa uma variedade de rotinas para a visualização de dados. Ele também contém as preferências de visualização, que permitem ao usuário indicar certos parâmetros de visualização para serem usados como padrão. A maioria dos elementos deste menu será estudada no próximo exercício.

O menu Análise é o mais extenso de todos. O IDRISI for Windows contém mais de 100 módulos, a maioria dos quais devotada à análise de dados espaciais. Como você pode observar,

---

<sup>12</sup> Observe que você corre o perigo de paralisar o sistema se um destes recursos cair abaixo de 10%. Você pode livrar espaço na memória fechando outros aplicativos que possam estar abertos ao mesmo tempo que o IDRISI for Windows. Adicionalmente, você pode querer consultar seu material do Windows para seguir outros passos visando conservar esses recursos. De acordo com nossa experiência, problemas de recursos são substancialmente reduzidos no Windows 95 e ausentes no Windows NT 3.5.

<sup>13</sup> O IDRISI for Windows foi especialmente projetado para facilitar a tradução para outros idiomas. A interface do programa, o sistema de ajuda e partes do Manual do Usuário já foram traduzidas para vários idiomas, incluindo francês, português, espanhol, chinês, russo e alemão. Informações sobre a disponibilidade de traduções do *software* podem ser obtidas na página do Projeto Idrisi, no endereço [www.idrisi.clarku.edu](http://www.idrisi.clarku.edu), ou nos Centros de Recursos dos diferentes idiomas.

o menu Análise é constituído de uma série de grupos analíticos com conjuntos de módulos listados como submenus. Muitos desses módulos serão explorados nos exercícios a seguir.

O menu Reformatação apresenta uma série de módulos para alterar a natureza dos arquivos de dados geográficos. Eles vão desde o georreferenciamento e mudanças de projeção até rotinas de conversão de formato raster/vetorial.

O menu Entrada de Dados, como o próprio nome sugere, acessa um conjunto de módulos destinados à entrada de dados. Você pode observar que a digitalização é uma operação independente que requer um programa específico, o qual, por esse motivo, não está listado aqui. A versão corrente do IDRISI for Windows inclui uma cópia livre de um programa for DOS para digitalização e edição de vetores, chamado TOSCA, que pode ser usado para criar arquivos vetoriais compatíveis com o IDRISI. Há também alguns outros programas de digitalização que funcionam muito bem com o sistema IDRISI for Windows.

As duas últimas opções do menu são razoavelmente parecidas com as de outros programas para Windows. O menu Janela possibilita simplificar o arranjo e o acesso a várias janelas. O menu Ajuda já foi por nós examinado. Entretanto, é um menu ao qual você retornará com frequência, conforme for utilizando os aplicativos do IDRISI for Windows.

## 2. O sistema de visualização

Nos próximos três exercícios será explorado o sistema de visualização do IDRISI for Windows. O IDRISI for Windows está mais para um sistema de análise de dados cartográficos e de dados de sensoriamento remoto do que para um programa de construção de mapas. Entretanto, a análise visual é um ingrediente importante de qualquer análise geográfica. Adicionalmente, a produção de mapas de qualidade com o propósito de ilustração (e, às vezes, persuasão) é muito importante. Como consequência, o IDRISI for Windows oferece um extenso sistema para a visualização em tela e para a composição gráfica de diversos planos de mapas em mapas finais que podem ser impressos.

Neste primeiro exercício da seqüência, nós daremos uma rápida olhada nos elementos fundamentais da visualização de planos de mapas. Já no segundo exercício, nós examinaremos os meios através dos quais uma composição mais complexa de mapa é criada, salva e impressa. Finalmente, no último exercício da seqüência de visualização, veremos um tópico importante sobre a criação e o uso de símbolos e tabelas de cores.

### *Conhecendo as imagens disponíveis: LIST e DESCRIBE*



- a) Agora que temos o diretório de trabalho indicado adequadamente (aquele que contém os dados dos exercícios tutoriais), clique sobre o ícone LIST (o segundo da esquerda para a direita). Como o nome sugere, este módulo lista os arquivos de dados no diretório de trabalho. O módulo LIST tem como opção padrão mostrar os arquivos imagem. Entretanto, você perceberá que qualquer outro dos muitos tipos de arquivos de dados que o IDRISI usa pode ser listado. Você perceberá que para alguns tipos de arquivos, como imagens, vetoriais e arquivos de valores, o módulo LIST mostra também o título dos mesmos. A opção Máscara possibilita listagens mais específicas. Para ilustrar, selecione a opção Máscara e digite WEST\*.\* para ver todos os arquivos no diretório de dados cujo nome inicia com as letras WEST.



- b) Selecione Imagem e verifique que a imagem BRAZILFC está em nosso diretório de dados. Para obter informação mais detalhada sobre este arquivo, clique sobre o ícone do módulo DESCRIBE, situado imediatamente à direita do ícone LIST na barra de ferramentas. Localize então a imagem BRAZILFC na lista de imagens e selecione a mesma para visualizar seu arquivo documento na caixa de diálogo principal. Você deve navegar para baixo e para a direita com o auxílio das barras de rolagem para ver toda a informação do documento.

Como você pode ver nesta descrição, a imagem BRAZILFC é uma imagem composição colorida

em falsa cor. Composições em falsa cor são imagens coloridas produzidas originalmente a partir de três imagens independentes em tons de cinza. As imagens são chamadas de composições em falsa cor sempre que contiverem informação espectral fora do intervalo sensível ao olho humano. Neste caso, os comentários no arquivo documento indicam que a imagem foi composta a partir dos canais verde, vermelho e infravermelho próximo (bandas 4, 5 e 7) do *Multi-Spectral Scanner* (escanerizador multi-espectral) do satélite LANDSAT.

O arquivo documento contém, adicionalmente às informações descritivas, uma variedade de parâmetros muito importantes usados pelo IDRISI for Windows na visualização e na análise do plano de informação. Ele indica, por exemplo, o tipo de dados e o tipo de arquivo usado para armazenamento, o número de linhas e de colunas, o sistema de georreferenciamento e o intervalo de coordenadas geográficas abrangidas em sua extensão. O módulo que permite a você editar um arquivo documento é Documentar. Entretanto, esses detalhes específicos referentes a tamanho, localização e formato de armazenamento normalmente não deveriam ser modificados.

### Visualização básica de imagem: Lançador de visualização



- c) Para visualizar a imagem BRAZILFC, clique sobre o ícone do Lançador de visualização (o quinto da esquerda para a direita). O Lançador de visualização é o primeiro de vários componentes importantes do sistema de visualização. Ele apresenta uma caixa de diálogo na qual uma nova janela de mapa pode ser visualizada ao se trazer para a tela uma imagem, um arquivo vetorial ou ainda a composição completa de um mapa (a composição de mapas será tratada no próximo exercício).

Para visualizar uma imagem nós necessitamos indicar o seguinte:

- o tipo de arquivo a ser visualizado (a indicação padrão é um arquivo imagem)
- o nome da imagem (veja a nota especial que segue)
- a tabela de cores (a qual, por definição, é indicada a um conjunto de 256 cores)
- se a imagem deve ser realçada automaticamente (ele fará uma sugestão) - isto será tratado de forma mais completa no Exercício 4
- o fator de expansão (ele determinará um automaticamente)
- qualquer componente auxiliar ao mapa (como legenda, escala, etc.)

Como há indicações padrão para cada item, exceto para o nome do arquivo a visualizar, isso é tudo o que necessitamos indicar. Entretanto, indicaremos dois elementos - o arquivo e a tabela de cores.



- d) Para indicar o nome do arquivo a visualizar, digite simplesmente o nome na caixa de diálogo. Existe, entretanto, um meio mais fácil! ***Simplesmente acione o mouse duas vezes seguidas sobre a caixa de diálogo de entrada e ela mostrará uma lista de escolhas que você pode fazer.*** Isto é verdadeiro para praticamente todas as caixas de diálogo de entrada que requerem informação sobre um arquivo de dados<sup>14</sup>. Experimente selecionar agora a imagem BRASILFC clicando uma vez para selecioná-la e uma segunda vez para inseri-la na caixa de entrada (ou simplesmente clicar duas vezes seguidas para alcançar o mesmo resultado). Clique a seguir, na tabela de cores, o item “Composição colorida 256”, seguida do botão OK.

- e) Neste ponto, você deve ter a imagem BRAZILFC na tela.

1. Mova o cursor do mouse sobre a imagem. O que pode ser observado na barra de status (barra inferior da tela) à medida que você move o cursor sobre ela?

<sup>14</sup> Além do clicar duplo ser uma solução nova para a necessidade de visualizar uma lista de arquivos disponíveis, nós percebemos que ele também era superior às caixas de lista mais tradicionais por que ele pode fornecer uma lista mais longa em uma variedade de contextos. Em sistemas de geoprocessamento é comum haver um grande número de arquivos e a possibilidade de escolher um a partir de uma lista longa é extremamente útil.

### Uma introdução à Composição de mapas

- f) Você deve ter percebido que, juntamente com a imagem, apareceu um segundo elemento importante do sistema de visualização, uma pequena janela chamada Composição. A Composição é usada para criar composições de mapas, bem como para controlar as características visuais dos arquivos que já estão na tela. Exploraremos a Composição em profundidade no próximo exercício. Entretanto, como uma breve ilustração, clique o ícone do Lançador de visualização novamente (você deve deixar a imagem BRAZILFC na tela) e carregue uma imagem denominada DEC88C com a tabela de cores NDVI 16 e em todos os outros elementos aceite os indicadores padrão. Adicionalmente, clique sobre as opções de legenda, de título e de escala na porção inferior da caixa de diálogo (não dê atenção aos outros elementos por enquanto - eles levam em consideração tópicos que ainda não discutimos). Clique então no botão OK.

Diferente de BRAZILFC que parece muito mais uma *imagem*, esta se parece mais com um mapa. Entretanto, podemos definir um mapa simplesmente como sendo um ou mais planos de informação interpretados. Aqui a interpretação é fornecida (mesmo que num sentido ordinal grosseiro) pela legenda.

- g) Para agregar qualidade a esse mapa, vamos adicionar um segundo plano de informações - os limites dos países. Para fazer isso, certifique-se que DEC88C seja a imagem ativa<sup>15</sup> e clique sobre a opção Adicionar plano da Composição. Isso trará uma outra caixa de diálogo que solicitará o nome de um arquivo vetorial a ser colocado sobre a imagem, assim como o arquivo de símbolos correspondente. Nós exploraremos os arquivos de símbolos mais detalhadamente no Exercício 4. Entretanto, por agora compreenda apenas que eles indicam como elementos gráficos (como as linhas neste caso) devem aparecer. Dê um clique duplo na caixa de diálogo Nome do arquivo, selecione o arquivo COUNTRY e, a seguir, clique no botão OK para aceitar o arquivo de símbolos padrão (linha preta fina).

Você perceberá que a Composição mostra agora a adição de um segundo plano. Você pode sobrepor até 16 planos em um mesmo mapa.

### Tabelas de cores

O próximo assunto que precisa ser explorado é o das tabelas de cores. Caso você esteja trabalhando com a visualização de 15 bits (32.767 cores), 16 bits (65.536 cores) ou de 24 bits (16 milhões de cores), você não notará o que será discutido no item abaixo. Entretanto, para aqueles que possuem sistemas de 8 bits (256 cores)<sup>16</sup>, as considerações são importantes.

- h) Mova o cursor para o topo da imagem visualizada e clique com o mouse sobre sua barra superior. Segure o botão esquerdo do mouse pressionado e desloque a imagem para o lado de forma a visualizar ambas imagens. Caso você esteja trabalhando com um sistema de 8 bits (256 cores), mude a janela ativa da imagem DEC88C para BRAZILFC e retorne novamente a DEC88C clicando sobre a barra superior da janela. Você perceberá um efeito pouco comum quando uma janela de mapa que se torna ativa toma, momentaneamente, a tabela de cores da outra janela de mapa. Como o adaptador gráfico é capaz de mostrar apenas 256 cores e como cada tabela pode ter apenas até 256 cores, não é possível mostrar simultaneamente duas tabelas

<sup>15</sup> A janela ativa refere-se à possibilidade da janela receber uma entrada do usuário. Apenas uma janela pode estar ativa de cada vez - o elemento que o Windows usa para indicar a janela ativa é uma cor diferente para a barra superior da mesma. Você pode alternar a janela ativa para a próxima simplesmente clicando sobre a janela correspondente (ou selecionando-a de uma lista de janelas ativas no menu do Windows). Isso fará com que a janela que vier para a frente (se ela foi encoberta) se torne ativa. A Composição sempre indica o conteúdo da janela ativa, ou da que foi ativada por último.

<sup>16</sup> O IDRISI for Windows requer uma memória de visualização de pelo menos 8 bits por *pixel* (256 cores). Embora o sistema fisicamente possa funcionar em sistemas de 4 bits (16 cores), a qualidade de visualização de cores pode ser imprevisível e frequentemente pobre.



perfeitas de 256 cores ao mesmo tempo. Por isso o Windows permite à janela de imagem ativa determinar a tabela de cores a usar. É por esta razão que todas as janelas que não estão ativas (chamadas de janelas de fundo) repentinamente assumem a tabela de cores daquela que está ativa. Para compensar, o Windows permite à qualquer imagem de fundo o uso de suas respectivas tabelas de cores, dentre aquelas cores já selecionadas pela janela anterior (junto com o conjunto padrão de 20 cores que o Windows reserva para si próprio). Esta é a correção que você vê após esta modificação.

Neste caso, a combinação de duas tabelas de cores envolvidas (Composição colorida 256 e NDVI 16) não representou maiores problemas para o Windows. Embora possamos ver o sistema trocar a tabela de cores e processar o ajuste, ele faz isso com relativo sucesso. Entretanto, para ilustrar como este problema pode ser difícil, use o Lançador de visualização para trazer uma imagem denominada ETDEM à tela, mantendo as outras imagens também na tela. Neste caso, use a tabela Idrisi 256 e uma legenda e clique OK.

Esta imagem contém um modelo digital de elevação da Etiópia. Como você já fez anteriormente, mude a janela ativa para um outro mapa.

2. O que aconteceu com as tabelas de cores das imagens de fundo? Com que qualidade o Windows funcionou para compor suas tabelas ao mesmo tempo que a da janela de mapa ativa?

É importante reconhecer que este problema de ajuste de tabela de cores desaparece completamente se você tiver um adaptador gráfico de 15 bits ou mais memória de visualização. Entretanto, atualmente, muitos de nós possuem sistemas gráficos de 8 bits, assim, é melhor reconhecer este fato e levar em consideração as seguintes sugestões:

- Com tabelas de 16 cores os problemas são menos prováveis. Por exemplo, a razão do Windows ter sido capaz de fazer adequadamente a combinação de BRAZILFC com DEC88C é porque a tabela NDVI 16 possui apenas 16 cores (além disso, a tabela Composição colorida 256 contém uma gama de escolha de cores bem mais ampla).
  - Algumas vezes você encontrará dificuldades em perceber uma tabela de cores verdadeira de 256 cores, mesmo se sua placa gráfica é capaz de mostrar tantas cores. Windows reserva sempre 20 cores para assegurar que ele tenha as cores necessárias para mostrar seus elementos básicos. Como resultado, você tem controle verdadeiro sobre apenas 236 cores. No caso de sua tabela de cores usar as 20 cores que o Windows usa, sua tabela pode aumentar até o total de 256. Entretanto, para algumas tabelas esta tarefa é quase impossível sem que haja problemas. Este é o caso da tabela de 256 tons de cinza. Como ela contém somente tons de cinza, ela não pode utilizar-se de quase nenhuma das 20 cores do Windows. Como consequência, você talvez somente veja cores esparsas e o resultado não é exatamente cinza.
- i) Para ilustrar este último ponto, vamos mudar a tabela de cores da imagem ETDEM a Composição. Certifique-se que a janela do mapa ETDEM esteja ativa e clique sobre seu nome na lista de arquivos da Composição. Você perceberá que seu nome muda de preto para vermelho, indicando que ela foi selecionada (isto é algo mais significativo no contexto de uma composição com vários planos de informação). Clique então o botão Propriedades. Aqui você perceberá que são listados os arquivos de tabelas de cores associados a este plano e se ele possui ou não uma legenda. Altere a tabela de cores para GREY256 clicando duas vezes sobre a caixa de diálogo de arquivos de tabela de cores e selecionando da lista. Solicite a exibição da legenda e pressione OK.

O grau de correção da tabela de cores irá depender em grande parte da configuração de cores que você estiver usando no Windows. Ela poderá ser boa ou ter dificuldades para fazer todos os 256 tons de cinza. Os resultados irão variar de um sistema para outro, de acordo com a configuração.

Novamente, se você estiver trabalhando com um sistema de visualização de 15 bits ou superior, os problemas acima não serão um obstáculo para você. Você poderá visualizar várias imagens, cada uma com sua própria tabela de 256 cores, sem correções ou perda de fidelidade da tabela de cores quando você muda a janela ativa de uma para a outra. É importante notar, entretanto, que independente da capacidade do seu sistema gráfico, cada imagem individual é exibida com uma única tabela e por isso pode ter até (mas não mais que) 256 cores.

## Legendas

Vale a pena observar aqui como a legenda que produzimos para ETDEM é diferente daquela de DEC88C. Primeiro, percebemos que a legenda possui uma barra de rolagem. Tente mover a barra em toda sua extensão. A seguir execute DESCRIBE e veja o arquivo documento de ambas as imagens.

3. Qual é o tipo de dados de cada imagem? Qual a diferença entre as categorias de legenda nos seus arquivos documento?

Como você vê, o IDRISI for Windows tem um meio de produzir uma legenda mesmo para imagens que não tenham uma categoria de legenda específica para cada classe de seu arquivo documento. No caso de ETDEM, ele produz uma legenda mostrando 256 valores representativos do intervalo numérico da imagem. Como não existe espaço para mostrar todas as 256 classes, ele produz uma barra de rolagem e permite a você percorrer os valores. Note também que os valores são expressos de forma exponencial (também chamada algumas vezes de notação científica). Assim, 4.26700E+03 pode ser interpretado como 4,267 vezes 10 elevado à potência 3, ou 4267. Essa notação é sempre usada quando a legenda é produzida automaticamente para imagem com números reais, de forma que ele pode mostrar o mesmo número de casas decimais, independente do tamanho maior ou menor que o número possui.

Como estas duas imagens ilustram, você pode ter sempre uma legenda para cada imagem. Entretanto, se desejar um controle completo sobre seu conteúdo, você necessitará adicionar uma informação de legenda no arquivo documento de sua imagem. Isso é feito através do módulo Documentar, o qual permite indicar até 256 categorias de legenda, ou interativamente através da visualização (isso será ilustrado no próximo exercício).

## Dimensionando a legenda e a moldura do mapa

- j) Caso desejar, você pode fechar agora todas as janelas de visualização abertas, antes de prosseguir. Cada janela de visualização aberta toma recursos da memória. Para continuar a exploração da legenda, use o Lançador de visualização para examinar um arquivo chamado AFFAOSOL. Use a tabela de cores chamada Qualitativa 256 e especifique que devem aparecer a legenda e o título. Observe novamente que há mais categorias de legenda do que cabem na tela, mas desta vez elas vem do arquivo documento ao invés de terem sido geradas automaticamente.

Como você deve ter percebido, a legenda mostra automaticamente 16 categorias numeradas de 0 a 15 (a barra de rolagem horizontal esconde a categoria 15). Neste caso, podemos nos deslocar pela legenda usando a barra de rolagem vertical para ver outras categorias. Entretanto, independente do número total de categorias, há momentos em que desejamos menos ou mais categorias de legenda de uma vez na tela. Isto pode ser alcançado através da opção de dimensionamento.

Muitos dos elementos do mapa no IDRISI for Windows podem ser dimensionados. Para proceder assim, clique sempre duas vezes sobre o elemento desejado. Uma linha correspondente à caixa de controle aparecerá com barras e marcas de dimensionamento ao longo de seus

limites. Escolha qualquer uma destas barras de dimensionamento usando o botão esquerdo do mouse (i.e., colocando o cursor do mouse sobre a barra, acionando o botão esquerdo do mouse e mantendo-o acionado). O cursor irá mudar para setas duplas e você poderá então puxar ou empurrar a barra para alterar o tamanho. Tente isso com a legenda e altere apenas sua extensão vertical. Tente a seguir rolar novamente pela legenda.

Tente o mesmo com a janela dos dados. A janela dos dados é o retângulo cujos limites contém os planos de informação do mapa. Você pode clicar sobre ele duas vezes para alterar seu tamanho (a imagem irá desaparecer até você começar a redimensionar o retângulo). Tente fazer a moldura pequena o suficiente para englobar apenas a região leste da África. Use então a barra de rolagem que aparecerá para deslocar o campo de visão para o leste da África.

A própria janela de mapa pode ser redimensionada movendo-se o cursor sobre qualquer borda da janela até aparecer uma seta, e então arrastando-se a borda até a posição desejada. Você também pode aumentar a janela de mapa e aumentar a legenda (dando um clique duplo na legenda e arrastando a barra de dimensionamento) de forma que as descrições mais longas da legenda possam ser completamente visualizadas e a barra de rolagem horizontal da legenda desapareça.

Observe que assim como eles podem ser dimensionados, os elementos do mapa também podem ser deslocados. Para fazer isso, simplesmente coloque o mouse sobre o elemento em questão e segure o botão esquerdo do mouse acionado enquanto move o mapa para uma nova posição. Mova a janela menor de AFFAOSOL para o canto superior esquerdo da janela de mapa, imediatamente abaixo do título. Desloque a seguir a legenda para o seu lado e torne-a similar em tamanho. Mova a seguir a moldura da janela do mapa para um tamanho confortável suficiente para englobar estes elementos (para fazer isso, mova o cursor do mouse para o limite da janela até você poder enxergar uma das setas de dimensionamento; empurre então a borda para sua nova posição).



Existem momentos em que você, após ter alterado o tamanho da moldura do mapa ou da legenda, não deseja ver as barras de rolagem a elas associadas. Neste caso você pode clicar sobre o ícone de ligar/desligar as barras de rolagem no menu principal. Isso irá alternar entre a visualização e a não visualização das mesmas.

### *Fatores de expansão / Zoom / Janela*

Como você já deve ter deduzido, barras de rolagem anexadas à moldura do mapa aparecem toda vez que esta moldura é pequena demais para conter toda a imagem. O redimensionamento pode ser uma das causas disto acontecer. Isto também pode ocorrer como resultado de uma operação de zoom ou da extração de uma janela ou ainda como resultado do uso de um fator de expansão que faça a imagem ficar maior do que a tela.

- k) Feche qualquer janela de mapa que ainda estiver aberta clicando duas vezes na caixa de controle no canto superior esquerdo de cada janela. Use a seguir o Lançador de visualização para chamar BRAZILFC novamente com a tabela Composição colorida 256, mas desta vez opte por um fator de expansão igual a 2. Note como a barra de rolagem é anexada automaticamente. Note que caso você tivesse tentado reduzir por um fator de dois, teria sido necessário indicar um fator de expansão igual a -2.



- l) Remova BRAZILFC da tela mais uma vez e traga-a novamente com o fator de expansão normal. O fator de expansão normal é automaticamente calculado para ajustar a imagem completa aos limites da tela com o maior tamanho possível. Fatores de expansão diferentes podem resultar da configuração de diferentes resoluções do sistema gráfico no Windows (p. ex. 640x480 Vs 1024x768). Clique então sobre o ícone de zoom (aquele com uma lupa). A seguir, movimente o mouse sobre a imagem BRAZILFC e note como o cursor do mouse altera sua

forma e transforma-se numa lupa. Pressionar o botão esquerdo do mouse fará com a imagem seja expandida enquanto que o botão direito do mouse fará a imagem ser reduzida.

Experimente expandir BRAZILFC clicando o botão esquerdo do mouse. Note como as barras de rolagem aparecem. Note também que a moldura do mapa irá ajustar-se de tal forma que o que era previamente o centro da janela permanece centrado na de novo tamanho. Volte o zoom para o tamanho original.

O processo de zoom tem papel significativo nos recursos de memória do Windows. Com a expansão a imagem é aumentada por duplicação de *pixels*. Assim o consumo de memória aumenta exponencialmente à medida que sucessivas expansões são solicitadas. Como consequência, nós incorporamos algumas rotinas de segurança. A primeira é que a expansão se dá passo a passo. Para prosseguir expandindo a imagem você terá que acionar o ícone de Zoom novamente e repetir a operação. Neste caso será difícil expandir inadvertidamente um número excessivo de vezes. A segunda é que você pode expandir uma imagem no máximo apenas três vezes (embora você possa reduzir um número ilimitado de vezes). Caso você ache necessário um grau maior de expansão, você deverá usar a operação de ampliação de janela descrita a seguir.

A operação de ampliação de janela permite a você selecionar uma sub-área da uma imagem para visualização. Ela irá expandir a sub-área da imagem original automaticamente tanto quanto possível (dentro dos limites do número total de expansões) dentro da área original da moldura do mapa. Quando isso ocorre, apenas essa porção da imagem fica retida na memória (ao contrário do zoom, que retém a imagem inteira na memória).



- m) Tente ampliar uma janela de BRAZILFC. Clique sobre o ícone de ampliação de janela na barra de ferramentas principal (à esquerda do ícone de Zoom). Mova o cursor para o canto superior esquerdo da região que você deseja ampliar a janela, segure o botão esquerdo do mouse acionado e mova o mouse para criar um caixa ao redor da região a ser expandida. Quando você soltar o botão a janela irá aparecer. Observe que você pode maximizar o tamanho da região selecionada expandindo as bordas da janela do mapa e, então, aumentando a moldura do mapa para depois selecionar uma janela do mesmo para ampliar. Para visualizar toda imagem novamente, clique sobre o ícone de ampliação de janela, coloque o cursor sobre a imagem e clique o botão direito do mouse. Feche a janela de mapa BRAZILFC.

### *Outros elementos interativos de visualização*

Mover, redimensionar, expandir/reduzir e ampliar janelas são meios através dos quais você pode interagir diretamente com o sistema de visualização. Existem várias outras ações interativas de visualização que podem ser utilizadas, a maioria delas envolvendo a digitalização na tela e que serão temas cobertos mais tarde. O único elemento adicional que nós precisamos introduzir aqui é o modo de consulta interativa com o cursor do mouse. O processo de composição de mapa será tratado no próximo exercício.

Com o modo de consulta interativa via cursor você pode mover o cursor do mouse até um determinado ponto de uma imagem e solicitar o valor do dado armazenado naquele local.



- n) Para experimentar isso, visualize ETDEM uma vez mais com a tabela de cores Idrisi 256. Clique sobre o ícone do modo de consulta do cursor na barra de ferramentas. Mova a seguir o cursor do mouse para qualquer local e clique com o botão esquerdo do mouse. O valor z discriminado na barra de status inferior indica a altitude neste local. Observe que este modo permanecerá ativo enquanto você estiver com a janela ativa ou clicar o botão de consulta via cursor uma segunda vez. Se a imagem que você está consultando tem categorias de legenda no seu arquivo de documentação, o texto da legenda e o valor z para a localização consultada irá aparecer na barra de status.

A consulta expandida do cursor possibilita o usuário a consultar simultaneamente a mesma localização em várias imagens diferentes que são especificadas em um arquivo de grupo. Isso será melhor discutido e ilustrado no exercício 11 (Exploração de imagens).

### *Visualização de vetor básico*

A discussão feita até agora considerou praticamente apenas imagens raster. Existem, entretanto, pequenas diferenças nos procedimentos no caso de uma visualização na qual o plano de informação básico de informação (i.e., a primeira camada) é um arquivo vetorial. Neste caso a caixa de diálogo do Lançador de visualização se altera para refletir o fato de que há parâmetros diferentes que necessitam ser indicados. Eles incluem:

- o nome do arquivo vetorial
- o arquivo de símbolos a usar
- se ele deve ser ligado a um arquivo de valores
- qualquer componente complementar ao mapa (com legenda, escala, etc.)

A natureza do arquivo de símbolos será explorado mais detalhadamente nos exercícios que seguem. Em resumo, existem arquivos de símbolos distintos para cada tipo de arquivo vetorial (ponto, linha, polígono e texto) e cada um descreve a natureza dos até 256 símbolos que podem ser usados.

Arquivos de valor têm um papel importante no contexto da visualização de arquivos vetoriais. Arquivos vetoriais simplesmente contém as características geográficas de um conjunto de elementos. Normalmente, eles são identificados por números inteiros, com a intenção de ligá-los a um arquivo de valores que contém atributos para estes elementos (juntamente com alguma informação específica na legenda). Entretanto, é possível (embora, na maioria dos casos, não recomendado) considerar os identificadores dos elementos como atributo. Nestes casos, um arquivo de valores não precisaria ser ligado a um arquivo vetor para visualização.

- o) Para ilustrar esta diferença, execute o Lançador de visualização e indique que você deseja visualizar um arquivo vetorial. Especifique então o nome CLARKBLK e que deve ser usado o arquivo de símbolos Idrisi 256 (IDRIS256 é um arquivo de símbolos para polígonos que corresponde ao arquivo tabela de cores IDRIS256 para imagens).

Neste caso, as cores das quadras urbanas são resultado de seus próprios identificadores -- isto é, os identificadores são tratados como se fossem códigos de símbolos. Entretanto, neste caso nós simplesmente queremos ver esta camada de dados como referência geográfica para outra informação a ser mostrada sobre ela. Por este motivo, vamos modificar o arquivo de símbolos associado a este plano de informação.

- p) Clique sobre o botão Propriedades na Composição e mude o arquivo de símbolos a ser usado para IDRPOLY. Este é o nome do arquivo de símbolos pré-definido para polígonos (assim como IDRPTS é o padrão para pontos, IDRLINE é o padrão para linhas e IDRTEXT é o padrão para texto)<sup>17</sup>. O arquivo de símbolo padrão para polígonos consiste de polígonos vazios com uma borda preta para todos os índices de símbolos. Pressione OK. Agora todos os polígonos são tratados identicamente, independente dos seus valores de índices.
- q) Clique agora em Adicionar plano para adicionar um arquivo de nome CLARKBLD, mas neste caso indique que você deseja usar um arquivo de valores chamado BLDGUSE e escolha o arquivo de símbolos Idrisi 16 (este arquivo de símbolos para polígonos corresponde ao arquivo de tabela de cores Idrisi 16 para imagens). Indique também que você deseja uma legenda e clique OK. Use então Adicionar plano mais uma vez para adicionar o plano de informação

---

<sup>17</sup> Cada opção de arquivo de tabela de cores e de símbolos na caixa de diálogo possui um arquivo correspondente que pode ser selecionado da lista de arquivos. Idrisi 256 e Qualitativa 16 na caixa de diálogo, por exemplo, correspondem aos arquivos Idris256 e qual16 na lista de arquivos.

denominado CLARKBD2, usando o arquivo de símbolo padrão. Isto simplesmente acrescenta linhas pretas em torno de cada edificação. Caso a janela da composição estiver ocultando parte da sua visualização, ative a janela de mapa para trazê-la para a frente.

Perceba como as cores dos edifícios não possuem significado. Neste caso não estamos considerando os identificadores e sim os atributos que estes elementos possuem.

4. Agora que observamos a visualização de um arquivo vetorial, como você compararia a maneira pela qual a visualização é mostrada em relação a um arquivo raster? Por que isso acontece?

### *Visualização de relevo em perspectiva e imagens de cobertura*

Todos os mapas que produzimos até agora têm tido a visão ortogonal tradicional (i.e., nós os olhamos verticalmente sobre o mapa). Entretanto, o IDRISI for Windows também oferece a possibilidade de mostrar dados em perspectiva. O módulo que cria estas visualizações é ORTHO (uma abreviação do termo *ortographic* - ortográfico), porque o tipo de perspectiva utilizado é conhecido como *ortographic perspective* - perspectiva ortográfica).

ORTHO trabalha tomando informações de uma ou duas imagens que se deseja visualizar em perspectiva para criar um nova imagem raster que contenha essa visão em perspectiva. Entretanto, como se assume que você deseja visualizar o resultado imediatamente, o Lançador de visualização é automaticamente chamado para permitir que você faça isso. Como consequência, ele também perguntará a você a tabela de cores a usar, assim como os parâmetros da perspectiva.

Como já foi mencionado, ORTHO solicitará informações acerca de uma ou de *duas* imagens. A primeira imagem é a que contém os dados de elevação e é a que será mostrada em perspectiva. Esta é uma imagem raster comumente conhecida como *Digital Elevation Model* - Modelo Digital de Elevação (DEM), que pode conter qualquer tipo de número (byte, inteiro ou real) e não necessariamente representar dados de altitude. A segunda imagem é opcional e é chamada de imagem de cobertura. A imagem de cobertura é uma imagem que nós colocamos sobre o modelo de elevação. Pode ser uma imagem de satélite, por exemplo, ou talvez um mapa de cobertura do solo. Deve ser uma imagem em formato byte binário e, por isso, você necessita prepará-la previamente antes de poder sobrepô-la ao DEM (esse tópico é tratado em maior profundidade no Exercício 4).



- r) Feche as janelas que você ainda tiver abertas e execute ORTHO. Você pode fazer isso a partir do menu Visualização ou clicando sobre o ícone correspondente, ilustrado à esquerda. Indique o nome RELIEF como o nome do DEM e indique que o arquivo de saída deve ser denominado PERS1. Clique simplesmente OK. para aceitar todas as indicações-padrão. Como você provavelmente já deve ter percebido, os módulos do IDRISI for Windows sempre possuem um conjunto de parâmetros pré-definidos.

Você provavelmente também percebeu que o Lançador de visualização é chamado no processo de criação da visualização. Como resultado, a imagem que nós vemos pode ser examinada novamente em um momento posterior simplesmente usando o Lançador de visualização. Neste caso, uma tabela de cores especial chamada BW foi usada. Esta tabela colore os valores 0 de branco e qualquer outro valor é colorido de preto.

Sem uma imagem de cobertura, o resultado visual do ORTHO fica melhor se existir algum espaço entre as linhas dos perfis (i.e., entre as linhas). Este espaço, entretanto, irá depender de dois fatores: o número de linhas na imagem e a resolução com que a imagem é produzida. Nós usamos a resolução mais baixa,

mas poderíamos ter aumentado o espaço usando uma resolução maior<sup>18</sup>. A melhor maneira para apreciar estas diferenças é fazer alguns exemplos.

- s) No caso de usar-se uma imagem de cobertura, a imagem ortográfica irá funcionar melhor se o espaço entre os perfis for eliminado. Como exemplo de uma imagem de cobertura, execute ORTHO novamente e especifique a imagem de entrada como NJOLODEM. Este é um DEM para a região de Njolomole no Malawi. Indique então que você deseja uma imagem de cobertura e especifique seu nome como NJOLOFC. Esta é uma composição colorida em falsa cor de uma imagem multiespectral SPOT. Chame a imagem a ser produzida de PERS2. Modifique a direção de visão para 10 graus e especifique que deverá ser usada a tabela de cores Composição colorida 256. Especifique então uma resolução de saída imediatamente inferior à de seu monitor (p.ex. para uma tela de 1024×768, especifique 800×600) - isto produzirá a maior visualização que couber em sua tela. Clique a seguir OK para ver o resultado.
5. Usando qualquer uma das seqüências do ORTHO que você acabou de experimentar, tente alterar o ângulo de visão e o fator de exagero vertical (um intervalo útil oscila entre 0,5 e 2,0). Como você caracterizaria a ação destes dois parâmetros?
- t) Como consideração final sobre o ORTHO, o uso de uma imagem de cobertura pode realçar sensivelmente o impacto visual da sua imagem em perspectiva. Use o Lançador de visualização para examinar uma imagem chamada AFSURF usando a tabela Tons de cinza 16. Esta imagem foi criada com ORTHO e usa uma imagem de cobertura que foi criada usando a opção sombreamento analítico do módulo SURFACE. Com a opção de sombreamento analítico de SURFACE você pode indicar a direção e a altura angular do Sol para o programa determinar a quantidade de iluminação em cada ponto da superfície. Como você vê, ele é capaz de produzir modelos do relevo muito bons. Você também pode querer explorar o módulo ILLUMINATE para a criação de imagens de cobertura. Ele possibilita combinar os efeitos do sombreamento analítico do relevo com a tabela de cores de uma imagem. Você pode fechar agora a janela de mapa AFSURF.

### *Preferências de visualização*

Neste exercício, você irá ver como visualizar planos de informação com uma tabela de cores ou arquivo de símbolos específico, elementos do mapa como títulos e legendas, além de outros. É possível configurar certos parâmetros de visualização de forma que eles se tornem a sua configuração padrão. Por exemplo, você pode achar que na maioria das vezes gostaria de ter um título exibido na visualização e também usualmente gostaria de usar uma tabela de cores específica criada por você. Você pode configurar as Preferências de visualização de forma que a exibição do título e a tabela de cores criada por você sejam utilizadas como padrão do sistema.

- v) Para fazer isso, vá para o menu Visualização e escolha Preferências de visualização. Na base da tela das Preferências de visualização, clique na caixa de diálogo de Tabela de cores padrão e selecione a tabela chamada RO. Pressione OK.
- w) Agora use o Lançador de Visualização para examinar a imagem ETDEM. Observe que a tabela de cores RO já está especificada na caixa de diálogo e que o título também já está selecionado. Pressione OK. Esses parâmetros padrão de visualização serão adotados automaticamente até que você mude as configurações nas Preferências de visualização.
- x) Retorne para Preferências de visualização e redefina os parâmetros pressionando o botão Padrões do sistema.

---

<sup>18</sup> Nos casos em que você percebe que as possibilidades de resolução oferecidas não oferecem alcance suficiente para aumentar ou diminuir o espaço entre os perfis, você pode usar CONTRACT para encolher a imagem (aumentando assim a distância) ou RESAMPLE para interpolar uma imagem com maior resolução.

Nós iremos discutir as duas opções de Preferências de visualização acima nos próximos exercícios. A visualização automática de resultados analíticos será ilustrada no exercício 5 e a consulta estendida do cursor será ilustrada no exercício 11.

Isto completa este exercício. Você pode excluir PERS1 e PERS2 e qualquer outra imagem ORTHO que você eventualmente produziu até aqui. Para fazer isso, use a opção Excluir da Manutenção de arquivos a partir do menu Arquivo.





### **3. Composição de mapas**

O exercício anterior deu uma noção das possibilidades que o sistema de visualização do IDRISI for Windows oferece. Neste exercício exploraremos de forma mais completa a natureza do processo de composição de mapas e as formas como as composições de mapas podem ser gravadas, visualizadas e impressas.

- a) Limpe sua tela de todas as janelas de mapas que possam estar abertas. Use então o Lançador de visualização para visualizar uma imagem chamada WESTBORO. Use a tabela de cores definida pelo usuário chamada WESTBORO. Além disso, especifique que você deseja ver uma legenda e um título.

Esta é uma imagem de uso /cobertura do solo de Westboro em 1985. Utilizaremos esta imagem como um plano básico para uma composição com múltiplos planos que incluem informações de rios e estradas, assim como alguns textos e uma variedade de componentes acessórios do mapa.

- b) Pressione a opção Adicionar plano da Composição e adicione o arquivo vetorial chamado WESTLULC usando o arquivo de símbolos padrão (IDRLINE). Este é simplesmente um arquivo com os limites dos polígonos para fornecer um limite nítido para o mapa.
- c) Agora pressione a caixa Propriedades da Composição. Escolha o botão Modificar componentes. Isto vai gerar uma nova caixa de diálogo, que também pode ser chamada pelo Lançador de visualização, para facilitar a adição de componentes marginais do mapa. Caso você ainda não tenha feito isto, é sensato ler o tópico de Ajuda desta caixa de diálogo.
- d) Usando o guia gráfico para componentes do mapa, pressione a opção Título e modifique o título para que ele fique em negrito, itálico e em azul escuro. Você pode deixar todos os outros ajustes com seus valores correntes. Escolha a opção Texto e ajuste-a para ser visível clicando na caixa Quadro de texto visível. Indique que o nome do arquivo de texto é WESTBORO ou selecione WESTBORO.TXT da lista de arquivos (quando uma extensão não é indicada é automaticamente assumida a extensão “.txt”). Escolha também a cor azul escuro para o texto. Novamente, você deve deixar os outros ajustes com seus valores correntes. Selecione as opções Barra de escala e Seta Norte e ajuste-as para serem visíveis na composição clicando respectivamente nas caixas Escala visível e Norte visível.. A seguir, selecione a opção Logotipo, clique em Logotipo visível e escolha o nome de arquivo MASSGIS.WMF. Pressione OK.

É normal a necessidade de algum rearranjo dos componentes marginais do mapa. Neste caso, a forma irregular dos limites oferece várias oportunidades para a colocação dos componentes do mapa sem que o tamanho do mapa tenha de ser aumentado. Você pode tentar o seguinte:

- mova a seta de norte para o espaço livre no canto inferior esquerdo (lembre-se que para mover um objeto você só precisa colocar o cursor do mouse sobre ele e manter acionada o botão esquerdo enquanto o estiver movendo).
  - redimensione o logotipo para torná-lo tão largo quanto a legenda e com uma altura que faça com que as letras tenham uma proporção adequada. Para fazer isto, pressione duas vezes o logotipo e mova as barras de dimensionamento. Mova-o para uma posição logo abaixo da legenda.
  - redimensione a moldura de texto (um duplo clique sobre a mesma, seguido do arraste das barras de dimensionamento) para uma largura tal que na primeira linha se possa ler “Land use/Land cover data interpreted from 1:40,000”. Dimensione a altura para que todo o texto encaixe. Coloque a moldura de texto no canto inferior direito.
- e) Em seguida selecione Adicionar plano e adicione o arquivo vetorial WESTSTRM usando o arquivo de símbolos chamado BLUE. Como o nome sugere, o arquivo de símbolos BLUE ajusta todos os símbolos para linhas azuis.
- f) Agora vamos adicionar o plano de estradas. Aqui nós usaremos um truque para criar um estilo de linha que não está no repertório do Windows -- um estilo de linha dupla com o centro preenchido (este estilo é normalmente conhecido no contexto de cartografia como *road casings*). Para fazer isso nós iremos, na verdade, desenhar duas linhas -- uma linha preta com três *pixels* de largura e outra linha centralizada sobre ela, como um preenchimento colorido (neste caso, branco) com um *pixel* de largura. Os dois arquivos de vetores são chamados WESTRDS e WESTRDS2. Use Adicionar plano para adicionar o primeiro com o arquivo de símbolos chamado BLAKMASK e, a seguir, use Adicionar plano novamente para adicionar o segundo com o arquivo de símbolos chamado WHITE.
- g) Agora adicione o plano final - o plano de texto chamado WESTTEXT. Para isso você deve usar o arquivo de símbolos de mesmo nome (WESTTEXT). Note que uma barra de rolagem aparece agora na Composição, já que há mais planos do que podem ser ajustados em sua lista. A Composição permitirá até 16 planos simultâneos em uma única composição, mas, como você pode ver, apenas seis planos já fornecem muitos detalhes.
- h) A composição está pronta. Tenha certeza de que todos os elementos estão arranjados da forma que você quer e, então, grave a composição usando a opção Salvar composição na janela de Composição. Escolha a sub-opção adequada para salvar como um arquivo MAP e grave ele com o nome WESTMAP.
- i) Agora remova a janela do mapa e acione o Lançador de visualização. Escolha Composição de mapa como o tipo de arquivo a visualizar e especifique WESTMAP. Você deve ver sua composição reaparecer.

Note que, ao contrário de uma captura de tela, o processo de composição de mapas recria completamente a composição usando seus planos componentes. Como resultado, você pode continuar a elaborar uma composição a partir do ponto em que parou. É importante ressaltar que o arquivo de composição de mapa WESTMAP que você acabou de criar contém todas as instruções para efetuar a visualização da composição, mas não contém os arquivos de planos de informação, tabelas de cores e arquivos de símbolos usados na composição. Eles permanecem como arquivos independentes no nosso diretório de dados e são chamados pela composição de mapa quando você quiser visualizá-la. Se você estiver movendo ou copiando sua composição de mapa, você precisa mover ou copiar o arquivo de composição de mapa propriamente dito e todos os arquivos que compõem essa composição. DESCRIBE pode ser usado para ver uma listagem de todos os arquivos usados em uma composição de mapa.

- j) Escolha Descrever a partir do menu Arquivo, atione a opção Composição de mapa e selecione WESTMAP. É possível que seja necessário usar a barra de rolagem vertical para ver a lista completa de todos os arquivos usados na composição WESTMAP. Após examinar a lista, feche a janela de DESCRIBE.

Uma das características importantes do sistema de Composição é que a tela não é estática. Você pode não apenas mover os elementos, mas também escondê-los temporariamente. Para esconder um plano, clique na caixa à esquerda do nome desse plano na lista de arquivos da Composição. Isso fará com que ele desapareça. Clicando novamente na caixa o plano reaparece.

- k) Tente isto com um dos planos. Clique para fazê-lo desaparecer e reaparecer.

Por definição, a Composição trabalha em modo Automático, significando que ele implementa uma mudança assim que ela é especificada. No modo Manual ele armazena as modificações, mas não as implementa até que o botão Refazer seja clicado. Se você tiver um conjunto de modificações a fazer pode ser mais eficiente mudar para o modo Manual.

- l) Para fazer isto, pressione o botão na parte superior da Composição para mudar para o modo Manual. Pressione nas caixas de exibir/omitir de todos os planos, exceto para o plano base (na verdade, não é possível remover o plano base). Você irá perceber que nada acontece. Então pressione o botão Refazer e perceba como todos eles desaparecem. Clique em todos os planos novamente e em Refazer.

Você pode achar o modo manual muito útil em casos onde você tem vários planos altamente detalhados que levam um longo tempo para serem redesenhados e você está envolvido com uma operação que exige muito movimento de molduras de planos (como ampliação, preparação de janelas ou digitalização). Nestes casos, é útil clicar no modo manual, fazendo desaparecer os planos, e continuar a operação.

Com o modo Manual, sempre que caixa de diálogo ou janela de mapa cobrir a composição, qualquer plano vetorial que ficar abaixo da mesma irá desaparecer até que Refazer seja pressionado. Para evitar isso, há um terceiro modo na Composição, o modo Congelar. Esse modo congela a janela de mapa exatamente como ela aparece quando o botão Congelar for pressionado. Entretanto, os elementos do mapa não podem ser movidos e as funções interativas do sistema de visualização, como o zoom e a consulta do cursor, são desligadas.

Abaixo seguem algumas sugestões sobre o uso dos modos de exibição da Composição.

- Para composições simples, use o modo Auto. Este é o modo mais fácil, e possibilita acesso completo ao sistema de Composição.
- Para composições complexas, use o modo Manual. Isso evitará repetições necessárias na exibição dos planos de informação enquanto você faz ajustes. Uma vez concluída a composição, mantenha em modo Manual e pressione o botão Refazer, ou o botão Congelar quando a visualização estiver exatamente como você deseja.
- Em casos em que você tiver muitas janelas de mapa abertas, cada uma com vários planos de informação vetoriais, congele cada uma das janelas de mapa com as quais você não necessita interagir com frequência. Isto previne o Windows de redesenhar arquivos vetoriais complexos sempre que uma caixa de diálogo for removida.
- Mudar os modos de exibição é rápido. Esteja livre para mudar o modo de exibição de uma janela de mapa tantas vezes quantas você julgar necessário.

Finalmente, agora que você montou e salvou sua composição, você pode imprimí-la. A impressão no IDRISI for Windows é feita através da Oficina de Impressão, acessível no menu Arquivo. Se você tiver uma impressora compatível com Windows no seu computador pode tentar fazer o seguinte:

- m) Escolha Oficina de impressão a partir do menu Arquivo e selecione WESTMAP como a composição a imprimir.

As margens padrão estão configuradas no limite da área de impressão para a impressora específica. A Oficina de impressão automaticamente faz sua composição tão grande quanto o possível e coloca-a centrada entre as margens. O gráfico mostra como sua composição de mapa (área em preto) se ajusta na página e onde sua janela de mapa (retângulo amarelo) está posicionada na composição de mapa. A extensão da janela no terreno fornece a distância em metros coberta pela largura da janela de mapa da composição. Isso é calculado usando informação do arquivo de documentação do plano de informação.

- n) Mude todas as margens para uma polegada. Uma mensagem de erro a respeito da escala irá aparecer quando você mudar a primeira margem. Limpe essa mensagem pressionando OK e então configure as demais margens para uma polegada. Agora pressione o botão Escala máxima e veja que a escala muda.

A escala é a relação entre uma distância medida no mapa e a mesma distância no terreno. Uma escala de 1:200.000, por exemplo, quer dizer que uma unidade no mapa (polegada, p. ex.) representa uma distância de 200.000 destas mesmas unidades no terreno. A Oficina de impressão possibilita a você imprimir seu mapa em uma escala específica.

- o) Arredonde a porção da escala referente às unidades no terreno para o múltiplo mais próximo de 100.000, e então pressione o botão Testar escala fixa para ver como isso afeta a composição de mapa na página. Para retornar ao máximo tamanho possível do mapa dentro das margens especificadas pressione o botão Escala máxima.

1. Porque você não pode entrar um valor de escala maior que a “Escala máxima” padrão já fornecida pela Oficina de impressão?

- p) Para obter uma visualização da impressão de sua composição na página, pressione o botão Visualizar. Feche a visualização de impressão e imprima sua composição pressionando o botão Imprimir.

Isso conclui nossa exploração sobre composições de mapas. Se você quiser, pode excluir todos os arquivos que foram criados durante este exercício.

## 4. Tabelas de cores, símbolos e autoescalamento

Nos exercícios anteriores usamos vários arquivos de tabelas de cores e de símbolos sem pensar muito em como elas foram criadas. Neste exercício iremos usar a Oficina de tabelas de cores e a Oficina de símbolos e investigar o fenômeno do autoescalamento.

- a) Acione o Lançador de visualização e escolha a imagem ETDEM com a tabela de cores padrão Idrisi 256. Embora a tabela de cores padrão funcione bem na visualização de dados muito diferenciados, ela nem sempre funciona de forma tão agradável. Como resultado, exploraremos o uso da Oficina de tabelas de cores para criar uma nova tabela de cores para esta imagem.

### *Oficina de tabelas de cores*



A Oficina de tabelas de cores tem várias outras características além das que iremos explorar aqui. Por isso, você deve ler as informações da Ajuda deste módulo para um tratamento mais aprofundado do assunto. No entanto, existem vários conceitos e comandos principais que devem ser revisados antes de começarmos a trabalhar com a Oficina de tabelas de cores:

- Uma tabela de cores consiste da definição da cor para até 256 cores, numeradas com índices de 0 a 255. As caixas no formulário mostram 16 destas cores por vez. Você pode navegar por todos os índices, 16 por vez, usando o botão de rolagem no lado direito das caixas de cores ou pressionando as teclas PgUp/PgDn. Para mudar a cor referente a qualquer um destes índices você deve primeiro clicar na caixa correspondente ao índice.
- As cores são definidas em termos de mistura das cores primárias vermelho, verde e azul necessárias para produzir a cor desejada. Este é um sistema aditivo primário (RGB) que exige algum esforço para aprender a usá-lo. Por exemplo, misturando-se vermelho e verde produz-se amarelo e misturando-se todas as três cores na mesma quantidade produz-se algumas formas de cinza, branco ou preto, dependendo das quantidades (quanto mais das três cores, mais claro). A quantidade de cada cor primária é medida por unidades que vão de 0 (ausência) até 255 (máximo). Você usa as barras de rolagem das cores para produzir estas misturas.
- Uma função extremamente útil ao desenvolvimento de tabelas de cores para dados quantitativos é a função Misturar. Para usá-la, defina as duas cores para os dois extremos de uma seqüência.

Depois, especifique estes índices como as âncoras superior e inferior na função de mistura da tabela e pressione o botão Misturar. Isto fará com que a Oficina de tabelas de cores interpole os valores intermediários para todas as caixas entre as duas cores-âncora.

- A faixa de autoescalonamento define a faixa de cores que será usada quando a imagem é autoescalada (você verá mais sobre isso no próximo exercício).
  - Caso você escolha reverter a tabela de cores, somente as cores dentro da faixa de autoescalonamento serão revertidas. Se você quiser reverter cores fora da faixa, mude temporariamente a faixa de autoescalonamento conforme for necessário.
- b) Feche a janela do mapa ETDEM. Pressione o ícone da Oficina de tabelas de cores. O ícone é aquele que se parece com um arco-íris. Quando a caixa de diálogo da Oficina de tabelas de cores é mostrada ela está automaticamente ajustada para iniciar a definição de uma nova tabela de cores. Definiremos uma tabela de cores de 16 cores simplesmente porque será mais fácil de ver o que acontece.

Para ilustrar o uso da função Misturar, vá até a caixa da cor número 1 e selecione-a. Use as barras de rolagem e mova o botão do vermelho para a quantidade máxima. Isto irá produzir uma cor vermelha na caixa da cor 1. Vá para a cor 15 e mova o botão azul para o valor máximo. Agora vá para a área da Função de mistura da tabela e especifique os pontos de âncora como sendo 1 (Valor mínimo) e 15 (Valor máximo), e pressione então o botão Misturar<sup>19</sup>.

1. Descreva a natureza das cores produzidas através desta mistura.

A função Misturar funciona muito bem, mas em muitos casos é necessário ter várias séries diferentes de misturas para obter a seqüência de cores necessária. Neste caso nós usaremos a função Misturar, porém com dois pontos intermediários. Além disso, nós definiremos a primeira e a última cor separadamente.

- c) A primeira cor que queremos definir é a cor 0, que será preta. Felizmente, ela já é assim por definição, de forma que podemos selecionar diretamente a cor 1. Clique na caixa número 1 e use os botões de rolagem para ajustar um RGB de 136 222 64. Clique na caixa 3 e use as barras de rolagem para ajustar em RGB 255 232 123. Agora use a função de mistura para misturar as cores 1 a 3. Isso irá interpolar um valor para a cor 2.

Agora selecione a cor 7 e ajuste os valores para RGB 255 188 76 e misture as cores entre 3 e 7. Após isso, selecione a cor 14 e ajuste um RGB de 180 255 255. Misture as cores entre 7 e 14. Finalmente ajuste a cor 15 para 255 255 255.

- d) Agora que estabelecemos nossa tabela de cores, precisamos ter certeza que a faixa de autoescalonamento está ajustada apropriadamente. Como temos cores definidas somente para índices entre 0 e 15, ajuste o mínimo e o máximo de Autoescalonar limites respectivamente para 0 e 15.
- e) Finalmente, podemos gravar nossa tabela de cores. Escolha a opção Salvar como... no menu Arquivo da Oficina de tabelas de cores e denomine o resultado de TERRAIN. Você pode usar as opções padrão de gravação para ter a tabela de cores salva como um arquivo “.smp” do IDRISI for Windows em seu diretório de trabalho<sup>20</sup>. Depois de salvar a tabela de cores feche a Oficina de tabelas de cores.

---

<sup>19</sup> Ao invés de escrever o número de cada cor âncora para a mistura, você pode selecionar a caixa da primeira cor da mistura e clicar duas vezes na caixa de diálogo da primeira âncora (Valor mínimo). Após, faça o mesmo para a segunda âncora (Valor máximo).

<sup>20</sup> As tabelas de cores também podem ser salvas no diretório do programa IDRISI for Windows. Neste caso elas são consideradas parte da biblioteca permanente e não de um projeto específico. Na busca por tabelas de cores, o IDRISI for Windows sempre pesquisa nos dois diretórios.

- f) Agora acione o Lançador de visualização e visualize a imagem chamada ETDEM, mas desta vez use a tabela de cores TERRAIN.

### Oficina de símbolos

- g) A próxima tarefa que faremos é adicionar um arquivo vetorial com as linhas dos limites das províncias à imagem de elevações. Use Adicionar plano na Composição e adicione o arquivo chamado ETPROV com o arquivo padrão de símbolos. Como você pode ver, a linha padrão (fina, inteira e preta) é muito escura para a delicada tabela de cores que nós criamos. Por isso, vamos criar um novo arquivo de símbolos usando linhas cinza.



- h) Acione a Oficina de símbolos através do sistema de menus ou clicando em seu ícone (ao lado do ícone da Oficina de tabelas de cores). A Oficina de símbolos está automaticamente ajustada para criar um arquivo de linhas. Ela usa uma lógica similar à Oficina de tabelas de cores, porém com mais opções.

Como não conhecemos muito sobre a natureza dos identificadores para os limites das províncias e queremos que todos os limites sejam semelhantes, o procedimento mais fácil é criar um arquivo de símbolos de linhas no qual todas as 256 símbolos descritos sejam iguais. A forma mais fácil de fazer isso é criar um símbolo e copiá-lo para todos os outros.

- i) Selecione o símbolo de linha 0. Mude sua mistura de cores RGB para 127 127 127 (cinza médio). Ele já deve estar ajustado para ser uma linha sólida de 1 *pixel* de largura (se não estiver, mude-o para tal). Use a função Copiar símbolo para aplicar esta definição para todos os símbolos de 1 a 255. Escolha a opção Salvar como... do menu Arquivo e salve o arquivo como GREY (use a opção padrão para salvar no diretório de trabalho). Feche a Oficina de Símbolos.
- j) Agora selecione ETPROV na lista da Composição e pressione em seguida o botão Propriedades. Mude então o arquivo de símbolos para aquele que você recém criou (GREY).

Para completar nosso mapa, vamos adicionar os nomes das províncias como um plano de texto.

### Criando planos de texto e arquivos de símbolos de texto

Planos de texto são uma característica nova no IDRISI for Windows e merecem atenção especial por causa da maneira pela qual são criados. Um plano de texto consiste de dois arquivos básicos de dados (mais seus arquivos de documentação, totalizando quatro arquivos) -- um arquivo vetorial de pontos modificado indica a localização dos caracteres de texto e um arquivo de banco de dados associado contém os caracteres de texto e seus códigos de símbolos. Estes códigos de símbolos são, por sua vez, ligados ao arquivo de símbolos de texto.

Nós queremos primeiro introduzir os passos do processo para depois procedermos à criação de nosso plano de texto com os nomes das províncias. Os passos na criação de um plano de texto são os seguintes (não tente executá-los, o texto dos itens a seguir isto é apenas uma explicação):

- Criar um arquivo vetorial de pontos para a localização dos símbolos.
- Acionar a Oficina de banco de dados e selecionar a opção para criar um plano de texto no menu Arquivo. A Oficina de banco de dados perguntará pelo nome do arquivo de pontos e por um nome para o próximo arquivo a criar (o nome pode ser o mesmo, se você quiser).



- O banco de dados recém-criado irá conter três campos (colunas) -- um com os identificadores dos pontos digitalizados chamado IDR\_ID, um com o nome do arquivo de texto, seguido de um sufixo “\_SYM”, e um terceiro com o nome do arquivo de texto seguido de um sufixo “\_TEXT”. O primeiro estará ajustado para o 0 (padrão) e o último estará em branco. Sua próxima tarefa será entrar com os caracteres de texto no campo \_TEXT e o código dos símbolos no campo \_SYM. Já que a Oficina de banco de dados sempre salva seus dados para o disco, você pode terminar este passo simplesmente saindo deste módulo.

No final desse processo você irá ter os seguintes arquivos que são parte do plano de texto: um arquivo “.vec” com uma estrutura de arquivo de pontos, um arquivo de documentação “.dvc” que lista o tipo de objeto geográfico como “texto”, um arquivo de banco de dados “.mdb” com o mesmo nome do arquivo vetorial, contendo os três campos especialmente projetados (você pode adicionar outros campos se quiser), e um arquivo de documentação “.dvl” para os valores dos atributos no arquivo do banco de dados.

O exercício 10 trata especificamente das muitas características da Oficina de banco de dados. Todavia, por enquanto, esta operação é suficientemente simples para que nós possamos usá-la com uma pequena introdução.

Para digitalizar as posições para os textos, tenha certeza de que o mapa ETDEM esteja na tela com o plano dos limites ETPROV. A lógica que vamos usar é digitalizar um único ponto no centro de cada província. Depois iremos centralizar o texto neste ponto (na verdade, já que iremos centralizar o texto em cada região, você provavelmente desejará colocar cada ponto no centro da região mais larga de cada província).

Antes de iniciar o processo de digitalização, perceba que se você iniciar na província mais ao norte e mover no sentido horário ao redor do limite, você poderá contar 11 províncias, com duas delas no interior do mapa -- uma ao norte e outra ao sul. Esta é a ordem pela qual nós vamos digitalizar: número 1 para a província mais ao norte (no limite), número 2 para aquela na borda seguindo no sentido horário e assim por diante, finalizando com o número 13 para a província no meio e mais ao sul.



- k) Para iniciar a digitalizar certifique-se de que a janela de mapa está ativa e pressione o botão DIGITIZE na barra de ferramentas. Você será solicitado a fornecer um nome para o arquivo a ser criado e o seu tipo. Escolha a opção de arquivo de pontos e especifique o nome como PROVTEXT. Você deve também usar a opção padrão para iniciar com uma ID (identidade) de 1 e com incremento de 1.



Agora digitalize os pontos movimentando o cursor para o centro da região mais larga de cada província e clicando no botão da esquerda do mouse. Mova de uma província para outra no sentido horário, finalizando com as duas províncias centrais (por primeiro a mais ao norte e, por último, a mais ao sul). Se você cometer um erro é possível excluir a última feição digitalizada pressionando o botão de Excluir feições digitalizadas (o botão com um “X”), e então siga digitalizando como antes. Quando você tiver terminado, pressione o botão direito do mouse.



Agora pressione o botão salvar (aquele com uma seta curvada para baixo). Quando você tiver completado e gravado seus pontos, você notará que eles aparecem como símbolos de pontos na tela.



- l) Acione a Oficina de banco de dados. Ela pode ser encontrada em diversos locais no sistema de menus ou pode ser acessada através de seu ícone na barra de ferramentas, como ilustrado ao lado.

Uma vez carregada a Oficina de banco de dados estiver, escolha a opção Arquivo do menu do banco de dados para criar um plano vetorial de texto. Isto irá fazer surgir uma nova caixa de diálogo na qual você precisará entrar com o nome do arquivo vetorial de pontos que você digitalizou e o nome para o arquivo de texto a ser criado. Neste caso usaremos o mesmo nome

para o arquivo de saída e o de entrada: PROVTEXT (quando você clicar em OK, será perguntado se você realmente quer fazer isso -- selecione "Sim").

Quando terminar, use a opção Abrir do menu Arquivo para abrir o arquivo de banco de dados recém criado (ele também será chamado PROVTEXT). Você notará que ele contém três campos: IDR\_ID, PROVTEXT\_SYM e PROVTEXT\_TEXT. Usando o mouse ou as teclas de setas, coloque um "1" (sem as aspas) em cada uma das células de PROVTEXT\_SYM (indicando que todos usarão o símbolo com o código 1). Depois entre com os seguintes nomes para as províncias (em ordem, de 1 a 13) no campo PROVTEXT\_TEXT:

Tigray  
Welo  
Harerge  
Bale  
Sidamo  
Gamo Gofa  
Kefa  
Ilubabor  
Welega  
Gojam  
Gonder  
Shewa  
Arsi

O plano de texto foi criado. Você pode agora salvar o banco de dados usando a opção Salvar banco de dados do menu Arquivo da Oficina de banco de dados, ou simplesmente saindo da Oficina de banco de dados e respondendo "Sim" quando perguntado se deseja salvar as alterações.

- m) Agora que o arquivo de texto está finalizado, é necessário criar um arquivo de símbolos para ele. Acione a Oficina de símbolos e escolha a opção Novo no menu Arquivo. Indique que o novo arquivo será um arquivo de símbolos de texto chamado PROVTEXT (novamente usaremos o mesmo nome, embora neste caso seja somente para facilitar a identificação). Será apresentada então uma caixa de diálogo modificada para a especificação de símbolos de texto.

Selecione o índice 1 na caixa de símbolos. Use então os comandos para fazer as seguintes modificações:

- ajuste a fonte para *Times New Roman*
- ajuste o tamanho para 10 pontos<sup>21</sup>
- ajuste a forma para negrito itálico
- ajuste o alinhamento em X para 50
- ajuste o alinhamento em Y para 50
- ajuste o RGB para 127 0 0 (vermelho médio).

Então escolha a opção Salvar do menu Arquivo para salvar este arquivo. Feche em seguida a Oficina de símbolos.

O IDRISI for Windows é capaz de mostrar qualquer fonte *True Type* ou PostScript. No entanto, você deve estar consciente de que quando o tamanho é inferior a 6 pontos o Windows usa um procedimento especial para desenhar o texto na tela, o que fará com que todas as fontes tenham uma aparência similar. A propriedade de alinhamento diz respeito a como o texto é posicionado em relação ao seu ponto de localização. Se imaginarmos um retângulo delimitando os caracteres do texto, o processo de alinhamento pode ser comparado a colocar um alfinete atravessando esse retângulo em uma posição especificada (o ponto de justificação) e mover o alfinete para o ponto de localização. As coordenadas de

<sup>21</sup> O ponto é uma medida especial usada para letras. Existem 72 pontos em uma polegada e 28,35 pontos em um centímetro.

alinhamento 0,0 colocam o ponto de justificação no canto inferior esquerdo dos caracteres do texto. Da mesma forma, as coordenadas de alinhamento 100,100 colocam o ponto de justificação no canto superior direito. No nosso caso colocaremos o ponto de justificação em 50,50, que é o centro do conjunto de caracteres do texto. Como nossos pontos de localização estão no centro de cada província, o texto deve ficar centralizado dentro de cada província.

- n) Agora olhe o resultado usando o botão Adicionar plano da Composição para acrescentar o arquivo de texto chamado PROVTEXT, usando o arquivo de símbolos também chamado PROVTEXT.
  - o) Você notará que todos os textos estão centralizados, como era esperado. No entanto, um deles (Gamo Gofa) é muito longo para ser ajustado dentro dos limites da província. Use a Oficina de banco de dados para mudar o código do símbolo para esta província para 2 e, então, use a Oficina de símbolos para mudar a especificação do símbolo 2 para ser o mesmo que o símbolo 1, exceto pelo tamanho, diminuindo-o o suficiente para encaixar o texto dentro dos limites da província.
2. Que tamanho você necessita estabelecer para o símbolo 2 de forma a fazer o texto encaixar bem?

### *Autoescalamento*

No caso dos símbolos de texto e de linhas está bem clara a maneira como é dada uma apresentação gráfica específica. Se o elemento tem um atributo 2 ele é desenhado com o símbolo 2. Assim, quando criamos gráficos envolvendo arquivos vetoriais, os valores dos atributos mostrados são na realidade códigos de símbolos no intervalo de 0 a 255. No entanto, os valores nem sempre estão nesse intervalo (por exemplo, representação de população). Como conseqüência, necessitaríamos empreender um passo analítico para produzir um conjunto de códigos de símbolos para esses dados antes de visualizá-los (por exemplo, adequar a representação da população dentro de um intervalo de, no máximo, 256 classes de população).

A mesma lógica aplica-se a imagens rasterizadas. Caso uma célula contenha um valor de 6, a ela é dada a cor 6 da tabela de cores de cores. No entanto, no caso que temos na tela, sabemos que os valores caem bem fora do intervalo permissível para os índices da tabela de cores (0-255). Sabemos que as células contêm alturas e que essas alturas são, em alguns casos, maiores que 4.200 metros. Nada foi feito, ainda, para modificar esta imagem e, mesmo assim, esses valores caíram em uma faixa de 0-255... ou assim parece.

Você pode não ter notado, mas quando você carregou ETDEM, o Lançador de visualização automaticamente acionou a propriedade *autoescalamento*. Como o nome sugere, autoescalamento é um procedimento automático para adequar os valores dos dados a uma faixa possível para o enquadramento gráfico. A faixa especificada dependerá da tabela de cores usada e de como estão ajustados os seus valores mínimo e máximo para o autoescalamento. Em nosso caso, nós definimos o autoescalamento com um mínimo de 0 e um máximo de 15. Como conseqüência, cada altura foi ajustada para produzir um número índice dentro desta faixa. Se a altura é 0, ela tem cor 0. Se a altura é 4267 (o máximo), a cor é 15. Da mesma forma, se a altura é 2134, ela tem cor 7, e assim por diante. O autoescalamento é um ajuste linear simples dos valores entre o mínimo e o máximo da imagem e entre os índices de cor mínimo e máximo, como definido pelos valores mínimo e máximo do autoescalamento da tabela de cores utilizada.

O Lançador de visualização autoescalou a imagem para poder exibi-la, pois ela é composta por números reais. Todas as imagens de números reais devem ser autoescaladas porque os índices de cores das tabelas de cores são valores inteiros, e esse processo é feito automaticamente no momento da visualização. No entanto, quando uma imagem é inteira ou byte, nem sempre é necessário que isso seja efetuado. Se a imagem contém valores negativos ou se os valores excedem 255, o autoescalamento

será imediatamente acionado. Se os valores caem na faixa 0-255 é assumido que o autoescalamento não se faz necessário (já que, de fato, os valores cabem no intervalo padrão 0-255 das tabelas de cores). Todavia, você pode encontrar situações onde deseja usar o autoescalamento e poderá acioná-lo intencionalmente.

p) Use o Lançador de visualização para examinar a imagem chamada BRAZIL2 com a tabela de cores Tons de cinza 256 (esta é uma imagem da Banda 5 do sensor MSS LANDSAT, mais tarde conhecida como Banda 2 MSS).

3. Como a imagem aparece? (Não, não há nada errado!)

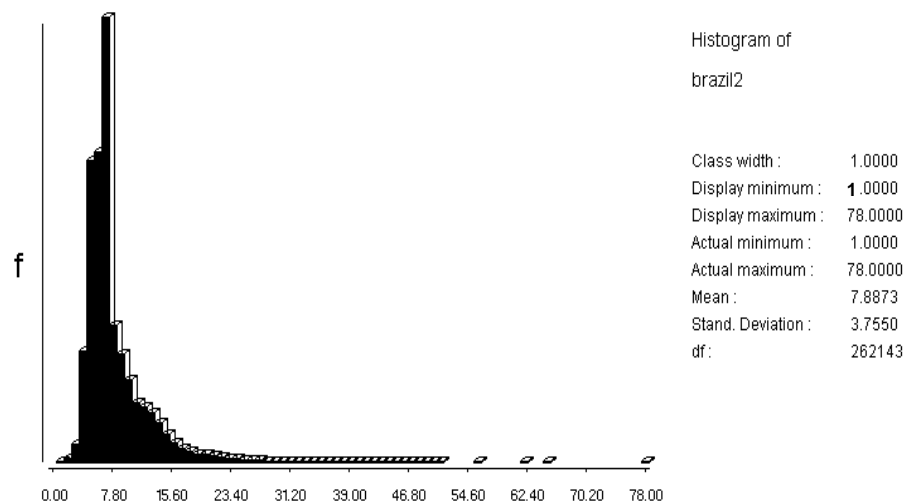
q) Feche a janela do mapa e visualize BRAZIL2 novamente, porém desta vez especificando o uso de autoescalamento.

4. Como ela aparece agora?

De fato sua aparência não é boa, mesmo com o autoescalamento ligado (embora até possamos enxergar alguma coisa). Quando a comparamos com ETDEM, que se mostrou visualmente boa, nós temos que concluir que o autoescalamento nem sempre funciona bem. Normalmente o uso do autoescalamento para tornar uma imagem visível dá bons resultados, mas BRAZIL2 ilustra claramente um caso onde isso não é verdade. Felizmente, há uma solução para isso.



r) Para entender porque o autoescalamento não funcionou bem na exibição de BRAZIL2, acione o módulo chamado HISTO. Este módulo pode ser encontrado no menu Visualização ou pode ser acessado pelo seu ícone na barra de ferramentas (ilustrado à esquerda). Como alternativa, há um acesso direto para o módulo HISTO a partir da visualização que iremos experimentar agora. Pressione o botão Propriedades da Composição e então o botão Histograma da imagem. Quando você usar este acesso rápido, é automaticamente assumido que a imagem a ser usada com HISTO é aquela em destaque na lista da Composição.



Como você pode ver neste histograma, BRAZIL2 tem uma distribuição extremamente distorcida. Por causa da lógica do autoescalamento, isto também representa a distribuição dos tons de cinza com o preto situado no extremo esquerdo do eixo X e o branco no extremo direito (e cinzas médios no meio da escala). Como podemos ver, a maior parte dos *pixels* apresenta-se muito escura, uma vez que seus valores são muito baixos comparados com a variação total de 1 até um máximo de 78. A frequência muito pequena de objetos altamente reflexivos (brilhantes) causou a predominância de *pixels* em cinza escuro.

A solução para este problema é reescalonarmos os valores de forma a concentrarmos as cores disponíveis no maior volume dos dados. Podemos fazer isso escalonando não entre os valores mínimos e máximos originais mas entre dois pontos que envolvam o volume dos dados. Analisando-se visualmente, isto parece estar entre 3 e 22. Nós podemos usar essa informação com o módulo STRETCH para criar um resultado melhor.

O módulo STRETCH é usado para aumentar o contraste de uma imagem na sua visualização, de forma que as características da imagem possam ser mais facilmente distinguíveis. Algumas vezes, isso é referido como aplicação de um realce do contraste. De forma mais geral, pode ser pensado como uma rotina de reescalonamento.



- s) Feche a janela do mapa BRAZIL2. Acione STRETCH pelo menu Visualização ou clicando no respectivo ícone na barra de ferramentas. Indique que a imagem de entrada é BRAZIL2 e que a imagem de saída deve ser chamada LINEAR. Use o tipo de contraste linear padrão e ajuste um novo mínimo de 3 e um novo máximo de 22. Aceite o indicado para os demais parâmetros. Quando terminar, use o Lançador de visualização para visualizar LINEAR usando a tabela de cores Tons de cinza 256<sup>22</sup>.

5. Como a imagem aparece agora?

O que aconteceu é que todos os *pixels* com valor 3 ou menores receberam a cor mais baixa (preto), enquanto aqueles com valor 22 ou maior receberam o índice de cor mais alto (branco). Isto é chamado de *saturação* e, como você pode ver, é um recurso muito eficiente para fazer com que a proporção de *pixels* saturados não seja muito grande (geralmente menor do que 5%).

Sempre que a imagem de entrada estiver no formato byte, o STRETCH incorpora uma forma de efetuar estes passos automaticamente (sem ser necessário examinar o histograma), utilizando o tipo de realce de contraste Linear com saturação. Com esta opção, nós especificamos a porcentagem de *pixels* que devem ser saturados em cada extremo do histograma. Ele fará seus próprios cálculos no histograma e irá saturar exatamente este total. Vamos experimentar isso.

- t) Acione STRETCH, especifique BRAZIL2 como a imagem de entrada e escolha a opção tipo de contraste linear com saturação. Chame a imagem de saída de SAT e especifique o grau de saturação de 2,5 (isto é, 2,5% em cada extremo, para um total de 5%). Veja o resultado usando a tabela de cores Tons de cinza 256.

O módulo STRETCH será melhor explorado no Exercício 11. É importante frisar aqui que as imagens por nós produzidas com STRETCH foram dirigidas somente para a visualização. Elas não devem ser usadas para análise -- **em análises use sempre a imagem original**, e não aquelas que tenham sido processadas para a visualização. Além disso, note que normalmente só recorremos ao uso de STRETCH nos casos onde queremos ter maior controle sobre os processos de aumento de contraste. Em outros casos, o processo de autoescalonamento da Visualização funciona bem.

Finalmente, você deve notar que a Oficina de banco de dados, que será melhor estudada no exercício 10, também contém um procedimento de autoescalonamento que pode ser usado para autoescalonar atributos de elementos vetoriais dentro de um intervalo necessário para a visualização.

---

<sup>22</sup>Se a opção Visualizar automaticamente as saídas dos módulos analíticos estiver ligada nas Preferências de visualização a imagem LINEAR será automaticamente visualizada com a tabela de cores padrão. Use o botão Propriedades existente na Composição para mudar a tabela de cores para GREY256.

# **INTRODUÇÃO À MODELAGEM CARTOGRÁFICA**

Um modelo cartográfico é uma representação gráfica dos dados e dos procedimentos analíticos usados em um estudo. Seu propósito é ajudar o analista a organizar e estruturar os procedimentos que serão usados em seu estudo e a identificar os dados necessários para completá-los. Também serve como fonte de documentação e referência para a análise.

Nós usaremos extensivamente os modelos cartográficos na próxima parte dos exercícios tutoriais. Alguns serão fornecidos para você, enquanto que outros você terá que construir. Nós encorajamos você a desenvolver o hábito de usar modelos cartográficos em seu próprio trabalho.

No desenvolvimento de um modelo cartográfico, considera-se mais útil iniciar pelo produto final e prosseguir para trás passo a passo até chegar nos dados existentes. Isso nos protege contra a tendência de fazermos com que os dados dêem o formato ao produto final. O procedimento inicia com a definição do produto final. Que valores ele terá? O que tais valores significarão? Nós então perguntamos que dados serão necessários para produzir o produto final, definimos cada um desses dados e como eles podem ser extraídos. O seguinte exemplo ilustra o processo:

Suponha que nós queremos produzir um produto final que mostre as áreas com declividade maior que 20 graus. Há várias questões que nos surgem: que dados serão necessários para produzir tal imagem? Para produzir uma imagem de declives maiores que 20 graus, nós primeiro necessitaremos de uma imagem de todos os declives. Existe uma imagem de todos os declives em nosso banco de dados? Se não existir, nós damos um passo atrás e fazemos mais perguntas: que dados serão necessários para produzir um mapa com todos os declives? Uma imagem de altitudes do terreno pode ser usada para criar o mapa de declives. Existe uma imagem de altitudes do terreno em nosso banco de dados? Se não, que dados serão necessários para produzi-la? O processo continua até chegarmos nos dados existentes.

Os dados existentes podem já estar na forma digital ou podem estar na forma de papel ou tabelas que necessitarão ser digitalizadas. Caso os dados necessários não estejam disponíveis, você poderá desenvolver uma forma de usar outros arquivos de dados ou combinações de arquivos como substitutos.

Nos diagramas, sempre iniciaremos com o produto final no lado esquerdo do modelo e desenvolveremos o restante para a direita. Certas convenções quanto à simbologia devem ser mantidas com fidelidade para que se mantenha a consistência. Você pode adotar estas convenções ou desenvolver as suas próprias para efetuar o seu trabalho.

Os arquivos de dados são representados como mostra a Figura 1. Os arquivos de imagens são representados por retângulos horizontais, os arquivos vetoriais por triângulos, os arquivos de valores por elipses e os dados tabulares por retângulos verticais. Nós identificamos campos individuais num banco de dados com o nome do campo sublinhado. Os nomes de arquivos são escritos com letras maiúsculas dentro do símbolo.




Figura 1

As operações são indicadas escrevendo-se o nome dos módulos acima ou abaixo das setas que conectam os arquivos de dados de entrada e de saída. Os nomes dos módulos são escritos em letra maiúscula itálica. Quando uma operação requer a entrada de dois arquivos, os dois são unidos com linhas e uma seta simples os une ao resultado. Nestes casos, o nome do módulo é escrito entre os arquivos de entrada. Parâmetros de entrada importantes podem ser vistos no modelo cartográfico próximo aos nomes dos módulos, em caixa baixa e itálico (p. ex., *multiplicação*). A Figura 2 mostra um exemplo de um modelo cartográfico muito simples.

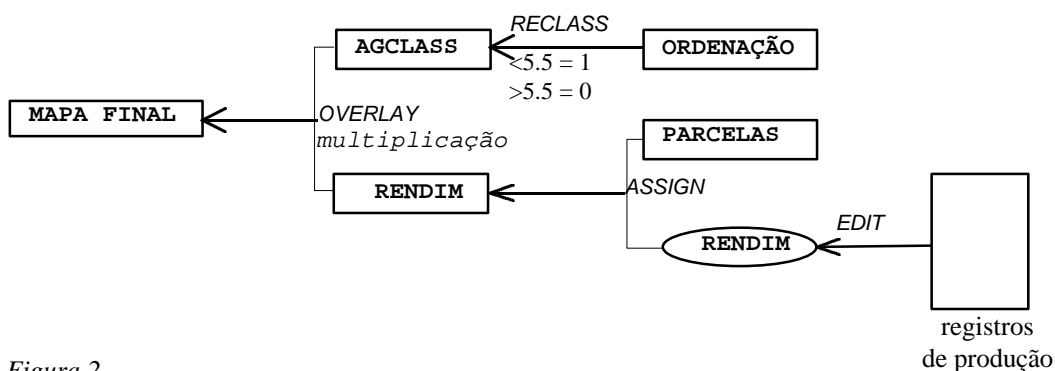


Figura 2

Você irá se familiarizar bastante com os modelos cartográficos assim que for trabalhando com os exercícios tutoriais restantes.

## 5. Consulta ao banco de dados

Neste exercício, exploraremos a mais fundamental das operações em SIG -- a consulta ao banco de dados. Com a consulta ao banco de dados estamos tentando responder uma de duas questões possíveis. A primeira é uma *consulta por localização* -- **o que existe neste local?** A segunda é uma *consulta por atributo* -- **mostre todos os locais que possuem este atributo**. Quando movemos o cursor através da imagem, a posição de suas colunas e linhas, bem como as coordenadas X e Y, são mostradas na barra de status na base da tela. Quando pressionamos o ícone do modo de consulta do cursor (o oitavo da esquerda para a direita), e então clicamos em diferentes locais na imagem, a barra de status irá mostrar, além da posição de coluna e linha e das coordenadas do cursor, também o valor da célula em cada local consultado -- o valor Z. Quando fazemos isso, estamos de fato realizando uma consulta através da localização. Em futuros exercícios veremos um meio mais elaborado de efetuar essa consulta (usando os módulos chamados EXTRACT e CROSSTAB), bem como de consultar interativamente um grupo de imagens ao mesmo tempo. Neste exercício veremos uma aplicação muito importante de consulta por atributo.

Para fazer uma consulta por atributo especificamos determinadas condições e a seguir solicitamos ao computador que extraia todas as áreas que preencham estas condições. Caso a condição envolva somente um atributo, poderemos usar apenas os módulos RECLASS ou ASSIGN para efetuar a consulta. Mas se tivermos uma condição que envolva atributos múltiplos, devemos usar também o módulo OVERLAY. O exercício a seguir ilustrará esses procedimentos. Caso você ainda não o tenha feito, leia o item sobre *Consulta ao banco de dados* no capítulo *Introdução a Sistemas de Informação Geográfica (SIG)* antes de iniciar o exercício.

- a) Use o Lançador de visualização para examinar o arquivo chamado DRELIEF. Utilize a tabela de cores Idrisi 16 e as opções padrão para os demais parâmetros. O autoescalamento será automaticamente acionado, já que DRELIEF possui dados do tipo real. Use a consulta através do cursor para examinar os valores em diferentes locais da imagem.

Este é uma imagem de *relevo* ou *topografia* (também denominada *modelo digital de elevação*) de uma região na Maurîtânia, ao longo do rio Senegal. A região ao sul do rio (no interior da curva em forma de ferradura) pertence ao Senegal e não foi digitalizada. Com o propósito de apenas preencher a área com dados, foi dada a ela uma altitude arbitrária de 10 m. Nossa análise enfocará somente o lado do rio que cai na **Maurîtânia**.

Esta região está sujeita a inundações periódicas a cada ano, durante a estação das chuvas. Como a região normalmente é muito seca, os agricultores locais praticam o que é conhecido como "agricultura



recessional”, cultivando as áreas que foram inundadas após o recuo da água. A principal cultura explorada nestas condições é o sorgo.

Foi proposto um projeto para construir uma represa ao longo da margem norte, na porção mais setentrional desta curva do rio. A intenção é que as águas da enchente entrem nesta área, como de hábito, mas que a represa possa retê-las por mais tempo, permitindo assim que um volume maior de água penetre no solo para se obter maiores rendimentos no cultivo de sorgo. . De acordo com dados de linímetro, a cota normal de inundação nesta área é de 9 metros.

Além da disponibilidade de água, o tipo de solo é uma consideração importante na agricultura recessional de sorgo porque alguns solos retêm melhor a umidade do que outros e alguns são mais férteis do que outros. Na região a analisar, apenas os solos argilosos são altamente apropriados para este tipo de agricultura.

- b) Use o Lançador de visualização para examinar uma imagem chamada DSOILS. Escolha a tabela de cores Qualitativa 16, com título e legenda visíveis. Este é o mapa de solos da área de estudo.

Na determinação de como proceder com o projeto da barragem, os planejadores necessitam saber qual será o provável impacto que o projeto terá. Uma informação importante é a área total (em hectares) de solos próprios ao cultivo recessional de sorgo. Caso a maior porção inundada seja constituída de solos impróprios, o incremento esperado na produção de sorgo será mínimo, e talvez seja necessário identificar outro local para o projeto. Em contrapartida, se grande parte da área de inundação tiver solos argilosos, então o projeto poderá resultar em um grande impacto no incremento da produção de sorgo.

Nossa tarefa, um tanto simples, é fornecer essa informação. Vamos mapear e calcular a área (em hectares) de todas as regiões aptas ao cultivo recessional de sorgo. Esta é uma consulta **clássica** ao banco de dados, e envolve uma condição composta -- necessitamos encontrar todas as áreas que estão:

- i. localizadas na região normal de inundação  
AND (e)
- ii. com solos argilosos

Para construir um modelo cartográfico para esse problema, vamos iniciar por especificar o resultado final desejado no lado esquerdo do modelo. No final, desejamos um número simples que represente a área apta ao cultivo recessional de sorgo, em hectares. Para obter este número, entretanto, nós necessitamos primeiro gerar uma imagem que diferencie os locais aptos dos demais e depois calcular a área que é considerada apta. Nós chamaremos esta imagem de BESTSORG.

Seguindo as convenções descritas no item *Introdução à modelagem cartográfica* da seção **EXERCÍCIOS TUTORIAIS BÁSICOS**, nosso modelo cartográfico do problema pode ser representado como na Figura 1.




Figura 1

A descrição do problema estabelece que existem duas condições que tornam uma área apta ao cultivo recessional de sorgo: uma é que a área deve ser inundável e a outra é que os solos sejam argilosos. Cada uma destas condições deve ser representada por uma imagem individual. Nós denominaremos estas imagens de FLOOD e BESTSOIL. BESTSORG, então, é o resultado da combinação destas duas imagens através de alguma operação, tal como reter apenas as áreas que preenham ambas as condições.

Se adicionarmos estes elementos ao modelo cartográfico da Figura 1, teremos a Figura 2.




Figura 2

Como BESTSORG é o resultado de uma *consulta por atributos múltiplos*, ela define a localização que preenche mais de uma condição. FLOOD e BESTSOIL são o resultado de uma *consulta por atributo simples* pois ela define os locais que preenchem apenas uma condição. O caminho mais comum para resolver tais problemas é produzir *imagens Booleanas* das consultas de atributos simples. A consulta multi-atributo pode então ser efetuada usando *Álgebra Booleana*.

Imagens *Booleanas*<sup>23</sup> (também conhecida como *binárias* ou *imagens lógicas*) contêm apenas valores iguais a zero ou um. Numa imagem *Booleana*, o valor zero indica um *pixel* que não preenche a condição desejada, enquanto um valor igual a um indica um *pixel* que preenche a condição. Usando valores de zero e um, operações lógicas podem ser feitas entre múltiplas imagens de forma bem simples. Por exemplo, neste exercício nós efetuaremos uma operação lógica AND de forma que a imagem BESTSORG conterá o valor um apenas para aqueles *pixels* que preenchem a condição de inundação AND tipo de solo especificado. A imagem FLOOD deve conter *pixels* com valor um apenas nos locais que serão inundados e zero nos demais. A imagem BESTSOIL deve conter *pixels* com valor um em todas as áreas com solo argiloso e zero nas demais áreas. Tendo-se estas duas imagens, a condição lógica AND pode ser calculada através da simples multiplicação de ambas. Quanto duas imagens são usadas como variáveis em uma operação de multiplicação, um *pixel* da primeira imagem (p.ex. FLOOD) é multiplicado pelo *pixel* na mesma posição da segunda imagem (p.ex. BESTSOIL). O produto desta operação (p.ex. BESTSORG) possui *pixels* com o valor igual a um apenas nos locais que possuem o valor um em ambas as imagens de entrada, como mostrado na Tabela 1. Esta lógica pode ser estendida a qualquer número de condições, desde que cada condição seja representada por uma imagem *Booleana*.

FLOOD		BESTSOIL		BESTSORG
0	×	0	=	0
0	×	1	=	0
1	×	0	=	0
1	×	1	=	1

Tabela 1

A imagem *Booleana* FLOOD mostrará áreas inundadas num evento de cheia normal (isto é, aquelas áreas com elevações inferiores a 9 m). Em função disso, para produzir FLOOD, nós necessitaremos o modelo de elevação DRELIEF já mostrado anteriormente. Para criar FLOOD a partir de DRELIEF, nós alteraremos todas as elevações inferiores a 9 metros para um valor de um e todas as elevações iguais ou superiores a 9 metros para um valor igual a zero.

De forma similar, para criar a imagem *Booleana* BESTSOIL partiremos da imagem com todos os tipos de solos (DSOILS) e então isolaremos apenas os solos argilosos. Para fazer isto alteraremos os valores da

<sup>23</sup> Apesar da palavra *binária* ser comumente usada para descrever uma imagem desta natureza (somente 1s e 0s), usaremos o termo *Booleana* daqui em diante para evitar confusão com o termo *binário* como referência a um formato de armazenamento de dados. O nome *Booleana* é derivado do nome de George Boole (1815--1864) -- um dos pais da Lógica Matemática. O nome é também apropriado porque as operações que executaremos nestas imagens são conhecidas como *Álgebra Booleana*.

imagem DSOILS de modo a substituir os valores de solo argiloso pelo valor um e os valores dos demais tipos de solo pelo valor zero. A adição destes passos ao nosso modelo cartográfico gera a Figura 3.




Figura 3

Nós chegamos agora a um ponto na modelagem cartográfica em que temos todos os dados necessários. A tarefa restante é determinar exatamente que módulos do IDRISI for Windows utilizar para realizar as operações desejadas (atualmente indicadas com pontos de interrogação na Figura 3). Nós os substituiremos pelo nome do módulo à medida que trabalharemos o problema com SIG.

Primeiro criaremos uma imagem FLOOD isolando todas as áreas na imagem DRELIEF com elevações inferiores a 9 metros. Para isso usaremos o módulo RECLASS.

- c) Nós já visualizamos DRELIEF anteriormente. Deixe-nos, agora, examinar as características deste arquivo. Se a visualização ainda estiver aberta, clique duas vezes no nome da imagem DRELIEF na lista de arquivos da Composição para ver seu arquivo de documentação. Se você já fechou a janela de DRELIEF, você pode acessar as informações usando Descrever do menu Arquivo ou da barra de ferramentas (terceiro ícone da esquerda para a direita).

1. Quais os valores mínimos e máximos de elevação na imagem?

- d) Antes de executarmos qualquer análise, configure as Preferências de visualização para que os resultados que produzirmos sejam automaticamente visualizados. Para isso, selecione Preferências de visualização no menu Visualização. Ligue a visualização automática das saídas dos módulos analíticos e indique QUAL256 como tabela de cores qualitativa e IDRIS256 como tabela de cores quantitativa. Selecione também as opções de Título visível e Legenda visível e deixe IDRIS256 como a tabela de cores padrão. Pressione OK.

Agora nós estamos prontos para criar nossa primeira imagem *Booleana*, FLOOD.

- E) Execute RECLASS a partir do menu Análise/Consulta ao banco de dados. Reclassificaremos um arquivo imagem com a opção de reclassificação personalizada. Especifique DRELIEF como o arquivo de entrada e indique FLOOD como arquivo de saída. Indique a seguir os seguintes valores:

Atribuir um novo valor de:	1
a todos valores desde:	0
até imediatamente inferiores a:	9

Continue pressionando a seta direita do botão de alteração de classes para a próxima caixa em branco e digite o que segue:

Atribuir um novo valor de:	0
a todos valores desde:	9
até imediatamente inferiores a:	999

Indique um título para a nova imagem e “Boolean” como novas unidades de valor. Pressione OK.

Note que nós indicamos “999” como o valor máximo que deverá ser indicado para zero porque ele é um valor maior que qualquer outro de nossa imagem. Qualquer número superior ao atual máximo de 16 poderia ser usado em função do termo “imediatamente inferior a”.

- f) Quando RECLASS tiver concluído, examine a nova imagem denominada FLOOD (ela será automaticamente visualizada se você seguiu as instruções do passo d). Esta é uma imagem *Booleana*, conforme descrito acima, onde o valor 1 representa áreas que atendem à condição especificada e o valor zero representam áreas que não atendem à condição.
- g) Agora vamos criar uma imagem *Booleana* (BESTSOIL) com todas as áreas com solos argilosos. O arquivo imagem DSOILS é um mapa de solos desta região. Se você fechou a janela de DSOILS visualize-a novamente usando a tabela de cores Qualitativa 16 (o título e a legenda serão automaticamente exibidos se você seguiu as instruções do passo d).

## 2. Qual é o valor numérico da classe de solos argilosos?

Nós poderíamos usar o módulo RECLASS aqui para isolar esta classe numa imagem *Booleana*. Se o usássemos (o que não faremos neste caso), nossa seqüência para definir a reclassificação seria:

Atribuir um novo valor de: 0  
a todos valores desde: 0  
até imediatamente inferiores a: 2

Atribuir um novo valor de: 1  
a todos valores desde: 2  
até imediatamente inferiores a: 2

Atribuir um novo valor de: 0  
a todos valores desde: 3  
até imediatamente inferiores a: 999

Note que o intervalo de valores que não têm interesse para nós devem ser explicitamente reclassificados para 0 enquanto os que interessam (solo tipo 2) são reclassificados para 1. Em RECLASS, quaisquer valores não englobados por um intervalo especificado permanecerão com seus valores originais na imagem de saída<sup>24</sup>. Note também que quando um único valor, em vez de um intervalo de valores, é reclassificado, o valor original deve ser digitado duas vezes (em “a todos valores de” e em “até imediatamente inferiores a”).

RECLASS é o meio mais universal de reclassificar ou atribuir novos valores aos dados de uma determinada imagem. Há um preço por esta universalidade -- é de certa forma lento. Em alguns casos podemos usar um procedimento bem mais rápido chamado ASSIGN para obter o mesmo resultado. ASSIGN atribui novos valores a um conjunto de valores inteiros. Diferente de RECLASS, a imagem de entrada para ASSIGN deve possuir números inteiros ou em byte (RECLASS permite imagens do tipo real). Em ASSIGN, valores de dados não mencionados na reclassificação serão automaticamente substituídos por 0 (RECLASS deixa dados não mencionados com seu valor original). Isto pode ser particularmente útil quando desejamos criar uma imagem *Booleana*. Por último, ASSIGN difere de RECLASS no fato de que somente valores inteiros individuais podem ser especificados, não intervalos de valores.

Para trabalhar com ASSIGN, necessitamos primeiro criar um arquivo com valores de atributo (chamado de arquivo de valores) que liste os novos atributos para os valores de dados existentes. A forma mais simples de um arquivo de valores no IDRISI for Windows é um arquivo de texto ASCII com 2 colunas

<sup>24</sup> A saída de RECLASS é sempre de valores inteiros, de forma que valores reais serão arredondados na imagem de saída. Isto não afeta nossa análise porque estamos reclassificando para valores inteiros (0 e 1).

de dados (separadas por um ou mais espaços)<sup>25</sup>. A coluna da esquerda lista as classes da imagem existente (usando números inteiros como identificadores das feições). A coluna da direita lista os valores a serem atribuídos àquelas feições. No nosso caso, as feições são os tipos de solo aos quais atribuiremos novos valores. Para criar este arquivo de valores podemos usar um módulo chamado EDIT.

Para praticar o uso de ASSIGN, criaremos um mapa com o grau de adequação de uso que ilustre a aptidão variável do solo ao cultivo recessional de sorgo. Sabemos que os solos argilosos são os mais aptos, portanto atribuiremos a eles um grau 5. Os piores são os solos pedregosos, aos quais atribuiremos um grau 1. As classes argila pesada, argilo arenoso e dique receberão respectivamente graus 2, 3 e 4. Vamos usar EDIT para criar o arquivo de dados que contenha essa informação.

3. Para ajudar a tornar clara a reclassificação, preencha o quadro a seguir com as 5 classes de solo:

Classe de solo (número)	Classificação de aptidão do solo

- h) Execute EDIT a partir do menu Entrada de Dados e indique que você deseja criar um arquivo de valores chamado SOILRATE. Ele lhe dará a informação de que você está criando um novo arquivo ao perguntar-lhe pelo tipo de dado. Como estamos atribuindo novos valores inteiros entre 1 e 5, escolha o tipo de dado inteiro. Dê um título ao arquivo de valores e digite *classificação de aptidão* como unidade. A seguir aparecerá uma janela de edição. Você pode usar o sistema de ajuda de EDIT para orientá-lo, mas EDIT é muito simples. Digite os valores no arquivo em 2 colunas, como a seguir:

```
1 2
2 5
3 3
4 4
5 1
```

Quando você tiver terminado, salve e saia.

- i) Agora execute ASSIGN, a partir do menu Análise/Consulta ao banco de dados. Digite DSOILS como a imagem de definição de feições, já que o mapa de solos define as classes às quais atribuiremos novos valores. Indique SOILRATE como o nome do arquivo de valores de atributo. Para a imagem de saída especifique o nome SORGSUIT. A seguir dê um título para a imagem de saída.
- j) Quando ASSIGN tiver concluído o processamento SORGSUIT será automaticamente visualizada. Os valores dos dados agora não representam mais classes de solo mas sim uma classificação de aptidão para o cultivo recessional de sorgo. Pressione o botão Propriedades da Composição para mudar a tabela de cores para NDVI16<sup>26</sup>.

Observe como ASSIGN é bem mais rápido do que RECLASS. Embora ASSIGN e RECLASS possam ser usados freqüentemente para a mesma finalidade, eles não são exatamente equivalentes e usualmente um

<sup>25</sup> Arquivos de valores de atributo com múltiplos campos são acessíveis através da Oficina de banco de dados. O uso do ASSIGN através da Oficina de banco de dados é ilustrado no Exercício 10 dos **EXERCÍCIOS TUTORIAIS INTRODUTÓRIOS**.

<sup>26</sup> Nesse caso a visualização automática determinou que o resultado é qualitativo (valores inteiros) e por isso adotou uma tabela de cores qualitativa, embora os valores sejam quantitativos. A visualização automática ajuda a ganhar tempo, mas às vezes pode aplicar uma tabela de cores imprópria. Quando isso acontece, simplesmente mude a tabela de cores usando o botão Propriedades da Composição.

irá requerer alguns passos a menos do que o outro para um procedimento específico. Na medida em que você se familiarizar com a operação de cada um, a escolha entre os dois módulos em cada situação particular se tornará mais óbvia.

Agora retornaremos ao próximo passo da modelagem cartográfica -- criar a imagem BESTSOIL.

- k) Use EDIT novamente para criar um novo arquivo de valores chamado CLAYS. Escolha inteiro como novo tipo de dado, dê um título e digite "classes" como a unidade dos novos valores. Este arquivo será usado com ASSIGN para isolar os solos argilosos no mapa de solos original. Nós determinamos anteriormente que solos argilosos possuem o valor de classe 2 na imagem DSOILS. Neste caso queremos que seja atribuído o valor 1 às áreas com grau 2 e às demais áreas seja atribuído o valor 0. Nosso arquivo de valores, portanto, será assim:

```
1 0
2 1
3 0
4 0
5 0
```

Como já foi mencionado, qualquer classe não especificada no arquivo de valores terá atribuída automaticamente um novo valor de 0. Desta maneira, nosso arquivo de valores, na verdade, necessita de apenas uma linha, como segue:

```
2 1
```

A todas as classes com valores diferentes de 2 será atribuído automaticamente o valor 0.

- l) Depois de haver criado este arquivo de valores, execute ASSIGN usando DSOILS como arquivo de definição de feições e CLAYS como o arquivo de valores. Chame a nova imagem de BESTSOIL e lhe dê um título. Examine a imagem BESTSOIL resultante.

Neste ponto nós realizamos uma consulta a um atributo simples para produzir duas imagens *Booleanas* (FLOOD e BESTSOIL) que atendem a condições individuais por nós especificadas. Agora necessitamos realizar uma consulta por atributos múltiplos para encontrar locais que preenchem ambas as condições e são, portanto, aptos ao cultivo recessional de sorgo.

Como descrito anteriormente neste exercício, a operação de multiplicação entre duas imagens *Booleanas* pode ser usada para produzir o resultado da operação lógica AND. No IDRISI for Windows, isto é feito com o módulo OVERLAY. OVERLAY produz imagens novas como resultado de uma operação matemática entre duas imagens existentes. A maioria delas são operações aritméticas simples. Por exemplo, podemos usar OVERLAY para subtrair uma imagem de outra visando examinar suas diferenças.

Como ilustrado na Tabela 1, se usarmos OVERLAY para multiplicar FLOOD e BESTSOIL, o único caso no qual nós obteremos um valor 1 na imagem de saída BESTSORG é quando os *pixels* correspondentes em ambos mapas de entrada contiverem o valor 1.

OVERLAY pode ser usado para produzir uma variedade de operações *Booleanas*. Por exemplo, a opção de cobertura (Primeira cobre a Segunda se diferente de 0) em OVERLAY produz um OR (ou) lógico. A imagem de saída de uma operação de cobertura tem o valor um na posição em que ambas as imagens de entrada têm valor um.

4. Construa uma tabela similar à Tabela 1 para ilustrar a operação OR e então sugira uma operação OVERLAY **diferente de cobertura** que possa ser usada para produzir o mesmo resultado.

- m) Execute OVERLAY a partir do menu Análise/Consulta ao banco de dados para multiplicar FLOOD e BESTSOIL e criar uma nova imagem chamada BESTSORG. Dê um título à imagem e especifique “Boolean” para as unidades de valor. Examine o resultado (mude a tabela de cores para QUAL256 se estiver difícil de enxergar). BESTSORG mostra todos os locais que estão dentro da zona normal de inundação AND (e) possuem solos argilosos.
- n) Nosso próximo passo é calcular a área, em hectares, destas áreas próprias em BESTSORG. Isto pode ser feito com o módulo AREA. Execute AREA a partir do menu Análise/Consulta ao banco de dados, indique BESTSORG como a imagem de entrada, selecione formato de saída tabular e calcule a área em hectares.
5. Quantos hectares encontram-se na área de inundação em solos argilosos? Qual o significado da outra área relatada na figura?

Adicionar o nome dos módulos ao modelo cartográfico da Figura 3 produz o modelo cartográfico completo para a análise acima, mostrado na Figura 4.

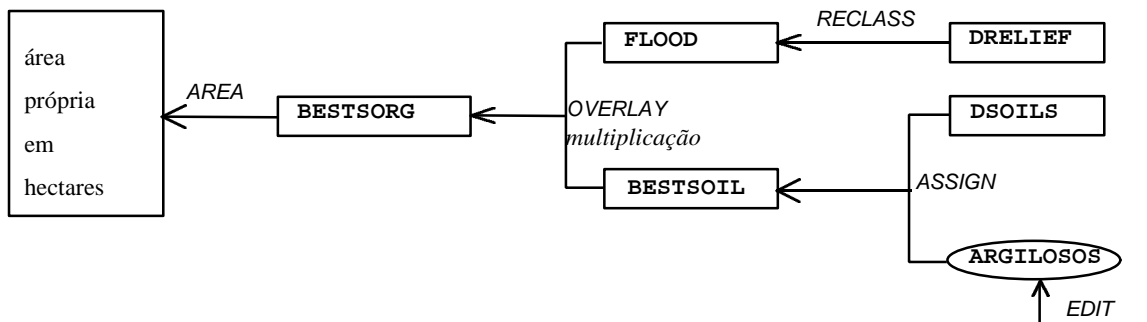


Figura 4

O resultado que produzimos envolveu consultas por atributo único para cada uma das condições especificadas na definição de aptidão. Depois, utilizamos os produtos dessas consultas para executar uma consulta por atributos múltiplos que identificou os locais que satisfazem a todas as condições. Apesar de analiticamente muito simples, este tipo de análise é um dos mais comuns efetuados com SIG. A capacidade de desempenhar consultas à base de dados baseado não somente em atributos, mas também na localização desses atributos, é o que distingue um SIG de um *software* de gerenciador de banco de dados convencional.

A área que acabamos de calcular representa o número total de hectares para todas as regiões que satisfazem nossas condições. Observe que há algumas regiões distintas que são fisicamente separadas das demais. Como devemos proceder, se desejarmos calcular o número de hectares de cada uma dessas áreas potenciais para o cultivo de sorgo separadamente?

Quando você visualiza uma imagem, é capaz de interpretar *pixels* contíguos com o mesmo identificador como uma feição maior única, tal como um polígono de solo. Na imagem BESTSORG, por exemplo, você pode distinguir três locais aptos separados. Entretanto, em sistemas raster como o IDRISI for Windows, a única feição definida é o *pixel* individual. Todavia, como cada região distinta em BESTSORG tem o mesmo atributo (1), o IDRISI for Windows as interpreta como sendo a mesma feição, não possibilitando calcular a área de cada região em separado. A única forma de calcular a área dessas regiões espacialmente distintas é primeiro atribuir a cada região um único identificador. Isso é conseguido com o módulo GROUP.

GROUP é projetado para encontrar e identificar grupos espacialmente contíguos de *pixels* de mesmo valor. Ele atribui novos valores a esses grupos de *pixels*, iniciando no canto superior esquerdo da imagem e processando da esquerda para a direita e do topo para a base da mesma, associando ao primeiro grupo o valor zero. O valor de um determinado *pixel* é comparado com o de seus vizinhos

contíguos. Caso ele tenha o mesmo valor, recebe o mesmo identificador de grupo que os *pixels* vizinhos. Se o valor for diferente, o *pixel* recebe um novo identificador de grupo.

A definição de *espacialmente contíguo* pode ser feita de duas formas. Na primeira, os *pixels* são considerados de um mesmo grupo se forem adjacentes em um ou mais de seus lados (esquerda, direita, topo ou base). Na segunda, são considerados de um mesmo grupo se forem adjacentes em seus lados *ou* também em seus cantos. Este caso é chamado no IDRISI for Windows de *Incluir diagonais*. A opção a utilizar depende da aplicação que você pretende desenvolver.

A Figura 5 ilustra o resultado da execução de GROUP sobre uma imagem *Booleana* simples. Note a diferença causada pela inclusão das diagonais. O exemplo sem as diagonais produz oito novos grupos (identificadores 0-7), enquanto a mesma imagem original com a inclusão das diagonais produz somente três novos grupos distintos.

original	sem diagonais	incluindo diagonais
1 1 0 1	0 0 1 2	0 0 1 2
1 0 0 1	0 1 1 2	0 1 1 2
0 1 0 0	3 4 1 1	1 0 1 1
1 0 1 0	5 6 7 1	0 1 0 1

Figura 5

o) Execute GROUP, a partir do menu Análise/Operadores de contexto, sobre BESTSORG para produzir uma imagem de saída chamada PLOTS. Inclua as diagonais e digite um título para a imagem. Quando GROUP tiver terminado, examine PLOTS. Use o modo de consulta do cursor para examinar os valores dos dados em cada região individual. Note como agora cada grupo contíguo de *pixels* de mesmo valor tem um identificador único diferente dos demais grupos.

6. Quantos grupos foram produzidos? (lembre-se de que o primeiro grupo recebeu o valor zero!)

Três desses grupos são nossas regiões aptas para o cultivo de sorgo, mas os outros são grupos compostos por *pixels* de fundo. Antes de calcular o número de hectares em cada região apta devemos determinar os identificadores dos grupos que representam as áreas aptas para sorgo, com a finalidade de encontrar os identificadores e as respectivas áreas na tabela de áreas. Alternativamente, podemos mascarar os grupos de fundo atribuindo-lhes o identificador zero, deixando os demais grupos de interesse com seu identificador único, diferente de zero. A tabela de áreas será então bem mais fácil de ler. Nós vamos utilizar, a seguir, este último método.

Nesse caso, desejamos criar uma imagem em que as regiões aptas para sorgo retenham seu identificador único de grupo e todos os grupos de fundo tenham valor zero. Há várias formas de se fazer isso. O método mais fácil é utilizar uma operação de OVERLAY.

7. Qual opção de OVERLAY você pode usar para criar a imagem desejada? Utilizando que imagens?

p) Execute a operação sugerida acima para produzir a imagem PLOTS2, e examine o resultado. Mude a tabela de cores para QUAL256. Como na imagem PLOTS, as regiões aptas são distinguidas do fundo, cada uma com seu próprio identificador.

q) Agora estamos prontos para executar o módulo AREA. Use PLOTS2 como a imagem de entrada e solicite a saída em forma tabular e em hectares.



8. Qual é a área em hectares de cada região apta para o cultivo de sorgo?

A Figura 6 mostra o passo adicional que anexamos ao nosso modelo cartográfico original. Você será solicitado a produzir modelos cartográficos em vários dos próximos exercícios. Nós o encorajamos a usar a modelagem cartográfica como uma ferramenta para organizar análises em seu próprio trabalho da melhor forma possível.




Figura 6

Neste exercício nós utilizamos a mais básica das operações em SIG -- a consulta ao banco de dados. Aprendemos que podemos consultar o banco de dados de duas formas -- por localização e por atributo. Neste exercício nós nos concentramos em consultas por atributo. As ferramentas utilizadas para isso foram RECLASS, ASSIGN e OVERLAY. RECLASS e ASSIGN são similares e podem ser utilizados para isolar categorias de interesse localizadas em um mesmo mapa. OVERLAY nos permite combinar consultas de pares de imagens e através disso produzir consultas compostas.

Um conceito particularmente importante que aprendemos nesse processo foi a expressão de consultas simples na forma de imagens *Booleanas* (imagens contendo somente zeros e uns). Expressar os resultados de consultas por atributo único como imagens *Booleanas* permitiu-nos utilizar operações *Booleanas* ou lógicas com as operações aritméticas de OVERLAY para efetuar consultas por atributos múltiplos. Por exemplo, nós aprendemos que a operação de multiplicação de OVERLAY produz um AND (e) lógico quando são usadas imagens *Booleanas*, enquanto a operação de cobertura produz um OR (ou) lógico.

Nós também vimos como uma imagem *Booleana* pode ser usada em uma operação de OVERLAY para manter alguns valores e mascarar os demais através da atribuição do valor zero aos mesmos. Em tais casos, a imagem *Booleana* pode ser tomada como uma máscara *Booleana* ou simplesmente como uma imagem máscara.

É extremamente importante entender a lógica da reclassificação e da sobreposição de imagens (com OVERLAY) porque elas constituem o centro de muitas análises que usam SIG. A melhor forma de conseguir esse entendimento é efetuando cada operação e examinando o resultado para verificar se ele se parece com o esperado. Entretanto, O IDRISI for Windows oferece um atalho que possibilita aos usuários executar várias operações individuais a partir de uma única caixa de diálogo -- A CALCULADORA PARA IMAGENS. A Calculadora para imagens permite a entrada de expressões lógicas ou matemáticas usando constantes ou imagens como variáveis. Ela oferece muitas das funções de RECLASS, OVERLAY, SCALAR e de TRANSFORM em uma caixa de diálogo.

- r) Para ver como a criação de BESTSORG neste exercício pode ser feita com a Calculadora para imagens, acione-a a partir do menu Análise/Consulta ao banco de dados e escolha o tipo de operação Expressão lógica (estamos procurando o AND lógico de dois critérios). Chame a imagem de saída de BESTCALC (daremos um nome diferente para podermos comparar o resultado com a imagem BESTSORG produzida há pouco). Agora entre com a expressão usando os botões da Calculadora para imagens, reproduzindo a expressão mostrada a seguir. Note que você pode pressionar o botão Inserir imagem para escolher um arquivo da lista de arquivos disponíveis, cujo nome ficará automaticamente entre colchetes.

BESTCALC = ([DRELIEF]<=9)AND([DSOILS]=2)

Pressione Processar expressão e, quando o cálculo estiver concluído, compare o resultado com aquele obtido anteriormente, chamado BESTSORG (você deve mudar a tabela de cores para QUAL256).

Note que não podemos concluir completamente nossa análise apenas com a Calculadora para imagens porque ela não inclui as funções GROUP e AREA. Note também que no desenvolvimento de nosso modelo é muito mais fácil identificar erros no processo se fizermos cada passo individual com o módulo apropriado e examinarmos cada resultado. Embora o uso da Calculadora para imagens nos permita ganhar tempo, ela não nos fornece as imagens intermediárias para verificarmos nosso progresso lógico. Em função disso, em muitos dos exercícios restantes iremos optar por usar os módulos individuais.

Neste ponto você pode apagar todos os arquivos que foram criados neste exercício. A função Excluir pode ser encontrada na Manutenção de arquivos do menu Arquivo. Apenas não apague os dados originais DSOILS e DRELIEF.



## 6. Operadores de distância e de contexto

Neste exercício<sup>27</sup> introduziremos dois novos grupos de operações analíticas (após a consulta ao banco de dados e a álgebra com mapas) -- operadores de distância e de contexto. Os *operadores de distância* calculam distâncias a partir de uma feição única ou de um conjunto de feições. Em um ambiente raster eles produzem uma imagem resultante onde cada *pixel* recebe um valor representando a sua distância da feição mais próxima. Há vários conceitos de distância que podem ser modelados. A distância *Euclidiana* ou *linear*, com a qual estamos mais familiarizados, é o tipo de análise de distância que usaremos neste exercício. No IDRISI for Windows, distâncias Euclidianas são calculadas com o módulo DISTANCE. No Exercício 8 será explorado outro tipo de análise de distância, conhecido como distância de custo.

Os *operadores de contexto* determinam o novo valor de um *pixel*, baseado no valor dos *pixels* ao seu redor. O módulo GROUP, utilizado no Exercício 5 para identificar grupos contíguos de *pixels*, é um operador de contexto, uma vez que o identificador atribuído a qualquer *pixel* depende do valor dos *pixels* à sua volta. Neste exercício, nos familiarizaremos com outro operador de contexto denominado SURFACE, o qual será usado para calcular as declividades a partir de uma imagem de relevo. O valor de declividade atribuído a cada *pixel* depende de sua altitude e da altitude dos seus quatro vizinhos mais próximos.

Utilizaremos estes operadores de distância e de contexto e as ferramentas exploradas em exercícios anteriores para realizar uma das tarefas de análise mais comuns em SIG -- *mapeamento de aptidão*, um tipo de avaliação por critérios múltiplos. Um mapa de aptidão indica os locais próprios a um determinado propósito. Ele é produzido a partir de várias imagens, cada uma representando todas as áreas que atendem a um determinado critério. Aqui, imagens *Booleanas* serão combinadas usando-se o módulo OVERLAY para produzir um mapa final que mostra os locais que satisfazem todos os critérios especificados. Este tipo de avaliação *Booleana* por critérios múltiplos é freqüentemente chamado de mapeamento de restrições, já que cada critério é definido por uma imagem *Booleana* indicando áreas aptas (valor 1) ou impróprias a determinado uso (valor zero).<sup>28</sup> Os mapas que você fez em exercícios

---

<sup>27</sup> A esta altura dos exercícios, espera-se que você já seja capaz de operar módulos como o Lançador de visualização, RECLASS e OVERLAY sem instruções detalhadas. Caso você não saiba como preencher as caixas de diálogo, use as sugestões padrão. Entretanto, é uma boa idéia colocar títulos descritivos para os arquivos de saída ao invés de deixar as caixas de diálogo em branco.

<sup>28</sup> A avaliação por critérios múltiplos é descrita com maior detalhamento no capítulo *Apoio à decisão* na seção *TÓPICOS ESPECIAIS* do Manual do Usuário. É introduzida uma lógica diferente. Enquanto critérios que são absolutamente aptos ou absolutamente impróprios para a seleção (chamados restrições) são representados por imagens *Booleanas*, outros critérios (chamados fatores) são representados por imagens contínuas nas quais os valores indicam o grau de aptidão de cada *pixel*. Estas imagens contínuas de fatores são então agregadas usando um número de operações possíveis e multiplicadas pelas imagens *Booleanas* das restrições. O resultado é

anteriores indicando áreas para o cultivo de sorgo e de piretro são exemplos simples de mapeamento restrições.

Nosso problema neste exercício é encontrar todas as áreas adequadas à localização de uma fábrica de manufaturados leves numa pequena região no centro de Massachusetts (USA), próximo à Clark University. A companhia industrial está preocupada, primeiramente, que a área escolhida esteja em local plano (com declives inferiores a  $2,5^\circ$ ) e que seja uma área contínua de pelo menos 10 hectares. Já os técnicos da prefeitura estão interessados em proteger reservatórios de água da cidade, tendo especificado que nenhuma obra deverá ocorrer a menos de 250 m de qualquer reservatório. Adicionalmente, é necessário considerarmos que nem toda a superfície do terreno está disponível para essa obra. De fato, nesta área apenas superfícies cobertas por vegetação florestal estão disponíveis. Resumindo, locais adequados ao desenvolvimento devem estar:

- i) Em terras com declive inferior a  $2,5^\circ$ ;
- ii) Em áreas a mais de 250 m em torno dos reservatórios de água;
- iii) Em terras atualmente cobertas por florestas;
- iv) Em área contínua superior a 10 ha.


Você tem duas imagens desta área: um mapa de relevo, denominado RELIEF, e um mapa de uso do solo, denominado LANDUSE. A área de estudo é pequena para acelerar seu progresso neste exercício.

- a) Para se familiarizar com a área de estudo, execute ORTHO a partir do menu Visualização, escolhendo RELIEF como a imagem de superfície e LANDUSE como a imagem de cobertura. Aceite o nome ORTHOTMP e os demais parâmetros padrão para a imagem de saída. Indique que você quer usar a tabela de cores personalizada LANDUSE e uma legenda e escolha uma resolução de saída menor do que a configuração do seu Windows (por exemplo, se seu monitor está ajustado para  $1024 \times 768$ , escolha uma saída de  $800 \times 600$ ).

Como você pode ver, a área de estudo é dominada por floresta decídua e tem topografia ondulada.

Agora iremos resolver o problema da aptidão em quatro passos, um para cada critério de aptidão. O primeiro critério listado determina como aptas áreas em terrenos cuja declividade é inferior a  $2,5^\circ$ . Nosso objetivo neste primeiro passo é produzir uma imagem *Booleana* para áreas que preenchem este critério. Nós a chamaremos de SLOPEBL.

1. Antes de ler adiante, desenhe abaixo um modelo cartográfico completo, com o nome dos módulos e das imagens, mostrando os passos necessários à produção de SLOPEBL.



- b) Visualize RELIEF<sup>29</sup> com a tabela de cores Idrisi 16 e a opção de autoescalamento. Examine os valores com o modo de consulta do cursor.

Os limites entre cores nesta visualização são similares às curvas de nível em um mapa topográfico. Quanto mais próximas estiverem as curvas umas das outras, mais rapidamente a altitude está mudando e, conseqüentemente, mais íngreme é a encosta.

Criar um mapa de declividades manualmente é muito tedioso. Basicamente, ele requer que o distanciamento entre curvas de nível seja avaliado em todo o mapa. Como freqüentemente ocorre, tarefas tediosas para humanos são simples para computadores (o oposto também tende a ser verdadeiro -- coisas

---

uma imagem de aptidão com valores contínuos que oscilam de inapto até altamente apto.

<sup>29</sup> Para este exercício certifique-se de que as Preferências de visualização estão configuradas com os valores padrão pressionando o botão Padrões do sistema. Escolha então Legenda visível e pressione OK.

que parecem simples e intuitivas para nós são normalmente difíceis para computadores). No caso de modelos topográficos digitais raster (tais como a imagem RELIEF), o declive em qualquer célula pode ser determinado comparando sua altitude com a altitude de cada uma de suas células vizinhas. No IDRISI for Windows, esta operação é realizada usando-se o módulo SURFACE. De forma similar, SURFACE pode ser usado para determinar a direção de orientação da encosta (*aspecto*) e a maneira pela qual a luz do Sol iluminaria a superfície considerando-se uma posição específica do Sol (*sombreamento analítico*).

- c) Execute SURFACE a partir do menu Análise/Operadores de contexto. Calcule a declividade em graus usando RELIEF como modelo digital de entrada. Chame a imagem de declividades resultante SLOPES. Examine alguns dos valores usando o modo de consulta do cursor.
- d) Outra maneira de olhar para as informações deste mapa de declividades é sobrepondo-o à superfície de elevação usando o módulo ORTHO, como fizemos anteriormente com a imagem do uso do solo. Entretanto, a imagem de cobertura para ORTHO deve ter dados com valores inteiros e com no máximo 256 níveis (0 a 255). Execute STRETCH a partir do menu Visualização para fazer um realce linear de em SLOPES. Especifique SLOPEC como imagem de saída e aceite as demais sugestões padrão para os parâmetros da imagem da saída (256 níveis, 0 como o valor mínimo e 255 como valor máximo). A seguir execute ORTHO com RELIEF como superfície e SLOPEC com imagem de cobertura. Use a tabela de cores Idrisi 256 e todos os outros parâmetros pré-definidos.

A imagem chamada SLOPES pode ser agora reclassificada para produzir uma imagem *Booleana* que preenche nosso primeiro critério -- áreas com declividade inferior a 2,5°. (*Não use SLOPEC!*. Via de regra, imagens submetidas a realce como SLOPEC só deveriam ser usadas para visualização, nunca para análise. Apenas dados originais deveriam ser usados para análise).

- e) Use RECLASS para criar uma imagem *Booleana* de todas as declividades inferiores a 2,5°. Neste caso, precisaremos atribuir 1 para todos os declives entre 0 e 2,5° e 0 para todos aqueles declives iguais ou maiores que 2,5°. Chame a imagem resultante de SLOPEBL e examine o resultado.

O segundo critério para localizar a fábrica de manufaturados leves estabelece que as áreas devem estar além de uma zona tampão de 250m ao redor dos reservatórios. Nosso segundo passo é criar uma imagem *Booleana* que represente esta condição.

2. Antes de continuar a leitura, esquematize abaixo um modelo cartográfico para este passo da análise. Chame a imagem final de BUFFERBL.



O novo módulo que necessitamos usar neste passo é DISTANCE. Dada uma imagem que apresenta um conjunto de feições, DISTANCE irá calcular uma nova imagem na qual o valor armazenado em cada célula é a menor distância entre ela e a feição mais próxima. O resultado é, portanto, uma superfície de *distâncias* (uma representação *espacialmente contínua* das distâncias). No nosso caso, os reservatórios d'água serão as feições a partir das quais calcularemos uma superfície de distâncias. A superfície de distâncias resultante pode então ser reclassificada em duas classes -- aqueles *pixels* que estão a mais de 250m dos reservatórios (aptos) e aqueles que estão a menos de 250m dos reservatórios (impróprios).

- f) Visualize a imagem LANDUSE usando a tabela de cores personalizada LANDUSE e uma legenda. Determine o identificador inteiro dos reservatórios e use então RECLASS ou ASSIGN para criar uma imagem *Booleana* de reservatórios denominada RESERV.
- g) Execute DISTANCE a partir do menu Análise/Operadores de distância e especifique RESERV como a imagem de feições e RESDIST como a imagem de saída.

- h) Examine os valores individuais dos dados em RESDIST usando o modo de consulta do cursor. Observe como os valores de distância variam continuamente. Para confirmar que RESDIST é realmente uma superfície suave, visualize-a com ORTHO (sem imagem de cobertura). Neste caso estamos olhando os dados de distância como uma superfície (anteriormente havíamos usado os dados de altitude como superfície). Como esperado, as distâncias aumentam (a superfície fica mais elevada) à medida que nos afastamos dos reservatórios.
- i) Use RECLASS para criar uma imagem *Booleana* e atribua valor 1 para os *pixels* que estão a 250m ou mais de um reservatório e atribua o valor 0 para aqueles *pixels* que estão a menos de 250m de um reservatório. Chame a imagem de saída BUFFERBL e examine o resultado.

A criação de faixas tampão é uma tarefa comum em SIG. No IDRISI for Windows, a combinação de DISTANCE e RECLASS está contida no comando BUFFER. A caixa de diálogo de BUFFER possibilita a você especificar de uma só vez todos os parâmetros para executar as operações DISTANCE e RECLASS.

- j) Se você quiser tentar, pode recriar BUFFERBL usando o comando BUFFER para ver como ele funciona.

A esta altura já temos dois dos quatro componentes exigidos para nosso mapa final de aptidão. Agora considere o terceiro -- apenas as áreas com florestas estão disponíveis para o desenvolvimento.

3. Descreva o conteúdo da imagem final para este critério e desenhe o modelo cartográfico mostrando os passos usados para produzi-la. Chame a imagem final de FORESTBL.

FORESTBL

- k) Use DESCRIBE (clique duas vezes no nome de LANDUSE na lista de arquivos da Composição) ou o modo de consulta do cursor para verificar os códigos de uso do solo para as duas categorias de floresta. Não considere as superfícies com pomares (*orchards*) e com florestas em solos úmidos (*for. wetland*) -- obviamente não poderemos construir sobre elas. Siga as instruções do modelo cartográfico que você desenhou há pouco para criar um mapa *Booleano* das áreas com florestas.

4. Que outra técnica você poderia ter usado para obter o mesmo resultado?

A condição que resta atender é que os locais aptos devem ter área igual ou superior a 10 hectares. Até agora, entretanto, nós não temos nenhum "sítio" para o qual possamos calcular a área. Nós temos três imagens *Booleanas* separadas, para cada uma das condições prévias. Antes de nos atermos ao critério área, devemos combinar estas três imagens *Booleanas* para obter os locais que preenchem os três critérios anteriores.

- l) Use OVERLAY para criar uma imagem *Booleana* composta mostrando as áreas que preenchem as primeiras três condições que especificamos. Para fazer isto você terá que combinar duas imagens e criar um resultado intermediário, o qual será então combinado com a terceira para produzir o resultado final. Chame este resultado final de COMBINED.

5. Que operação de OVERLAY você usou para produzir COMBINED? Esquematize um modelo cartográfico que ilustre os passos seguidos na geração de COMBINED a partir de SLOPEBL, BUFFERBL e FORESTBL.

COMBINED

- m) Examine COMBINED usando uma tabela de cores qualitativa. Existem várias áreas contíguas na imagem que mostram sítios potenciais para o nosso propósito. O último passo é determinar quais deles preenchem a condição de área mínima de 10 hectares.
- n) Produza um mapa mostrando todos os sítios de COMBINED que possuem 10 hectares ou mais. Chame a este mapa final de SUITABLE (Observe que há várias maneiras de fazer isto, todas elas aceitáveis. Você poderá achar útil ler a descrição dos módulos AREA e GROUP no Sistema de ajuda *on-line*. Caso você usar GROUP, faça-o *com diagonais*).
6. Quantos sítios aptos foram identificados? Esquematize um modelo cartográfico mostrando como você criou SUITABLE a partir de COMBINED.

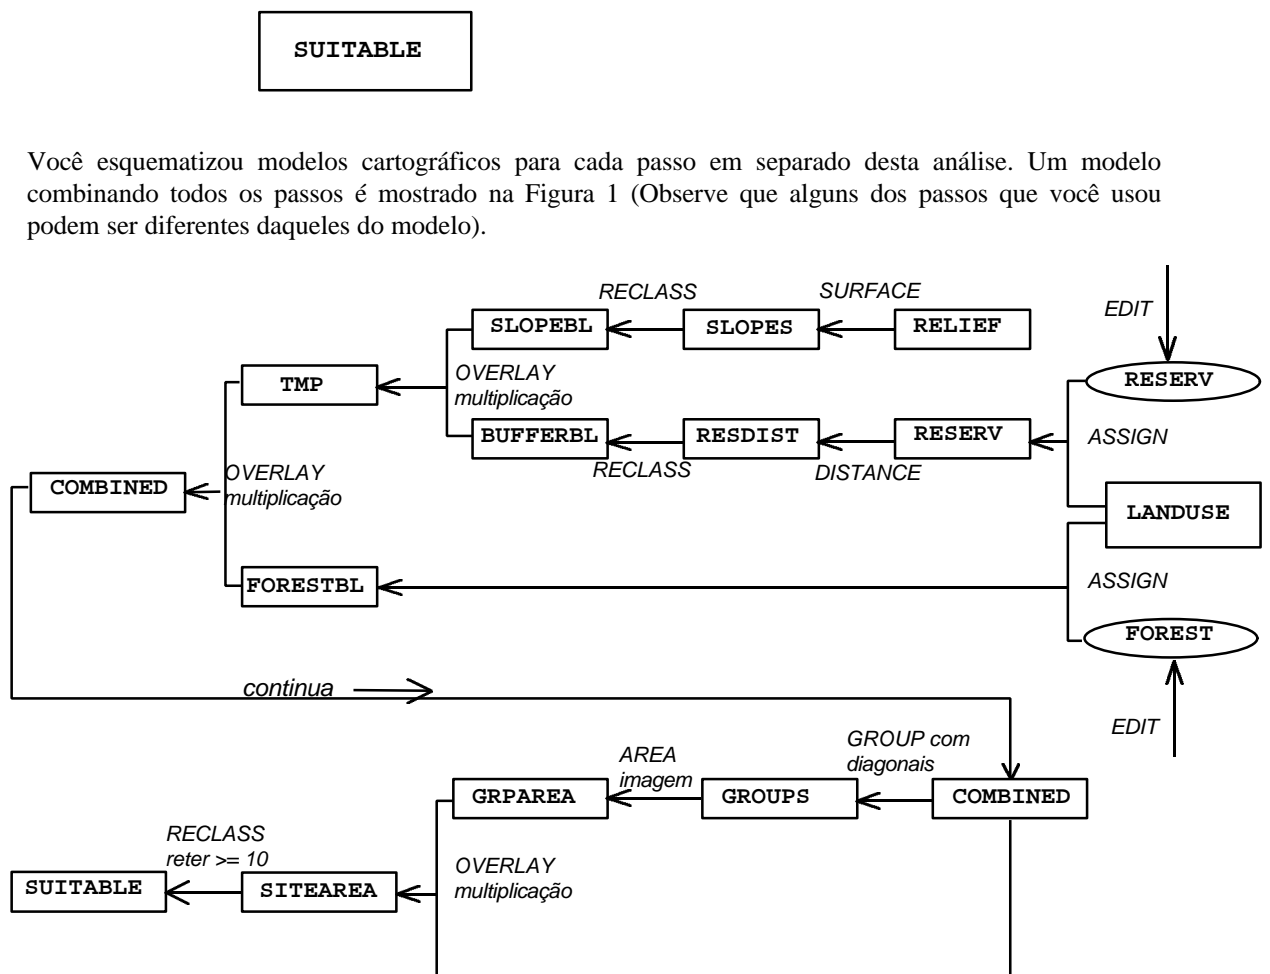


Figura 1

- o) Finalmente, para completar este exercício, crie uma imagem ORTHO que superponha a imagem com áreas aptas ao mapa de relevo. Para evitar uma visualização que apresente os locais aptos suspensos no ar, você terá que especificar um valor maior do que 0 para o fundo de SUITABLE. Use SCALAR ou ASSIGN para criar um novo mapa chamado SUIT2 a partir de SUITABLE, tal que tanto o fundo quanto as áreas aptas tenham valores diferentes de 0. Depois, use ORTHO com RELIEF como imagem de relevo e SUIT2 como imagem de cobertura.

Este exercício introduziu duas classes de funções de SIG importantes -- operadores de distância e operadores de contexto. Em especial, nós vimos como o módulo DISTANCE pode ser usado para criar uma superfície contínua de distâncias a partir de um conjunto de feições. Também vimos como



SURFACE, como operador de contexto, usa os valores de *pixels* vizinhos para calcular a declividade de cada *pixel* da imagem.

Vimos ainda como a álgebra *Booleana* efetuada com o módulo OVERLAY pode ser usada para três ou mais imagens através do uso de imagens temporárias. Finalmente, usamos o módulo ORTHO de forma exhaustiva para visualizar nossos dados em uma perspectiva tridimensional.

Não exclua SUITABLE nem as imagens originais LANDUSE e RELIEF. Você necessitará de todas elas no próximo exercício, onde usaremos uma macro para automatizar o processo de mapeamento de aptidão desenvolvido neste exercício.

## 7. Automação de análises com macros

Suponha que os planejadores que estabeleceram os quatro critérios do estudo de aptidão no Exercício 6 decidiram posteriormente que declividades até 4 graus, ao invés de 2,5 graus, deveriam ser consideradas aptas para o propósito desejado. Embora fosse bastante simples repetir o procedimento usando o novo critério (especialmente por termos desenhado o modelo cartográfico para o processo), seria também tedioso. Além disso, eles talvez queiram testar algumas variantes destes critérios.

Nós podemos automatizar nossas análises através do uso de macros. Uma macro é algumas vezes definida como um metaprograma, uma vez que ela é de fato um programa que executa um conjunto de programas. No IDRISI for Windows uma macro é um arquivo ASCII que lista, em ordem, cada módulo a ser usado e todos os parâmetros necessários para sua execução. Todo conjunto de módulos pode ser executado simplesmente indicando o nome do arquivo macro na caixa de diálogo da função *Executar Macro*, acionada a partir do menu Arquivo. Se tivéssemos criado uma macro para nossa análise de aptidão, poderíamos facilmente trocar qualquer parâmetro de qualquer módulo usando EDIT (p.ex., mudar de 2,5 para 4,0 no passo da reclassificação das declividades) e aí executar todo o processo novamente.

Para cada módulo do IDRISI for Windows que pode ser usado em um arquivo macro, existe um formato específico conhecido como *formato de comando macro*. Esta estrutura pode ser encontrada na descrição dos módulos no sistema de Ajuda *on-line*. O formato sempre inicia com o nome do módulo, seguido por um X para indicar que parâmetros devem ser tomados do arquivo e não da caixa de diálogo. Depois disso são dados todos os parâmetros necessários para a execução dos módulos em uma ordem e formato específicos. Estes parâmetros suprem toda a informação que você indicaria nas caixas de diálogo caso estivesse usando os módulos interativamente.

Arquivos macro devem ter a extensão *.IML* (*Idrisi Macro Language* -- Linguagem Macro do IDRISI). Se a macro for criada no módulo EDIT do IDRISI for Windows, a extensão *.IML* será automaticamente fornecida ao selecionar-se a edição de arquivos macro.

Observe que alguns módulos não possuem uma versão de comando macro. Estes módulos não produzem um arquivo como resultado (p.ex., DESCRIBE, LIST) ou são módulos que requerem interação com o usuário (p.ex., EDIT). Qualquer módulo que aparece no menu todo em letras maiúsculas pode ser usado em uma macro. Para informações mais detalhadas, veja o capítulo *Criação de Macros* no Manual do Usuário.

Neste exercício, escreveremos uma macro para toda a análise feita interativamente no Exercício 6. Todos os módulos usados naquele exercício podem ser empregados em macros, exceto EDIT. Uma vez que

EDIT não está disponível para uso em macros, nós podemos produzir os arquivos de valores necessários para uso em ASSIGN antes de executar a macro, ou podemos ainda substituir o uso de EDIT e ASSIGN por RECLASS. Nós faremos este último.

- a) Para iniciar, vamos olhar os passos que foram necessários para criar a imagem SLOPEBL a partir do modelo digital de elevação RELIEF, examinando a Figura 1 do exercício 6. O primeiro módulo que usamos foi SURFACE. Vá para o sistema de ajuda do IDRISI, procure por SURFACE e depois veja o item Comando macro deste módulo. A informação se parece com o seguinte:

*Comando macro de SURFACE*

*A execução deste módulo em modo batch requer os seguintes parâmetros:*

- 1 : x (para indicar que o modo batch está sendo usado)*
- 2 : número da operação (1=Declividade / 2=Orientação / 3=Declividade e orientação / 4=Sombreamento analítico)*
- 3 : nome do arquivo de entrada (a imagem a partir da qual serão feitos os cálculos)*
- 4 : nome do arquivo de saída (a nova imagem a ser criada com SURFACE)*
- 5 : Nome do segundo arquivo (se a opção foi Declividade e orientação, # se foi outra opção)*
- 6 : medida de declividade (“d”=graus / “p”=porcentagem)*
- 7 : fator de conversão (opcional -- converte elevações para unidades de referência)*

*p. ex., “surface x 1 relief slope # d  
“surface x 3 relief slope aspect p”*

*Para a operação Sombreamento analítico, os parâmetros 5 e 6 requerem:*

- 5 : azimute do sol (em graus)*
- 6 : elevação angular do sol (em graus)*

Para executar o primeiro passo da nossa análise (criar uma imagem de declividades a partir do modelo digital de elevação) iremos usar o seguinte comando macro:

```
surface x 1 relief slopes # d
```

- b) O próximo módulo que usamos foi RECLASS, para criar uma imagem *Booleana* de declividades menores que 2,5° a partir de nossa imagem de declividades. Novamente, procure pelo comando macro de RECLASS no sistema de ajuda *on-line*. Dadas nossas variáveis, a próxima linha de texto no arquivo macro será:

```
reclass x i slopes slopebl 2 1 0 2.5 0 2.5 999 -9999
```

- c) Execute EDIT e indique que você quer editar um arquivo macro. Selecione o arquivo EXER6. A macro já foi criada para você. Cada linha executa um módulo do IDRISI for Windows usando os mesmos parâmetros que usamos no exercício 6. Como a última linha indica, a imagem final será chamada de SUITAB2 em vez de SUITABLE, para podermos comparar as duas mais tarde. Quando houver terminado de digitar os comandos, salve o arquivo e saia. Observe que as linhas que iniciam com as letras REM são consideradas pelo programa como comentários e não serão executadas. Esses comentários são usados para documentar a macro.
- d) Gaste algum tempo comparando a informação sobre o formato de comando macro do sistema de ajuda com algumas das linhas da macro. Você pode diminuir a janela do sistema de ajuda para tê-la com a janela de EDIT ao mesmo tempo na tela.
- e) Quando tiver terminado de examinar a macro pressione o botão Sair. Não save mudanças que você possa feito inadvertidamente na macro.

- f) Escolha *Executar Macro* a partir do menu Arquivo, dê EXER6 como nome do arquivo macro e deixe a caixa de diálogo de parâmetros da macro em branco. Enquanto a macro roda, você verá um relatório na tela mostrando qual o passo que está sendo processado. Quando a macro terminar, visualize SUITAB2 com a tabela de cores QUAL256. Visualize também SUITABLE com a mesma tabela de cores e posicione-a de tal forma que você possa visualizar ambas as imagens simultaneamente.
1. As imagens são iguais? Que operação poderia ser usada para determinar se as imagens são exatamente as iguais?
- g) Abra a macro com EDIT e modifique-a de forma que as declividades inferiores a 4 graus sejam consideradas aptas. Pressione os botões Salvar e depois Sair. Execute a macro e compare os resultados (SUITAB2) com SUITABLE.
- h) Use EDIT para mudar a macro uma vez mais de forma a não incluir as diagonais no processamento de GROUP. Mude também o nome da imagem final para SUITAB3.
2. Descreva as diferenças entre SUITABLE, SUITAB2 e SUITAB3 e explique o que causou estas diferenças.

Comandos macro são efetivamente uma ferramenta muito poderosa na análise em SIG. Uma vez criados, eles permitem uma avaliação rápida de variações numa mesma análise. Exatamente a mesma análise pode ser executada rapidamente também para outra área de estudo simplesmente alterando-se os nomes dos arquivos de entrada originais. Como vantagem adicional, os arquivos macro podem ser salvos ou impressos juntamente com o modelo cartográfico correspondente. Isso fornecerá um registro detalhado para verificar possíveis fontes de erro em uma análise ou para a repetição do estudo.

**Nota:**

O IDRISI for Windows salva no seu diretório de programas todos os comandos que você executa em um arquivo texto, chamado arquivo LOG. Os comandos são gravados em um formato similar ao formato de comando macro que usamos neste exercício. Todas as mensagens de erro que são geradas são também gravadas. Cada vez que você abre o IDRISI for Windows um novo arquivo LOG é criado e o anterior é renomeado. Os arquivos LOG das últimas cinco sessões de uso do IDRISI for Windows são gravadas com os nomes IDRISIW.LOG, IDRISIW.LO1, IDRISIW.LO2, ... IDRISIW.LO5.

O arquivo LOG pode ser editado e salvo como arquivo macro usando EDIT. Escolha a opção Outro arquivo em outro diretório de EDIT e abra o arquivo LOG no diretório do programa IDRISI for Windows. Edite o arquivo para dar-lhe o formato de arquivo macro e escolha a opção Salvar como..., dê ao arquivo uma extensão .IML e salve-o no diretório de dados.



## 8. Distâncias de custo e caminhos de menor custo

No exercício 6 usamos um dos operadores de distância do IDRISI for Windows chamado DISTANCE. DISTANCE produziu uma superfície contínua de valores de distância Euclidiana a partir de um conjunto de feições. Neste exercício nós usaremos uma variante de DISTANCE chamada COST. Enquanto DISTANCE produz valores medidos em unidade como metros ou quilômetros, COST calcula a distância em termos de alguma medida de custo e os valores resultantes são conhecidos como *distância de custo*. De modo similar a DISTANCE, COST requer uma imagem de entrada a partir da qual as distâncias são calculadas. Diferente de DISTANCE, no entanto, COST requer uma *imagem de atrito* que indica o custo relativo do deslocamento através de cada célula. O resultado é uma imagem contínua conhecida como *superfície de distâncias de custo*.

Os valores de atrito são expressos em termos de uma medida de custo específica a ser calculada. Estes valores frequentemente têm um valor monetário igual ao custo de deslocamento ao longo da paisagem. Embora os valores do atrito possam ser expressos em outros termos, como tempo de viagem (no qual eles representam quanto tempo seria necessário para cruzar áreas com determinados atributos), eles podem representar também equivalentes energia, onde eles seriam proporcionais ao total de combustível gasto ao viajar de um *pixel* determinado até a feição mais próxima.

Estes valores de atrito são sempre calculados de acordo com um valor básico previamente fixado, geralmente igual a 1. Por exemplo, se nosso único atrito fosse profundidade de neve, nós poderíamos atribuir a áreas sem neve o valor 1 (isto é, o custo básico) e para áreas cobertas com neve valores maiores que 1. Se sabemos que atravessar áreas com acúmulo de neve entre 6 e 10 polegadas de profundidade custa o dobro do que atravessar áreas com solo nu, nós podemos atribuir àquelas células com profundidade de neve neste intervalo o valor de atrito 2. Valores de atrito são especificados como números reais para permitir valores fracionários, podendo assumir valores entre 0 e  $1,0 \times 10^{37}$ . Os atritos raramente são especificados com valores inferiores a 1,0 (o custo básico) porque um valor de atrito inferior a 1 representa uma *aceleração* ou *força* que atua como auxílio ao movimento.

Independente do esquema usado para representar os atritos, a imagem de distância de custo resultante irá incorporar os efeitos da distância percorrida e do atrito encontrado ao longo do caminho. Além disso, como os valores de atrito são sempre usados para calcular a distância de custo, esta será sempre relativa ao valor de atrito ou custo básico. Por exemplo, se para uma célula é atribuído o valor 5,25, isto indica que custa cinco vezes e um quarto mais do que o custo básico chegar a esta célula a partir da feição mais próxima de onde partiu o cálculo do custo. Em outras palavras, para chegar a esta célula custa o mesmo que cruzar cinco células e um quarto com valor de atrito básico. O módulo SCALAR poderia ser usado

para transformar os valores de distância de custo em valores monetários atuais, tempo ou outras unidades.

A discussão acima focaliza *atrito isotrópico*, um dos dois tipos básicos de efeito de atrito. Atritos isotrópicos são independentes da direção de movimento. Por exemplo, a superfície de uma estrada pode ter um atrito específico independente da direção em que se viaja. A superfície da estrada possui características (pavimentação, lama, etc.) que tornam o movimento mais fácil (baixo valor de atrito) ou mais difícil (alto valor de atrito). Nós trabalharemos com este tipo de superfície de atrito neste exercício. O módulo COST do IDRISI for Windows considera efeitos de atrito isotrópicos.

Aqueles atritos que variam em intensidade dependendo da direção do movimento são conhecidos como *atritos anisotrópicos*. Um exemplo pode ser o movimento em relação a um vento predominante. Um movimento contra o vento causaria um aumento do custo, enquanto que viajar a favor do vento auxiliaria o movimento, talvez até causando uma aceleração. De modo a efetivamente modelar tais efeitos de atrito anisotrópico, duas superfícies de atrito são necessárias -- uma imagem contendo informação sobre a magnitude do atrito e outra contendo informação sobre a direção do efeito de atrito. O módulo VARCOST é usado para modelar este tipo de superfície de custo. Para maiores informações, veja o capítulo *Análise anisotrópica de custo* no Manual do Usuário do IDRISI for Windows.

Neste exercício, nós trabalharemos apenas com atritos isotrópicos e, portanto, com o módulo COST. COST oferece dois algoritmos distintos para calcular superfícies de custo. O primeiro, Esforço de custo, é mais rápido e trabalha bem quando as superfícies de atrito não são complexas ou do tipo rede. O segundo, Crescimento de custo, pode trabalhar com superfícies de atrito muito complexas, incluindo barreiras absolutas ao movimento<sup>30</sup>.

Outro módulo interessante e útil que pode acompanhar COST é o módulo chamado PATHWAY. Uma vez tendo sido criada a superfície de custo, PATHWAY pode ser usado para determinar a rota de menor custo entre qualquer célula ou grupo de células definidas e a feição mais próxima a partir da qual as distâncias de custo foram calculadas.

Usaremos ambos os módulos COST e PATHWAY neste exercício.

Nosso problema diz respeito a uma nova planta industrial. A instalação e o funcionamento desta planta requerem um volume considerável de energia e necessitam de uma subestação transformadora, além de uma linha alimentadora ligada com a linha de alta tensão mais próxima. Naturalmente, os executivos da fábrica querem que a linha alimentadora tenha o menor custo possível. Nosso problema é determinar a rota de menor custo para a ligação com a linha de alta tensão.

- a) Examine a imagem chamada WORCWEST com a tabela de cores personalizada denominada WORCWEST<sup>31</sup>. Este é um mapa de uso do solo do subúrbio ocidental de Worcester, Massachusetts, USA, criado através da classificação de imagens de satélite LANDSAT TM (esta é uma técnica de processamento de imagem que será explorada no Exercício 14). Use a Composição para sobrepor à imagem o arquivo vetorial chamado NEWPLANT com o arquivo de símbolos personalizado denominado NEWPLANT. A localização da nova unidade industrial será mostrada por um grande círculo branco a noroeste da porção central da imagem. Adicione também o arquivo vetorial POWERLN à composição, usando o arquivo de símbolos personalizado denominado POWERLN. A linha de alta tensão existente está localizada na porção inferior esquerda da imagem e é representada por uma linha vermelha. São estas duas feições que nós necessitamos conectar pelo caminho de menor custo.

A análise de distância de custo requer dois planos de informação -- um contendo as feições a partir das quais as distâncias de custo serão calculadas e um descrevendo uma superfície de atrito.

<sup>30</sup> Para maiores informações sobre estes algoritmos, veja Eastman, J.R. 1989. Pushbroom Algorithms for Calculating Distances in Raster Grids. *PROCEEDINGS, AUTOCARTO 9*, 288-297.

<sup>31</sup> Para este exercício, certifique-se de que as Preferências de visualização estejam com a configuração padrão do sistema pressionando o botão Padrões do sistema. Depois ligue a opção de Legenda visível e pressione OK.

Nosso primeiro passo é criar uma superfície de atrito que defina os custos associados ao deslocamento através dos diferentes tipos de cobertura do solo existentes na área. Para os propósitos deste exercício, suponhamos que existe um custo básico para construir a linha de alimentação atravessando terras abertas, como campos de cultivo. Dado este custo básico, a Tabela 1 mostra os custos relativos de construção da linha de alimentação transpondo cada um dos demais tipos de uso do solo nos subúrbios de Worcester:

<i>Uso do solo</i>	<i>Atrito</i>	<i>Descrição</i>
Agricultura	1	o custo básico
Floresta decídua	4	as árvores necessitam ser desgalhadas, removidas e vendidas
Floresta de coníferas	5	esta madeira não possui o mesmo valor das madeiras de lei das decíduas, não permitindo cobrir todo custo
Urbano	1000	um custo muito alto -- virtualmente uma barreira
Pavimentação	1	o custo básico
Suburbano	1000	um custo muito alto -- virtualmente uma barreira
Água	1000	um custo muito elevado -- virtualmente uma barreira. Moradores não querem linhas de alta tensão afetando a vista dos lagos e reservatórios
Solo nu / pedregoso	1	o custo básico

Tabela 1

Você notará que alguns destes atritos são muito altos. Eles atuam essencialmente como barreiras. Entretanto, não desejamos proibir totalmente caminhos que cruzem estes tipos de uso -- apenas evitá-los através de um custo elevado. Por isso, nós simplesmente definimos o grau de dificuldade com valores extremamente altos. Isso também nos permite usar o algoritmo de custo bem mais rápido, chamado COSTPUSH – Esforço de custo (esse algoritmo não permite o uso de barreiras absolutas verdadeiras).

- b) Clique duas vezes no plano WORCWEST na lista de arquivos da Composição para acionar a descrição da sua informação de documentação. Determine os identificadores para cada uma das categorias de uso do solo em WORCWEST. Associe-os às categorias de uso do solo dadas na Tabela 1 e depois use EDIT para criar um arquivo de valores chamado FRICTION, o qual será usado para atribuir os valores de atrito às categorias de uso do solo de WORCWEST. Especifique o tipo de dado do arquivo de valores a editar como real. A seguir use ASSIGN para criar uma imagem de saída chamada FRICTION com WORCWEST como a imagem de definição de feições e FRICTION como o arquivo de valores.

Isso completa a criação da nossa superfície de atrito. A outra variável necessária para COST é a feição a partir da qual as distâncias de custo devem ser calculadas. COST requer isso na forma de uma imagem, não como um arquivo vetorial. Em função disso, precisamos criar uma versão raster do arquivo vetorial NEWPLANT.

- c) A partir do menu Reformatação, escolha Conversão raster/vetor e selecione POINTRAS. Digite NEWPLANT como o nome do arquivo vetorial de pontos. No IDRISI for Windows, a conversão de vetor para raster é feita através da atualização de uma imagem existente com a informação do arquivo vetorial NEWPLANT. Digite NEWPLANT como o nome da imagem a ser atualizada. Usaremos as opção padrão Modificar células pelo identificador dos pontos. Pressione OK. Como a imagem NEWPLANT ainda não existe, responda sim quando perguntado se quer acionar INITIAL para criá-la. Nós desejamos uma imagem do mesmo tamanho de WORCWEST, portanto indique que você quer copiar os parâmetros espaciais dela. Especifique byte como o tipo de dado, binário como o tipo de arquivo e zero como o valor inicial. Pressione OK.



- d) A imagem NEWPLANT será automaticamente visualizada. Caso você tenha dificuldades de visualizar o único *pixel* vermelho que representa a localização da fábrica, você pode usar a ferramenta de extração de janela para ampliar a porção da imagem que contém a fábrica. Você também pode adicionar o plano vetorial NEWPLANT, selecionar uma janela em torno do ponto e então omitir sua exibição clicando na caixa ao lado do seu nome na lista de arquivos da Composição. Você pode agora ver um único *pixel* com o valor 1 representando a nova planta industrial.

A operação que você acabou de concluir é conhecida como conversão de dados de vetorial para raster. Nós temos agora as duas imagens necessárias para executar o módulo COST -- a superfície de atrito (FRICTION) e a imagem de definição de feições (NEWPLANT).

- e) Execute COST a partir do menu Análise/Operadores de distância. Selecione o algoritmo Esforço de custo, especifique NEWPLANT como a imagem com feições de origem e FRICTION como a imagem de superfície de atrito. Denomine COSTDIST a imagem a ser criada. Seu computador poderá levar algum tempo para o cálculo caso ele não possua uma CPU muito rápida. Você pode fazer uma pausa neste ponto e deixar o computador processando. Outra alternativa é pular o próximo passo e continuar com o exercício, enquanto o módulo COST continua processando (O progresso no processamento do módulo é registrado no lado direita da barra de status).
- f) Quando o processamento tiver sido completado, use o modo de consulta do cursor para examinar alguns dos valores dos dados. Verifique que os menores valores da imagem ocorrem próximo à localização da nova planta e que eles aumentam com a distância da mesma. Observe que a passagem por apenas alguns *pixels* com atrito elevado, tais como corpos d'água, conduz a valores de distâncias de custo extremamente elevadas.

Para calcular o caminho de menor custo desde a fábrica até a linha de energia existente, necessitaremos alimentar o módulo PATHWAY com a superfície de distâncias de custo recém criada e com uma representação raster da linha de força existente.

- g) Desta vez vamos usar o módulo LINERAS para transferir a definição vetorial da linha de força para um arquivo imagem. Execute LINERAS a partir do menu Reformatação/Conversão raster/vetor, especifique POWERLN como o arquivo vetorial de linhas e POWER como o arquivo imagem a ser atualizado. Novamente, pressione Sim quando lhe for perguntado se deseja acionar o módulo INITIAL para criar a imagem POWER.

Agora estamos prontos para executar o módulo PATHWAY. PATHWAY escolhe a alternativa de menor custo cada vez que ele se move de um *pixel* para o próximo. Como a superfície de custo foi calculada usando a planta industrial como ponto de partida, os custos mais baixo ocorrerão próximo da mesma. Em função disso, PATHWAY começará pelas células ao longo da linha de força (POWER), continuando por escolher a alternativa de menor custo até conectar com o ponto mais baixo na superfície de distâncias de custo -- a planta industrial (Isto é análogo ao fluxo de água encosta abaixo, sempre correndo para a célula de menor altitude).

- h) Execute PATHWAY a partir do menu Análise/Operadores de distância. Especifique COSTDIST como superfície de custo, POWER como imagem destino e NEWLINE como imagem de saída. Examine o resultado. Você poderá usar a Composição para sobrepor NEWPLANT e POWERLN como planos adicionais, usando os arquivos de símbolos com o mesmo nome.

NEWLINE é o caminho que a nova linha de alimentação de energia deveria seguir de modo a incorrer no menor custo, de acordo com os valores de atrito estabelecidos.

- i) Crie agora uma imagem final, com legenda, na qual a nova linha de força (NEWLINE) seja sobreposta ao mapa de uso do solo existente (WORCWEST). Chame o resultado de SOLUTION

(Sugestão: para isto serão necessários vários passos. Use Documentar ou o modo interativo de edição da legenda<sup>32</sup> para mudar as entradas da legenda).

1. Como você criou a imagem chamada SOLUTION?
2. O lugar de encontro da linha de alimentação com a linha de energia existente é evidentemente a posição da nova subestação transformadora. Como você imagina que PATHWAY determinou que a nova linha de alimentação deveria encontrar a linha de energia existente neste local ao invés de qualquer outro ao longo da mesma? (Leia atentamente a descrição do módulo PATHWAY no sistema de ajuda *on-line*).
3. Qual seria o resultado de PATHWAY caso fosse usado sobre uma superfície de distâncias Euclidiana criada com o módulo DISTANCE, com a imagem NEWPLANT como origem e POWERLN como feição de destino?
4. Enquanto os cálculos que efetuamos são computacionalmente muito intensivos, o modelo cartográfico para a análise é relativamente simples e pode ser visto na Figura 1. Preencha o nome dos módulos nas caixas tracejadas (duas foram feitas para você) e adicione ao modelo os passos que você usou para chegar de NEWLINE a SOLUTION.

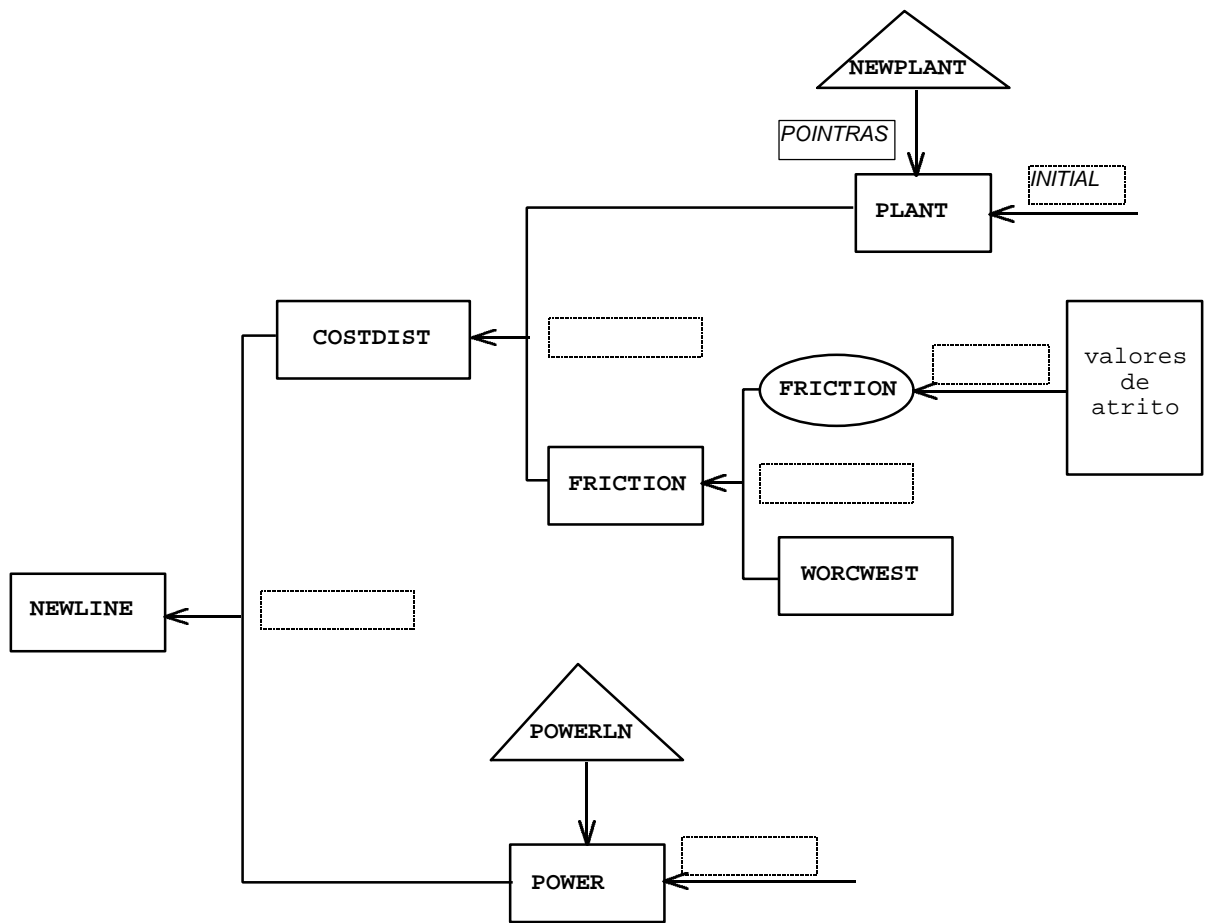
Neste exercício fomos introduzidos a distâncias de custo como um meio de modelar o movimento através do espaço onde vários elementos de atrito agem para tornar o movimento mais ou menos difícil. Isto é útil na modelagem de tempo de viagem e de custos monetários de movimento. Nós também vimos como o módulo PATHWAY pode ser usado com uma superfície de distâncias de custo para encontrar o caminho de menor custo que conecte as feições a partir das quais as distâncias foram calculadas a outras feições definidas como destino.

Adicionalmente, nós aprendemos como converter dados vetoriais para raster para uso com os módulos analíticos do IDRISI for Windows. Isto foi realizado com POINTRAS para dados vetoriais de pontos e LINERAS para dados vetoriais de linhas. Estes módulos necessitam uma imagem existente que será atualizada com a informação vetorial.

Não é necessário salvar nenhuma das imagens criadas neste exercício.

---

<sup>32</sup> Instruções para usar o modo interativo de edição da legenda podem ser encontrados no sistema de ajuda, sob o tópico Visualização.



Figural

## 9. Álgebra com mapas

Nos exercícios 5 e 6 usamos o módulo OVERLAY para efetuar operações *Booleanas* (ou lógicas). Entretanto, este módulo também pode ser usado como um operador aritmético entre imagens. Isto leva, assim, a outro importante conjunto de operações em SIG -- Álgebra com mapas.

Álgebra com mapas refere-se ao uso de imagens como variáveis em operações aritméticas normais. Com um SIG nós podemos realizar operações algébricas plenas com conjuntos de imagens. No caso do IDRISI for Windows, as operações matemáticas estão disponíveis em três módulos diferentes -- OVERLAY, TRANSFOR e SCALAR (e por extensão através da Calculadora para imagens, que inclui a funcionalidade desses três módulos). Como já vimos, enquanto OVERLAY realiza operações matemáticas entre duas imagens, SCALAR e TRANSFOR atuam sobre um único mapa. SCALAR é utilizado para alterar matematicamente todos os *pixels* em uma imagem através de uma constante. Por exemplo, com SCALAR nós podemos modificar um mapa de relevo de metros para pés, multiplicando cada *pixel* da imagem por 3,28084. TRANSFOR é usado para aplicar uma transformação matemática uniforme a cada *pixel* na imagem. Por exemplo, TRANSFOR pode ser usado para calcular o recíproco (1 dividido pelo valor do *pixel*) de uma imagem ou para aplicar transformações logarítmicas ou trigonométricas.

Estes três módulos nos oferecem capacidade de modelagem matemática. Neste exercício, nós trabalharemos primeiramente com SCALAR e OVERLAY. Também faremos uso de um módulo chamado REGRESS, que avalia relações entre imagens ou entre dados tabulares para produzir equações de regressão. Os operadores matemáticos serão então utilizados para avaliar as equações derivadas. Àqueles que não estão familiarizados com a modelagem da regressão, sugere-se que estudem a respeito deste importante tópico em um livro de estatística. Nós também faremos uso do módulo CROSSTAB, que produz uma nova imagem baseada em todas as combinações de valores de duas imagens.

Neste exercício criaremos um mapa de zonas agroclimáticas para o distrito de Nakuru no Quênia. O distrito de Nakuru localiza-se no Great Rift Valley na África oriental e contém vários lagos que são o habitat de imensos bandos de flamingos cor-de-rosa.

- a) Visualize a imagem NRELIEF com a tabela de cores Idrisi 256<sup>33</sup>.

Este é um modelo digital de elevação para a área. O Rift Valley aparece nas cores preto e azul escuro e suas encostas com elevações maiores são mostradas em tons de verde.

---

<sup>33</sup>Para este exercício, certifique-se de que as Preferências de visualização (no menu (Visualização) estão com a configuração original pressionando o botão Padrões do sistema. Ligue também a opção de Legenda visível e pressione OK.

Um mapa de zonas agroclimáticas é um meio básico para definir a aptidão climática de áreas geográficas para várias alternativas de cultivo. O procedimento ilustrado aqui é muito simples e foi adaptado do mapa de zonas agroclimáticas do Quênia em escala 1:1.000.000 (Kenya Soil Survey, Ministry of Agriculture, 1980). Ele reconhece que os principais aspectos do clima que afetam o crescimento das plantas são a disponibilidade hídrica e a temperatura. A disponibilidade hídrica é um índice do balanço entre a precipitação e a evaporação, e é calculada usando-se a seguinte equação:

$$\text{Disponibilidade hídrica} = \text{precipitação média anual} / \text{evaporação potencial}^{34}.$$

Embora outros fatores importantes para a agricultura, como duração e intensidade da estação seca e chuvosa e variabilidade anual não sejam levados em consideração neste modelo, esta metodologia oferece uma ferramenta básica para fins de planejamento nacional.

Este exercício difere dos exercícios 5 e 6 de uma forma importante. Nos Exercícios 5 e 6, nós identificamos e diferenciamos áreas aptas de todas as outras áreas. Nossas imagens finais foram imagens *Booleanas*. No presente caso, na imagem final cada *pixel* terá o valor da própria zona agroclimática à qual ele pertence em função dos critérios estabelecidos. Pode-se imaginar os exercícios 5 e 6 como um problema de *seleção*, enquanto este exercício pode ser entendido como um problema de *classificação*.

As zonas agroclimáticas são definidas como combinações específicas de zonas de disponibilidade hídrica e zonas de temperatura. Os valores para estas zonas variam conforme a Tabela 1.

Zona de disponibilidade hídrica	Intervalo de disponibilidade hídrica	Zonas de temperatura	Intervalo de temperatura (°C)
7	< 0,15	9	< 10
6	0,15 - 0,25	8	10- 12
5	0,25 - 0,40	7	12 - 14
4	0,40 - 0,50	6	14 - 16
3	0,50 - 0,65	5	16 - 18
2	0,65 - 0,80	4	18 - 20
1	> 0,80	3	20 - 22
		2	22 - 24
		1	24 - 30

Tabela 1

Para o distrito de Nakuru, a área mostrada na imagem NRELIEF, estão disponíveis três conjuntos de dados do Manual de Gerenciamento de Propriedades Agrícolas do Quênia (Kenya Farm Management Handbook) para nos auxiliar na produção do mapa de zonas agroclimáticas:

- i) uma imagem com o total médio anual da precipitação, denominada NRAIN;
- ii) um modelo digital de elevação, denominado NRELIEF;
- iii) tabelas com dados de temperatura média anual e altitude para nove estações meteorológicas.

Adicionalmente a esses dados, nós possuímos uma equação estabelecida pela pesquisa relacionando a evaporação potencial com a altitude no Quênia.

Vamos ver como estas peças se encaixam no modelo cartográfico ilustrando como nós produziremos as zonas agroclimáticas. Sabemos que queremos como produto final um mapa de zonas agroclimáticas para este distrito e sabemos também que estas zonas são baseadas em zonas de temperatura e de disponibilidade hídrica, conforme a Tabela 1. Dessa forma, necessitamos imagens representando as

<sup>34</sup> O termo evaporação *potencial* indica o total de evaporação que *ocorreria* caso a umidade fosse ilimitada. A evaporação efetiva pode ser bem inferior a essa, uma vez que podem ocorrer períodos de seca durante os quais simplesmente não existe umidade para ser evaporada.

zonas de temperatura (a qual nós chamaremos de TEMPZONE) e as zonas de disponibilidade hídrica (MOISZONE). A seguir, precisamos combiná-las de tal forma que cada combinação única de TEMPZONE com MOISZONE tenha um valor único no resultado (ACZONES).

Para produzir as imagens com as *zonas* de temperatura e de disponibilidade hídrica, necessitamos dispor de imagens contínuas da temperatura e da disponibilidade hídrica. Nós as chamaremos de TEMPERA e MOISTAVL. Essas imagens serão classificadas de acordo com os intervalos da Tabela 1 para produzir as imagens das zonas. O início do modelo está construído na Figura 1.




Figura 1

Infelizmente, nem a imagem de temperatura nem a de disponibilidade hídrica estão na lista dos dados disponíveis -- nós precisaremos derivá-las de outros dados.

A única informação disponível sobre a temperatura desta área é a das nove estações meteorológicas. Também temos informação sobre a altitude de cada estação meteorológica. Em grande parte da África oriental, inclusive no Quênia, a temperatura e a altitude estão estreitamente correlacionados. Podemos avaliar a relação entre estas duas variáveis para nossos nove pontos e se ela for consistente, podemos usar esta relação para derivar uma imagem com a temperatura (TEMPERA) a partir da imagem de altitudes disponível.

Esses elementos novos foram adicionados ao modelo cartográfico mostrado na Figura 2. Como não sabemos ainda a natureza exata da relação entre a temperatura e a altitude, nós não podemos preencher os passos para esta parte do modelo. Por ora, indicaremos que pode haver mais de um passo envolvido, usando uma linha tracejada.

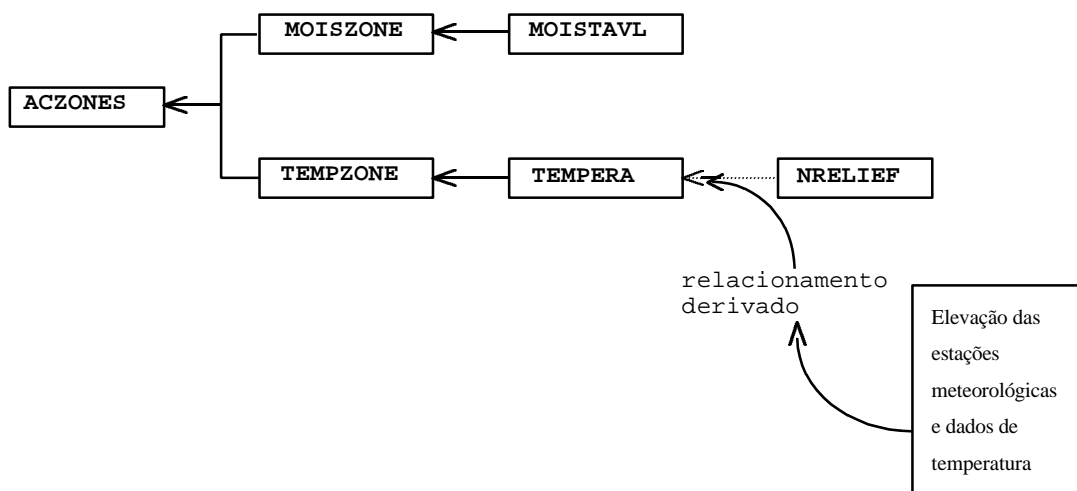


Figura 2

Agora vamos pensar na parte do problema referente à disponibilidade hídrica. Na introdução ao problema, a disponibilidade hídrica foi definida como a razão entre a precipitação e a evaporação

potencial. Sabemos que iremos necessitar de uma imagem de cada uma dessas duas variáveis para produzir MOISTAVL. Esses elementos estão adicionados ao modelo cartográfico na Figura 3.

Já temos uma imagem da precipitação pronta (NRAIN) no conjunto de dados disponíveis, mas não temos a imagem da evaporação potencial (EVAPO). Temos, entretanto, uma publicação técnica com a relação entre altitude e evaporação potencial. Como já temos o modelo digital de elevação, NRELIEF, podemos derivar a imagem da evaporação potencial usando esta relação definida. Como antes, não sabemos os passos exatos requeridos para produzir EVAPO antes de examinarmos a equação. Por ora, indicaremos que há uma ou mais operações necessárias usando a linha tracejada para nosso modelo cartográfico final na Figura 4.

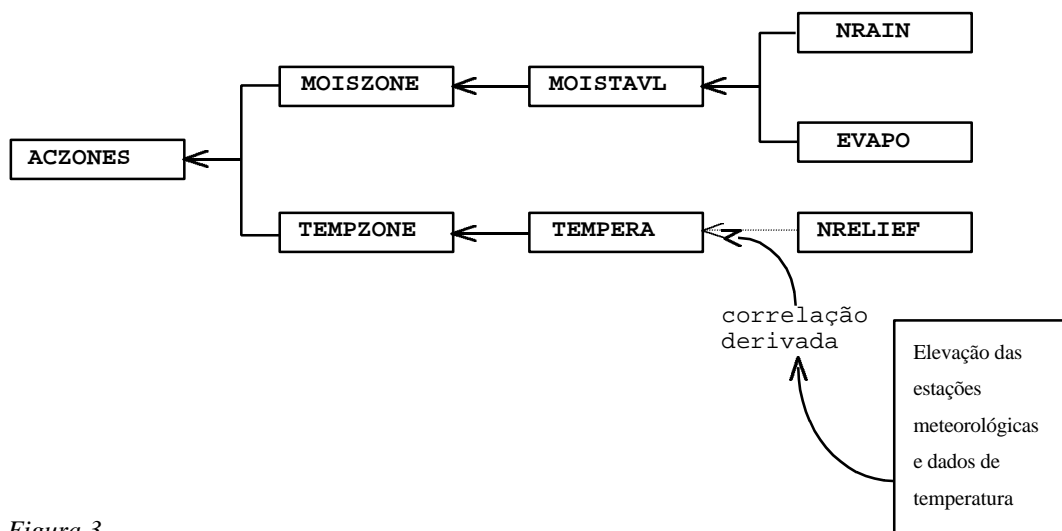


Figura 3

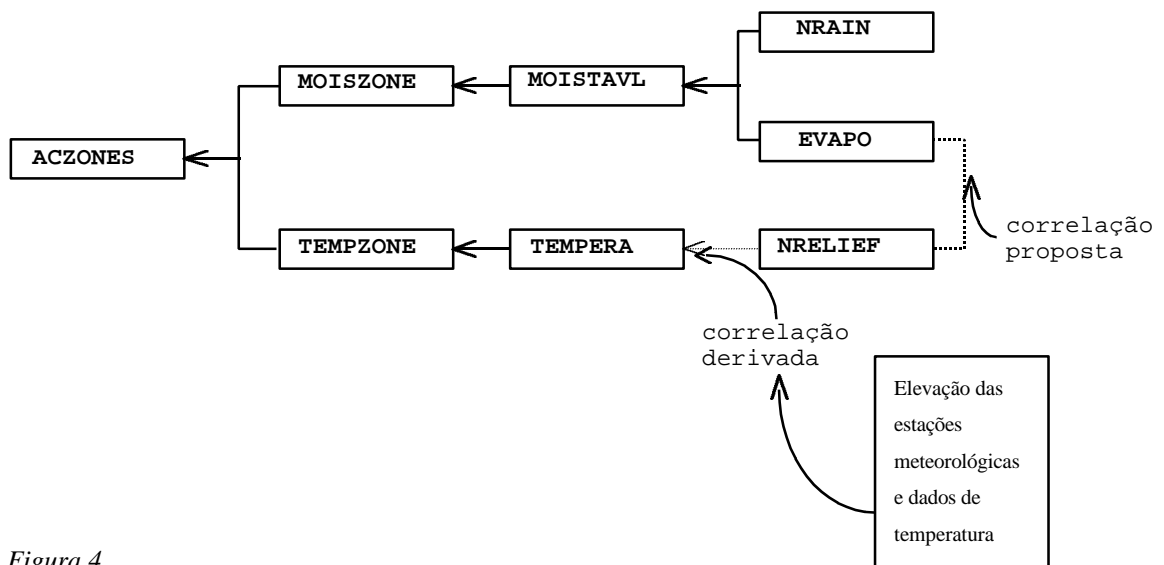


Figura 4

Agora que temos nossa análise organizada no modelo cartográfico, estamos prontos para iniciar a executar as operações com o SIG. Nosso primeiro passo será derivar a relação entre a altitude e a temperatura usando os dados das estações meteorológicas apresentados na Tabela 2.

Nº da estação	Altitude (pés)	Temperatura média anual (°C)
1	7086	15,7
2	7342	14,9
3	8202	13,7
4	9199	12,4
5	6024	18,2
6	6001	16,8
7	6352	16,3
8	7001	16,3
9	6168	17,2

Tabela 2

Podemos ver a natureza da relação com uma olhada inicial nos números -- quanto maior a altitude da estação, mais baixa a temperatura média anual. Entretanto, necessitamos uma equação que descreva esta relação de forma mais precisa. Um procedimento estatístico chamado análise de regressão poderá nos fornecer isso. No IDRISI for Windows, a análise de regressão é efetuada pelo módulo REGRESS.

REGRESS analisa a relação entre duas imagens ou entre dois arquivos de valores de atributo. No nosso caso, temos dados tabulares e podemos criar dois arquivos de valores de atributo usando EDIT. O primeiro arquivo de valores irá listar as estações e suas respectivas altitudes enquanto o segundo listará as estações e suas respectivas temperaturas médias anuais.

- b) Use EDIT, a partir do menu Entrada de dados, para criar esses dois arquivos de valores e denomine-os ELEV e TEMPER. Escolha real para o tipo de dados. Especifique as unidades de medida apropriadas e de um título a cada arquivo. Lembre que cada arquivo deve possuir duas colunas separadas por um ou mais espaços. A coluna da esquerda deve conter o número da estação (1-9) e a coluna da direita os dados de atributo.
- c) Quando você tiver concluído a criação dos arquivos de valores, execute REGRESS a partir do menu Análise/Estatística. Indique que deseja fazer uma regressão entre arquivos de valores. A seguir, você deve especificar o nome do arquivo contendo a variável independente. A variável independente é aquela que pensamos ser a *causa* da relação. Neste caso, dizemos que a altitude causa a alteração da temperatura. Outra forma de explicar isto é dizer que a variável dependente *depende* da variável independente. A temperatura é a nossa variável dependente porque ela *depende* da altitude. Indique ELEV como a variável independente e TEMPER como a variável dependente.

REGRESS irá exibir um gráfico da relação e a sua equação. O gráfico nos mostra várias coisas. Primeiro, ele mostra os dados da amostra como um conjunto de símbolos de ponto. Lendo os valores de X e de Y para cada ponto nós podemos ver a combinação da altitude com a temperatura em cada estação. A reta de tendência da regressão mostra o melhor “ajuste” da relação linear entre os dados para esta amostra de estações. Quanto mais próximos os pontos estiverem da reta de regressão, mais forte é a relação. O coeficiente de correlação (“r”) próximo da equação nos diz o mesmo numericamente. Caso a reta esteja inclinada para baixo, da direita para a esquerda, “r” terá valor negativo indicando uma relação “negativa” ou “inversa”. Este é o caso dos nossos dados, pois à medida que a altitude aumenta, a temperatura diminui. O coeficiente de correlação pode variar de -1,0 (relação fortemente negativa) para 0 (nenhuma relação) até +1,0 (relação fortemente positiva). No nosso caso, o coeficiente de correlação é -0,9652, indicando uma relação inversa muito forte entre a altitude e as temperaturas para as nove estações meteorológicas.

1. Qual é a equação? (Caso você esteja tendo problemas com a notação, a fórmula de uma regressão linear é  $Y = a + bX$ , onde  $a$  é o ponto intercepto do eixo das ordenadas ( $Y$ ) e  $b$  é a declividade da reta.  $X$  é a variável independente e  $Y$  a variável dependente).

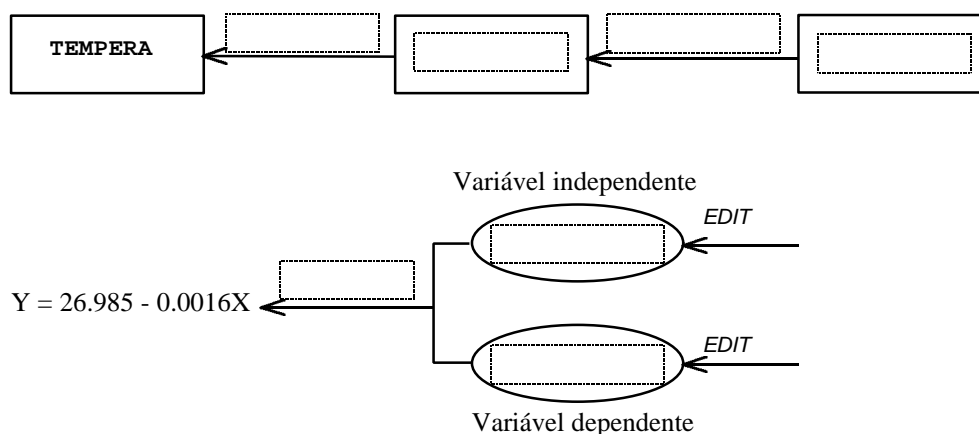


A equação é a expressão matemática da reta. Neste exemplo você deveria ter chegado, com arredondamentos, à seguinte equação:

$$Y = 26,985 - 0,0016X$$

De fato, esta equação está dizendo que você pode estimar a temperatura em qualquer local dentro desta região se você tomar a altitude em pés, multiplicá-la por -0,0016 e adicionar 26,985 ao resultado. Este é o nosso “modelo”.

- d) Este modelo pode ser desenvolvido com SCALAR a partir do menu Análise/Operadores matemáticos. Primeiro use SCALAR com NRELIEF como arquivo de entrada, para produzir um arquivo de saída temporário chamado TMP. Escolha a operação de multiplicação, indicando o valor -0,0016 como o valor escalar pelo qual multiplicar. Use SCALAR novamente, agora com TMP, para produzir TEMPERA adicionando 26,985. Dê um título a esta imagem e “graus Celsius calculados” como a unidade dos novos valores. A imagem resultante deveria ser muito similar ao mapa do relevo, exceto pelo fato de que os valores são invertidos -- altas temperaturas são encontradas no Rift Valley, enquanto baixas temperaturas são encontradas em altas altitudes. Para verificar isso, visualize NRELIEF novamente e diminua as imagens de modo a poder visualizar simultaneamente ambas as imagens na tela.
2. A seguir aparecem os passos que deixamos de lado no modelo cartográfico da Figura 4. Preencha nas caixas tracejadas sobre as setas o nome dos módulos que faltam e nas caixas tracejadas dos retângulos e elipses os nomes de arquivos ausentes.



Agora que temos nosso mapa de temperaturas, necessitamos criar um segundo mapa necessário para o nosso zoneamento agroclimático -- um mapa de disponibilidade hídrica. Como afirmado anteriormente, a disponibilidade hídrica pode ser estimada dividindo-se a precipitação média anual pela média anual da evaporação potencial.

Nós já temos a imagem da precipitação NRAIN, mas necessitamos criar a imagem da evaporação. A relação entre altitude e evaporação potencial foi desenvolvida e publicada por Woodhead (1968, Studies of Potential Evaporation in Kenya, EAAFRO, Nairobi) e constitui a seguinte equação:

$$\text{Evaporação potencial (mm)} = 2422 - (0,109 \times \text{altitude (pés)})$$

Conhecendo essa relação, podemos usar a imagem do relevo e derivar o total médio anual de evaporação potencial.

- e) Poderíamos aplicar esta equação usando SCALAR duas vezes como fizemos para produzir TEMPERA. Todavia, desta vez usaremos a Calculadora para imagens para chegar ao mesmo resultado. Acione a Calculadora para imagens a partir do menu Análise/Operadores matemáticos. Iremos efetuar uma operação matemática. Digite EVAPO como o nome do

arquivo de saída e depois entre com a seguinte expressão a processar (lembre que você pode pressionar o botão Inserir imagem para chamar uma lista de arquivos que podem ser selecionados diretamente):

2422 – (0.109\*[NRELIEF])

Pressione o botão Processar expressão.

- f) Temos agora as duas peças necessárias à produção do mapa de disponibilidade hídrica. Use OVERLAY a Calculadora para imagens para dividir NRAIN por EVAPO e chame o resultado de MOISTAVL. A imagem resultante tem valores que não possuem unidade de medida, já que dividimos precipitação em *mm* por evaporação potencial que também é em *mm*. Quando o resultado for visualizado examine alguns dos valores usando o modo de consulta do cursor. Os valores em MOISTAVL indicam o balanço entre precipitação e evaporação. Por exemplo, se uma célula tem o valor 1,0 como resultado, isto indica que existe um balanço exato entre precipitação e evaporação.

3. O que pode indicar um valor superior a 1?

4. O que pode indicar um valor inferior a 1?

Neste ponto temos toda informação que necessitamos para criar nosso mapa de zonas agroclimáticas (ACZONES). O governo do Quênia usa as classes específicas de temperatura e de disponibilidade hídrica listadas na Tabela 1 para formar as várias zonas de aptidão agrícola. Nosso próximo passo é portanto, dividir nossas superfícies de temperatura e de disponibilidade hídrica nestas classes específicas e encontrar as várias combinações existentes para o distrito de Nakuru.

- g) Primeiro, use a rotina RECLASS do menu Análise/Consulta ao banco de dados para dividir o mapa de disponibilidade hídrica nos intervalos indicados na Tabela 1. Esta é uma classificação personalizada com MOISTAVL como arquivo de entrada e MOISZONE como arquivo de saída.

- h) Mude a tabela de cores de MOIZONE para NDVI16 em vez da tabela qualitativa padrão.

5. Quantas zonas de disponibilidade hídrica existem na imagem? Por que isto é diferente do número de zonas informadas na Tabela 1? (Caso você tenha problemas em responder à pergunta, você pode visualizar o histograma de MOISTAVL, usando HISTO).

A informação que temos sobre as zonas é publicada para uso em todas as regiões do Quênia. Entretanto nossa área de estudo é apenas uma pequena parte do Quênia., motivo pelo qual algumas zonas não estão representadas em nosso resultado.

- i) A seguir, procederemos de forma similar para criar um mapa de zonas de temperatura. Antes disso, entretanto, vamos primeiro verificar os valores mínimos e máximos em TEMPERA, para evitar qualquer passo de classificação supérfluo. Use a rotina Descrever do menu Arquivo para verificar os valores mínimos e máximos em TEMPERA. Finalmente use RECLASS, dentro dos intervalos de classe da Tabela 1, para criar TEMPZONE. Novamente, mude a tabela de cores para NDVI16.

Agora que temos as imagens das zonas de temperatura e de disponibilidade hídrica, nós podemos combiná-las para criar zonas agroclimáticas. Cada zona agroclimática resultante deve ser o resultado de uma combinação única de zonas de temperatura e de umidade.

6. Anteriormente já usamos OVERLAY para combinar duas imagens. Dado o critério para a imagem final, por que não podemos usar OVERLAY para este passo final?

- h) A operação que atribui um novo identificador a cada combinação distinta de classes de entrada é conhecida como classificação cruzada. No IDRISI for Windows, isto é oferecido no módulo CROSSTAB do menu Análise/Consulta ao banco de dados. Execute CROSSTAB e especifique TEMPZONE como a primeira imagem e MOISZONE como a segunda imagem. Escolha Imagem de classificação cruzada e tabela como produtos de saída. Chame a imagem resultante da classificação cruzada de ACZONES. Quando a operação estiver concluída, a saída da classificação cruzada mostrará o número de células que pertencem à cada combinação de zonas de temperatura com zonas de disponibilidade hídrica. Após visualizar a tabela, examine a imagem ACZONES.

A imagem da classificação cruzada mostra todas as combinações entre as zonas de temperatura e de disponibilidade hídrica na área de estudo. Observe que a legenda para ACZONES mostra claramente estas combinações na mesma ordem que os nomes das imagens de entrada aparecem no título.

- k) Como uma forma de revisar os últimos passos do processo recém concluído, volte à Figura 2 e escreva o nome dos módulos usados para cada uma das operações.

Neste exercício, usamos OVERLAY, SCALAR e a Calculadora para imagens para realizar uma série de operações matemáticas básicas. Nós utilizamos imagens como variáveis em equações, através das quais derivamos novas imagens. Este tipo de modelagem matemática, também denominada álgebra com mapas, juntamente com a consulta ao banco de dados, formam o coração de um SIG. Também introduzimos o módulo CROSSTAB, que cria uma nova imagem baseado na combinação de classes de duas imagens de entrada.

Embora ainda novato neste campo, você tem agora não apenas as ferramentas básicas necessárias, mas também aquelas que você usará inúmeras vezes daqui para a frente.

### ***Problema opcional 1:***

As zonas agroclimáticas que nós acabamos de delinear têm sido estudadas por geógrafos para determinar a atividade agrícola ótima para cada combinação. Por exemplo, foi determinado que áreas aptas ao cultivo de piretro, uma planta cultivada para uso em repelentes de inseto, são aquelas definidas pela combinação das zonas de temperatura 6-8 e zonas de disponibilidade hídrica 1-3.

- l) Crie um mapa mostrando as regiões aptas ao cultivo de piretro.
7. Existem vários caminhos para criar um mapa de áreas aptas ao cultivo de piretro. Descreva como você fez seu mapa e como você o poderia ter feito usando outro método.

### ***Problema opcional 2:***

- m) Caso a atmosfera se tornasse 2 graus mais quente devido ao aquecimento global, áreas próprias ao cultivo de piretro iriam mudar. Nesse caso, a fórmula para a relação entre altitude e temperatura modificar-se-ia da seguinte forma:

$$\text{Temperatura} = 28,985 - (0,0016 \times \text{altitude})$$

(Isto também pode ser feito adicionando-se 2 graus a cada temperatura na comparação temperatura/altitude e executando REGRESS novamente).

Também seria necessário modificar nossa fórmula de evaporação potencial. As duas fórmulas originais podem ser usadas para derivar a relação entre a evaporação potencial e a temperatura. Retrabalhando algebricamente esta relação temos:

$$\text{Evaporação potencial} = 583,6469 + (68,125 \times \text{temperatura})$$

- n) Usando estas duas relações, determine o mapa das novas zonas agroclimáticas e as áreas aptas ao cultivo de piretro. Use a seguir a operação de subtração em OVERLAY, seguida de AREA, para determinar o número de hectares afetados por esta mudança climática. Finalmente, use a operação cover em OVERLAY para criar uma imagem mostrando as áreas próprias ao cultivo de piretro sob *ambos* os regimes climáticos (isto é, aquelas áreas não afetadas pela mudança de temperatura).
8. Qual é a área em hectares que mantém-se apta ao cultivo de piretro sob ambos os regimes climáticos?

Nós não iremos usar nenhuma das imagens criadas neste exercício em exercícios posteriores, de forma que você poderá excluir todas se desejar, exceto os arquivos de dados originais NRAIN e NRELIEF.

## 10. Oficina de banco de dados

Um *sistema de gerenciamento de bancos de dados* (SGBD) oferece um conjunto valioso de ferramentas para as aplicações de SIG, permitindo análises sobre a informação tabular armazenada em um arquivo de banco de dados. Não há nenhuma componente espacial nas operações efetuadas em um SGBD. Para incluir essa componente torna-se necessário integrar o SGBD com um SIG. Quando utilizado dentro de um SIG, um SGBD habilita a informação contida em um banco de dados a ser ligada a arquivos de definição geográfica em formato raster ou vetorial. Essa ligação possibilita a passagem da informação entre o componente SGBD do SIG e outros componentes, como o sistema de análise geográfica e o sistema de visualização cartográfica.

No IDRISI for Windows, essa possibilidade é oferecida no módulo Oficina de Banco de Dados. Caso você ainda não tenha feito, leia o capítulo sobre a *Oficina de banco de dados* na seção **FUNDAMENTOS DO SISTEMA** do Manual do usuário antes de prosseguir com o exercício. Ao contrário dos outros módulos do IDRISI for Windows, a Oficina de banco de dados é na verdade um programa completo adicionado ao IDRISI. Ele possui seus próprios menus, ícones e comandos, e pode executar uma variada gama de operações.

Neste exercício aprenderemos o básico para utilizar o módulo Oficina de banco de dados, fazendo especificamente o seguinte:

- explorar a base de dados,
- executar consultas por localização ao banco de dados,
- visualizar atributos do banco de dados na forma de mapas,
- executar consultas por atributos simples e múltiplos ao banco de dados,
- solucionar um problema envolvendo álgebra com mapas.

Neste processo, também iremos considerar as similaridades e diferenças entre a forma de execução dessas operações no módulo Oficina de banco de dados e em tarefas similares executadas nos exercícios 5 e 9.

## Parte 1: Exploração dos dados

No Exercício 4 utilizamos as altitudes do terreno e os limites de províncias da Etiópia para ilustrar o uso de arquivos de texto em composições de mapa. Neste exercício também utilizaremos dados da Etiópia, mas com as várias unidades administrativas que constituem as províncias, no arquivo chamado *awrajas*.

Começaremos examinando os planos de dados espaciais que definem as *awrajas*.

- a) Para este exercício desligue a opção Visualizar automaticamente as saídas dos módulos analíticos nas Preferências da visualização. Desligue também as opções Título visível e Legenda visível, e quaisquer outros componentes do mapa que você eventualmente tenha ligado. Durante este exercício nós vamos explicitar aquilo que queremos visualizar. Visualize a imagem AWRAJAS utilizando a tabela de cores personalizada denominada ETHIOPIA e a opção de autoescalonamento. Adicione o arquivo vetorial AWRAJAS utilizando o arquivo de símbolos Padrão usual. Use o modo de consulta do cursor para examinar alguns dos valores da imagem.

Os valores contidos na imagem AWRAJAS são *identificadores de feições*. Cada awraja possui um único identificador. Como você provavelmente percebeu, alguns possuem valores elevados e o sistema de numeração não aparenta ser sequencial (vários valores são deixados de fora). De fato, os identificadores indicam tanto as províncias quanto a awraja. Por exemplo, awrajas 401, 402, 403 e 404 pertencem todos à mesma província (aquela que chamamos de Gamo Gofa no Exercício 4) e são todas mostradas com a mesma cor, verde claro. As Awrajas 101, 102 e 103 pertencem a outra província (Arsi) e são todas mostradas na visualização com a mesma cor azul. Mediante a visualização da imagem em autoescalonamento, utilizando essa tabela de cores em particular, todos as awrajas contidas em uma única província são mostradas com a mesma cor. Sobrepor um arquivo vetorial com os limites nos ajuda a distinguir as awrajas individuais.

Nossos arquivos de definição de feições raster e vetorial, AWRAJAS, possuem identificadores únicos para cada awraja e permitirão sua ligação com o banco de dados.

- b) Abra o módulo Oficina de banco de dados pressionando o ícone correspondente ou selecionando-o do menu Arquivo/Mostrar conteúdo do arquivo. Você está agora à frente dos menus e ícones que comandam a Oficina de banco de dados. Escolha Abrir arquivo de banco de dados, a partir do menu Arquivo da Oficina de banco de dados, e selecione o arquivo Access ETHIOPIA.
- c) Caso necessário, use a barra de rolagem horizontal para visualizar todos os campos do banco de dados. O primeiro campo, IDR\_ID, contém os identificadores únicos das awrajas e tem os mesmos valores que foram pesquisados com o modo de consulta do cursor na imagem AWRAJAS. Este campo serve de chave para ligar a informação do banco de dados ETHIOPIA aos arquivos de definição de feições AWRAJAS e vice-versa. Outros campos do banco de dados incluem os nomes de cada awraja, população e números de vários tipos de rebanho.

Use a barra de rolagem vertical para olhar através dos registros do banco de dados. A altura e largura do mesmo podem ser ajustadas movendo as suas bordas com o mouse.

- d) Para aprender mais sobre esse banco de dados, vamos examinar a informação contida na sua documentação. Escolha Documentar banco de dados do menu Arquivo da Oficina de banco de dados. Aqui podemos ver que o arquivo está em formato Access e podemos determinar o número de campos (colunas) e de registros (linhas) da tabela. Pressionando a seta da direita do botão de rolagem Mudar campo, você poderá ver a informação específica sobre o próximo campo do banco de dados. Desloque-se através da informação apresentada aqui e depois feche a janela de Documentar banco de dados pressionando Cancelar.

## Parte 2: Consulta ao banco de dados por localização

Apesar do que vimos ser muito útil para examinar diretamente os valores no banco de dados, nós freqüentemente também necessitamos ver a sua distribuição espacial e fazer consultas. No Exercício 5 aprendemos que há basicamente duas formas de consulta ao banco de dados: por localização e por atributo. Dissemos que poderíamos fazer consultas por localização utilizando o modo de consulta do cursor em uma imagem na tela, assim como fizemos para examinar os identificadores de cada awraja. Naquele exercício trabalhamos com uma imagem de solos (DSOILS) e com um modelo digital de elevação (DRELIEF). Caso desejássemos saber o tipo de solo e a elevação em uma mesma localização necessitaríamos visualizar ambas as imagens e fazer a consulta separadamente, ou criar um arquivo de grupo para as duas imagens e usar a consulta expandida do cursor com o mesmo.

Neste exercício será possível fazer consultas para atributos múltiplos (armazenados no banco de dados) por localização, simplesmente usando o modo de consulta do cursor na imagem. Podemos fazer isso porque toda a informação de atributo no banco de dados está armazenada para cada awraja, e, portanto, todos os atributos têm a mesma geografia (em outras palavras, as feições que os atributos descrevem têm a mesma posição e forma). Depois de estabelecer uma ligação entre a janela de visualização e o banco de dados estaremos habilitados a consultar uma awraja e conhecer todos os atributos armazenados no seu registro do banco de dados (nome, população, número de cabeças de gado, etc.). Quando vários atributos forem coletados para as mesmas feições é muito eficiente estocá-los num banco de dados e ligar esse banco a um arquivo de definição de feições.

Podemos realizar consultas por localização de múltiplos atributos com esse banco de dados porque toda a informação de atributo foi coletada e estocada no banco de dados para a mesma unidade geográfica (as awrajas). Isto é completamente diferente da informação de atributo contida nas imagens DSOILS e DRELIEF. Naquele caso, tipos de solo e elevações têm distribuições geográficas que não estão relacionados entre si. As feições contendo os polígonos dos tipos de solo não têm feições correspondentes na imagem de relevo. De fato, não há outras feições além dos próprios *pixels* individuais na imagem de relevo. Se tivermos informações sobre várias outras variáveis, como precipitação, densidade de população e uso do solo, cada uma com sua própria geografia, necessitaremos de uma imagem separada para cada uma delas na nossa base de dados. É a natureza dos dados e a forma como foram coletados e armazenados no SIG que determina a lógica segundo a qual as consultas podem ser executadas.

No caso dos dados das awrajas da Etiópia, temos atributos múltiplos para as mesmas feições. Vamos continuar agora com a consulta por localização usando a Oficina de banco de dados.

- e) Nesta versão do IDRISI for Windows a consulta por localização é possível apenas com arquivos imagem. Para simplificar nossa exploração da Oficina de banco de dados, use a Composição para remover o plano vetorial AWRAJAS da visualização, mantendo apenas o plano raster AWRAJAS.

Para executar consultas por localização deve ser primeiro estabelecida uma ligação entre a janela de mapa e o banco de dados.

- f) Para estabelecer a ligação, selecione Fixar parâmetros de ligação à visualização a partir do menu Ligação da Oficina de banco de dados. Isso ativará a caixa de diálogo de Parâmetros de ligação à visualização.

### Janela de mapa

Todas as janelas de mapa que estão abertas serão mostradas na porção superior esquerda da caixa de diálogo. Os nomes mostrados são os mesmos que estão na barra superior de cada janela de visualização.

- g) Note que a janela de mapa AWRAJAS já está selecionada porque ela é a única que está aberta.

### Imagem para consulta com cursor

Como já mencionado, consultas por localização só são possíveis em arquivos imagem. Cada janela de

mapa deve conter um plano raster (imagem). Se a janela de mapa que você selecionou para ligação tem uma imagem, seu nome é mostrado aqui. Se não existir um plano raster na janela de mapa, consultas por localização não serão possíveis<sup>35</sup>.

- h) Veja que o plano raster AWRAJAS já está listado como a imagem a ser usada para consulta com cursor.

#### **Campo contendo identificadores de feições**

Já indicamos qual plano raster (imagem) deve ser ligado ao banco de dados. Precisamos agora indicar que campo do banco de dados contém os identificadores de feições encontrados na imagem. Essa informação permitirá ao programa localizar o registro da tabela que tem o mesmo identificador que qualquer *pixel* consultado na imagem.

- i) Mantenha o campo de identificador padrão IDR\_ID como o Campo contendo os identificadores de feições. Isso instrui a Oficina de banco de dados a localizar o registro da tabela que possui o mesmo valor no campo IDR\_ID que o valor obtido pela consulta com o cursor na imagem AWRAJAS. Isto completa tudo que é necessário para fazer consultas por localização. Pressione OK.
- j) Agora redimensione a janela da Oficina de banco de dados e mude a sua posição e a posição da janela de visualização, de forma que você possa ver ambas ao mesmo tempo.
- k) Clique na barra superior da janela de mapa para ativá-la. Selecione o modo de consulta do cursor na barra de ferramentas e consulte algumas posições na janela de mapa awrajas. Veja como, a cada vez que você consulta uma localização, o ponteiro no banco de dados se move e realça o registro da awraja correspondente. Você pode então navegar por todos os atributos da localização consultada usando a barra de rolagem horizontal da janela da Oficina de banco de dados. Se você consultar uma awraja que não possuir registro no banco de dados uma mensagem com esse aviso irá aparecer. Quando você tiver terminado de consultar o banco de dados, feche a janela de mapa AWRAJAS, mas mantenha a Oficina de banco de dados aberta com a tabela Ethiopia.

Ainda que muito simples, esse tipo de consulta por localização pode constituir uma ferramenta muito valiosa para exploração dos dados. Aqui nós estabelecemos a ligação dos locais consultados na imagem para os registros do banco de dados. Na parte seguinte deste exercício, iremos estabelecer uma ligação do banco de dados para a janela de mapa. Assim, estaremos aptos a visualizar os atributos do banco de dados na forma de mapas.

### ***Parte 3: Visualização de atributos do banco de dados***

Freqüentemente, desejamos visualizar os atributos contidos num campo de um banco de dados na forma de um mapa, de maneira a poder examinar sua distribuição espacial. Nesta parte do exercício seguiremos passo a passo os procedimentos para fazer essa visualização. Como primeiro exemplo criaremos um mapa de população.

- l) Nesta versão do IDRISI for Windows a visualização de atributos do banco de dados somente pode ser feita com planos vetoriais. Visualize o plano vetorial AWRAJAS usando o arquivo de símbolos IDRISI256. Nós iremos usar este plano vetorial que contém a definição geográfica das nossas feições, as awrajas, para visualizar os dados de atributos do banco de dados usando os códigos de cores do arquivo de símbolos escolhido. Neste ponto, as cores representam os identificadores das awrajas. A maioria dos valores são superiores a 255, e por isso são visualizados com o símbolo 255 (verde). Quando ligamos a visualização ao banco de dados, as

---

<sup>35</sup> Para criar uma imagem raster a partir de um arquivo vetorial, veja o tópico Conversão raster/vetor no sistema de ajuda *on-line*.



cores passam a representar os atributos do campo que escolhemos para visualizar. Iremos ver agora como escalonar os atributos em um intervalo que pode ser plenamente visualizado usando símbolos que vão de 0 a 255.

- m) Para dar uma melhor definição à visualização, adicione o plano vetorial AWRAJAS2 com o arquivo de símbolos Padrão usual.
- n) Agora que preparamos a visualização, vamos ligá-la com o banco de dados. Novamente vá para o menu Ligação/Fixar parâmetros de ligação à visualização da Oficina de banco de dados e selecione a janela de mapa AWRAJAS. Note que não há plano raster (imagem) disponível para a consulta com o cursor. AWRAJAS já está selecionado como plano Vetorial para visualizar atributos, pois ele é o único plano existente na janela de mapa. O Campo contendo identificadores de feições é novamente IDR\_ID. Cada polígono em AWRAJAS tem um identificador que corresponde a um registro em IDR\_ID. O Campo contendo códigos de visualização é POPULATION. Escolha POPULATION pressionando a seta ao lado da caixa de diálogo para Campo contendo códigos de visualização e selecionando POPULATION da lista. Pressione OK.
- o) Mude a visualização de modo *Booleano* (configuração padrão) para modo contínuo, clicando no ícone semelhante a um tabuleiro de xadrez (o quinto da esquerda para a direita na Oficina de banco de dados).
  - 1. Porque todas as AWRAJAS são visualizadas com o símbolo 255 (verde)?
- p) Examine os valores no campo POPULATION do banco de dados. Esses valores situam-se entre 39.073 e 1.711.686 (você pode verificar isso usando Documentar banco de dados como no passo “d”). Nossa visualização, entretanto, é limitada a 256 símbolos, numerados de 0 a 255. Quando um valor maior que 255 é encontrado, ele é exibido com o símbolo 255. Para conseguir visualizar adequadamente os dados de população precisamos autoescalonar<sup>36</sup> os valores para que coincidam com o intervalo de 256 símbolos.
- q) Para autoescalonar os dados de população, volte ao menu Ligação/Fixar parâmetros de ligação à visualização. Ligue Escalonar campo para visualizar e mantenha 256 como o número de níveis. Pressione OK. Os valores de população (campo POPULATION) foram escalonados para visualização em um intervalo de 0 a 255, ajustando-se agora aos códigos no arquivo de símbolos. Convém alertar que os novos valores calculados estão armazenados somente na memória e são usados para fins de visualização – os valores originais de população no banco de dados não foram alterados.

A operação de autoescalonamento que acabamos de fazer é o mesmo procedimento que o Lançador de visualização usa quando você visualiza uma imagem com autoescalonamento. Ele é simplesmente um ajuste linear que divide o intervalo original de valores em um número específico de classes de mesmo intervalo. Neste caso, o intervalo original dos valores de população foi dividido em 256 classes, às quais foram atribuídos os valores 0-255.

- r) Uma vez estabelecida a ligação, a informação contida nos outros campos do banco de dados pode ser facilmente visualizada. Vá para o menu Ligação/Fixar parâmetros de ligação à visualização e selecione o campo CATTLE para visualização. Pressione OK. Os valores do campo CATTLE são automaticamente escalonados e a visualização é atualizada. Examine o resultado, e depois siga o mesmo procedimento para os campos SHEEP e GOATS. Observe que o ícone de ligação à visualização pode ser usado como atalho para selecionar outro campo para visualização.

---

<sup>36</sup> O autoescalonamento aplica um ajuste linear aos valores originais dos dados de forma que eles se ajustem a um novo intervalo de valores. Para uma maior explanação veja como o autoescalonamento foi usado no exercício 4.

Nesta parte do exercício aprendemos a estabelecer a ligação entre o banco de dados e a janela de visualização para visualizar os atributos armazenados em um banco de dados na forma de mapa. Em alguns casos, ao invés de visualizar todas as feições, podemos selecionar um *subconjunto* de acordo com alguma condição. Isto significa consultar o banco de dados por atributo e é o objeto da próxima parte do exercício.

#### Parte 4: Consulta ao banco de dados por atributo - Filtro

Relembre que no Exercício 5 nós usamos RECLASS e ASSIGN para criar imagens *Booleanas* para cada uma das condições especificadas (consultas por atributos simples), e então as combinamos com OVERLAY para criar um resultado *Booleano* mostrando as áreas que atendiam todas as condições (consulta por atributos múltiplos). Uma consulta por atributo é executada na Oficina de banco de dados usando SQL (*Structured Query Language* - Linguagem de consulta estruturada). Embora o termo SQL intimide um pouco, utilizá-lo, atualmente, não é mais complexo do que usar uma sintaxe específica para expressar as condições de uma análise. Antes de continuar, gaste alguns minutos para revisar o item sobre SQL no capítulo *Oficina de Banco de Dados* da seção *FUNDAMENTOS DO SISTEMA* do Manual do Usuário do IDRISI for Windows.

Vamos começar nossa exploração da consulta por atributo na Oficina de banco de dados com um problema bastante simples de um único atributo:

Identificar todas as awrajas onde a população exceda 300.000 habitantes.

- s) Primeiro, certifique-se de que o campo do banco de dados que está sendo visualizado é POPULATION (e não CATTLE, SHEEP ou GOATS). Escolha a opção Criar filtro (SQL) do menu Consulta. A porção inicial do filtro já está escrita para você. Complete a condição WHERE como mostrado a seguir, de forma que a expressão SQL fique:

```
SELECT Ethiopia.*  
FROM Ethiopia  
WHERE POPULATION > 300000
```

Isto pode ser interpretado da seguinte forma:

selecione todos os campos do banco de dados Ethiopia  
do banco de dados Ethiopia  
para todos os registros que tem um valor no campo POPULATION maior do que  
300.000

Execute o filtro. Observe que os registros das feições que não atendem essa condição de filtragem não são mostrados no banco de dados -- somente os registros para awrajas com população excedendo 300.000 habitantes aparecem. A visualização é automaticamente atualizada para mostrar aquelas awrajas cuja população excede 300.000. Você pode usar, neste caso, o modo de visualização *Booleano* (clicando no ícone semelhante a um tabuleiro de xadrez), uma vez que nós dividimos nossos dados em duas classes -- aqueles que atendem à condição especificada e aqueles que não a atendem.

Se você tenha escolhido o modo de visualização *Booleano*, as awrajas que atendem a condição ficam todas preenchidas com o símbolo um, que é azul escuro no arquivo de símbolos de polígonos IDRIS256. Se você escolher o modo de visualização contínuo, cada awraja que atende a condição especificada será mostrada com o símbolo correspondente aos valores de população autoescalados. Em ambos os casos, as awrajas que não satisfazem à condição não são mostrados.

Há nitidamente um padrão espacial presente nos dados de população -- nós não o teríamos percebido se não tivéssemos estabelecido a ligação do banco de dados tabular à visualização espacial!

Vamos continuar nossa exploração da consulta ao banco de dados por atributo executando uma consulta por atributos múltiplos. No Exercício 5, utilizamos álgebra *Booleana* com OVERLAY e um par de imagens para produzir a condição lógica AND (e). Na Oficina de banco de dados utilizamos SQL para esse propósito. Aqui nós vamos usar SQL para produzir o AND lógico para o seguinte problema:

Identificar todas as awrajas onde a população exceda 300.000 habitantes  
AND (e)  
o número de cabeças de gado exceda 300.000.

- t) Primeiro, selecione Remover filtro do menu Consulta para retornar ao banco de dados completo. Depois escolha Criar filtro e complete a declaração WHERE da seguinte forma:

WHERE POPULATION > 300000 AND CATTLE > 300000

Não esqueça que, na visualização do resultado, se você usar o modo contínuo verá cores que significam somente população, já que é esse o campo escolhido para visualização de atributos. Neste caso particular, é mais razoável visualizar o resultado da nossa consulta por atributos múltiplos no modo *Booleano*.

- u) Remova o filtro atual e execute uma consulta por atributos múltiplos para aquelas awrajas onde POPULATION, CATTLE e SHEEP sejam superiores a 300.000.

2. Quantos awrajas satisfazem a essas três condições? Quais são seus nomes?

Os recursos de SQL oferecidos na Oficina de banco de dados podem ser usados para executar consultas bastante sofisticadas ao banco de dados. Podem também ser empregados para criar filtros de operações lógicas como OR (ou) e NOT (não), em adição ao AND (e) lógico que fizemos. Na próxima parte deste exercício vamos utilizar SQL para atender outro propósito. Ao invés de selecionar um *subconjunto* do banco de dados de acordo com critérios especificados através de um filtro com uma declaração WHERE, nós iremos calcular valores para novos campos utilizando a opção Calcular (SQL) e um comando SET.

### Parte 5: Álgebra com mapas - Calcular

No Exercício 9, nós usamos os módulos SCALAR e OVERLAY para desenvolver e aplicar equações nas quais imagens eram as variáveis. Nós mesmos desenvolvemos uma das equações utilizando o módulo REGRESS. Para a parte final deste exercício, iremos executar álgebra de mapas dentro da Oficina de banco de dados com a finalidade de avaliar uma série de equações que modelam as emissões de metano por parte dos rebanhos.

O contexto deste exercício vem da UNFCCC (United Nations Framework Convention On Climate Change - Convenção da Rede das Nações Unidas sobre Mudança Climática). Os Países signatários dessa rede são requisitados a relatar anualmente a emissão nacional de gases do efeito estufa. A emissão de metano relacionada aos rebanhos é um dado que precisa ser incluído. Nós vamos calcular isto para as awrajas da Etiópia.

As emissões de metano relacionadas aos rebanhos derivam de duas fontes -- da fermentação entérica (emissão por parte do animal vivo) e da decomposição do esterco. O total das emissões de metano por parte dos rebanhos pode ser então expressa pela seguinte equação:

$$\begin{array}{rcccl} \text{Total das Emissões} & = & \text{Componente Fermentação} & + & \text{Componente Decomposição} \\ \text{de Metano (kg)} & & \text{Entérica (kg)} & & \text{do Esterco (kg)} \end{array}$$

As equações para ambas as componentes são estabelecidas em material de suporte produzido pela ONU para os signatários da UNFCCC. Estas equações são as seguintes:

$$\begin{aligned} \text{Fermentação Entérica (kg)} &= \Sigma (\text{n}^\circ \text{ total de animais em cada rebanho} \times \text{constante do rebanho}) \\ &= (\text{CATTLE} \times 32) + (\text{SHEEP} \times 5) + (\text{GOATS} \times 5) \end{aligned}$$

$$\begin{aligned} \text{Decomp. Esterco (kg)} &= \Sigma (\text{n}^\circ \text{ total de animais em cada rebanho} \times \text{função do rebanho}) \\ &= \text{CATTLE} + (\text{SHEEP} \times (0,047 + 0,005 \times T)) + \text{GOATS} \times (0,057 + 0,0055 \times T) \end{aligned}$$

Onde T = temperatura média anual (graus Celsius)

A equação da componente de fermentação entérica é muito simples e praticamente direta. Baseado em dados empíricos, é sabido que um animal de cada tipo de rebanho emite um total médio anual de metano. Esse total médio é simplesmente utilizado como constante que é multiplicada pelo número de animais de cada rebanho.

A equação para a componente de decomposição do esterco é mais complexa. O esterco de cada cabeça de gado bovino produz um quilograma de metano por ano. Para ovelhas e caprinos, entretanto, a relação com a temperatura média anual precisa ser incorporada. Emissões de metano dessas duas fontes têm correlação positiva com a temperatura do ar circundante (ou seja, com o aumento da temperatura, é emitido mais metano pela decomposição do esterco).

Assim como fizemos em exercícios anteriores, agora que definimos o problema, vamos criar um modelo cartográfico mostrando os passos necessários para confeccionar o produto final. Neste caso, a maior parte dos nossos dados de entrada são campos específicos do banco de dados. Na simbologia apresentada na Introdução à Modelagem Cartográfica, campos do banco de dados são representados em modelos cartográficos pelos seus nomes, em letra maiúscula e sublinhados.

Para simplificar, vamos construir modelos cartográficos separados para cada uma das duas componentes (Fermentação Entérica e Decomposição do Esterco). O modelo com os passos necessários para criar o novo campo FERMENT, onde serão armazenados a contribuição total da fermentação entérica é muito mostrado na Figura 1. Todas as variáveis de entrada estão presentes no banco de dados.




Figura 1

- v) Antes de começar, precisamos remover o filtro anteriormente executado para restaurar todos os registros no banco de dados. Para fazer isso, escolha Remover filtro do menu Consulta.
- w) O próximo passo é adicionar um novo campo para receber nossos valores calculados. Para fazer isso, use Modificação/Adicionar campo e crie um novo campo chamado FERMENT. O tipo de dado para esse campo precisa ser real, uma vez que os valores a armazenar serão maiores que o intervalo de dois bytes do tipo inteiro. Depois escolha Calcular (SQL) a partir do menu Modificação. Observe que o início da expressão SQL já está escrita. Complete a expressão para que fique da seguinte forma:

```
UPDATE Ethiopia
SET FERMENT = (CATTLE*32) + (SHEEP*5) + (GOATS*5)
```

Isso significa que iremos atualizar o banco de dados ETHIOPIA especificando os valores do campo FERMENT a serem iguais à expressão dada. Pressione Executar. Você será alertado de que executando este comando estará alterando o conteúdo do banco de dados em uso e será questionado se deseja prosseguir. Escolha Sim. Examine os valores armazenados no campo FERMENT. Você necessitará redimensionar a largura da coluna arrastando com o mouse o seu limite direito para a direita.

O modelo cartográfico para a segunda componente da emissão de metano relacionada aos rebanhos (Decomposição do Esterco) inicia de modo muito semelhante à primeira componente e é mostrado na Figura 2. Podemos chamar o novo campo contendo essa informação de DECOMP.




Figura 2

Dispomos agora de todos os dados de entrada para calcular DECOMP, exceto a temperatura média anual AVGTEMP. Esse dado não existe no banco de dados ETHIOPIA, nem há mapas de temperatura disponíveis para a Etiópia. Entretanto, existem dados de temperatura que são coletados em estações meteorológicas espalhadas pelo país. Nós também sabemos a altitude de cada uma dessas estações. Assim como verificado no Exercício 9, a relação entre elevação e temperatura no leste da África é muito forte. Da mesma forma que fizemos no Exercício 9 com as 9 estações meteorológicas do Quênia, derivamos uma equação expressando a relação entre a altitude e a temperatura média anual para 35 estações meteorológicas da Etiópia e a utilizamos para criar uma imagem de temperatura a partir de uma imagem de altitudes.

A imagem de temperatura que foi criada chama-se TEMPSURF e está no nosso conjunto de dados do diretório EXERCISE. A equação utilizada para criar TEMPSURF<sup>37</sup> tem um coeficiente de correlação ( $r$ ) de -0,9478 e é a seguinte:

$$Y = 30,388041 - 0,006171X$$

Onde Y é a temperatura em graus Celsius e X é a elevação em metros

- x) Visualize TEMPSURF com a tabela de cores IDRIS256. Você pode adicionar o arquivo AWRAJAS com o arquivo de símbolos padrão. As regiões mais altas têm temperaturas mais baixas, mostradas em azul e vermelho, enquanto as elevações mais baixas apresentam temperaturas mais elevadas, mostradas em tons de verde.

A imagem TEMPSURF é uma imagem contínua da temperatura média anual para a Etiópia. O que necessitamos para completar nosso cálculo, entretanto, é um campo em nosso banco de dados com um único número para cada awraja. Podemos produzi-lo com o módulo EXTRACT, que usa um arquivo de definição de feições e um arquivo de dados para produzir um sumário estatístico de cada feição. As opções do sumário incluem total, média, intervalo, desvio padrão, mínimo e máximo. Neste caso queremos calcular o valor médio de temperatura para todos os *pixels* em cada awraja.

<sup>37</sup> Caso você mesmo queira criar TEMPSURF, os arquivos necessários estão no seu conjunto de dados de exercício. ELEVMTS e CELSIUS são os arquivos de elevação e temperatura e ETDEM é o modelo digital de elevação. Siga a metodologia descrita no Exercício 9.

EXTRACT pode ser acessado a partir do menu Análise/Consulta ao banco de dados do IDRISI for Windows, ou, alternativamente, através da Oficina de banco de dados. Como queremos adicionar o sumário extraído da imagem ao nosso banco de dados, adotaremos o segundo procedimento, já que ele possibilita importar automaticamente o resultado para o banco de dados.

- y) Na Oficina de banco de dados, primeiro prepare o banco para receber os novos dados adicionando o campo AVGTEMP com dados do tipo real. Com o novo campo pronto, estamos aptos agora para utilizar EXTRACT. Escolha Extrair sumário estatístico da imagem a partir do menu Ligação da Oficina de banco de dados. Use AWRAJAS como a imagem com definição de feições, TEMPSURF como a imagem a processar, IDR\_ID como o campo de definição de feições e AVGTEMP como o campo para o sumário estatístico. Escolha o cálculo da média no sumário estatístico e pressione OK. Examine os valores armazenados no campo AVGTEMP.
- z) Agora dispomos de todos os campos de dados necessários para efetuar o cálculo ilustrado na Figura 2. Adicione outro campo chamado DECOMP ao banco de dados, com dados do tipo real. Escolha Calcular a partir do menu Modificação e digite o comando que irá calcular os valores para o novo campo.

3. Que comando SET você usou para calcular o campo DECOMP?

Para finalizar, necessitamos ainda combinar as contribuições da fermentação entérica (FERMENT) e da decomposição do esterco (DECOMP) para obter o total da emissão de metano por awraja. Os valores que temos para cada componente estão em quilogramas, mas os totais precisam estar em toneladas métricas (uma tonelada métrica corresponde a 1000 kg).

- aa) Modifique o banco de dados para adicionar um campo final, do tipo real, chamado TOTMET e digite o comando SQL para calcular as emissões de metano totais, em toneladas métricas.

4. Que comando SET você executou?

- bb) Na caixa de diálogo de Ligação/Fixar parâmetros de ligação à visualização, escolha TOTMET como o campo contendo os códigos de visualização. Use o modo de visualização contínuo para ver o resultado.

5. Descreva os padrões espaciais que você percebe para as emissões de metano na Etiópia.

O metano é um dos componentes do modelo de gases de efeito estufa. É possível que estes dados possam ser combinados com vários outros arquivos em um modelo mais compreensível. Como alguns dos outros arquivos do modelo podem ser contínuos ou estar baseados em unidades espaciais outras que não awrajas, será necessário transferir também os dados de emissão total do campo do banco de dados para uma imagem. Isso pode ser efetuado pelo módulo ASSIGN. Usamos ASSIGN em um exercício anterior para alterar os valores de uma imagem com base em um arquivo de valores ASCII contendo os identificadores. No presente caso estamos fazendo praticamente a mesma coisa, só que especificando os campos do banco de dados com o identificador e a emissão total de metano respectivamente como os identificadores de unidades espaciais (awrajas, neste caso) e os novos valores a atribuir.

- cc) Escolha Atribuir valores de campo à imagem a partir do menu Ligação da Oficina de banco de dados. Use AWRAJAS como a imagem de definição de feições, TOTMET como o nome da imagem de saída, IDR\_ID como o campo de definição das feições e TOTMET como o campo do banco de dados onde estão os dados. Visualize sua nova imagem, usando o Lançador de visualização, com a tabela de cores Idrisi 256.

### ***Exercício opcional***

Use a Oficina de banco de dados para criar uma janela de visualização mostrando a densidade de gado por awraja (cabeças/km<sup>2</sup>).



# 11. Exploração de imagens

Com este exercício, iniciamos uma extensiva exploração de imagens de sensoriamento remoto e de técnicas de processamento de imagens. Como as imagens de sensoriamento remoto são uma fonte usual de dados para analistas em SIG e têm uma estrutura raster, muitos sistemas de geoprocessamento oferecem algumas ferramentas para processamento de imagem. Caso você ainda não tenha lido o capítulo *Introdução ao sensoriamento remoto e ao processamento de imagens*, faça-o antes de continuar com este exercício.

Exploraremos diferentes caminhos para aumentar o contraste de imagens de sensoriamento remoto para auxiliar a interpretação visual, um processo conhecido como realce de imagem. Nós introduzimos este tópico no Exercício 4, mas iremos revisá-lo e ampliar a discussão aqui, já que este é um aspecto muito importante do processamento de imagens. Também aprenderemos sobre a natureza das imagens de satélite e a informação que carregam.

Usaremos dados de sensoriamento remoto de uma região imediatamente a oeste de Worcester, Massachusets, chamada Howe Hill. Para esta pequena área, você possui 4 bandas de uma imagem LANDSAT *Thematic Mapper* (TM) adquirida pelo satélite em 10 de setembro de 1987. Elas são chamadas de HOW87TM1, HOW87TM2, HOW87TM3 e HOW87TM4 e correspondem, respectivamente, às bandas de comprimento de onda do azul visível, do verde visível, do vermelho visível e do infra vermelho próximo.

Iniciaremos nossa investigação de realce de imagem estudando o modo de ampliar seu contraste visual. Ao trabalhar com imagens de satélite, na maioria dos casos necessitamos usar uma tabela de cores de tons de cinza para a visualização. Esta opção de tabela de cores, assim como outros aspectos da visualização, podem ser automatizados na configuração das Preferências de visualização.

- a) Selecione Preferências de visualização a partir do menu Visualização. Verifique se a opção de Visualizar automaticamente as saídas dos módulos analíticos está ligada e especifique a tabela de cores quantitativa a usar como GREY256. Isto fará com que os resultados de todos os módulos analíticos que executarmos seja automaticamente visualizado com a tabela de cores de 256 tons de cinza. Além disso, na área de Padrões de mapa, ligue a opção de Título visível e especifique GREY256 como Tabela de cores padrão. Isto fará com que a tabela de cores de 256 tons de cinza e o título do mapa sejam automaticamente carregados sempre que o Lançador de visualização for utilizado.
- a) Visualize a imagem HOW87TM4 (observe que a tabela de cores Tons de cinza 256 e o título já estão selecionados. Observe o tom cinza médio, ou contraste baixo, em toda a imagem. A tabela



de cores Tons de cinza 256 vai de preto (cor 0) até branco (cor 255), mas parece não haver nenhum *pixel* branco ou cinza claro na visualização. Para ver por que isto acontece, clique duas vezes no nome de HOW87TM4 na lista de arquivos da Composição. Isto aciona a ligação rápida com DESCRIBE. Observe que o valor mínimo da imagem é 0 e o máximo é 190. Isso explica porque a imagem parece escura – as cores mais claras da tabela de cores (191 – 255) não estão sendo utilizadas.

- b) Para entender melhor como o intervalo de valores dos dados afeta a visualização, execute HISTO a partir do menu Visualização. Selecione HOW87TM4 como imagem de entrada, mantenha o intervalo de classe igual a 1, produza um a saída gráfica e altere os valores máximos e mínimos para 0 e 255. Ao terminar, mova o histograma para o lado para permitir a visualização da imagem e do histograma ao mesmo tempo.

O eixo horizontal do histograma pode ser interpretado como se fosse a tabela de cores de 256 tons de cinza. Um valor de reflectância igual a zero é mostrado como preto, uma reflectância igual a 255 como branco e todos os demais valores entre estes extremos são mostrados em tons variáveis de cinza. O eixo vertical mostra quantos *pixels* na imagem tem o valor que está sendo mostrado por aquela cor (Figura 1). Observe também a estrutura bimodal do histograma. Iremos comentar mais tarde sobre as causas dos dois picos na banda infravermelha, neste exercício, quando aprenderemos acerca das informações que as imagens de satélite contêm.




Figura 1

Como mostra o histograma, nenhum dos *pixels* da imagem tem o valor de 255 (Figura 1). Em consequência, não existem *pixels* claros na imagem. Observe também que a maioria dos *pixels* possui valores em torno de 90. Este valor cai no intervalo médio da tabela de cores Tons de cinza 256, razão pela qual HOW87TM4 aparece com predominância de cinza médio.

1. Se a imagem HOW87TM4 tivesse um único *pixel* com valor de reflectância 0 e um outro com o valor 255 (todos os outros valores dos dados permanecendo como são), o contraste visual da imagem seria melhorado? Por que ou por que não?

Para aumentar o contraste da imagem, necessitaremos modificar a visualização de forma que todas as cores da tabela, do preto ao branco, sejam utilizadas. A maneira mais fácil de se fazer isto é através do autoescalonamento da imagem. Quando o autoescalonamento é utilizado, o valor mínimo da imagem é mostrado com a cor de valor mais baixo na tabela de cores e o máximo é mostrado com o valor mais elevado na tabela. Todos os valores intermediários são distribuídos ao longo das demais cores disponíveis na tabela de cores.

- d) Visualize HOW87TM4 novamente com a tabela de cores Tons de cinza 256, mas desta vez use o autoescalonamento. Observe que o contraste aumenta. Certifique-se do efeito de autoescalonamento mostrando a mesma imagem HOW87TM4 com e sem autoescalonamento lado a lado. Agora execute HISTO novamente, mas desta vez mantenha os valores mínimos e máximos fornecidos (que são, na verdade, os valores mínimos e máximos da imagem). Você também pode usar a ligação rápida Histograma da imagem acionando o botão Propriedades da Composição para ver o histograma da imagem ativa com os valores fornecidos pelo programa.
2. Faça um desenho esquemático (similar ao da Figura 1) do histograma de HOW87TM4 com autoescalonamento. Se você estiver conectado a uma impressora pode também pressionar o ícone de Imprimir na janela do histograma. Identifique o eixo horizontal com valores dos dados nos pontos extremos e com uma descrição da tabela de cores ao longo do eixo (p.ex., preto, cinza e branco).

A diferença entre os dois histogramas ilustra os efeitos do autoescalonamento. Os pontos extremos do segundo histograma agora alcançam o extremo do eixo horizontal. O valor mínimo igual a zero é mostrado em preto e o valor máximo de 190 é mostrado em branco, com os valores médios tendo tons variáveis de cinza. O autoescalonamento não altera os valores armazenados no arquivo; ele apenas modifica o intervalo de cores que é mostrado.

Embora o autoescalonamento geralmente melhore o contraste, o resultado é, ainda assim, muitas vezes insuficiente para a interpretação visual.

- e) Visualize HOW87TM1 com autoescalonamento e a tabela de cores Tons de cinza 256. Observe como ela está escura. Execute HISTO e mantenha as opções oferecidas. Como alternativa, você pode acionar Histograma da imagem a partir do botão propriedades da Composição.
3. O que você observa com relação à forma do histograma? Por que o autoescalonamento não melhora muito o contraste?

Nós podemos alcançar contrastes melhores realizando um *realce* na imagem. Quando fazemos uma operação de realce, criamos um novo arquivo com novos valores de dados. Existem três formas diferentes de realce que podem ser feitos em uma imagem:

**Contraste linear:** Este realce funciona de modo similar ao autoescalonamento, mas você pode especificar como valores mínimos e máximos valores diferentes dos mínimos e máximos da imagem, além de poder estabelecer o número de níveis para a imagem de saída.

**Contraste linear com saturação:** Este realce atribui uma porcentagem indicada pelo usuário (p. ex., 2,5%) de *pixels* em cada extremidade do histograma para serem agrupados num mesmo valor e então aplica um realce linear aos valores restantes entre eles.

**Equalização de histograma:** O realce tende a agrupar o mesmo número de *pixels* em cada nível de dados, com a restrição de que os *pixels* que na imagem original pertencem à mesma classe não podem ser divididos em mais do que uma categoria na imagem de saída.

Exploraremos abaixo cada um destes realces:

- f) Execute STRETCH a partir do menu Visualização. Use a opção de realce linear com saturação, especifique 2,5% de saturação e indique HOW87TM1 como a imagem de entrada e TM1L25 como a imagem de saída. Dê um título à nova imagem e indique “valores de índice de cor” para as unidades dos novos valores. Use as configurações sugeridas para as demais opções. A imagem de saída será automaticamente visualizada com a tabela de cores Tons de cinza 256. Não faça autoescalonamento; não é necessário autoescalonar imagens realçadas. Execute então HISTO sobre TM1L25, aceitando todas as opções sugeridas pelo programa.

4. Desenhe ou imprima o histograma de TM1L25 e identifique o eixo horizontal como anteriormente. Compare a imagem TM1L25 e seu histograma com a imagem HOW87TM1 mostrada com autoescalonamento e seu histograma (i.e., aceitando valores mínimos e máximos sugeridos). Você também pode dispor na tela ambas as imagens com seus histogramas para examiná-las de uma só vez. Preste atenção nas diferenças de contraste evidentes na visualização. Feche todas as janelas depois que você tiver terminado.
- g) Visualize HOW87TM4 com a tabela de cores Tons de cinza 256. Execute os seguintes realces em HOW87TM4, chame as imagens de saída como indicado abaixo e compare os resultados visualizados. Crie seus histogramas e desenhe ou imprima um esboço dos histogramas como você fez anteriormente.
  - i. Linear simples com mínimos e máximos como extremos, realçados para 256 níveis. Chame o resultado de TM4L
  - ii. Linear com 5% de saturação, realçado para 256 níveis. Chame o resultado de TM4L50.
  - iii. Linear com 2.5% de saturação, realçado para 256 níveis. Chame o resultado de TM4L25.
  - iv. Equalização de histograma, realçado para 256 níveis. Chame o resultado de TM4HE.
  - v. Equalização de histograma, realçado para 16 níveis. Chame o resultado de TM4HE16. (para esta imagem aplique a tabela de cores Tons de cinza 16, com o auxílio do botão Propriedades da Composição).

A quantidade de saturação requerida para produzir uma imagem com “bom” contraste varia e requer algum ajuste por tentativa e erro. Geralmente 2,5% funciona bem.

5. Em que imagem você percebe que as feições são melhor identificadas, no realce com 2,5 ou 5% de saturação?

A equalização de histograma tende a colocar um número igual de *pixels* em cada nível de cinza. Observe que as barras são praticamente iguais no histograma das 16 classes criadas pelo realce de equalização de histograma. Em teoria, nós poderíamos esperar que as barras tivessem exatamente o mesmo tamanho. O IDRISI for Windows, assim como outros sistemas de processamento de imagens, não separará um valor de dado simples em mais de uma classe. Por isso, algumas desigualdades permanecerão.

De acordo com a Teoria da Informação, a imagem da equalização do histograma deveria carregar mais informação porque ela contém a maior variação para qualquer número de classes. Nós veremos mais tarde neste exercício, entretanto, que “informação” não é o mesmo que “significado”.

Primeiramente, vamos continuar a explorar o que estas imagens “significam”.

- h) Visualize as quatro imagens originais (HOW87TM1 a HOW87TM4) ao mesmo tempo, usando a tabela de cores Tons de cinza 256. Você necessitará visualizá-las com um fator de expansão menor que o sugerido pelo Lançador de visualização. Organize as imagens próximas umas das outras na tela de forma que você possa visualizar todas as quatro ao mesmo tempo. Como o contraste é baixo em todas as imagens, visualize também TM4L25. Nós iremos usar essa imagem realçada para localizar áreas específicas para consultar, mas estamos interessados de fato nos valores dos dados dos arquivos originais.

Há três tipos de cobertura do solo que são facilmente identificáveis na imagem: áreas urbanas, florestas e água. Nós vamos agora estudar como esses tipos diferentes de cobertura do solo refletem em cada um dos intervalos de comprimento de onda registrados nas quatro bandas originais.

- i) Desenhe três gráficos como o da Figura 2 e dê-lhes o nome de água, floresta e urbano.




Figura 2

Para examinar os valores de reflectância em todas as quatro imagens iremos utilizar a consulta expandida do cursor, que possibilita consultar simultaneamente todas as imagens cujos nomes estejam incluídos em um arquivo de grupo de imagens.

- j) Para criar um arquivo de grupo de imagens execute EDIT a partir do menu Entrada de dados. Escolha editar um arquivo de grupo de imagens e digite o nome TMGRP. Escolha a opção Usar editor de arquivo de grupo para adicionar ao arquivo de grupo os nomes das quatro bandas originais (HOW87TM1 a HOW87TM4) e a imagem realçada TM4L25. Salve o arquivo e saia de EDIT.
- k) Abra as Preferências de visualização a partir do menu Visualização e verifique se a opção Usar modo expandido de consulta do cursor está ligada. Selecione a opção Arquivo de grupo de imagens e digite o nome do arquivo de grupo de imagens TMGRP recém criado. Esses passos instruem o IDRISI for Windows para que sempre que o modo de consulta do cursor for acionado em um dos arquivos contidos no arquivo de grupo de imagens TMGRP, todas as imagens cujo nome estiver contido nesse arquivo serão consultadas e os resultados mostrados (isso não interfere na consulta normal em uma imagem que não faz parte do grupo).
- l) Selecione a imagem TM4L25 clicando na barra superior de sua janela de visualização e ative o modo de consulta do cursor. Movimente o cursor por sobre a imagem TM4L25 buscando três ou quatro *pixels* representativos de cada tipo de cobertura e clique sobre os mesmos para conferir seus valores. Observe que imediatamente uma pequena janela abre do lado inferior direito de seu vídeo e mostra os valores de reflectância para os *pixels* consultados em todas as cinco imagens do grupo. Determine o valor de reflectância para os *pixels* de água, floresta e urbano em cada uma das quatro bandas originais. Preencha o gráfico que você desenhou no passo i) para cada tipo de cobertura plotando os valores dos *pixels*.

Você acabou de fazer um esboço do que é chamado de *padrões de resposta espectral* para os três tipos de cobertura do solo. Com esses gráficos você pode ver que diferentes tipos de cobertura refletem diferentes quantidades de energia nos vários comprimentos de onda. Nos próximos exercícios iremos classificar imagens de satélite em categorias de uso do solo com base no fato de que os tipos de cobertura do solo têm padrões de resposta espectral singulares.

Isto constitui a chave para desenvolver mapas de cobertura do solo a partir de imagens de sensoriamento remoto.

Iremos agora retornar a duas excelentes questões que foram mencionados anteriormente mas ainda não foram esclarecidas. Em primeiro lugar, vamos reconsiderar a forma do histograma de HOW87TM4 (Figura 1). Observe novamente a sua estrutura bimodal.

5. Agora que você viu como diferentes bandas (ou comprimentos de onda eletromagnéticas) de uma imagem interagem de modo distinto com diferentes tipos de

cobertura do solo, qual você pensa ser o tipo de cobertura do solo que está causando o pequeno pico de *pixels* com valores baixos na banda do infravermelho?

Em segundo lugar, vamos retornar rapidamente às nossas imagens submetidas ao processo de realce e pensar como imagens realçadas podem aumentar o contraste e, desta forma, a “informação”, mas sem acrescentar, na verdade, nenhum “significado”.

- m) Realce HOW87TM1 com equalização de histograma e 256 níveis. Chame o resultado TM1HE. Visualize também TM1L25.

Observe como essas imagens são diferentes. A versão da banda 1 com equalização de histograma certamente tem muita variação, mas nós perdemos a noção de que a maior parte da cobertura nesta imagem (floresta) absorve muita energia nesta banda (devido à umidade e aos pigmentos das folhas). É melhor evitar a técnica de equalização de histograma sempre que você quiser ter no resultado uma noção visual das características de absorção/reflectância de tipos de cobertura do solo. De fato, na maioria das vezes, um *realce linear com saturação* é melhor. Lembre que imagens realçadas servem **apenas para visualização**. Como elas foram manipuladas, não são confiáveis para análise. **Use apenas dados originais (ou brutos)** para análise, a não ser que você tenha uma razão muito especial e tecnicamente justificada para usar dados realçados.

## 12. Classificação supervisionada

No exercício anterior desenhamos em um gráfico os padrões de resposta espectral para três tipos de cobertura do solo: urbano, floresta e água. Dissemos que as assinaturas desses tipos de cobertura do solo eram singulares. Tipos de cobertura do solo, então, são identificados ou diferenciados uns dos outros pelo seu padrão de resposta espectral singular. Esta é a lógica por trás da *classificação de imagens*. Muitos tipos de mapas, incluindo os de cobertura do solo, mapas de solos e os mapas batimétricos, podem ser construídos a partir da classificação de imagens de sensoriamento remoto.

Existem dois métodos de classificação de imagem: classificação supervisionada e classificação não supervisionada. Na classificação supervisionada, o usuário define as assinaturas espectrais de categorias conhecidas, tais como urbano e florestas e, então, o programa associa cada *pixel* da imagem à assinatura mais similar. Na classificação não supervisionada, o programa agrupa *pixels* em categorias de assinaturas parecidas e o usuário identifica que tipo de cobertura efetivamente aquelas categorias representam.

Os passos para a classificação supervisionada podem ser resumidos nos seguintes:

1. Localizar exemplos representativos de cada tipo de cobertura que pode ser identificado na imagem (chamadas áreas de treinamento);
2. Digitalizar polígonos em torno de cada área de treinamento, atribuindo um único identificador para cada tipo de cobertura;
3. Analisar os *pixels* contidos nas áreas de treinamento e criar assinaturas espectrais para cada tipo de cobertura;
4. Classificar a imagem inteira considerando cada *pixel* individualmente, comparando sua assinatura particular com cada uma das assinaturas conhecidas. As chamadas classificações rígidas resultam da atribuição de cada *pixel* à classe de cobertura tem a assinatura mais similar. Classificações relativas, por outro lado, avaliam o grau de associação do *pixel* em todas as classes em consideração, incluindo classes desconhecidas e não especificadas. Decisões sobre quão similares as assinaturas são umas das outras são feitas através de análises estatísticas. Existem diversas técnicas distintas que podem ser utilizadas -- freqüentemente denominadas *classificadores*.

Este exercício ilustra certas técnicas rígidas de classificação supervisionada. Classificadores relativos são estudados nos exercícios tutoriais avançados. Uma discussão mais detalhada sobre classificação pode

ser encontrada no capítulo *Classificação de imagens de sensoriamento remoto* do Manual do usuário do IDRISI for Windows.

Iniciaremos com a criação de áreas de treinamento. A área que classificaremos é uma pequena janela extraída de uma imagem em torno de Howe Hill, imediatamente a noroeste do aeroporto que vimos em HOW87TM1-4 no exercício anterior. A Figura 5 (no final deste exercício) mostra os resultados de um trabalho de campo nesta área. As áreas de treinamento criadas neste exercício serão baseadas no conhecimento dos tipos de cobertura do solo identificados durante esta visita.

Para cada tipo de cobertura do solo conhecido será atribuído um único identificador inteiro e será identificada uma ou mais áreas de treinamento.

- a) Escreva uma lista com todos os tipos de cobertura do solo identificados na Figura 5, juntamente com um identificador específico para representar cada tipo de cobertura. Embora as áreas de treinamento possam ser digitalizadas em qualquer ordem, elas não deveriam omitir nenhum número na série. Dessa forma, se você tiver dez classes de cobertura do solo diferentes, seus identificadores deverão ir de 1 a 10.

A ordem sugerida (para melhor ajustar as classes à tabela de cores qualitativa padrão da visualização automática) é:

- 1-Água rasa
- 2-Água profunda
- 3-Agricultura
- 4-Área urbana
- 5-Floresta decídua
- 6-Floresta de coníferas

- b) Visualize a imagem chamada H874S usando a tabela de cores Tons de cinza 256. Use o modo de digitalização na tela do IDRISI for Windows para digitalizar polígonos em torno de suas áreas de treinamento. Isto é feito do seguinte modo:

Amplie uma janela de imagem em torno do lago com águas profundas no lado esquerdo da imagem (Figura 5). Selecione a seguir o ícone de digitalização na tela:



Crie um arquivo vetorial de nome TRSITES, escolha criar polígonos e indique o identificador numérico escolhido para água profunda.

O cursor aparece agora com a mesma forma do ícone quando está posicionado sobre a imagem. Desloque o cursor para um ponto de partida no limite de sua área de treinamento e pressione o botão esquerdo do mouse. Mova então o cursor ao próximo ponto ao longo do limite e pressione novamente o botão esquerdo do mouse (você verá a linha do contorno criar forma). O polígono da área de treinamento deve abarcar um tipo de cobertura homogêneo, então evite incluir a margem do corpo d'água, que contém solo exposto, neste polígono de águas profundas (para ter certeza de que estamos amostrando apenas água). Continue digitalizando até pouco antes de fechar todo o contorno e então pressione o botão direito do mouse. Isto finalizará a digitalização desta área de treinamento e assegurará que o contorno seja perfeitamente fechado (o polígono fechado é exibido com uma linha preta, que pode ser de difícil visualização em áreas de água profunda da imagem, cuja cor também é escura. No entanto, não se preocupe, o polígono da área de treinamento está lá). Caso você tenha feito algum erro e não queira salvar este polígono, pressione o seguinte ícone para excluí-lo:



Com isto a última área de treinamento digitalizada será excluída.

Retorne a imagem para seu tamanho normal e então amplie uma janela em torno da sua próxima área de treinamento, tomando como referência a Figura 5. Selecione novamente o ícone de digitalização na tela. Digite um identificador para a nova área. Mantenha o mesmo identificador caso você queira digitalizar outro polígono em torno de uma área de igual tipo de cobertura que a anterior. Caso contrário, indique outro identificador.

Qualquer número de áreas de treinamento, ou de polígonos com o mesmo identificador, podem ser criados para cada tipo de cobertura. De modo geral, entretanto, eles deveriam ser amostras de *pixels* adequadas para cada tipo de cobertura com vistas à sua caracterização estatística. Via de regra, o número de *pixels* de cada conjunto de treinamento (i.e., todas as áreas de treinamento para uma única classe de cobertura do solo) não deveria ser menor do que dez vezes o número de bandas. Assim, neste exercício onde usaremos sete bandas, nós deveríamos ter pelo menos 70 *pixels* por conjunto de treinamento.

- c) Continue até que você tenha digitalizado áreas de treinamento para cada classe de cobertura. Pressione então o seguinte ícone:



Isto armazenará o arquivo vetorial TRSITES e o recolocará na tela.

Depois de ter o arquivo vetorial de áreas de treinamento você está pronto para o terceiro passo do processo, a criação dos arquivos de assinaturas. Arquivos de assinatura contêm informação estatística sobre os valores de reflectância dos *pixels* em cada conjunto de treinamento.

- d) Execute MAKESIG a partir do grupo Desenvolvimento de assinaturas do menu Análise/Processamento de imagens. Escolha vetor como o tipo de arquivo de áreas de treinamento e informe TRSITES como o nome do arquivo de áreas de treinamento. Indique que sete bandas de imagem serão processadas e sete caixas com nomes de entrada irão aparecer automaticamente. Digite nelas os nomes das bandas que você irá analisar: H87TM1 (banda azul), H87TM2 (banda verde), H87TM3 (banda vermelha), H87TM4 (infravermelho próximo), H87TM5 (infravermelho médio), H87TM6 (infravermelho termal) e H87TM7 (infravermelho médio). Após selecione Continuar, indique os nomes para cada categoria de cobertura do solo nas caixas de entrada com o rótulo identificador apropriado, em ordem ascendente. Esses nomes de classes de cobertura serão usados como nomes de arquivos de assinaturas, de forma que devem seguir as normas das convenções MS-DOS (8 caracteres ou menos). Igualmente, não chame a assinatura de coníferas de CON porque este é um comando reservado ao MS-DOS e não funcionará adequadamente. Pressione o botão com uma seta descendente próxima às caixas reservadas ao nome das assinaturas de modo a encontrar a caixa para o último arquivo assinatura.
- e) Use a opção Listar do menu Arquivo para visualizar os arquivos de assinatura e verificar se todas as suas assinaturas foram criadas. Caso você tenha esquecido alguma, repita todo o processo descrito para criar um novo arquivo vetorial de áreas de treinamento (apenas para o tipo de cobertura do solo que foi esquecido) e execute MAKESIG novamente.

Para comparar as assinaturas é possível fazermos um gráfico, do mesmo modo que fizemos manualmente em exercícios anteriores.



- f) Execute SIGCOMP, a partir do grupo Desenvolvimento de assinaturas do menu Análise/Processamento de imagens. Escolha a visualização de 6 arquivos assinatura e escreva os nomes de todos os arquivos, optando por mostrar suas médias.
1. Das sete bandas da imagem, quais as bandas que melhor diferenciam a cobertura vegetal?
- g) Execute SIGCOMP novamente, mas desta vez escolha a visualização de apenas 2 assinaturas e escreva os nomes dos arquivos assinatura para área urbana e coníferas. Indique que você deseja visualizar seus valores máximos, mínimos e médias. Observe que os valores de reflectância destas assinaturas se sobrepõem em grau variável ao longo das bandas. Esta é uma fonte de confusão espectral entre tipos de cobertura.
2. Qual das duas assinaturas tem a maior variação em valores de reflectância (maior intervalo de valores) nas diferentes bandas? Por quê?
- h) Para melhorar nossa compreensão sobre estes arquivos de assinaturas, podemos editá-los usando EDITSIG. Execute EDITSIG a partir do grupo Desenvolvimento de assinaturas do menu Análise/Processamento de imagens. Escolha editar a assinatura de coníferas e visualizar o histograma de H87TM1. Veja se há evidência de uma curva normal (bem formada) que possa sugerir que um conjunto homogêneo de *pixels* representativos de coníferas foi selecionado. Caso a assinatura seja fortemente bimodal (tendo dois picos), isto sugere que dois tipos de cobertura, com padrões de resposta espectral diferentes, foram incluídas na mesma área de treinamento. Para uma discussão sobre assinaturas *fuzzy*, que podem acomodar misturas de tipos de cobertura, veja o capítulo **Classificação de imagens de sensoriamento remoto** no Manual do usuário do IDRISI for Windows. Valores extremos que parecem não pertencer à curva principal também sugerem que as áreas de treinamento não são homogêneas. Feche o histograma da banda 1.
- Para a assinatura de coníferas, visualize os histogramas de cada uma das outras bandas em sequência. Selecione as bandas pressionando o botão com uma seta para a direita situado abaixo do nome da banda. Você pode comparar vários histogramas ao mesmo tempo e ir fechando as janelas à medida que tiver terminado de examinar cada um. Observe como a variabilidade nos valores de reflectância muda nas diferentes bandas. Agora escolha editar o arquivo assinatura de água rasa com EDITSIG e visualize o histograma de H87TM4.
3. Por que com esta banda você vê uma estrutura bimodal nesta assinatura?

Antes de partir para a próxima parte do exercício, vamos criar um arquivo de grupo de assinaturas que contenha todos os nomes das nossas assinaturas. Usar arquivos de grupo (em vez de especificar cada assinatura individualmente) acelera o processo de preencher a informação de entrada em todos os módulos de classificação. Da mesma forma que um arquivo de grupo de imagens, um arquivo de grupo de assinaturas é um arquivo ASCII (com uma extensão .sgf). A primeira linha do arquivo indica o número de assinaturas e as demais linhas listam os nomes das assinaturas, uma por linha.

- h) Execute EDIT, escolha Arquivo de grupo de assinaturas e digite SIGS como o nome para o novo arquivo. Escolha então Usar editor de arquivo de grupo e adicione suas assinaturas à lista, seguindo a ordem numérica dos identificadores das assinaturas definida no início do exercício (para manter a consistência das cores da tabela de cores qualitativa da visualização automática). Salve o arquivo e saia de EDIT.

Agora que temos os arquivos de assinatura para todas as nossas categorias, estamos prontos para o último passo no processo de classificação de imagem -- classificar a imagem com base nestes arquivos de assinaturas. Cada *pixel* na área de estudo tem um valor em cada uma das sete bandas da imagem (HOW87TM1-7). Como mencionado anteriormente, essas bandas correspondem respectivamente aos comprimentos de onda do azul, verde, infravermelho próximo, infravermelho médio, infravermelho termal e outro infravermelho médio. Os valores de uma assinatura nas 7 bandas formam uma assinatura

singular que pode ser comparada a cada um dos demais arquivos assinatura recém criados. Cada *pixel* é então atribuído ao tipo de cobertura com assinatura mais similar. Existem várias técnicas estatísticas que podem ser usadas para avaliar a similaridade entre assinaturas. Estas técnicas estatísticas são chamadas de *classificadores*. Nós criaremos imagens classificadas com três dos classificadores rígidos disponíveis no IDRISI for Windows. Exercícios ilustrando o uso de classificadores relativos e discretizadores podem ser encontrados nos *Exercícios tutoriais avançados*.

O primeiro classificador que usaremos é um classificador de distâncias mínimas às médias. Este classificador calcula a distância do valor de reflectância de um *pixel* à média espectral do arquivo de assinaturas e atribui ao *pixel* a categoria com a média mais próxima. Existem duas formas para o cálculo da distância. A primeira calcula a distância Euclidiana, ou *bruta*, do valor de reflectância do *pixel* à média de cada categoria espectral. Este conceito é ilustrado em duas dimensões (como se as assinaturas espectrais fossem feitas a partir de apenas duas bandas) na Figura 1<sup>38</sup>. Neste diagrama heurístico, os valores de reflectância das assinaturas são indicados com letras minúsculas, os *pixels* que estão sendo comparados às assinaturas estão indicados com números e as médias espectrais estão indicadas com pontos. O *pixel* 1 está mais próximo da média espectral da assinatura do milho (c) e é por isso atribuído à categoria milho. A desvantagem deste classificador é ilustrada pelo *pixel* 2, que está mais próximo à média da areia (s) mesmo parecendo estar dentro do intervalo de reflectâncias com maior probabilidade de ser urbana (u). Em outras palavras, a distância mínima bruta à média não leva em consideração a dispersão dos valores de reflectância em torno da média.




Figura 1

- i) Para visualizar um diagrama de espalhamento similar das nossas assinaturas, você pode usar o módulo SCATTER. Esse módulo usa duas bandas como eixos X e Y para ilustrar as posições relativas dos *pixels* de acordo com seus valores nessas duas bandas. Além disso, ele cria em torno da média da assinatura em cada banda um contorno retangular igual a dois desvios padrão da média. A saída é uma composição de mapa que inclui tanto a imagem quanto o plano vetorial com a legenda. A legenda mostra os nomes das assinaturas com cores correspondentes.

Execute SCATTER a partir do grupo Desenvolvimento de assinaturas do menu Análise/Processamento de imagens. Indique H87TM3 (a banda do vermelho) como o eixo Y e H87TM4 (a banda do infravermelho próximo) como o eixo X. Deixe ligado a opção Sobrepor gráfico de assinatura e especifique SIGS como o nome do arquivo de grupo de assinaturas. Dê o nome de SCAT para o arquivo de saída e mantenha o Logaritmo do número de *pixels* como o Tipo de visualização. Pressione OK. Quando a composição de mapa resultante for visualizada, mova o cursor em torno do diagrama de espalhamento. Observe que as coordenadas X e Y mostradas na barra de status são as coordenadas X e Y do diagrama de espalhamento. Os eixos X e Y estão sempre configurados para o intervalo 0 – 255. Amplie o canto inferior esquerdo para ver melhor o diagrama e os contornos das assinaturas.

Para visualizar as freqüências de posição dos *pixels* em duas bandas selecionadas, SCATTER usa cores mais claras para mostrar densidades maiores (log da freqüência) de *pixels* e cores

<sup>38</sup> As Figuras 1-4 foram adaptadas de Lillesand & Kiefer, 1979. *Remote Sensing and Image Interpretation*. First edition. New York, Chichester, Brisbane and Toronto: John Wiley & Sons.

escuras para densidades menores. Retângulos superpostos mostram áreas onde diferentes assinaturas têm valores similares. SCATTER é útil para avaliar a qualidade das nossas assinaturas. Algumas assinaturas se superpõem devido à natureza inadequada da definição das classes de cobertura do solo. Superposição também pode indicar especificação errada das assinaturas. Todavia, superposição também pode ocorrer devido a padrões de reflectância semelhantes de certos objetos (p. ex. florestas de madeiras de lei e áreas úmidas florestadas).

- j) Todos os classificadores que iremos explorar neste exercício podem ser encontrados no grupo Classificadores rígidos do menu Análise/Processamento de imagens. Para tornar a visualização automática das imagens de saída mais informativa, abra as Preferências de visualização a partir do menu Visualização e ligue a opção de Legenda visível.

Execute MINDIST (o classificador de distância mínima às médias) e indique que você quer usar um arquivo de grupo para especificar as assinaturas. Digite o nome SIGS e os nomes das assinaturas irão aparecer nas caixas de diálogo correspondentes na ordem especificada no arquivo de grupo. Escolha o tipo de distância Bruta e use Infinita como máxima distância de busca. Chame a imagem de saída de RAW e digite um título para a nova imagem. Pressione o botão Continuar... para acessar a próxima tela de MINDIST, e mantenha todas as bandas selecionadas para análise. Examine a imagem de cobertura do solo resultante.

Tentaremos o classificador de distância mínima às médias novamente, mas desta vez usaremos um segundo tipo de cálculo -- distâncias Normalizadas. Neste caso, o classificador irá avaliar o desvio padrão dos valores de reflectância em torno da média -- criando isolinhas de desvio padrão. Ele atribui então a um dado *pixel* uma categoria em termos de desvio padrão. Podemos ver na Figura 2 que o *pixel* 2 seria corretamente atribuído à categoria urbana (u) porque ele está a menos de dois desvios padrão da média dessa categoria, enquanto está a pelo menos três desvios padrão da média da areia (s).




Figura 2

- l) Para ilustrar este método, execute MINDIST novamente. Escolha o tipo de distância Normalizada e chame o resultado de MINSTD. Digite o título para a imagem a ser criada.
4. Compare os dois resultados. Como você descreveria o efeito da normalização das distâncias com o classificador de distância mínima à média?

O próximo classificador que utilizaremos é o classificador por máxima verossimilhança. Aqui, a distribuição dos valores de reflectância em uma área de treinamento é descrita por uma função de densidade de probabilidade, desenvolvida com base na estatística *Bayesiana* (Figura 3). Este classificador avalia a probabilidade de um determinado *pixel* pertencer a uma categoria e classifica o *pixel* para a categoria à qual ele tem a maior probabilidade de associação.




Figura 3

- m) Execute MAXLIKE. Indique o nome do arquivo de grupo de assinaturas SIGS. Assim como em MINDIST, seus nomes irão aparecer nas caixas de diálogo quando você pressionar o botão Continuar... Escolha classificar todos os *pixels* e opte por pesos iguais (i.e., usar probabilidades iguais) para cada classe. Chame o resultado de MAX. Pressione o botão Continuar... e digite um título para a imagem de saída. Pressione Continuar... novamente e escolha manter todas as bandas e pressione OK. A máxima verossimilhança é a mais lenta das técnicas disponíveis no IDRISI, mas se as áreas de treinamento forem boas (representativas) ela tende a ser mais acurada.

Finalmente, examinaremos o classificador por paralelepípedo. Este classificador cria 'caixas' usando unidades de desvio padrão (escores Z) ou valores de reflectância mínimos e máximos dentro de cada área de treinamento. Caso um determinado *pixel* caia numa 'caixa' de assinatura, ou espaço de banda, ele é atribuído àquela categoria. Este é o classificador mais rápido e a opção com valores Mín./Máx. foi usada como classificador para visualização rápida quando a velocidade e capacidade de processamento dos computadores ainda era uma séria limitação tecnológica. Ele é fadado, entretanto, a classificações incorretas. Devido à correlação da informação nas bandas espectrais, os *pixels* tendem a agrupar-se em nuvens na forma de charuto ou de *Zeppelin*. Como ilustrado na Figura 4, as 'caixas' se ajustam de uma forma tal que tomam *pixels* que provavelmente deveriam ser atribuídos a outras classes. Neste caso, o *pixel* 1 será classificado como decídua (d) enquanto deveria provavelmente ser classificado como milho (c). Além disso, as 'caixas' frequentemente se superpõem. *Pixels* com valores que caem nesta superposição são atribuídos à última assinatura, seguindo a ordem na qual os nomes das assinaturas foram introduzidos no módulo.

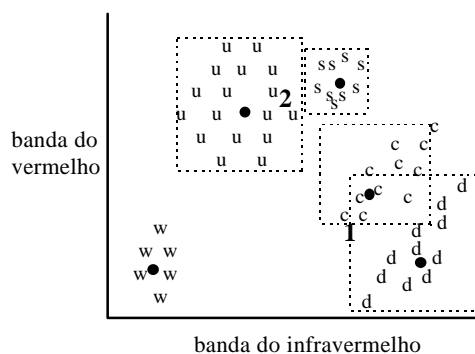


Figura 4

- n) Execute PIPED e indique o nome do arquivo de grupo de assinaturas como anteriormente. Escolha a opção de definir paralelepípedo por Mín./Máx. e chame a imagem PIPEORIG, digitando um título para a mesma. Pressione o botão Continuar... e mantenha todas as bandas para a análise. Observe os *pixels* com valor 0 na imagem de saída. Esses *pixels* não se enquadraram no intervalo Mín./Máx. de nenhum conjunto de treinamento e por isso foram atribuídos a uma categoria 0.

- n) Antes, EDITSIG foi usado em conjunto com o procedimento de classificação por paralelepípedo para redefinir os valores máximos e mínimos para cada assinatura, excluindo os valores extremos de cada assinatura, já que o classificador é bastante sensível aos valores máximos e mínimos registrados em cada assinatura (Observe que EDITSIG recalcula a estatística das assinaturas após editá-las. Caso você for experimentar qualquer dos outros classificadores mais tarde, use EDITSIG para recalcular os mínimos e máximos originais.).

A outra opção de PIPED que usa unidades de desvio padrão ao invés de valores Mín./Máx. tenta resolver este problema atenuando os efeitos dos extremos. Assim, não é necessário usar EDITSIG para editar os valores das assinaturas, exceto para obter suas estatísticas e visualizar seus histogramas.

- o) Execute PIPED novamente, com a opção de definir paralelepípedo por Escores Z, usando o arquivo de grupo de assinaturas SIGS novamente e denomine esta nova imagem de PIPEDST. Digite um título e mantenha todas as bandas para a análise.

5. Como a classificação por paralelepípedo foi afetada pelo fato de você ter usado desvios padrão ao invés de valores máximos e mínimos?

- q) Compare cada uma das classificações que você criou: MAX, RAW, MINSTD, PIPEORIG e PIPEDST. Para fazer isso, visualize todas as imagens com a tabela de cores Qualitativa 256. Você pode usar um fator de expansão menor que o sugerido pelo Lançador de visualização para poder dispor todas na área do seu monitor ao mesmo tempo.

Como uma observação final, considere o seguinte: caso suas áreas de treinamento forem muito boas, o classificador por máxima verossimilhança deve produzir o melhor resultado. Entretanto, quando áreas de treinamento não são bem definidas, o resultado é geralmente muito pobre. Nestes casos, o classificador por distâncias mínimas com a opção de distâncias do desvio padrão freqüentemente produz resultados bem melhores. O classificador por paralelepípedos com a opção de desvios padrão (Escore Z) também produz bons resultados e é o mais rápido dos classificadores que acabamos de considerar.

Você pode eliminar os arquivos MAX, RAW, MINSTD, PIPEORIG e PIPEDST.




Figura 5. Áreas de treinamento para classificação supervisionada

## 13. Análise de componentes principais

Em imagens de satélite é comum encontrar-se um elevado grau de correlação entre bandas multiespectrais. Caso exista correlação, por exemplo, se as reflectâncias forem altas em algum local particular em uma banda, elas também tenderiam a ser elevadas em outra. Num caso extremo, se duas bandas fossem perfeitamente correlacionadas, elas descreveriam a mesma informação. Não é incomum encontrar-se em uma imagem com 7 bandas, tal como as do LANDSAT *Thematic Mapper*, menos do que 7 bandas de informação verdadeira.

Pergunta-se, portanto, porque apenas algumas bandas possibilitam uma adequada caracterização de reflectâncias da superfície da Terra. Para responder a isso, vamos explorar as características da informação contida em imagens LANDSAT através de análise de componentes principais.

A análise de componentes principais (PCA) está relacionada com análise fatorial e pode ser usada para transformar um conjunto de bandas de uma imagem em novas bandas (denominadas *componentes*) não correlacionadas entre si e ordenadas em termos da proporção da variância da imagem original que podem explicar. As componentes são uma abstração estatística da variabilidade inerente ao conjunto original de dados.

Como cada componente produzida por esta correlação não está correlacionada com a outra, cada uma carrega informação nova. Além disso, por elas estarem ordenados em termos da quantidade de informação que carregam, as primeiras componentes tenderão a carregar a maior parte da informação real existente no conjunto de bandas original, enquanto as últimas componentes irão descrever apenas variâncias menores. Uma aplicação da análise de componentes principais é a compactação de dados -- retendo apenas as primeiras componentes pode-se guardar a maior parte da informação, descartando uma grande parte dos dados.

Usaremos o conjunto de dados de Howe Hill (H87TM1-7) para estudar a análise de componentes principais e as características da informação contida nos dados LANDSAT TM.

- a) Visualize H87TM4 (a banda do infravermelho próximo) com a tabela de cores Tons de cinza 256 e autoescalonamento. Veja também cada uma das demais bandas com autoescalonamento e com a tabela de cores Tons de cinza 256.

1. Há alguma outra banda que se pareça com a banda 4 (H87TM4)? Qual dela(s)?

- b) Execute agora PCA (Análise de componentes principais) a partir do grupo Transformações do menu Análise/Processamento de imagens. Indique que você deseja calcular as covariâncias

diretamente, que você deseja usar sete bandas e quer extrair sete novas componentes. Indique H87 como o novo prefixo para as imagens de saída. Especifique que você quer variáveis não padronizadas e aí forneça os nomes das sete bandas (H87TM1 a H87TM7).

PCA irá proceder ao cálculo das equações de transformação e criará os arquivos com as novas componentes, com nomes que variam de H87CMP1 a H87CMP7.

Quando o módulo PCA tiver concluído o processamento, os resultados irão aparecer na tela como tabelas de sumário. Selecione o ícone de impressão à direita do quadro caso queira ter um relatório impresso das tabelas com os resultados.

2. Examine a matriz de correlação. Você encontra muita correlação entre as bandas? Que bandas se correlacionam mais com a banda 4? Como isto se compara à sua resposta à pergunta 1?
- c)
- Mova agora a barra de rolagem para baixo para examinar a tabela sumário das componentes onde os autovalores (*eigenvalues*) e os autovetores (*eigenvectors*) para cada componente são mostrados. O autovalores expressam a quantidade de variância explicada por cada componente e os autovetores são as equações de transformação. Observe que isto foi apresentado como o *percentual da variância explicada* (% var.) medida no topo de cada coluna.
3. Quanto da variância é explicada pelas componentes 1, 2 e 3 separadamente? Quanto é explicado pelas componentes 1 e 2 juntas (some a quantidade explicada por ambas)? Quanto é explicado pelas componentes 1, 2 e 3 juntas?
  4. Se você quisesse de reter apenas as componentes 1, 2 e 3, qual a quantidade de informação que seria retida? Quanta informação seria descartada? Qual o volume de dados que seria descartado?
- d)
- Agora desloque-se para baixo na janela dos resultados e examine o conteúdo da última tabela (*LOADING*). Os valores referem-se ao grau de correlação entre estas novas componentes (as colunas) e as bandas originais (as linhas).
5. Que banda tem a maior correlação com a componente 1? É uma correlação elevada?
  6. Que banda tem a maior correlação com a componente 2?

Se você não imprimiu as tabelas não feche esta janela porque necessitaremos voltar a ela mais tarde. Simplesmente minimize-a para deixar espaço na tela para a visualização de outras imagens.

- e)
- Visualize agora a componente 1 (H87CMP1) com autoescalonamento e com a tabela de cores Tons de cinza 256. Você pode usar um fator de expansão menor que o sugerido pelo Lançador de visualização reservar espaço para arranjar mais de uma imagem na tela. Visualize a seguir também H87TM4 com autoescalonamento e com a tabela de cores Tons de cinza 256. Visualize também H87CMP2 e H87CMP3 com autoescalonamento e com a tabela de cores Tons de cinza 256 para ambos. Tente arranjar todas estas imagens na tela ao mesmo tempo, escolhendo as opções *em cascata* ou *lado a lado* no menu Janela. Você também pode movimentá-las em torno da tela clicando sobre a barra superior da janela de cada imagem e arrastando-as.
7. Quão similares parecem ser a componente 1 e a imagem do infravermelho? Quão similares parecem ser a componente 2 e a imagem do vermelho?
- f)
- Agora examine a componente 7 (H87CMP7) com a opção de autoescalonamento.
8. Quão correlacionada está esta componente com as sete bandas originais (use a tabela de valores de correlação para determinar isso)? Julgando a partir do que você vê, o que você imagina estar contido na componente 7? Quanta informação será perdida caso



você descarte esta componente?

As relações que vemos neste exemplo não serão as mesmas em todas as paisagens. Entretanto, isto não é algo incomum. Caso você tenha que escolher apenas uma banda para trabalhar, freqüentemente a banda do infravermelho próximo (banda 4) carregará a maior quantidade de informação. Depois desta é geralmente a banda do vermelho visível que carrega a segunda maior proporção de informação. Entretanto, as bandas do verde visível (banda 2 TM) e do infravermelho médio (banda 5 TM) são duas boas candidatas para uma terceira banda a ser considerada.

Voltando à nossa questão original, está claro que três bandas podem carregar uma grande quantidade de informação. Adicionalmente, nós também podemos ver que as bandas que são usadas na composição tradicional em falsa cor (verde, vermelho e infravermelho) são muito bem escolhidas - elas nitidamente carregam a essência da informação do conjunto completo de dados. Assim, para os propósitos da classificação não supervisionada que faremos no próximo exercício, faz sentido usarmos apenas três bandas da imagem para fazer nossa classificação de imagem.

Você pode agora excluir as sete imagens das componentes principais (H87CMP1-7).

## **14. Classificação não supervisionada**

A classificação não supervisionada é outra técnica de classificação de imagem. No método não supervisionado, os padrões de resposta espectral dominantes que ocorrem em uma imagem são extraídos e essas classes de informação são identificadas através de confirmação no terreno (verdade de campo). No IDRISI for Windows, a classificação não supervisionada é oferecida através dos módulos denominados CLUSTER e ISOCLUST. Este exercício utilizará o módulo CLUSTER.

CLUSTER usa uma técnica de seleção pelo pico do histograma. Isto equivale a buscar os picos em um histograma unidimensional, onde um pico é definido como um valor de frequência maior que a de seus vizinhos de cada lado. Uma vez que os picos tenham sido identificados, todos valores observados são associados ao pico mais próximo. Em consequência, as divisões entre as classes tendem a cair no ponto médio entre os picos. Como esta técnica tem critérios específicos para aquilo que constitui um pico, você não necessita fazer uma primeira estimativa (como algumas técnicas requerem) do número de agrupamentos que uma imagem contém – o módulo determinará isto para você.

CLUSTER trabalha diretamente com imagens em composição colorida de três bandas. As imagens com as quais temos trabalhado até agora mostram apenas a informação de uma banda espectral única. O IDRISI for Windows oferece também a possibilidade de criar-se uma composição colorida de três bandas que permite a combinação dos dados das três bandas em uma única imagem de tamanho físico similar ao das imagens de entrada. Nós discutiremos as composições em maior detalhe a seguir.

Dessa forma, CLUSTER avalia um histograma tridimensional de três bandas de imagem representadas na composição colorida. Qualquer combinação de imagens pode ser utilizada na composição colorida. Como vimos no exercício sobre análise de componentes principais, o infravermelho, o vermelho e o verde (uma composição colorida tradicional) contém a maior parte da informação um conjunto de dados completo de 7 bandas espectrais. Por esse motivo, iremos usar estas três bandas neste exercício.

- a) Execute COMPOSIT a partir do grupo Realce do menu Análise/Processamento de imagens. Especifique HOW87TM2 como a banda azul, HOW87TM3 como a banda verde e HOW87TM4 como a banda vermelha (Observe que não usamos a banda 1, a banda do azul visível, sendo cada uma das demais “deslocada para cima”. Devido a isso ela é chamada uma composição colorida em “falsa” cor). Escolha realce linear com saturação de 2,5% e não omita o zero do realce. Chame o resultado de TMFC. Seja paciente, pois isto exigirá algum tempo para ser efetuado. O resultado será visualizado com a tabela de cores Composição colorida 256.
- b) Abra as Preferências de visualização no menu Visualização e ligue as opções de Título visível e Legenda visível. Certifique-se também de que a opção de Visuaizar automaticamente as saídas

dos módulos analíticos está ligada. Execute então CLUSTER a partir do grupo Classificadores rígidos do menu Análise/Processamento de imagens. Especifique TMFC como o nome da composição colorida e chame a imagem de saída de BROAD. Escolha a opção Grosseiro para o nível de generalização e opte por eliminar os agrupamentos não significativos. Dê um título para a imagem. O resultado BROAD será visualizado com a tabela de cores Qualitativa 256.

Esta é uma imagem das classes espectrais muito grosseiras na imagem. Os níveis de generalização Grosseiro e fino usam diferentes regras de decisão ao avaliar os picos do histograma de freqüências. Na generalização ampla, uma classe deve conter uma freqüência maior que todos os seus vizinhos não diagonais.

- c) Use CLUSTER novamente para criar uma imagem chamada FINE, com TMFC como arquivo de composição colorida. Desta vez, use o nível de generalização Fino e novamente opte por eliminar os agrupamentos não significativos. O resultado será visualizado com legenda e com a tabela de cores Qualitativa 256. Como você pode ver, a generalização  *fina*  produz um número muito maior de agrupamentos. Desloque-se legenda abaixo ou aumente o tamanho da caixa de legenda para ver quantos agrupamentos foram identificados.

A classificação fina permite a um vizinho não diagonal possuir freqüência superior. Isto acomoda picos verdadeiros que de outra forma seriam perdidos porque picos vizinhos, de maior magnitude, obscureceriam o vale usual entre os picos. Este conceito é ilustrado em um espaço unidimensional na Figura 1. Agrupamentos grosseiros são divididos apenas nos vales. Agrupamentos finos são divididos tanto nos vales quanto nos picos.




Figura 1

- a) Histogramas da imagem nos permitem ver as diferenças na distribuição dos  *pixels*  entre as classes em função do nível de generalização. Execute HISTO a partir do menu Visualização para criar os histogramas de BROAD e de FINE. O agrupamento 1 é sempre o que possui a maior freqüência de  *pixels* . Ele corresponde ao maior tipo de cobertura do solo detectado durante a classificação. O segundo agrupamento tem um número de  *pixels*  menor que o primeiro, e assim por diante.

O problema que nós temos agora é como interpretar estes agrupamentos. Se você conhece a região, os agrupamentos grosseiros são geralmente fáceis de interpretar. Os agrupamentos finos, entretanto, podem exigir um cuidado consideravelmente maior na interpretação. Normalmente são necessários mapas, fotografias aéreas e visitas ao terreno para identificar adequadamente estes agrupamentos finos. Adicionalmente, nós freqüentemente teremos necessidade de juntar certos agrupamentos para produzir nosso mapa final. Por exemplo, nós podemos encontrar um agrupamento representando floresta em uma encosta sombreada, enquanto outra floresta de igual composição encontra-se em encosta ensolarada. Para juntar e reatribuir agrupamentos como neste caso, podemos usar ASSIGN.

- e) A imagem denominada WORCWEST que utilizamos em um exercício anterior foi de fato criada através de uma classificação não supervisionada com o nível de generalização Fino. Ela

foi então reagrupada usando-se ASSIGN e depois modificada usando-se trabalho de campo e reclassificação. Visualize WORCWEST com legenda e com a tabela de cores personalizada WORCWEST.

Nós iremos repetir o primeiro passo que fizemos e comparar os agrupamentos derivados com os tipos de cobertura do solo existentes. Para efeito didático, usaremos o mapa WORCWEST em vez de trabalho de campo.

- f) Use CROSSTAB a partir do menu Análise/Estatística para comparar WORCWEST com FINE e para ver como as categorias em FINE foram reagrupadas e reclassificadas para criar WORCWEST. Indique WORCWEST como a primeira imagem de entrada e FINE como a segunda. Especifique uma tabela completa de classificação cruzada como saída e aceite as demais opções padrão. Depois que o resultado for exibido, desloque-se para baixo para visualizar toda a tabela. Você também pode imprimir a tabela para facilitar o trabalho de examiná-la.

Descubra agora como as 24 categorias em FINE podem ser reagrupadas para corresponder às 14 categorias de WORCWEST. Observe que alguns agrupamentos foram particionados entre duas categorias de uso do solo. Crie então um arquivo de valores com EDIT que possibilite um reagrupamento similar ao mapa de uso do solo. No caso em que agrupamentos são particionados entre duas categorias, escolha a categoria que abarca o maior número de *pixels* do agrupamento. Na realidade, esta decisão deve ser feita com base também em outras considerações, como trabalho de campo adicional. Em particular, é evidente que o agrupamento 24 está dividido em duas grandes partes – residencial urbano e pedregulhos (*gravel*).

Use ASSIGN para ver se você pode criar uma nova imagem chamada REGRP2, que é parecida com WORCWEST. O propósito disso é ilustrar o processo de reagrupamento usando ASSIGN. O resultado será visualizado com a tabela de cores Qualitativa 256. Mude a tabela de cores de REGRP2 para WORCWEST, usando o botão Propriedades da Composição. A imagem parece agora similar ao mapa de uso do solo?

1. Descreva e explique a natureza do reagrupamento que foi necessário para criar WORCWEST (p.ex., quais foram os maiores reagrupamentos que você teve de fazer?)
- g).
1. Usando as informações de WORCWEST interprete a imagem produzida através da análise de agrupamentos com generalização grosseira, chamada BROAD. Edite a legenda interativamente de forma a atribuir os nomes das classes de uso do solo aos agrupamentos. Para fazer isso, aponte o cursor para a caixa de cores da legenda correspondente à categoria em questão e pressione o botão direito do mouse. Uma caixa de edição da legenda irá aparecer, permitindo a você mudar os nomes na legenda e modificar as cores. Dê ao agrupamento o nome do tipo de cobertura do solo correspondente e, se quiser, modifique a cor de acordo com a tabela de cores de WORCWEST.
  2. Observe que uma das classes urbanas em WORCWEST está interpretada como floresta em BROAD. A que classe urbana em WORCWEST ela pertence? Isto é lógico?

## 15. Georreferenciamento de imagens usando reamostragem

A reamostragem é um procedimento para georreferenciar espacialmente uma imagem à sua posição conhecida no terreno. Esse procedimento é usado frequentemente para registrar uma imagem a um sistema de coordenadas de referência universalmente reconhecido, como Lat/Long ou Universal Transversa de Mercator (UTM). Se uma imagem já está georreferenciada, mas necessita ser transformada a um outro sistema de referências (e.g., de Lat/Long para UTM), recomenda-se seguir o método exposto no Exercício 17 sobre mudança do sistema de referência com PROJECT. A reamostragem só deve ser empregada quando uma imagem não está georreferenciada ou quando sua projeção não é conhecida. Para maiores informações, consulte o capítulo **Georreferenciamento** na seção **TÓPICOS ESPECIAIS** do Manual do usuário do IDRISI for Windows.

Ainda que imagens de satélite e outros dados possam ser comprados pré-georreferenciados, há duas razões pelas quais você deve considerar a aquisição de dados não georreferenciados e fazê-lo você mesmo. Em primeiro lugar, você pode monitorar e reduzir o erro de posição inevitavelmente introduzido durante qualquer processo de reamostragem. Uma imagem pré-georreferenciada apresenta um erro de posição que nem sempre está documentado e que pode ser maior do que aquele que você mesmo pode obter fazendo-o.

Em segundo lugar, você pode escolher o sistema de referência para o qual a imagem será transformada. A reamostragem é uma transformação do tipo *rubber sheet* que estende e deforma uma imagem para adequá-la a um sistema particular de referência. Esse processo introduz distorção espacial. Alguns sistemas de referência, e as projeções a eles associadas, introduzem mais distorção espacial que outros para a mesma área. Ao escolher fazer você mesmo a reamostragem, você pode optar pelo sistema de referência que introduz menos distorção espacial para referenciar seus dados de modo a coincidirem com o sistema de referência de outros dados já em uso no seu trabalho.

O procedimento de reamostragem é feito da seguinte forma:

1. O usuário identifica as coordenadas X,Y de dois pares de pontos que representam o mesmo lugar, no antigo e no novo sistema de coordenadas (Figura 1). As coordenadas do novo sistema podem ser obtidas de um mapa, de uma imagem já georreferenciada, de um arquivo vetorial ou através de levantamentos em campo com instrumentos tradicionais ou com GPS (*Global Positioning System* – Sistema de Posicionamento Global).




Figura 1

2. O usuário cria um arquivo de correspondência que contém esses pares de coordenadas.

```
nº pontos
Xantigo Yantigo Xnovo Ynovo
Xantigo Yantigo Xnovo Ynovo
...
```

3. O IDRISI for Windows resolve uma equação que descreve a relação entre os dois sistemas de coordenadas.

4. Usando essa equação, o IDRISI for Windows converte o arquivo para o novo sistema de referências através do que é denominado uma transformação do tipo *rubber sheet*.

Neste exercício, nós iremos georreferenciar uma imagem LANDSAT *Thematic Mapper* da folha de Paxton - uma área a oeste de Howe Hill, no centro de Massachusetts. Nós reamostraremos a imagem, chamada PAXTON, para o sistema de coordenadas UTM.

a) Visualize a imagem PAXTON com a opção de autoescalamento e a tabela de cores Tons de cinza 256. Esta é a banda do infravermelho.

Mova o cursor sobre a imagem e observe que as posições de coluna correspondem às coordenadas X. Esse sistema de referência foi criado pela atualização da documentação do arquivo imagem com coordenadas mínimas X e Y iguais a 0 e coordenadas máximas X e Y iguais a 512, o número exato de linhas e de colunas na imagem. Execute DESCRIBE em PAXTON para ver o sistema de referência no arquivo documentação. Feche a caixa de diálogo de DESCRIBE quando tiver terminado. A razão pela qual esse sistema de referência arbitrário é usado será explicada no final desse exercício, quando considerarmos o erro de posição introduzido durante a reamostragem.

1. Por que as posições de linha e a coordenada Y não coincidem?

O primeiro passo no procedimento de reamostragem é encontrar pontos que possam ser facilmente identificáveis tanto na imagem como no mapa já georreferenciado. As coordenadas X,Y desses pontos no mapa georreferenciado serão o "novo" par de coordenadas, enquanto as coordenadas do sistema de referências arbitrário da imagem serão o par de coordenadas "antigas". Locais que oferecem bons pontos de controle incluem intersecções de estradas e de rios, represas, pistas de aeroportos, edifícios proeminentes, topos de montanhas ou qualquer outra feição física perfeitamente identificável.

b) Visualize o arquivo vetorial PAXROADS usando o arquivo de símbolos padrão, mas coloque-o como um arquivo separado ao lado da imagem PAXTON, não em sobreposição. Esse arquivo vetorial das principais rodovias foi digitalizado da carta **Paxton** e é distribuído pelo **USGS** (*United States Geological Survey* -- Serviço Geológico dos Estados Unidos) como um arquivo vetorial de linhas no formato DLG (*digital line graph*). Esse arquivo digitalizado e uma janela do mapa original do qual ele foi extraído são mostrados na Figura 3. Enquanto o mapa

impresso em papel apresenta georreferenciamento Lat/Long e UTM, PAXROADS foi digitalizado no sistema UTM, que é o sistema de referência ao qual PAXTON será reamostrado neste exercício.

- c) Para orientar na imagem raster PAXTON e o arquivo vetorial PAXROADS um com o outro, procure intersecções de estradas que possam ser encontradas em ambos. Use a Figura 3 para ajudar você na orientação. Encontre o local com o nome Kettlebrook Reservoir No. 4 na fotocópia do mapa impresso em papel e na imagem PAXTON. A seguir identifique a rodovia imediatamente ao sul do reservatório em PAXROADS e em PAXTON. Amplie uma janela nessa área, se necessário.

Para ilustrar como os pontos de controle são encontrados, volte novamente a janela para a imagem inteira e, a seguir, amplie uma janela no canto superior esquerdo da imagem, aproximadamente desde a coluna 90 e linha 155 até a coluna 155 e linha 255. Olhe para o *pixel* que define a intersecção das estradas entre os dois reservatórios. Essa intersecção corresponde à intersecção encontrada na posição X=254150, Y=4692590 em PAXROADS. Note como é difícil determinar a localização precisa da intersecção em PAXTON por causa da resolução do *pixel*. Esse é o motivo da reamostragem ser uma tarefa que requer tempo e exatidão.

Duas questões são críticas durante essa fase do processo: a obtenção de uma boa distribuição dos pontos de controle e a acurácia de posicionamento. Primeiro, os pontos devem estar distribuídos por toda a imagem, uma vez que a equação que descreve o ajuste espacial entre os dois sistemas de referência é desenvolvida a partir desses pontos. Se os pontos de controle estão agrupados em alguma área da imagem, a equação descreverá somente o ajuste espacial dessa pequena área, e o resto da imagem não estará acuradamente posicionada durante a transformação para o novo sistema de referência. Uma boa sugestão é tentar encontrar pontos ao longo da borda da imagem. Se, entretanto, você está interessado somente numa parte da imagem, você pode concentrar todos os pontos nessa área e então desprezar o resto da imagem durante a reamostragem.

Segundo, ao localizar os pontos, você deve rascunhar um pequeno croqui da área, atribuir um identificador à posição de cada ponto de controle no croqui e registrar o seu nível de confiança na acurácia de posicionamento de cada um dos pontos (p.ex., baixo, médio, alto). Mais tarde, durante o processo de reamostragem, será possível omitir os pontos que apresentem um alto erro de posicionamento na equação. A fim de manter uma boa distribuição de pontos e alta confiança nos pontos de controle remanescentes, será importante lembrar as suas posições na imagem e sua acurácia de posicionamento relativa.

- d) Desfaça novamente a ampliação da imagem para voltar à janela da imagem completa de PAXTON e então, usando a Composição, adicione um plano vetorial chamado PAXPNTS com o arquivo de símbolos personalizado chamado PAXPNTS. Os 20 pontos vermelhos que aparecem são os pontos de controle que já foram encontrados e gravados em um arquivo de correspondência. Os dois círculos azuis são as posições relativas onde você poderá encontrar mais dois pontos de controle. Adicione outro plano chamado PAXTXT com o arquivo de símbolos personalizado chamado PAXTXT. Esses são os identificadores dos pontos de controle com indicação de sua acurácia de posicionamento relativa.

As “novas” coordenadas dos pontos de controle foram tomadas do mapa impresso em papel usando uma mesa digitalizadora e um *software* de digitalização. O uso da mesa digitalizadora garante a coleta de coordenadas de posição precisas. As coordenadas “antigas” dos mesmos pontos de controle são encontradas com o cursor na imagem PAXTON.

Muitas dessas coordenadas “novas” dos pontos de controle podem também ser obtidas no arquivo vetorial PAXROADS, que foi digitalizado a partir do mapa em papel. É isso que você fará para encontrar a localização das “novas” coordenadas dos pontos de controle 21 e 22.

- e) Encontre as intersecções das rodovias que servirão como os pontos de controle 21 e 22 no arquivo vetorial PAXROADS olhando na Figura 3. Amplie uma janela bem próxima da

intersecção da rodovia do ponto 21 no arquivo vetorial. Essas mesmas intersecções estão marcadas com os círculos azuis e os identificadores #21 e #22 em PAXTON. Amplie uma janela muito próxima da intersecção da rodovia do ponto de controle 21 na imagem PAXTON. Copie as coordenadas X e Y “novas” e “antigas” dessa intersecção do arquivo vetorial (“novas”) e da imagem (“antigas”). Repita o mesmo procedimento no ponto de controle 22.

O ponto 21 é um tanto especial. Note que na imagem PAXTON, a rodovia que desce desde o norte parece cruzar a rodovia principal e seguir ao longo do Kettlebrook Reservoir Nº 4, antes de terminar. Na Figura 3, entretanto, nós vemos que a rodovia que desce desde o norte está, de fato, mais para a direita que a rodovia que segue para sul ao longo do reservatório.

2. Quais são as coordenadas X e Y “novas” e “antigas” dos pontos de controle 21 e 22?

O segundo passo no processo de reamostragem é gravar as coordenadas dos pontos de controle no arquivo de correspondência.

- f) Execute EDIT e indique que você quer editar um arquivo de correspondência chamado PAXCOR. A primeira linha no arquivo de correspondência especifica o número de pontos ou pares de coordenadas no arquivo. Logo abaixo os pontos são listados na ordem sequencial.
- g) Para adicionar seus dois novos pontos de controle ao arquivo, comece modificando a primeira linha de modo a atualizar para o novo número de pontos de controle: 22. Vá, então, ao final do arquivo e adicione o novo conjunto de coordenadas. As duas colunas da esquerda são as coordenadas X,Y “antigas” da imagem de satélite e as da direita são as “novas” coordenadas do arquivo vetorial. Após finalizar, salve o arquivo e saia.

Agora estamos prontos para começar o terceiro passo que será calcular a equação de melhor ajuste entre os dois sistemas de referência.

- h) Execute RESAMPLE a partir do menu Reformatação e indique o arquivo PAXTON como o arquivo de entrada a ser reamostrado, PAXRESAM como arquivo de saída e PAXCOR como o arquivo de correspondência. Então selecione o arquivo de parâmetros de sistema de referência US27TM19.

US27TM19 é o nome do arquivo com os parâmetros do sistema de referência que corresponde à Projeção Universal Transversa de Mercator na Zona 19 (que cobre o centro de Massachusetts), baseada no *Datum* NAD27. Essa informação foi encontrada na carta Paxton do USGS. Uma discussão mais completa dos arquivos de parâmetros de sistema referência é feita no Exercício 17, sobre mudança do sistema de referência com PROJECT, assim como no capítulo *Georreferenciamento* do Manual do usuário do IDRISI for Windows.

- i) Mantenha os valores padrão para as unidades de referência, unidades de distância e para o valor de fundo.

Um valor de fundo é necessário porque, após ajustarmos a imagem a uma projeção, a forma atual sofrerá uma rotação. Nesse caso, algum valor necessita ser colocado como valor de fundo para preencher a grade no exterior da nova imagem. O valor zero é a escolha mais comum. Isso é ilustrado na Figura 2.



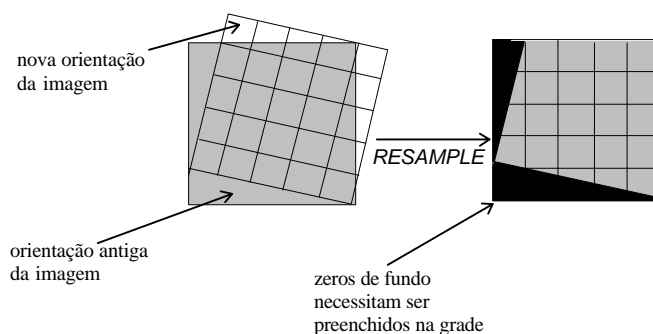


Figura 2

j) Indique os seguintes X e Y mínimos e máximos:

Min X = 253000  
 Max X = 262000  
 Min Y = 4682000  
 Max Y = 4695000

Esse é o retângulo que delimita o novo arquivo que será criado. Qualquer retângulo de delimitação pode ser indicado e é comum selecionar-se uma janela de estudo menor do que a imagem inteira durante esse processo.

O próximo conjunto de parâmetros a determinar é o número de colunas e linhas da imagem de saída. O número de colunas do novo arquivo é calculado pela seguinte equação:

$$\text{n}^\circ \text{ de colunas} = \frac{\text{MaxX} - \text{MinX}}{\text{Resolução}}$$

PAXTON é uma imagem LANDSAT TM que possui uma resolução de 30 metros. Essa é a resolução que nós desejamos manter na imagem de saída. A equação é, portanto:

$$\text{n}^\circ \text{ de colunas} = \frac{262000 - 253000}{30} = 300$$

3. Qual a equação para a determinar o número de linhas?

k) Indique 300 colunas e 433 linhas e escolha uma reamostragem do tipo bilinear.

O processo de reamostragem é como o posicionamento da nova imagem na sua correta orientação sobre a imagem antiga. Os valores são estimados para cada nova célula pela busca da célula correspondente na imagem antiga. Duas lógicas básicas podem ser usadas para a estimativa. Na primeira delas, a célula antiga mais próxima (com base na posição do centro da célula) é escolhida para determinar o valor da nova célula. Esse é o chamado critério do *vizinho mais próximo*. Na outra, a média ponderada pela distância das quatro células antigas mais próximas é utilizada atribuída como o valor da nova célula. Essa técnica é chamada *interpolação bilinear*. A reamostragem com o vizinho mais próximo deve ser usada quando os valores do dado não podem ser alterados, por exemplo, com dados de classes ou dados qualitativos como tipos de solos. A rotina bilinear é apropriada para dados quantitativos como imagens de sensoriamento remoto.

l) Finalmente, escolha a função de mapeamento linear e pressione OK.

A função de mapeamento usada depende da deformação necessária para transformar a imagem original na nova imagem georreferenciada. Você deve escolher a função de ordem mais baixa que produza um resultado aceitável. Um número mínimo de pontos de controle é requerido para cada função de mapeamento (três para linear, seis para quadrática e dez para cúbica), mas o número de pontos usados para esta reamostragem (22) reflete bem a quantidade que deveria ser encontrada para uma área superficial como a de PAXTON com a função de mapeamento linear.

Você está agora diante do erro médio quadrado (RMS) total e do erro residual individual de cada ponto de controle. Cada ponto é mostrado individualmente e numerado de acordo com a ordem em que aparece no arquivo de correspondência. Esses resíduos expressam quanto cada ponto de controle se desvia da equação de melhor ajuste. Novamente, a equação de melhor ajuste descreve a relação entre o sistema de referência arbitrário da imagem e o novo sistema de referência ao qual ela está sendo reamostrada, e essa relação é calculada a partir dos pontos de controle. Um ponto com resíduo alto sugere que as coordenadas do ponto foram mal escolhidas no sistema “antigo”, no sistema “novo” ou em ambos.

O RMS total descreve o erro de posicionamento característico de todos os pontos de controle em relação à equação. Ele descreve a probabilidade com a qual uma posição mapeada poderá variar da sua localização verdadeira. De acordo com os padrões de acurácia dos mapas dos Estados Unidos, o RMS para imagens deve ser menor que  $\frac{1}{2}$  da resolução da imagem de entrada. Neste caso, deve-se esperar que o RMS seja menor que 15. O RMS é expresso, portanto, nas unidades do sistema de referência de entrada. Aqui, nós necessitamos rever como foi escolhido o sistema de referências "arbitrário" de PAXTON.

O sistema de coordenadas X,Y de PAXTON coincide com o número de linhas e colunas da imagem. Isso significa que uma unidade no sistema de referência é igual à extensão de um *pixel*. Em outras palavras, movendo uma unidade na direção X você move um *pixel*. Entretanto, 0,5 unidades no sistema de referência é igual a extensão de  $\frac{1}{2}$  *pixel*. O objetivo, portanto, é reduzir o RMS a menos de 0,5.

- m) Desloque-se para baixo na tabela para visualizar os erros residuais de todos os pontos de controle.

Você notará que alguns pontos têm altos resíduos em comparação com outros. Isso não é inesperado nem incomum. Como vimos anteriormente, nem sempre é fácil saber que *pixel* escolher como ponto de controle, ou se devemos usar o centro da célula ou uma de suas bordas. Felizmente, podemos omitir pontos ruins do arquivo e calcular uma nova equação facilmente. Antes de omitir pontos, entretanto, nós devemos lembrar duas questões importantes mencionadas anteriormente: a manutenção de uma boa distribuição dos pontos e a retenção daqueles pontos em que você tem maior confiança. Pontos com um alto RMS tendem a terem pouco valor, mas nem sempre é assim. Alguns poucos pontos ruins em uma parte da imagem podem “forçar” a equação e fazer um bom ponto parecer ruim. Nesse momento você deve consultar o seu croqui e o nível de confiança anotado em cada ponto. Você pode escolher remover primeiro os pontos mais questionáveis ou, alternativamente, reexaminar suas coordenadas X,Y de posição e recomeçar o processo de reamostragem. Nós faremos considerações sobre cada uma dessas questões à medida que procedermos com a reamostragem.

- n) Avalie os erros residuais dos pontos de controle 21 e 22. Se eles são maiores que 0,46 e 0,92, respectivamente, você precisará recalculá-los a sua localização; eles estão em posições importantes na imagem. Dois pontos próximos ao ponto 21 são considerados de baixa confiança, de forma que são necessários mais pontos com alta confiança na área. Cancele o processo de reamostragem, encontre coordenadas melhores, use EDIT para atualizar o arquivo de correspondência e então recomece a partir do passo “i” deste exercício. Localize você mesmo os pontos ou, para ganhar tempo, indique as seguintes coordenadas:

21	348	185	259666.5	4687351.0
22	391.5	88	260295.8	4684403.0

- o) Com as coordenadas atualizadas dos pontos 21 e 22, o seu RMS total para os 22 pontos de

controle deve estar por volta de 0,85. Com relação aos outros, o ponto 7 é alto e, por ele estar muito próximo a outros dois pontos e ter uma baixa confiança, nós o omitiremos. Selecione o ponto 7 na caixa central, escolha omitir o ponto e recalcule a equação. Note que os resíduos de todos os pontos, assim como o RMS total, mudam. Uma nova equação foi calculada com os 21 pontos remanescentes.

- p) Agora, omita os pontos 18, 20 e 14. Todos esses pontos são de baixa confiança e não estão espacialmente isolados. Recalcule a equação. O RMS total ainda é maior que desejamos. O ponto de controle com o próximo resíduo mais alto é provavelmente o ponto 22 (dependendo das coordenadas que você usou). Ele foi bastante difícil de localizar na imagem e não está espacialmente isolado, então omita este ponto também. O ponto 9 também tem resíduo elevado e é de baixa confiança. Como temos os pontos 8 e 13 próximos ao ponto 9, ambos com nível de confiança bom, vamos omitir o ponto 9 e recalculamos o RMS.


#### 4. Qual é o erro RMS?

Embora o resultado esteja um pouco mais alto que o padrão de acurácia de mapas dos Estados Unidos, está bastante próximo. Além disso, o ponto com o próximo resíduo mais alto, o ponto 1, tem uma posição relativamente isolada e importante na imagem. Ele foi considerado bom com relação ao nível de confiança na determinação das coordenadas de posição. Não será vantajoso omitir esse ponto. Continuaremos com o processo de reamostragem com este conjunto de pontos de controle.

- q) Pressione OK para continuar o processo de reamostragem.

O computador está executando o quarto e último passo do processo de reamostragem. A imagem inteira está sendo transformada para o novo sistema de referência de acordo com a equação.

- r) Quando a reamostragem estiver completa, a equação atual será mostrada, junto com as coordenadas dos pontos de controle e os resíduos individuais. Você pode imprimir esse arquivo de texto selecionando o ícone de impressão.
- s) Visualize a nova imagem PAXRESAM com a tabela de cores Tons de cinza 256 e com autoescalonamento. Use a Composição para sobrepor o plano vetorial PAXROADS com o arquivo de símbolos padrão e examine o grau com que as informações vetoriais e raster coincidem.
- t) Visualize a imagem original PAXTON e note o giro no sentido horário que ocorreu durante a reamostragem. Essa transformação espacial é mais evidente quando olhamos os lagos no lado direito da imagem. Eles apresentam uma orientação muito mais vertical na nova imagem do que tinham na imagem original.



Digital Line Graph (DLG)  
 Quadrângulo de PAXTON  
 Massachussets - Worcester, Co.  
 United States Department of the  
 Interior Geological Survey  
 7.5 Minutes Series  
 1965



Figura 3

## 16. Bases de dados cartográficos digitais

Como a entrada de dados é uma das tarefas que mais consome tempo quando se trabalha com SIG, as agências nacionais de cartografia em vários países estão agora desenvolvendo bases de dados cartográficos digitais que podem fornecer planos de dados importantes com baixo custo. Neste exercício estudaremos dois tipos de dados disponibilizados pelo Serviço Geológico dos Estados Unidos (*United States Geological Survey* -- USGS) e os procedimentos disponíveis para incorporá-los no IDRISI for Windows.

Os dois formatos que estudaremos são arquivos de dados DLG (*Digital Line Graph*) e DEM (*Digital Elevation Model*). Arquivos DLG contém a informação planimétrica normalmente encontrada nos mapas topográficos do USGS, e estão disponíveis em formato vetorial nas escalas 1:24.000, 1:250.000 e 1:2.000.000. Os arquivos DEM contém informação hipsométrica (elevação) nas escalas 1:24.000 ou 1:250.000 e estão em formato raster. Tanto os arquivos DLG Formato Opcional Nível 3 1:24.000 quanto os arquivos DEM 1:24.000 são orientados no sistema de coordenadas UTM e estão formatados para proporcionar dados contidos nos limites definidos pelas folhas padrão de uma grade de 7,5 minutos (1:24.000).

Os dados com os quais trabalharemos neste exercício são os da folha 1:24.000 de Black Earth, Wisconsin. Eles incluem dois dos planos DLG e o DEM correspondente. Os planos DLG consistem nos arquivos de dados da hidrografia (BE\_HYD:DLG) e das rodovias (BE\_RD.DLG). O arquivo DEM é denominado BLKEAR.DEM.

Primeiro importaremos os elementos selecionados dos arquivos DLG. O USGS separa dados DLG em vários arquivos, cada um com uma informação específica. Por exemplo, as informações de estradas e trilhas estão em um arquivo enquanto a informação sobre a hidrografia está em outro. Ferrovias, linhas de transmissão e hipsografia (curvas de nível) são outros planos que também estão disponíveis. Em cada arquivo, os elementos são ordenados por tipo - nó (ponto), linha ou área (polígono) - aos quais são atribuídos códigos numéricos correspondentes aos valores de um dicionário de atributos padrão do USGS. Em cada DLG do USGS, por exemplo, um código principal igual a 180 indica uma feição de ferrovia e um código secundário de 201 e 208 indica respectivamente trechos ferroviários e derivações ferroviárias. Um livreto detalhado deste esquema de códigos, assim como um guia para o usuário dos produtos DEM e DLG estão disponíveis no USGS.

Nós extrairemos do arquivo DLG de rodovias os elementos denominados como rodovias (*routes*), estradas (*roads*) e ruas (*streets*). Extrairemos também informação acerca dos rios (*streams*), banhados (*marshes*), lagos (*lakes*) e açudes (*ponds*) do plano de hidrografia.

- a) Escolha a opção Importação/Exportação do menu Arquivo e execute o módulo DLG a partir do menu Importar/Formato do Governo dos EUA/Agências do módulo de importação e exportação. Este programa lê e converte especificamente dados no formato opcional *Digital Line Graph* (DLG) do USGS para o formato vetorial do IDRISI for Windows<sup>39</sup>.

A primeira feição que extrairemos são as rodovias (*routes*), estradas (*roads*) e ruas (*streets*). Especifique BE\_RD como o nome do arquivo DLG a ser usado. O módulo irá ler a informação do cabeçalho do arquivo DLG e preencher automaticamente as coordenadas da janela a extrair, as coordenadas do arquivo resultante e o sistema de referência. Os valores padrão das coordenadas são especificados de forma que as feições do retângulo inteiro sejam extraídas e mantenham suas coordenadas originais. Isto é exatamente o que queremos neste caso, de forma que manteremos os valores padrão como eles são sugeridos.

O sistema de referência US27TM16 é mostrado porque havia informação suficiente no cabeçalho do arquivo DLG sobre o *datum* e o número da zona UTM para que o sistema selecionasse um arquivo de parâmetros do sistema de referência específico. Caso tal informação não estivesse presente, o sistema de referência padrão "plano" teria sido introduzido<sup>40</sup>.

- b) Estaremos extraindo elementos de linha, escolha portanto Linhas para o tipo de dado e entre ROADS como nome do arquivo de saída. Se já soubéssemos os códigos numéricos dos elementos que desejamos extrair, poderíamos indicá-los agora na caixa de diálogo. Em vários aspectos, o procedimento de extração de feições DLG assemelha-se a RECLASS, onde novos identificadores são atribuídos para um código ou para um intervalo de códigos de atributo DLG.

Como não sabemos os códigos das rodovias (*routes*), estradas (*roads*) e ruas (*streets*), escolha Escanear dados (na caixa de diálogo no canto inferior direito) para visualizar a lista dos tipos de elementos de linha no arquivo DLG. Você pode deslocar-se para a frente ou para trás ao longo da lista pressionando as setas. Observe como o módulo DLG lista os códigos principais e os códigos secundários associados a cada feição. As descrições correspondentes são lidas no dicionário de atributos DLG que acompanha o IDRISI for Windows.

1. Qual é o código principal para rodovias (*routes*), estradas (*roads*) e ruas (*streets*)?
- c) Queremos extrair somente as rodovias (*routes*), estradas (*roads*), ruas (*streets*) e feições de revisão fotográfica (*photorevised features*). Escolha cada linha que representa um destes tipos clicando na caixa correspondente. Não escolha quaisquer símbolo alfanuméricos, números ou feições coincidentes. Você deve escolher cinco itens.

Pressione OK para sair da listagem e retorne à caixa de diálogo principal. Quando escolhemos combinações específicas de códigos principais e secundários, seus valores individuais foram automaticamente transferidos para a área *Feições a extrair* da caixa de diálogo. Pressione a seta esquerda para ver os valores que foram indicados. Por definição, o novo identificador (ID) introduzido é idêntico ao código secundário original. Neste caso, ao invés de manter os valores do código secundário, mude os novos valores de ID para os seguintes (chame novamente a lista de códigos caso você não lembre dos códigos correspondentes a cada elemento):

<sup>39</sup>Deve também ser observado que o formato DLG se tornou um padrão para intercâmbio de dados entre sistemas, de forma que o módulo DLG também pode ser usado para importar dados de outros *software* (Arc/Info, p. ex.) além de importar dados do USGS.

<sup>40</sup>Para maiores informações sobre arquivos de parâmetros de sistema de referência, *datums* e outras questões, veja o capítulo *Georreferenciamento* no Manual do usuário do IDRISI for Windows.

Feição	Novo ID
Rodovia principal ( <i>Primary Route</i> )	1
Rodovia secundária ( <i>Secondary Route</i> )	2
Estrada ou rua classe 3 ( <i>Road or Street Class 3</i> )	3
Estrada ou rua classe 4 ( <i>Road or Street Class 4</i> )	4
Fotorevisado ( <i>Photorevised</i> )	5

Agora estamos prontos para extrair as feições escolhidas um arquivo vetorial do IDRISI for Windows chamado ROADS. Para fazer isso, pressione OK.

- d) Quando o processo tiver terminado, o arquivo será automaticamente visualizado (desde que você tenha ligado a visualização automática nas Preferências de visualização) e o utilitário de Importação/Exportação será minimizado. Para a diferenciar os tipos de estrada na visualização, abra a Oficina de símbolos a partir do menu Visualização. No menu Arquivo da Oficina de símbolos escolha criar um novo arquivo de símbolos para linhas chamado ROADS. Crie tipos de símbolos apropriados com valores de 1 a 5 e salve o arquivo. Feche a seguir a Oficina de símbolos, pressione o botão Propriedades da Composição e selecione o novo arquivo de símbolos ROADS. Estas são as feições de rodovias, estradas e ruas que estão impressos na quadrícula 1:24.000 do USGS da folha de Black Earth, Wisconsin.
- e) Agora maximize o utilitário de Importação/Exportação e siga o mesmo procedimento com BE\_HYD para extrair os cursos d'água (*streams*), banhados (*marshes*), lagos (*lakes*) e reservatórios (*ponds*). Extraia os rios como linhas em um arquivo chamado STREAMS e dê a todas as linhas um novo ID igual a 1.
2. Quais são os códigos principais e secundários dos cursos d'água?
- f) Extraia banhados (*marshes*) lagos (*lakes*) e açudes (*ponds*) como elementos de área em um arquivo vetorial em separado chamado WATERBOD, dando o novo ID 1 para banhados e o novo ID a 2 para lagos e açudes. (São necessários arquivos separados para cursos d'água e corpos d'água já que linhas e polígonos (área) são tipos de objetos que não podem ser registrados no mesmo arquivo vetorial do IDRISI for Windows).
- g) Crie novos arquivos de símbolos para STREAMS e WATERBOD, visualizando-os a seguir juntamente com ROADS em uma mesma composição.

Nós completamos agora a porção de importação DLG deste exercício. Nossa próxima tarefa é importar o arquivo raster DEM.

- h) Execute o módulo DEMIDRIS do módulo de Importação/Exportação a partir do menu Arquivo/Importar/Formato do Governo dos EUA/Agências. Este módulo lê e importa especificamente dados do modelo digital de elevação do USGS para o formato imagem do IDRISI for Windows.

Especifique que você quer converter um arquivo denominado BLKEAR.DEM (é necessário especificar sua extensão) e indique DEM como o nome da imagem de saída.

- i) Esse processo pode levar alguns minutos, dependendo da velocidade do processador de seu computador. Quando a conversão estiver concluída, a imagem DEM será automaticamente visualizada. Feche o utilitário de Importação/Exportação (neste momento ele está minimizado).
3. Por que há áreas em preto contornando as bordas do DEM e por que elas têm esta forma peculiar?
4. Por que apenas a porção superior da tabela de cores é usada na visualização (Sugestão: qual é o valor mínimo na imagem? Qual é a elevação mínima?)?

- j) Para produzir uma visualização melhor do DEM, podemos aplicar um realce. Execute STRETCH a partir do menu Visualização e selecione realce Linear. Especifique DEM como imagem a ser realçada e DEMC como nome da imagem de saída. Escolha excluir os zeros, pois neste caso eles não representam um valor de altitude e sim um valor de fundo. Realce para 256 níveis e atribua um valor igual a 1 para o menor valor que não o de fundo. Isto nos permitirá distinguir o fundo da menor altitude. O valor mais alto será 255.
- k) Visualize DEMC com a tabela de cores Idrisi 256. Agora estamos usando toda a tabela de cores. O único problema restante é a dificuldade que temos em distinguir o fundo, que está sendo mostrado com cor zero, das menores altitudes na imagem, mostradas com cor um.
- Para remediar isto, execute Oficina de tabelas de cores e abra a tabela de cores IDRIS256, recuperando-a da biblioteca permanente. Selecione a cor número zero, alterando-a para branco. Use Salvar como... para salvar a nova tabela de cores no diretório de trabalho com o nome de BLKEARTH. Feche a Oficina de tabelas de cores. Agora pressione o botão Propriedades na janela da Composição e modifique a tabela de cores para BLKEARTH. Pressione OK.
- l) Vamos agora criar uma visualização especial que ilustra ambos, os dados DEM e DLG juntos. Adicione os arquivos STREAMS à visualização de DEMC. Quando aparecer o sinal de atenção, alertando que o sistema de referência dos dois dados não é o mesmo, escolha por adicionar o plano mesmo assim. Examine a visualização bem de perto?

5. Você percebe algo peculiar nesta composição de mapa?

É evidente que há algo errado aqui - a não ser que os cursos d'água em Wisconsin realmente fluam ao longo das encostas dos vales! O que você está vendo é a diferença na definição da posição dos elementos entre dois sistemas de referência diferentes. É para isso exatamente que o Lançador de visualização estava alertando. Ambos os dados DLG e DEM são georreferenciados ao sistema UTM, mas os arquivos DLG são baseados no *datum* North American 1927 (NAD 27) enquanto os arquivos DEM estão baseados no *datum* North American 1983 (NAD 83). Veja que diferença o *datum* pode fazer!

Esta diferença é bem visível nesta figura porque nós acrescentamos o arquivo de cursos d'água. Caso tivéssemos acrescentado o arquivo de rodovias, a discrepância não seria tão óbvia. Como estas incompatibilidades nem sempre são óbvias, é essencial que toda informação sobre o sistema de referência sempre seja determinada para qualquer plano de informação a incorporar na sua base de dados. Caso você esteja digitalizando seus próprios planos, esta informação é geralmente impressa diretamente nos mapas em papel. Se você estiver recebendo dados digitais de uma fonte como o USGS, a informação é freqüentemente incluída em um cabeçalho, em um arquivo de acompanhamento ou em documento em papel. Caso você adquira e use dados sem tal documentação, é bom estar ciente das conseqüências.

De modo a combinar adequadamente os dados DLG e DEM que importamos, todos os planos necessitam estar num mesmo sistema de referência. No próximo exercício usaremos o módulo PROJECT para transformar o *datum* dos planos DLG de NAD27 para NAD83 para fazê-los coincidir com os de DEM.

Salve todos os arquivos que criamos neste exercício. Você os usará no próximo.



## 17. Alteração do sistema de referência com PROJECT

No exercício anterior importamos dados DLG e DEM do USGS para o formato do IDRISI for Windows. Notamos então que os arquivos DLG possuíam *datum* diferente do arquivo DEM. Neste exercício, usaremos o módulo PROJECT para modificar o *datum* dos arquivos DLG para ajustá-los ao DEM.

O módulo PROJECT tem este nome porque a sua função é alterar a projeção de uma imagem ou arquivo vetorial. Entretanto, ele é mais especificamente um módulo de transformação entre sistemas de referência. Um sistema de referência consiste de:

- um *datum* que define a forma da Terra (através de um elipsóide de referência) e o ajuste específico deste elipsóide à forma real irregular da Terra (geralmente definido por um conjunto de três constantes conhecidas como constantes de Molodensky).
- uma projeção, consistindo do seu nome e todos os parâmetros necessários para ajustar esta projeção ao *datum*.
- um sistema de grade, consistindo de uma origem real e uma falsa origem de onde a numeração inicia, além das unidades de medida específicas.

PROJECT é capaz de transformar arquivos imagem e vetoriais sempre que qualquer um destes parâmetros for modificado. Assim, se desejamos apenas alterar o *datum*, mantendo a mesma projeção, nós usamos o módulo PROJECT.

- a) Execute PROJECT a partir do menu Reformatação. Escolha o tipo de arquivo vetorial e especifique STREAMS como arquivo de entrada. O sistema de referência para STREAMS é US27TM16. Dê STREAM83 como arquivo de saída e US83TM16 como arquivo de referência para o resultado.
- b) Visualize STREAM83 com o arquivo de símbolos STREAMS que você criou no exercício anterior. Adicione então o plano STREAMS com o arquivo de símbolos padrão. Quando o Lançador de visualização alerta para o fato dos sistemas de referência não coincidirem, opte por adicionar o plano assim mesmo. A diferença causada pela alteração de *datum* de NAD27 para NAD83 nesta região é bastante grande, particularmente na direção norte-sul.

- c) Agora use PROJECT com os outros arquivos vetoriais, ROADS e WATERBOD, transformando o sistema de referência de US27TM16 para US83TM16. Visualize DEMC com a tabela de cores BLKEARTH e coloque sobre ela os arquivos vetoriais recém convertidos com seus arquivos de símbolos correspondentes.

Nos Estados Unidos, o sistema de referência Universal Transverso de Mercator (UTM) é usado no mapeamento topográfico. Suas características de erro não servem para as necessidades de planejamento dos governos locais. Neste contexto, o erro não deveria exceder 1:10.000 (1 parte em 10.000) e o sistema UTM, com zonas de 6 graus, tem um erro em seu centro que pode ser de até 1:25.000. Assim ele não é usado para os propósitos de engenharia pelos governos locais. Nos Estados Unidos tem sido adotado um sistema de coordenadas planas estadual -- State Plane Coordinate System (SPCS), tendo cada estado o seu sistema particular. Ele é baseado na projeção Transversa de Mercator (não confundir com UTM) ou na Cônica Conforme de Lambert. Na maioria dos estados são necessárias várias zonas para que se tenha um erro abaixo do limite de 1:10.000.

O conjunto de dados de Black Earth com o qual estamos trabalhando cai no sistema *Wisconsin State Plane 1983 South Zone* (de acordo com uma folha topográfica recente). Arquivos REF foram fornecidos em separado para todas as zonas SPC, para o *datum* NAD27 e o *datum* NAD83, como explicado em detalhe no **Apêndice 3: Arquivos de parâmetros de sistema de referência fornecidos**. O que necessitamos para a nossa área é o SPC83W13. Vamos converter então nossos arquivos de dados ao sistema *State Plane*.

- d) Execute PROJECT e indique que você quer transformar o arquivo de entrada denominado DEM (o qual usa o sistema de referência US83TM16) para produzir um arquivo de saída denominado SPCDEM usando o sistema de referência SPC83WI3. Observe que existem alguns parâmetros adicionais nesta caixa de diálogo comparada àquela da última vez em que rodamos PROJECT, porque desta vez estamos projetando um arquivo imagem. Há referência ao valor de fundo e ao tipo de reamostragem a usar. Essas questões são idênticas às encontradas em RESAMPLE no Exercício 15, e por uma boa razão. O processo de projeção de um arquivo imagem é essencialmente idêntico ao processo usado por RESAMPLE - apenas as fórmulas usadas para as transformações geométricas são diferentes.

Você pode usar o valor padrão zero para o fundo. O tipo de reamostragem deve ser por Vizinheiro mais próximo para dados qualitativos e Bilinear para dados quantitativos. Entretanto, o processo Bilinear é um pouco lento e, caso você queira escolher a rotina mais rápida selecione Vizinheiro mais próximo, já que estamos realizando este processo apenas com propósitos ilustrativos e didáticos<sup>41</sup>. Pressione Continuar...

PROJECT perguntará então o número de colunas e de linhas e as coordenadas mínimas e máximas de X e Y para a área a ser projetada. Você poderá usar as opções sugeridas já que queremos no resultado a mesma área, com a resolução espacial inerente.

Quando PROJECT tiver terminado, visualize o resultado com autoescalonamento.

- e) Para confirmar se nossa transformação funcionou, execute PROJECT novamente e transforme o arquivo vetorial denominado STREAM83 para o sistema de referência SPC83WI3 (você pode denominar o resultado de SPCSTRM). Adicione então este resultado como outro plano na Visualização de SPCDEM (Você pode transformar também os outros arquivos vetoriais se desejar).

Aqui vemos então nossos arquivos no sistema *State Plane*. Desta vez, embora não tenhamos mudado o *datum*, nós alteramos tanto a projeção (de Transversa de Mercator para Cônica Conforme de Lambert) quanto o sistema de grade (já que eles tem origens falsas e verdadeiras diferentes).

---

<sup>41</sup> Atualmente, não há uma grande diferença entre as duas opções quando o dado é quantitativo e a resolução não for significativamente alterada. A opção Bilinear produz uma superfície mais suavizada, mas altera os valores dos seus níveis originais. O Vizinheiro mais próximo não altera qualquer valor, mas produz um resultado menos contínuo.

O IDRISI for Windows oferece mais de 400 arquivos de sistema de referência. Entretanto, existem possibilidades quase infinitas e é perfeitamente possível que o sistema que você necessita para seu trabalho não esteja disponível nesta lista. Neste caso, a melhor forma de proceder é copiar um arquivo existente que possua projeção similar à que você deseja e usar EDIT para atualizar esta cópia com os parâmetros corretos. Os detalhes sobre estes parâmetros podem ser encontrados no capítulo **Georreferenciamento** do Manual do usuário do IDRISI for Windows.

Antes de terminar este exercício, vale a pena observar aqui a diferença entre PROJECT e RESAMPLE (que nós usamos no Exercício 15). Eles são similares em alguns aspectos mas muito diferentes em outros. RESAMPLE é um meio para transformar um sistema de referência desconhecido (e possivelmente irregular) para um conhecido. PROJECT, por outro lado, transforma de um sistema conhecido para outro também conhecido. Adicionalmente, PROJECT usa fórmulas específicas para suas transformações enquanto RESAMPLE usa uma equação de melhor ajuste baseada em um conjunto de pontos de controle.

# EXERCÍCIOS TUTORIAIS AVANÇADOS

Os exercícios nesta seção oferecem a oportunidade de exploração de uma variedade de tópicos avançados em Sistemas de Informação Geográfica e Processamento de imagens. Os exercícios estão agrupados da seguinte forma:

## Classificação de dados de sensoriamento remoto

1. Teorema de Bayes e classificação por máxima verossimilhança
2. Desenvolvimento de assinaturas *fuzzy*
3. Classificadores relativos I: BAYCLASS
4. Discretizadores
5. Classificadores relativos II: BELCLASS
6. *Dempster-Shafer* modificado

## Índices de vegetação

7. Sensoriamento remoto em ambientes áridos

## Apoio à decisão

8. Avaliação por critérios múltiplos -- Análise *Booleana*
9. Avaliação por critérios múltiplos -- Combinação linear ponderada
10. Avaliação por critérios múltiplos -- Média ponderada ordenada
11. Tomada de decisão com objetivos múltiplos
12. Modelagem de peso de evidência com BELIEF
13. Incerteza no banco de dados e risco na decisão

## Modelagem estatística

14. Regressão múltipla em SIG
15. Variáveis dicotômicas e regressão logística

Diferente dos exercícios do conjunto introdutório, os exercícios avançados podem ser feitos em qualquer ordem de seqüência. Recomenda-se, entretanto, que os exercícios do grupo de classificação (exercícios 1- 6) sejam feitos em seqüência.

# **1. Teorema de Bayes e classificação por máxima verossimilhança**

O procedimento por máxima verossimilhança é inquestionavelmente o mais usual para classificação em sensoriamento remoto. O fundamento deste método é o teorema de Bayes, o qual expressa a relação de evidência, o conhecimento prévio e a probabilidade de que uma determinada hipótese seja verdadeira. Infelizmente e surpreendentemente, a possibilidade de incorporação de conhecimento prévio é pouco utilizada. Geralmente os analistas não fazem consideração alguma sobre a probabilidade relativa de encontrar-se classes de cobertura do solo de interesse antes de considerar a evidência e assim assumir que cada classe possui igual probabilidade. Em casos de forte evidência, isto causará pouco dano. Entretanto, é no caso de fraca evidência que o conhecimento prévio pode ter contribuição importante. O IDRISI for Windows é uma exceção ao oferecer um valioso conjunto de opções para a inclusão de conhecimento prévio no processo de classificação. Em particular, ele oferece a capacidade especial de incorporar conhecimento prévio na forma de imagens de probabilidade, de modo que a probabilidade a priori de qualquer classe pode variar de um local para outro. Como será visto neste exercício, isso é um melhoramento significativo no procedimento de classificação.

- a) Examine as três imagens multiespectrais SPOT (XS) denominadas SPWEST1, SPWEST2 e SPWEST3. Elas correspondem às bandas verde, vermelho e infravermelho próximo do sensor SPOT-HRV para a área de Westboro, Massachusetts. Construa uma composição colorida em falsa cor destas bandas, denominando-a SPWESTFC e usando o módulo COMPOSIT e realce linear com saturação de 1%. Visualize o resultado (caso você esteja com o módulo de visualização automático ativado, isto acontecerá automaticamente).

Westboro é uma pequena cidade que passou por um desenvolvimento substancial nos últimos anos devido à sua localização estratégica, em uma das regiões de maior desenvolvimento de alta tecnologia nos Estados Unidos. Também é uma área com ocorrência significativa de banhados -- um tipo de cobertura do solo de particular interesse ambiental.

- b) Usando a opção Adicionar Plano da janela de Composição, visualize um arquivo vetorial denominado SPTRAIN. Este plano contém um conjunto de áreas de treinamento para os seguintes tipos de cobertura:

1.	Residencial antiga	OLDRS
2.	Residencial nova	NEWRS
3.	Industrial/comercial	INDCM
4.	Estradas	ROADS
5.	Água	WATER
6.	Agricultura/pecuária	AGPAS
7.	Floresta decídua	DECID
8.	Banhados	WETLN
9.	Pistas de golfe/gramados	GOLFG
10.	Floresta de coníferas	CONIF
11.	Água rasa	SHALW

A última coluna desta lista contém os nomes de assinaturas sugeridos que serão usados nesta e nas demais seções deste conjunto de exercícios.

- c) Use MAKESIG para criar um conjunto de assinaturas para as áreas de treinamento do arquivo vetorial SPTRAIN. Indique que as 3 bandas SPOT denominadas SPWEST1, SPWEST2 e SPWEST3 devem ser usadas. As assinaturas devem ser identificadas com os nomes anteriormente indicados. Embora não seja requerida uma ordem a ser usada, eles deveriam ser introduzidos na ordem listada acima para que se possa usar uma tabela de cores específica para a visualização da classificação.
- d) Execute MAXLIKE no grupo Classificadores rígidos para criar uma imagem denominada SPMAX1. Nesta primeira tentativa, nós assumiremos que não temos informação prévia sobre a frequência relativa com a qual cada classe irá aparecer. Em função disso, opte por probabilidades a priori iguais e opte por classificar todos os *pixels*. Especifique a seguir os nomes para as 11 classes de assinaturas e use todas as bandas na classificação.
- e) Quando a classificação estiver completa, visualize o mapa resultante usando a tabela de cores denominada SPMAX. Opte também por visualizar a legenda. Compare a seguir o resultado com a composição colorida em falsa cor denominada SPWESTFC.
1. Compare a classificação com a composição colorida em falsa cor. Que classes foram, no seu entender, melhor classificadas? Qual a que parece ter sido a pior?

O estado de Massachusetts efetua regularmente inventários sobre o uso e cobertura do solo usando fotografias aéreas. A imagem SPOT usada aqui é de 1992. Antes dessa data, avaliações de uso do solo foram feitas também em 1978 e 1985. Com base nestes inventários para a cidade de Westboro, CROSSTAB foi usado para determinar a frequência relativa com a qual cada classe de cobertura do solo mudou com relação a cada uma das outras classes no período 1978-1985. Estas frequências relativas são conhecidas como probabilidades de transição e são a base subjacente para a previsão de uma Corrente de Markov de previsão de futuras transições. Caso seja assumido que as forças direcionais e trajetórias de mudança subjacentes permaneceram estáveis, é possível estimar a probabilidade com a qual cada classe de cobertura pode modificar para qualquer outra. Usando como base as classes de cobertura do solo de 1985, as probabilidades de transição foram aplicadas a esta base para produzir um conjunto de mapas de probabilidade que expressam a confiança prévia de como cada uma das classes de cobertura irá ocorrer em 1992. Estes mapas têm os seguintes nomes:

PROLDRS  
 PRNEWRS  
 PRINDCM  
 PRROADS  
 PRWATER  
 PRAGPAS  
 PRDECID  
 PRWETLN  
 PRGOLFG  
 PRCONIF  
 PRSHALW

- f) Visualize um destes mapas de probabilidades a priori (PRNEWS, p.ex.), usando a tabela de cores IDRISI 256. Observe que estas definições espaciais de probabilidades a priori somente são válidas dentro dos limites da cidade. Fora deles, a probabilidade a priori foi expressa como uma probabilidade de transição não espacial, de modo similar com o que se especificaria tradicionalmente no uso do procedimento Bayesiano de máxima verossimilhança. Por exemplo, na imagem PRNEWS, a área externa à cidade tem uma prioridade a priori de 0,18, o que representa simplesmente a probabilidade destas áreas serem novas áreas residenciais em 1992. Entretanto, as probabilidades a priori de caráter espacial atingem 0,70 em qualquer outro lugar, dependendo da cobertura do solo existente em 1985.
- g) Execute MAXLIKE novamente. Repita os mesmos passos feitos anteriormente, mas desta vez indique um arquivo de probabilidades a priori para cada assinatura. Indique junto a cada assinatura o seu mapa de probabilidades a priori correspondente. Denomine este novo mapa de SPMAX2.
- h) Visualize SPMAX2 com a tabela de cores SPMAX e com legenda. Adicione o arquivo vetorial WESTBND com o botão Adicionar Plano da janela de Composição. Este arquivo mostra os limites da cidade.
2. Descreva as classes nas quais ocorreram mudanças mais evidentes como resultado da inclusão de probabilidades a priori.
- i) Use CROSSTAB para criar um mapa de classificação cruzada e uma tabela de tabulação cruzada das diferenças entre SPMAX1 e SPMAX2. Chame o mapa da classificação cruzada de MAXIMAX2. Visualize MAXIMAX2 usando a tabela de cores QUAL256. Para facilitar o exame das áreas que apresentam modificação em função da introdução de probabilidades a priori, use a edição interativa da legenda modificando para preto cada categoria que *não* foi alterada<sup>42</sup>. Coloque o plano vetorial WESTBND sobre seu mapa para facilitar o exame dos efeitos do esquema de probabilidades a priori.
3. Você observou qualquer mudança significativa que não era óbvia na questão 2 acima?
  4. Como você descreveria o padrão de áreas que estão além dos limites da cidade e sofreram mudança, em comparação com aquelas que mudaram no interior da área urbana?
  5. O que pode ser concluído sobre o valor do uso de definição espacial de probabilidades a priori versus uma definição não espacial?

A definição espacial de probabilidades a priori oferece uma ajuda poderosa ao processo de classificação. Embora um interesse considerável tenha sido dirigido para a possibilidade de uso de SIG como uma entrada no processo de classificação, os progressos têm sido um pouco lentos, em grande parte devido à inabilidade de especificar probabilidades a priori de modo espacial. O procedimento ilustrado aqui oferece uma ligação muito importante e abre a porta para uma ampla gama de modelos em SIG (tal como o procedimento da Corrente de Markov ilustrado aqui) que podem auxiliar neste processo.

---

<sup>42</sup> Para usar a edição interativa da legenda, coloque o cursor sobre a caixa de legenda da classe a ser editada. Mantenha acionada a tecla "Shift" e clique o botão direito do mouse. Você poderá então mudar a cor e o nome desta classe. Você terá ainda a chance de salvar esta nova tabela de cores quando a janela de visualização do mapa for fechada.

## 2. Desenvolvimento de assinaturas fuzzy

Uma das principais suposições da abordagem Bayesiana para classificação de imagens é que as áreas de treinamento representam amostras puras das classes que representam. Entretanto, como mencionado no capítulo *Classificação de imagens de sensoriamento remoto* da seção *TÓPICOS ESPECIAIS* do Manual do Usuário, isto raramente ocorre. Por exemplo, é provável que mesmo um talhão muito uniforme de pinus tenha alguns elementos de fundo afetando os dados. A presença destas impurezas conduz a variâncias elevadas e a não-normalidades na distribuição multivariada de reflectâncias, as quais por sua vez degradam o poder de discriminação das assinaturas.

Para tratar este problema, o IDRISI for Windows implementou um procedimento para o desenvolvimento de assinaturas *fuzzy* baseado na pesquisa de Wang (1990)<sup>43</sup>, fundamentada no conceito de conjuntos *fuzzy*. Neste caso, consideramos que cada *pixel* tem potencialmente algum grau de associação a mais de um conjunto (classe), de acordo com o grau com que misturas destas classes existem dentro do *pixel*. Assim, por exemplo, se um *pixel* é coberto em 60% por espécies de coníferas e 40% por decíduas, ele seria considerado como tendo uma associação *fuzzy* de grau 0,60 no conjunto<sup>44</sup> “coníferas” e um grau de associação 0,40 no conjunto “decíduas”. O módulo FUZSIG é uma modificação do procedimento MAKESIG mais tradicional, de modo que ele efetivamente pondera as médias, variâncias e covariâncias calculadas pelo grau de associação ao conjunto *fuzzy* das classes envolvidas. O efeito é o de diminuir a importância da área de treinamento no desenvolvimento da assinatura para uma classe caso ela ocupe uma porção muito pequena deste *pixel*. Isto também implica em que uma simples área de treinamento possa oferecer entradas em mais do que uma classe de cobertura do solo.

Como preparação para este exercício, leia cuidadosamente o item *Assinaturas ambíguas (fuzzy) na classificação* no capítulo *Classificação de imagens de sensoriamento remoto*. Nós seguiremos aqui os mesmos passos que foram delineados naquele item.

- a) O primeiro passo no uso deste procedimento é a definição das áreas de treinamento. Diferente dos procedimentos tradicionais, entretanto, não é necessário que estas áreas de treinamento

---

<sup>43</sup> Wang, F. (1990) *Fuzzy supervised classification of remote sensing images*. IEEE Transactions on Geoscience and Remote Sensing, 28, 2, 194-201.

<sup>44</sup> Neste contexto, o termo *conjunto* e *classe* podem ser usados como sinônimos.



sejam homogêneas. Também, diferente dos procedimentos tradicionais, o processo é simplificado se criamos uma versão *raster* destas áreas de treinamento antes de iniciar FUZSIG. Normalmente isto seria feito com INITIAL e POLYRAS. Entretanto, caso você tenha completado o exercício anterior, isto já terá sido feito, já que MAKESIG gera automaticamente uma versão *raster* com as áreas de treinamento com o mesmo nome do arquivo vetorial (SPTRAIN neste caso)<sup>45</sup>. Independente disso, visualize a imagem denominada SPTRAIN usando a tabela de cores *Qualitativa 256* e uma legenda para certificar-se de que você tem este arquivo no formato apropriado.

- b) O próximo passo é criar uma matriz de partição *fuzzy*, que indica o grau de associação de cada área de treinamento a cada classe<sup>46</sup>. Isto deveria ser feito com a Oficina de Bando de dados como descrito no item *Assinaturas ambíguas (fuzzy) na classificação* no capítulo **Classificação de imagens de sensoriamento remoto**. Neste caso, no entanto, nós fornecemos uma matriz de partição *fuzzy* já criada. Use a Oficina de banco de dados para examinar o banco de dados denominado WESTFUZ.

Como você perceberá, o banco de dados é construído com uma coluna por classe de cobertura do solo e uma linha por área de treinamento (identificada pelo número das áreas de treinamento que aparecem em SPTRAIN).

1. Observe que o grau de associação *fuzzy* da área de treinamento 1 na classe residencial antiga foi arbitrado em 0,75. O que isso significa em termos de homogeneidade desta área de treinamento?
  2. Observe que a soma dos graus de associação *fuzzy* é 1,0 em cada linha. Por que isso?
- c) Como no último exercício, onde criamos representações espaciais de probabilidades a priori, nosso próximo passo é criar um conjunto de representações espaciais destes graus de associação *fuzzy*. Felizmente, isto é facilmente feito na Oficina de banco de dados. Use a operação ASSIGN no menu Ligação para criar um conjunto de imagens de associação de classes *fuzzy*. Para tal, especifique SPTRAIN como o nome da imagem de definição de feições. Dê a seguir um nome para a imagem de saída usando o prefixo “fz” no nome da assinatura. Caso o nome resultante exceda 8 caracteres, especifique apenas os 8 primeiros. Neste exercício usaremos nomes um pouco diferentes para as assinaturas de modo a distingui-las do conjunto criado no exercício anterior. Assim, adicionaremos também um “x” no final do nome de cada assinatura, resultando nos seguintes nomes para as imagens de associação *fuzzy*:

```
FZOLDRSX
FZNEWRSX
FZINDCMX
FZROADSX
FZWATERX
FZAGPASX
FZDECIDX
FZWETLNX
FZGOLFGX
FZCONIFX
FZSHALWX
```

Em cada caso, o campo de definição de feições deve ser indicado como “IDR\_ID” e o campo dos dados indicado de acordo com a classe apropriada.

<sup>45</sup> Caso você não tenha feito o exercício anterior ou caso tenha excluído os resultados, execute INITIAL para criar uma imagem vazia em formato byte binário denominada SPTRAIN, com valor inicial de zero. Execute a seguir POLYRAS para rasterizar os polígonos vetoriais do arquivo vetorial SPTRAIN sobre a imagem SPTRAIN.

<sup>46</sup> Teoricamente, esta informação pode ser especificada em nível de *pixel* individual. Entretanto, na prática, é mais provável que se queira especificar a associação à classe em nível de uma área de treinamento inteira, motivo pelo qual este procedimento foi escolhido como ilustração.

- d) Para verificar se o procedimento acima transcorreu apropriadamente, use a Visualização para examinar cada uma das imagens de associação aos conjuntos *fuzzy*.
- e) Execute a seguir FUZSIG exatamente do mesmo modo que fez com MAKESIG no exercício anterior, salvo para as modificações nos nomes das assinaturas. Existem 11 assinaturas derivadas das 3 bandas SPWEST1, SPWEST2 e SPWEST3. As assinaturas deveriam ser especificadas com seus nomes levemente modificados usando o sufixo X:

OLDRSX  
 NEWRSX  
 INDCMX  
 ROADSX  
 WATERX  
 AGPASX  
 DECIDX  
 WETLNX  
 GOLFGX  
 CONIFX  
 SHALWX

FUZSIG buscará automaticamente as imagens de associação a conjuntos *fuzzy* ao formar a mesma lógica de união de nomes considerada anteriormente (isto é, procurará por FZOLDRSX, FZNEWRSX, etc.).

- f) Agora que as assinaturas *fuzzy* foram criadas, execute MAXLIKE com probabilidades a priori iguais e especifique 11 assinaturas *fuzzy*:

OLDRSX  
 NEWRSX  
 INDCMX  
 ROADSX  
 WATERX  
 AGPASX  
 DECIDX  
 WETLNX  
 GOLFGX  
 CONIFX  
 SHALWX

Denomine o resultado de SPMAX3.

- g) Visualize a imagem SPMAX3 com a tabela de cores SPMAX e legenda. Compare-a com SPMAX1.

3. Que diferenças você observa entre as duas imagens?

- h) Execute MAXLIKE novamente usando as assinaturas *fuzzy* acima, mas especifique que serão usadas imagens de probabilidade a priori. Especifique-as juntamente com o nome das imagens. Por exemplo:

OLDRSX	e	PROLDRS
NEWRSX	e	PRNEWRS
INDCMX	e	PRINDCM
ROADSX	e	PRROADS
WATERX	e	PRWATER
AGPASX	e	PRAGPAS

DECIDX	e	PRDECID
WETLNX	e	PRWETLN
GOLFGX	e	PRGOLFG
CONIFX	e	PRCONIF
SHALW	e	PRSHALW

Denomine o resultado de SPMAX3.

4. Como você descreveria o efeito de ter as assinaturas *fuzzy* e a definição espacial das probabilidades a priori? Use a técnica CROSSTAB empregada no exercício anterior para ajudar a formular sua resposta.

### 3. Classificadores relativos I: BAYCLASS

Neste exercício vamos introduzir o conceito de *classificador relativo*. Um classificador relativo é aquele que avalia o grau com que cada *pixel* pertence a cada uma das classes de cobertura do solo. Assim, ao invés de tomar uma decisão rígida (isto é, *Booleana*) sobre a associação de cada *pixel* a uma determinada classe, o classificador relativo gera como saída uma imagem em formato de números reais para cada classe, a qual expressa a associação ao conjunto numa escala de 0 a 1. O IDRISI for Windows oferece um grupo de classificadores relativos, dos quais o módulo BAYCLASS é o mais acessível.

- a) Use EDIT para criar um arquivo de grupo de assinaturas para as 11 assinaturas criadas no exercício 1. Quando solicitado, indique que você deseja usar o editor de arquivos de grupo e denomine-o de WESTSIGs. Adicione a seguir cada uma das seguintes assinaturas na ordem indicada<sup>47</sup>:

OLDRS	(Residencial antiga)
NEWRS	(Residencial nova)
INDCM	(Industrial/comercial)
ROADS	(Estradas)
WATER	(Água)
AGPAS	(Agricultura/pecuária)
DECID	(Floresta decídua)
WETLN	(Banhados)
GOLFG	(Pistas de golfe/gramados)
CONIF	(Floresta de coníferas)
SHALW	(Água rasa)

- b) Execute agora o módulo BAYCLASS. Você perceberá que a interface para este módulo é quase igual à de MAXLIKE. Indique que você deseja usar o arquivo de grupo de assinaturas denominado WESTSIGs. Selecione probabilidades a priori iguais e use o prefixo “BAY” para as imagens de saída.

---

<sup>47</sup> A ordem na qual as assinaturas são introduzidas não é de fato importante. Esta ordem é simplesmente usada para que se possa utilizar mais tarde a tabela de cores pré-elaborada denominada SPMAX.

- c) A saída de BAYCLASS é na forma de uma série de mapas de probabilidade a posteriori, uma para cada classe (BAYOLDRS, BAYNEWRS, BAYINDCM, etc.). Os valores nelas armazenados representam a probabilidade de cada *pixel* pertencer à classe correspondente. Examine essas imagens de probabilidade a posteriori usando a Visualização e a tabela de cores padrão Idrisi 256.
1. Compare as imagens BAYDECID e BAYCONIF. Como você caracteriza a habilidade do classificador em indicar se um *pixel* pertence à classe floresta decídua ou se pertence à classe floresta de coníferas?
- d) Para facilitar a comparação destas imagens, o BAYCLASS cria duas saídas adicionais. A primeira é um arquivo de grupo de imagens com o prefixo que você indicou para os arquivos de saída ("BAY.IGF", neste caso). Vá para Preferências de visualização no menu Visualização e especifique que deseja usar o modo avançado de consulta do cursor com o arquivo de grupo de imagens denominado BAY. Saia da caixa de diálogo Preferências de visualização e clique sobre a barra superior da imagem BAYDECID para assegurar-se de que ela é a imagem ativa. Observe próximo ao topo da imagem a floresta distinta que inclui a célula da coluna 324 e linha 59. Use a opção de seleção de janela para ampliar uma janela deste talhão. Observe que existe uma quantidade comparativamente maior de incerteza sobre muitos destes *pixels* em comparação com outros talhões de floresta decídua. Ative novamente o botão de consulta com o cursor e consulte vários destes *pixels*. Você perceberá que uma janela especial se abrirá listando as probabilidades a posteriori para cada uma das classes em cada *pixel* consultado. Ative a opção de mostrar gráfico do valor z nas Preferências de visualização para facilitar seu exame.
2. Para a maioria dos *pixels* que têm alguma incerteza de pertencer à classe floresta decídua, que outra(s) classe(s) o classificador percebe que podem estar presentes?
  3. O que são as probabilidades a posteriori de todas as classes diferentes de zero na célula localizada na coluna 326 e linha 43. Como você interpreta estes dados (considere todas as classes em sua resposta)?
  4. Como a resolução da imagem é de 20 metros, cada *pixel* representa 0,04 hectares. Para a célula na coluna 326 e linha 43, quantos hectares de floresta decídua você imagina existirem neste *pixel*?
- e) A segunda saída adicional produzida por BAYCLASS é a imagem de incerteza na classificação ("BAYCLU" neste caso). Caso você ainda não tenha feito, leia sobre este tópico no capítulo **Classificação de imagens de sensoriamento remoto**. Visualize então a imagem denominada BAYCLU. Observe que ela foi incluída no arquivo de grupo de imagens BAY. Por isso, caso você examinar a imagem com o modo de consulta do cursor ativado, você obterá uma tabela/gráfico da incerteza neste local mais a probabilidade a posteriori de cada classe de cobertura.
5. Examine as células na coluna 325 e linha 43 e na coluna 326 e linha 43. Quais são os valores de incerteza nestes locais? O que explica a diferença entre eles?
  6. Examine a célula na coluna 333 e linha 37. Observe que as probabilidades são quase regularmente distribuídas entre três classes. Em quantas classes elas estiveram distribuídas na coluna 325 e linha 43? Qual foi o efeito sobre o valor de incerteza? Por que?
  7. Olhando a imagem de incertezas BAYCLU como um todo, que classes têm as menores incertezas associadas? Dado que a categoria decídua é um grupo heterogêneo de espécies, por que você vê que o classificador teve a capacidade de ser tão conclusivo sobre esta categoria? (Não se preocupe muito com sua resposta -- isto é simplesmente

uma possibilidade de especular sobre o porquê. A razão será explorada com maior profundidade no exercício 5).

- f) Use EXTRACT para extrair a incerteza média associada a cada uma das classes de cobertura do solo indicadas em SPMAX1 (a imagem classificada por máxima verossimilhança criada no primeiro exercício deste grupo -- como ela também foi criada usando-se probabilidades a priori iguais, corresponde exatamente às imagens produzidas em BAYCLASS). Especifique SPMAX1 como a imagem de definição de feições e BAYCLU como a imagem a ser analisada. Solicite saída tabular dos valores médios de incerteza.
8. Que classes têm a maior incerteza média. Você pode explicar o porquê disto?
9. Examine as células na vizinhança da coluna 408 e linha 287 na imagem BAYCONIF. Estas células mostram uma probabilidade intermediária de pertencerem à classe floresta de coníferas. A que outra(s) classe(s) esses *pixels* podem pertencer? Como você interpreta essa área? Teria sido possível descobrir esta(s) classe(s) se você tivesse usado o módulo MAXLIKE (compare com SPMAX1)? Explique a razão de sua resposta.

## 4. Discretizadores

No exercício anterior produzimos uma série de imagens que expressam a probabilidade a posteriori de pertencer a um conjunto de classes de cobertura do solo na região de Westboro. Isso é uma característica de todos os classificadores relativos. Todos eles adiam o resultado de tomar uma decisão sobre a classe de cobertura do solo de um *pixel*. Mais precisamente, eles simplesmente revelam o estado do conhecimento que temos desses *pixels*. Nós podemos, entretanto, forçar uma decisão usando um discretizador -- um módulo que implementa uma lógica de decisão simples.

- a) Execute o módulo MAXBAY, que encontra-se no grupo Discretizadores do menu Processamento de imagens. Esse é um discretizador apropriado para ser usado com o produto de BAYCLASS<sup>7</sup>. Especifique que você quer usar um arquivo de grupo de imagens chamado BAY. Você perceberá que esse procedimento faz com que MAXBAY preencha a caixa de texto do número de imagens de entrada com o número 12, e os nomes das 12 imagens nas caixas de entrada onde esses nomes são requeridos. Um desses arquivos é o arquivo de incerteza da classificação (o arquivo chamado BAYCLU neste caso). Como esse é sempre o último arquivo no grupo, vamos fazer MAXBAY ignorá-lo alterando o número de arquivos para 11.

Indique que 4 níveis de saída devem ser produzidos e deixe a probabilidade mínima para cada classe com o valor padrão de 0<sup>8</sup>. Especifique que você quer um arquivo de grupo chamado BAYMAX e use o prefixo BAYMAX também para os arquivos de saída.

- b) Visualize cada uma das imagens BAYMAX1, BAYMAX2, BAYMAX3 e BAYMAX4. Use a tabela de cores SPMAX em cada imagem e especifique que seja mostrada uma legenda. Você pode também ativar o arquivo de grupo BAYMAX nas Preferências de Visualização para auxiliar nas suas comparações. BAYMAX1 indica os resultados de atribuir a classe daquela que tem a probabilidade máxima nos resultados de BAYCLASS. O resultado obtido será essencialmente o mesmo daquele obtido a partir de MAXLIKE (SPMAX1, nesse caso)<sup>9</sup>.

---

<sup>7</sup> Todos os *discretizadores* atualmente usam MDCHOICE para empreender a análise. A única razão pela qual os diálogos para MAXBAY, MAXBEL e MAXFUZ foram incluídos é que eles foram desenhados para as necessidades específicas de usar MDCHOICE com essas formas de saída.

<sup>8</sup> *Pixels* receberão o valor 0 caso seu valor for menor ou igual ao valor especificado para a probabilidade mínima.

<sup>9</sup> O resultado é de fato idêntico, exceto pelo tratamento da questão da probabilidade mínima. Como MAXBAY (assim como MAXBEL, MAXFUZ e MDCHOICE) atribui um zero a qualquer *pixel* com probabilidade 0 de pertencer a todas as classes e MAXLIKE atribui uma escolha arbitrária, as opções padrão podem produzir pequenas diferenças nas áreas que sem representação na classificação.

BAYMAX2 indica a classe da segunda maior probabilidade, enquanto BAYMAX3 e BAYMAX4 indicam, respectivamente, a terceira e a quarta probabilidades.

1. Examine a grande porção de floresta decídua nas vizinhanças da coluna 583 e linha 307. Compare os resultados em BAYMAX1 e BAYMAX2. Como você interpreta essas áreas onde a segunda maior probabilidade aparece como floresta de coníferas, banhados ou pistas de golfe/gramados? Examine as probabilidades associadas com essas classes (do exercício anterior) para desenvolver sua resposta.
2. Observe o estriamento que aparece nas imagens de terceiro e quarto nível (BAYMAX3 e BAYMAX4). Por que você imagina que isso ocorre? Note também as distintas mudanças que ocorrem nas vizinhanças da coluna 73. Isso também está relacionado ao mesmo problema do estriamento.



## 5. Classificadores relativos II: BELCLASS

BELCLASS é o segundo do grupo Classificadores relativos, e um importante complemento para BAYCLASS. Enquanto BAYCLASS baseia-se na teoria de probabilidade Bayesiana, BELCLASS é baseado em uma variante da teoria de probabilidade Bayesiana conhecida como Teoria *Dempster-Shafer*. Se você ainda não o fez, leia sobre BELCLASS no capítulo *Classificação de imagens de sensoriamento remoto*. Você também pode ler o item sobre *Dempster-Shafer* no capítulo *Apoio à decisão*.

- a) Execute o módulo BELCLASS no grupo Classificadores rígidos do menu Processamento de imagens. Você notará que a interface desse módulo é idêntica àquela de BAYCLASS (e por conseguinte quase idêntica à de MAXLIKE). Indique que você quer usar o arquivo de grupo de assinaturas chamado WESTSIGS criado por você no exercício avançado 3. Selecione probabilidades a priori iguais e use o prefixo “BEL” para as imagens de saída.
- b) A saída de BELCLASS é na forma de uma série de imagens de confiança *Dempster-Shafer* (BELOLDRS, BELNEWRS, BELINDCM, etc). Os valores em cada uma dessas imagens representam a confiança estimada (uma forma de probabilidade) de cada *pixel* pertencer àquela classe. Examine essas imagens de confiança usando a Visualização e a tabela de cores padrão IDRISI 256. Examine também a imagem de incerteza da classificação chamada BELCLU.
  1. Descreva a diferença entre as imagens BELCLU e BAYCLU criadas no exercício 3. Supondo que você leu o capítulo *Classificação de imagens de sensoriamento remoto*, a que você atribui a diferença fundamental entre essas imagens?
- c) Examine a imagem chamada BELDECID e compare com BAYDECID. Repare a grande porção de floresta decídua que circunda a célula da coluna 215 e linha 457.
  2. Use o modo expandido de consulta do cursor com o arquivo de grupo chamado BEL para examinar os valores de confiança associados com as células nessa área. Quais são os valores de confiança típicos para floresta decídua (de BELCLASS)? Quais são as probabilidades a posteriori típicas (de BAYCLASS)?

3. Note que os valores de confiança ou probabilidades associadas às outras classes são iguais a zero ou próximas de zero em ambos os casos. Como então BAYCLASS produz probabilidades tão altas e BELCLASS produz valores de confiança tão mais baixos (lembre-se, ambos compartilham a mesma base matemática)?
  4. O quê você acha que pode ter causado a variação na confiança nessa porção da imagem BELCLASS (Sugestão: considere a questão da representatividade das áreas de treinamento)?
  5. Execute MAXBEL no grupo Discretizadores do menu Processamento de Imagens para aumentar o rigor desses resultados. Quanto difere a imagem de primeiro nível daquela produzida por BAYCLASS?
  6. Quais são os valores de confiança e de probabilidade a posteriori na coluna 229 e linha 481? Claramente, BAYCLASS (e portanto MAXLIKE) concluiu indubitavelmente que esse é um exemplo de floresta decídua. Entretanto, dada a confiança que você determinou, isso é razoável? Há talvez alguma outra razão além daquela que foi dada na resposta à questão 4 à qual se possa atribuir a forte diferença entre esses dois classificadores (Sugestão: BELCLASS incorpora implicitamente o conceito sobre uma OUTRA classe no cálculo, isto é, outra coisa além das classes tomadas nas áreas de treinamento)?
- d) Execute BELCLASS novamente e agora especifique somente duas assinaturas: DECID e INDCM. Use o prefixo BL2 para o produto. Execute então BAYCLASS e faça a mesma coisa (usando o prefixo BY2).
7. Compare BL2DECID com BY2DECID e BL2INDCM com BY2INDCM. Levando em conta tudo que você já aprendeu até agora sobre a diferença entre esses módulos, como você justifica as diferenças/similaridades entre esses dois classificadores no tratamento desse problema. Na formulação de sua resposta, compare seus resultados com BAYDECID, BELDECID, BAYINDCM e BELINDCM.

## 6. Dempster-Shafer modificado

No exercício anterior vimos que BELCLASS permite um exame do grau de suporte para cada classe de um conjunto de classes de cobertura do solo, independente do que é ou não é fornecido para as demais. *Dempster-Shafer* atualmente proporciona uma descrição muito valiosa da incerteza no processo de classificação, como será ilustrado a seguir.

- a) Execute BELCLASS e indique que você quer usar o arquivo de grupo de assinaturas chamado WESTSIG que foi criado no exercício 3. Entretanto, em lugar da *confiança* anteriormente escolhida, nesse caso indique que você quer *plausibilidade* como produto. Selecione probabilidades a priori iguais e use o prefixo “PLS” para as imagens de saída.
- b) A saída de BELCLASS com essa opção constitui uma série de imagens de *plausibilidade* de *Dempster-Shafer* (PLSOLDRS, PLNEWRS, PLINDCM, etc.). Os valores em cada uma representam a plausibilidade estimada, uma forma de probabilidade que expressa a maior probabilidade potencial de cada *pixel* pertencer a uma classe. Examine essas imagens de plausibilidade usando a Visualização com a tabela de cores padrão IDRISI 256. Também examine a imagem de incerteza na classificação PLSCLU (note que a imagem PLSCLU é a mesma que BELCLU).

Enquanto a confiança indica o grau de suporte rígido para uma hipótese, a plausibilidade expressa o grau com que essa hipótese não pode ser desacreditada -- isto é, expressa o grau com que há uma carência de evidências *contra* a hipótese.

1. Examine PLSDECID e compare com BELDECID. Como você descreveria a plausibilidade em decídua comparada com a confiança em decídua? Qual é a natureza dessa plausibilidade nas áreas em que BELDECID é alta? Compare PLSDECID com BAYDECID no exercício 2. Como PLSDECID se compara a BAYDECID em áreas onde BAYDECID é alta?
- c) Use OVERLAY para subtrair BELDECID de PLSDECID (isto é, PLSDECID - BELDECID). Chame o resultado de BINDECID. Visualize esse resultado usando a tabela de cores IDRISI 256. Essa imagem mostra o que é denominado de *intervalo de confiança*. Um intervalo de confiança é a diferença entre a plausibilidade e a confiança para uma determinada classe, e expressa uma medida de incerteza sobre o estado de conhecimento dessa classe.

2. Crie imagens de intervalos de confiança similares para coníferas e áreas úmidas. Chame os resultados de BINCONIF e CINWETLN. Quão similares essas imagens são de BINDECID?
- d) Visualize a imagem PLSCLU. Essa é a mesma imagem que BELCLASS criou quando calculamos os valores de confiança, chamada BELCLU -- ela é incluída como uma imagem de saída para uso em casos onde não foram produzidos valores de confiança.
1. Quão similar é PLSCLU às imagens de incertezas individuais BINDECID, BINCONIF e BINWETLN?
- e) As imagens BELCLU e PLSCLU criadas por BELCLASS expressam uma forma muito específica de incerteza, conhecida na teoria de *Dempster-Shafer* como *ignorância*. Ignorância é diferente de um intervalo de confiança no sentido que um intervalo de confiança é específico de uma categoria enquanto a ignorância aplica-se ao estado de conhecimento como um todo. Ignorância expressa o grau com o qual o estado de conhecimento é incapaz de distinguir entre as classes. Em BELCLASS, nós modificamos a teoria de *Dempster-Shafer* para incluir implicitamente uma classe adicional que chamamos OUTRA, ao admitir a possibilidade de um *pixel* pertencer a uma classe para a qual nós não fornecemos áreas de treinamento. Logo, a ignorância expressa o grau com que somos inaptos a dizer a que classe o *pixel* pertence, incluindo a possibilidade de não ser uma das classes que estamos examinando.

Na implementação de BELCLASS do IDRISI for Windows, nós também reconhecemos um outro aspecto da incerteza que chamaremos *ambigüidade*. Dado que a confiança expressa o grau de evidência que sustenta especificamente uma classe em particular, a ambigüidade expressa o grau em que esse suporte é ambíguo por também sustentar outras classes.

A ambigüidade pode ser calculada como a diferença entre o intervalo de confiança para uma classe específica e a ignorância como um todo. Crie então uma imagem de ambigüidade para decíduas chamada AMBDECID com OVERLAY, subtraindo BELCLU (ou PLSCLU) de BINDECID.

Veja o grau de ambigüidade na porção de floresta nas vizinhanças da célula da coluna 324 e linha 59. No exercício com BAYCLASS, nós identificamos essa área como uma mistura de coníferas e espécies decíduas. A presença da ambigüidade dá um suporte direto para a presença de misturas envolvendo as classes em exame.

4. Crie uma imagem de ambigüidade similar para coníferas e chame-a de AMBCONIF. Quão extensiva é a ambigüidade envolvendo coníferas ou decíduas?
  5. Considerando que a incerteza total de uma classe (p. ex. BINDECID) é composta tanto pela ignorância (BELCLU) como pela ambigüidade (AMBDECID), qual é o maior componente da incerteza, a ignorância ou a ambigüidade?
- f) O IDRISI for Windows também possui dois outros módulos que podem facilitar a análise da mistura de classes -- MAXSET e MIXCALC. A interface para MAXSET é a mesma que para MAXLIKE, BAYCLASS e BELCLASS. Execute MAXSET e indique que você quer usar as assinaturas contidas no arquivo de grupo de assinaturas WESTSIGs. Use novamente probabilidades a priori iguais e denomine o resultado de WESTMIX. Visualize o resultado usando a tabela de cores Qual 256 e legenda.

Repare que WESTMIX contém tanto classes puras quanto mistura de classes. Isso necessita ser interpretado. A teoria de *Dempster-Shafer* reconhece a possibilidade de que uma determinada evidência possa sustentar diversas classes sem ter condições de distinguir entre elas. Por exemplo, ela reconhece a possibilidade de que a evidência possa dar suporte à conclusão de que um *pixel* é floresta decídua ou de coníferas, sem estar apta a informar qual delas. MAXSET

avalia o grau de suporte para todos os conjuntos que podem ser criados para as classes individuais. Nesse caso, há 11 classes individuais principais para 2048 conjuntos possíveis. MAXSET então atribui a cada *pixel* o conjunto para o qual existe o máximo suporte.

6. MAXSET apenas informa sobre aqueles conjuntos de misturas não separáveis que foram identificados na imagem. Entretanto, muitos desses conjuntos serão muito pequenos em extensão. Use AREA para determinar as áreas associadas a cada classe em WESTMAX. Você também pode usar a opção *flash* da legenda para ver a distribuição espacial de cada categoria<sup>10</sup>. Quais são os conjuntos de mistura que têm uma representação significativa na imagem? Esses são casos onde a ambigüidade será alta.
- g) Finalmente, MIXCALC pode ser usado para determinar o grau de suporte para qualquer conjunto de mistura não separável. Normalmente, esse módulo é usado somente como um complemento de MAXSET ou para um exame de ambigüidade.

Use MIXCALC para calcular o grau de suporte para a mistura não separável (isto é, BPA) de DECIDUOUS e CONIFER. Chame o resultado de MIXDC. Visualize então MIXDC usando a tabela de cores IDRISI 256.

7. Em que sentido MIXDC corresponde às informações obtidas a partir do exame da ambigüidade?

Como uma nota final, vale a pena considerar a questão da classificação de sub-*pixel*. O conceito da classificação de sub-*pixel* é baseado no pressuposto de que toda a incerteza na classificação de um *pixel* se deve a presença de misturas não separáveis. Entretanto, como ficou evidente na exploração anterior baseada na teoria de *Dempster-Shafer*, a ambigüidade nem sempre é o maior componente da incerteza. Claramente, a ignorância pode ser o elemento principal. Com a gama de ferramentas de exploração de incerteza providas pelo IDRISI for Windows, entretanto, é possível distinguir entre esses conceitos e focar especificamente naqueles de interesse.

---

<sup>10</sup> Para usar a opção *flash* da legenda mova o mouse sobre a categoria de interesse na caixa de legenda. Comprima a tecla *shift* e aperte o botão esquerdo do mouse. A categoria selecionada mudará de cor. Quando você solta o botão esquerdo, a categoria volta à sua cor normal.

## **7. Análise de vegetação em ambientes áridos**

Nesse exercício, exploraremos o uso de diferentes modelos de cálculo de índice de vegetação disponíveis nos módulos VEGINDEX e TASSCAP para analisar a cobertura vegetal e as suas mudanças no espaço e no tempo. Assume-se que o leitor já leu ou revisou o terceiro item do capítulo *Índices de vegetação* na seção *TÓPICOS ESPECIAIS* do manual do IDRISI for Windows.

A cobertura vegetal desde cedo foi um foco de pesquisa no manejo de recursos naturais usando imagens de sensoriamento remoto, especialmente com o lançamento dos satélites para aplicações em recursos naturais, conhecidos como LANDSAT, a partir de 1972. As informações geradas pelos satélites LANDSAT, SPOT e NOAA oferecem imagens periódicas que são amplamente usadas para monitorar e avaliar o estado da vegetação em nível global, regional, nacional e local. Nesse exercício você terá a oportunidade de avaliar a cobertura vegetal e as suas mudanças em uma área do sul da Mauritânia usando imagens do *scanner* multiespectral (MSS) do LANDSAT. Essas imagens foram obtidas em 10 de outubro de 1980 e 12 de outubro de 1990 pelo LANDSAT 4. Em função da época de aquisição das duas imagens ser próxima é possível se fazer uma análise temporal da cobertura vegetal.

Há oito imagens que serão usadas para esse exercício, quatro de cada ano: M801W, M802W, M803W, M804W de 1980; M901W, M902W, M903W e M904W de 1990. Elas correspondem, respectivamente, às bandas MSS do verde visível, vermelho visível, infravermelho próximo e infravermelho próximo com comprimento de onda um pouco maior, respectivamente. Como essas imagens foram obtidas em duas datas diferentes, uma deve ser registrada à outra para análise. Essa tarefa já foi feita para você.

- a) Visualize M803W com a tabela de cores Grey 256 e com a opção de autoescalonamento da imagem.

Já tendo sido uma área relativamente úmida, um persistente déficit hídrico desde o final dos anos 60 vem tornando o Sahel cada vez mais semi-árido. Grande parte da vegetação mudou de savana para estepe. Relictos de vegetação de savana são encontrados somente ao longo dos vales dos rios sobre solos argilosos, areno-argilosos e argilo-arenosos. O incremento da pressão antropogênica que resultou dos esforços de adaptação às condições de seca contínua e é a principal causa da degradação da cobertura vegetal. Um dos desafios no processamento digital de imagens é isolar a cobertura vegetal de baixa densidade que caracteriza terras áridas e semi-áridas, tais como as encontradas no sul da Mauritânia.

Um dos objetivos desse exercício é avaliar qual dos modelos de índice de vegetação propostos é mais eficiente em distinguir a vegetação verde de seu substrato, o que ajudará a isolar a cobertura vegetal de baixa densidade.

A área coberta pelas imagens desse exercício está próxima da fronteira Senegal/Mauritânia e contém parte da várzea do rio Senegal, assim como a seção inferior da várzea do rio Gorgol (parcialmente visível no canto noroeste das imagens). Esse é o último tributário (afluente) do rio Senegal. Essas seções dos dois rios são cobertas por vegetação ciliar dominada pela espécie *Acacia nilotica*, utilizada para a produção de lenha. Outras espécies lenhosas, como *Borassius flabelifer* e *Iphaene tebaica*, são usadas como material de construção. A agricultura recessional nas áreas de várzea e a criação de gado também são praticadas nessa região.

Enquanto TASSCAP é um módulo individual usado para calcular o índice de Kauth e Thomas, o módulo VEGINDEX oferece a possibilidade de usar até 19 diferentes modelos de índices de vegetação. Nós usaremos somente sete desses modelos, juntamente com o índice TASSCAP, para extrair os índices de vegetação das imagens de 1980 e 1990. Os resultados serão usados para a análise da modificação entre as duas datas e para a avaliação estatística das relações entre os modelos de índices de vegetação. Assim como todos os módulos analíticos do IDRISI for Windows, TASSCAP e VEGINDEX podem ser usados interativamente ou com linhas de comando macro.

- b) Antes de iniciar nossa exploração dos índices de vegetação, acione a visualização automática das saídas dos módulos analíticos, nas Preferências de visualização do menu Visualização. Especifique a tabela de cores NDVI256 como tabela quantitativa e como tabela de cores padrão e ligue também a opção de título visível.
- c) Após ler sobre TASSCAP e VEGINDEX no sistema de ajuda on-line, execute TASSCAP tanto nas imagens de 1980 como nas de 1990. Escolha usar MSS como tipo das imagens de entrada e especifique M801W, M802W, M803W e M804W (nessa ordem) para 1980 e M901W, M902W, M903W e M904W para 1990. Para cada ano use 80 e 90 como o prefixo de saída.

TASSCAP produzirá quatro imagens para cada conjunto de imagens, correspondendo aos seguintes quatro índices: *Soil Brightness Index* (SBI), *Green Vegetation Index* (GVI), *Yellow Vegetation Index* (YVI) e *non-such index* (NSI). TASSCAP gera uma imagem para cada um desses índices. Seus nomes são respectivamente *bright*, *green*, *yellow* e *non-such* precedido pelo prefixo de dois caracteres que você determinou. Após executar TASSCAP, visualize cada resultado usando a tabela de cores ndvi256. Como você logo irá perceber, as imagens 80GREEN e 90GREEN são as mais úteis.

1. Que elementos do terreno são mostrados em cada um dos quatro índices? Qual dos índices praticamente não apresenta informação alguma?
  2. Somente uma das imagens é interpretada como uma imagem de índice de vegetação. Qual delas?
- d) O módulo VEGINDEX contém 19 modelos diferentes de índice de vegetação, que podem ser agrupados em índices baseados na declividade, índices baseados na distância e índices de vegetação de transformação ortogonal. Execute VEGINDEX e produza uma imagem para três destes modelos: NDVI, TVI e TTVI. Esses modelos baseados na declividade são combinações lineares simples que requerem somente o nome das bandas vermelha e infravermelha de entrada e um nome de arquivo de saída. Examine cada uma das imagens de saída.

Os índices baseados na distância baseiam-se no conceito de uma linha de solo. Uma linha de solo é uma equação linear que descreve o relacionamento entre valores de reflectância na banda vermelha e infravermelha para *pixels* de solo exposto. Essa linha é produzida efetuando uma regressão linear simples entre a banda vermelha e infravermelha em uma amostra de *pixels* de solo exposto. Uma vez conhecido o relacionamento, todos os *pixels* desconhecidos em uma imagem que possuem a mesma relação nos valores de reflectância no vermelho e infravermelho são assumidos como solo exposto.

*Pixels* desconhecidos que distanciam-se da linha de solo por terem valores de reflectância maiores na banda infravermelha são assumidos como vegetação (baseado no padrão de resposta espectral da vegetação em que as reflectâncias na banda infravermelha são elevadas em relação às da banda vermelha). Aqueles *pixels* que distanciam-se da linha de solo porque suas reflectâncias na banda vermelha são altas são frequentemente assumidos como água (também com base no padrão de resposta espectral característico da água, em que os valores de reflectância na banda vermelha são elevados em relação aos da banda infravermelha).

O primeiro passo na criação de índices baseados na distância é calcular a linha de solo e identificar os parâmetros intercepto e declividade. Esses índices podem ser separados posteriormente em dois grupos, aqueles que são baseados em uma regressão onde a banda vermelha é avaliada como variável independente, e aqueles em que a banda infravermelha é avaliada como variável independente. Uma vez que iremos criar ambos os tipos de índices baseados na distância, você necessitará criar duas linhas de solo.

- e) Examine a seção *Notas* no tópico VEGINDEX do sistema de ajuda on-line e leia a nota número 2 para obter instruções de como criar a linha de solo. Execute a regressão duas vezes e anote os valores da declividade (b) e do intercepto (a) para o caso em que a banda vermelha é tratada como variável independente e para o caso em que a banda infravermelha é a variável independente.
- f) Execute VEGINDEX novamente e produza os índices baseados na distância PVI, PVI1, TSAVII e WDV. Para cada índice, leia a seção *Determinando valores de declividade e intercepto* no tópico VEGINDEX do sistema de ajuda para determinar quais parâmetros da linha de solo usar em cada índice de vegetação.

Olhe para as imagens de saída e visualize também a saída de TASSCAP para o ano selecionado. A qualidade da imagem de saída é um importante elemento na análise. A visualização é o único meio que podemos usar para avaliar a performance de certos modelos de índice de vegetação em termos de separação do padrão da vegetação verde e de distinção dessa vegetação do solo que está sob ela. Em outras palavras, essa é a forma de produzir um mapa de cobertura vegetal a partir de imagens digitais de satélite. Isso também permite a avaliar visualmente variações no estoque de biomassa verde. Tudo isso é essencial para proteção ambiental ou para esquemas de reabilitação, bem como para o monitoramento de atividades agropecuárias.

3. Quais dos modelos usados (incluindo TASSCAP) apresentam o melhor desempenho?
4. Quais modelos você não recomendaria?
5. Dê notas para cada um dos modelos na escala de 1 a 5 (muito pobre, pobre, moderado, bom, muito bom).

Esses modelos de índices de vegetação também são usados como uma medida quantitativa da biomassa da vegetação. Nós podemos fazer isso pela verificação manual dos valores dos índices. Como regra geral, quanto menor a densidade ou quanto menor a biomassa sobre uma dada área (o *pixel*, no nosso caso), menor o valor do índice.

- g) Use o modo de consulta do cursor para ver os valores dos índices em cada uma das imagens produzidas e determine quais as imagens que contêm valores negativos e positivos e quais delas têm apenas valores positivos. Você também pode usar o módulo DESCRIBE para esse fim.
6. Baseado nos valores das imagens de 1980 e 1990, localize as áreas de densidade de vegetação ou biomassa densa, moderada e baixa.

Agora que nos familiarizamos com as imagens de índice de vegetação de ambas as datas, podemos prosseguir com análises mais aprofundadas. Nos concentraremos na identificação daquelas áreas onde



ocorreram mudanças significativas entre 1980 e 1990. Um dos maiores problemas ambientais do Sahel é a rápida degradação dos recursos naturais, como resultado do aumento da pressão humana em combinação com fatores naturais desfavoráveis como o déficit de chuva.

- h) Uma forma de avaliar as mudanças no período de 10 anos é analisar visualmente cada uma das imagens. Feche todas as janelas que estiverem abertas, com exceção de TTVI80 e TTVI90, pondo-as lado a lado. Tente identificar visualmente aquelas áreas de modificação na cobertura vegetal, corpos d'água e solo.
7. Descreva em detalhes a natureza das mudanças que ocorreram na área entre 1980 e 1990.

A estação pluviométrica mais próxima está na cidade de Mbout, localizada fora da imagem na direção leste. A estação mediu aproximadamente 200 mm de chuva em 1980 e 240 mm em 1990. Além disso, uma represa para irrigação foi construída em 1985 na seção média do rio Gorgol.

8. Como essa informação pode ajudar a explicar as mudanças que você observa?

Neste exercício, abordamos a análise de mudanças através de análise visual. No IDRISI for Windows há muitos outros métodos quantitativos disponíveis. Entretanto, a seguir apenas cobriremos rapidamente um deles na análise final. Outros métodos de análise de mudanças são detalhados no livro de trabalho do UNITAR *Change and Time Series Analysis* (Eastman & McKendry, 1991<sup>48</sup>) no capítulo sobre índices de vegetação (esse livro está disponível para aquisição no Projeto *IDRISI*, junto à Clark University).

Como uma análise final, determinaremos se os modelos de índice de vegetação usados produzem resultados estatisticamente similares. Essa questão pode ser facilmente respondida aplicando-se uma análise de regressão linear simples sobre as imagens de índices de vegetação ou sobre arquivos de valores extraídos dessas imagens. Neste exercício extrairemos um arquivo de valores de cada uma das imagens de índice de vegetação e executaremos o módulo REGRESS.

- i) O processo de criação de um arquivo de valores a partir de uma imagem pode ser realizado manualmente, usando a digitalização em tela disponível no IDRISI for Windows para extrair valores de posições conhecidas ou usando o módulo SAMPLE para extrair uma amostra randômica. Nós usaremos SAMPLE.
- j) Execute SAMPLE em cada uma das imagens que cobrem a área e especifique que você quer extrair uma amostra randômica de 30 pontos. Chame o arquivo vetorial de saída de SAMPLE. Use então INITIAL no menu Entrada de dados para criar uma imagem vazia do tipo inteiro e em formato binário (copie os parâmetros de uma das imagens existentes) e dê a ela o nome de SAMPLE. A seguir use POINTRAS no menu Reformatação para rasterizar o seu arquivo vetorial de pontos e atualizar a imagem SAMPLE. Finalmente, execute o módulo EXTRACT, encontrado no submenu Análise/Consulta ao banco de dados, e use SAMPLE como imagem de definição de feições para extrair um arquivo de valores de cada uma das imagens de índice de vegetação. Dê um nome apropriado para cada arquivo de valores.
- k) O próximo passo é executar o módulo REGRESS com pares de arquivos de valores a fim de avaliar a sua correlação. Você encontrará o módulo REGRESS no submenu Análise/Estatística. Nós estamos interessados em dois parâmetros de saída: a correlação estatística  $r$  e o coeficiente de determinação  $r^2$ . Ambos indicam o grau de relacionamento entre as duas variáveis de entrada. Você pode usar qualquer imagem como variável dependente ou independente. Você pode querer fazer uma tabela de 3 colunas para acomodar o relatório do arquivo de combinação e os valores  $r$  e  $r^2$ . Repare que  $r^2$  é expresso em porcentagem e indica quanto da variável dependente é explicado pela variável independente. Por exemplo, um valor de 95% significa que os dois modelos de índice de vegetação são estatisticamente equivalentes.

---

<sup>48</sup> Eastman, J.R.; McKendry, J.E. 1991. *Change and time series analysis*. Worcester. UNITAR. 85p.

9. Quais modelos de índice de vegetação têm relacionamentos estatísticos fortes?

Nosso exemplo de análise de índice de vegetação termina aqui, mas é possível fazer muito mais. Leia o capítulo ***Índices de vegetação*** para maiores informações e detalhes sobre outras análises, como a análise de componentes principais.

## 8. Avaliação por critérios múltiplos -- Análise Booleana

Os próximos quatro exercícios irão explorar o uso de SIG como sistema de apoio à decisão. Embora a análise apresentada irá discutir técnicas que podem realçar os processos de apoio à decisão em geral, será dada ênfase no uso de SIG para a decisão de destinação de recursos. Estas decisões podem ser auxiliadas por ferramentas de SIG porque freqüentemente envolvem uma variedade de critérios que podem ser representados como planos de dados geográficos. A avaliação por critérios múltiplos (*Multi Criteria Evaluation* - MCE) é um método muito usado para avaliar e agregar muitos critérios, mas apenas recentemente todo seu potencial foi constatado. Várias técnicas de MCE serão exploradas: métodos *Booleanos* simples, combinação linear ponderada (Weighted Linear Combination - WLC) e Média ponderada ordenada (Ordered Weighted Average - OWA).

Um primeiro passo importante para entender a MCE é desenvolver uma linguagem comum para apresentar e compreender tais métodos. Caso o leitor ainda não tenha feito isso, deveria revisar o capítulo *Apoio à decisão* na seção **TÓPICOS ESPECIAIS** do Manual do Usuário do IDRISI for Windows. Nestes exercícios, nós identificaremos e combinaremos uma variedade de critérios de modo a definir áreas próprias para novas áreas residenciais. Este problema com um simples objetivo irá inicialmente representar nosso *quadro de decisão*. O grupo de definição de áreas específicas será nosso *conjunto de decisão*, isto é, o conjunto de todos os locais aptos ao desenvolvimento imobiliário residencial. No Exercício 11, veremos como o quadro de decisão pode ser expandido de modo a incluir mais de um objetivo ou alternativa locacional.

Antes de combinar critérios, entretanto, valores de critérios devem ser reescalados para um intervalo numérico comum, um processo conhecido com *padronização*. Essencialmente este é o processo de conversão de valores de critérios em expressões de associação ao conjunto, isto é, sua associação ao conjunto de áreas locais para desenvolvimento imobiliário, o conjunto de decisão. Este exercício irá explorar como critérios são desenvolvidos e como estes critérios podem ser padronizados para MCE<sup>11</sup>.

---

<sup>11</sup> Para maiores detalhes sobre estes tópicos veja o volume IV da série de livros *Explorations in Geographic Information Systems Technology* do UNITAR, *GIS and Decision Making*, 1993 (Worcester, MA.: Clark University).

Para demonstrar os diferentes modos como os critérios podem ser desenvolvidos bem como a variedade de procedimentos de MCE disponíveis, os primeiros três exercícios estarão concentrados em um problema de aptidão simples. O objetivo é encontrar as melhores áreas para expansão residencial na cidade de Westboro, Massachusetts, EUA. A cidade está localizada muito próxima a duas áreas metropolitanas e é um local prioritário para expansão residencial semi-rural.

- a) Visualize a imagem WESTLUSE com a tabela de cores WESTLUSE. Escolha por visualizar a legenda e o título a partir dos componentes do mapa. Adicione também os arquivos vetoriais WESRDS e WESSTRM usando o arquivo de símbolos Qualitativa 16 para ambos.

Como você vê, a cidade de Westboro e sua vizinhança imediata são bem variados. O uso de SIG tornará a identificação de áreas apropriadas melhor gerenciável.

Por causa da localização principal, os incorporadores imobiliários cortejaram muito os administradores municipais no sentido de obter as áreas mais adequadas para a expansão residencial. Entretanto, grupos ambientalistas também têm alguma influência sobre onde esta expansão deverá ou não ocorrer. A paisagem ambientalmente mista de Westboro possui várias áreas a preservar para a vida selvagem. Além disso, a cidade de Westboro tem algumas regras específicas já vigentes que limitam as áreas de expansão urbana. Todas estas considerações devem ser incorporadas no processo de tomada de decisão.

Este problema enquadra-se bem no cenário de MCE. O objetivo é explorar possíveis áreas aptas ao desenvolvimento residencial para a cidade de Westboro: áreas que melhor suprem as necessidades de todos os grupos envolvidos. Os administradores da cidade estão trabalhando junto com os incorporadores imobiliários e os ambientalistas e, em conjunto, identificaram vários critérios que irão apoiar o processo de tomada de decisão. Identificar e desenvolver critérios é o primeiro passo na MCE.

### *Desenvolvimento de dados e critérios*

De modo a determinar que áreas considerar para o desenvolvimento residencial, a administração da cidade identificou três conjuntos de critérios: a legislação urbana, que define onde pode ser construído, os custos de investimento, importantes para os incorporadores, e as considerações de ordem ambiental, importantes para os ambientalistas.

O plano diretor da cidade tem critérios restritivos que delimitam áreas para desenvolvimento imobiliário. Para simplificar, incluiremos apenas um regulamento na presente análise: nenhum desenvolvimento novo pode ocorrer a menos de 50 metros de corpos d'água, banhados ou cursos d'água. Adicionalmente a esta limitação legal, novos loteamentos não podem ocorrer em áreas já usadas para tal fim, nosso segundo critério restritivo.

Tendo determinado os critérios restritivos, o maior desafio para os administradores foi identificar os critérios que determinariam a aptidão *relativa* das áreas restantes. Estes critérios não são uma restrição absoluta ao desenvolvimento, mas são *fatores* que realçam ou diminuem a aptidão relativa de uma área para o desenvolvimento residencial.

Para os incorporadores, estes critérios são fatores que determinam o custo de construir novas casas. A viabilidade para o desenvolvimento imobiliário é determinada por fatores tais como o tipo de uso atual do solo, a distância de rodovias, a declividade e a distância até o centro da cidade. O custo das novas áreas residenciais será menor em áreas em que a limpeza da área seja mais fácil, situem-se próximas de rodovias e estejam em baixas declividades. Adicionalmente, altos custos de construção podem ser compensados pela proximidade ao centro urbano, uma área atrativa aos novos compradores.

De outro lado, fatores importantes do ponto de vista ambiental são aqueles que determinarão a qualidade do terreno que irá permanecer como habitat natural. Para os ambientalistas, a criação de novas áreas residenciais deve ocorrer longe de corpos d'água e banhados e devem localizar-se o mais próximo possível de áreas construídas já existentes.

Já começamos a desenvolver a linguagem usada para MCE. Para resumir, os critérios acima são de dois tipos: barreiras/limitações absolutas (*restrições*) e fatores limitantes/limitações relativas (*fatores*). Restrições são aqueles critérios *Booleanos* que cerceiam ou limitam nossa análise a regiões geográficas específicas. Neste caso, as restrições diferenciam áreas ou alternativas que podemos considerar aptas para desenvolvimento residencial ou alternativas que não são aptas sob condição alguma. Fatores, por outro lado, são critérios que definem algum grau de aptidão para todas as regiões geográficas. Eles definem áreas ou alternativas em termos de uma medida contínua de aptidão, realçando ou diminuindo a importância de uma alternativa em consideração naquelas áreas fora das restrições impostas pelos critérios *Booleanos*, isto é, proximidade de rodovias, cursos d'água ou declividades íngremes. Em nosso exemplo, temos duas restrições e seis fatores a desenvolver com nosso conjunto original de dados. Direcionaremos nossa atenção agora ao desenvolvimento destes critérios para MCE em SIG.

### Restrição corpos d'água e banhados

A primeira restrição é a legislação urbana limitando o desenvolvimento imobiliário em áreas a menos de 50 metros de lagos, cursos d'água e banhados. Desenvolvimento residencial simplesmente não pode ocorrer em áreas sob estas condições. Dados de corpos d'água e cursos d'água são facilmente obtidos, mas os banhados geralmente não estão bem documentados na maioria dos mapas de cobertura do solo. Felizmente, estes mapas podem ser atualizados através de imagens de satélite. Os dados sobre os banhados usados aqui foram obtidos de imagens do satélite SPOT, os corpos d'água vieram do nosso mapa de uso do solo e os cursos d'água estavam disponíveis na forma de arquivo vetorial. Todos os três elementos serão combinados e sobre o resultado será excluída uma área tampão de 50 metros.

- b) Caso você não esteja com a imagem WESTLUSE na tela, visualize-a novamente com legenda usando a tabela de cores WESTLUSE.

1. Qual o valor de atributo dos corpos d'água?

Usando RECLASS ou EDIT e ASSIGN, crie uma imagem *Booleana* da categoria corpos d'água encontrados no mapa de uso do solo de tal modo que os corpos d'água recebam o valor 1 (um) e todas as demais classes o valor 0 (zero). Chame o resultado de OPENWATR e visualize-o usando a tabela de cores Qualitativa16, adicionando o arquivo vetorial WESSTRM. Para atualizar de forma permanente a imagem OPENWATR com os dados dos cursos d'água, execute LINERAS com o arquivo vetorial WESSTRM e a imagem OPENWATR como a imagem a ser atualizada. Visualize o resultado para certificar-se de que a imagem agora contém os corpos d'água e os cursos d'água.

A seguir, visualize a imagem dos banhados denominada WESTWETL usando a tabela de cores Qualitativa16.

2. Qual o valor de atributo das áreas de banhado? Qual a operação de OVERLAY que você pode usar para combinar WESTWETL com OPENWATR?

Execute OVERLAY com OPENWATR como a primeira imagem, WESTWETL como segunda imagem, WATRWETL como imagem de saída e escolha a opção de sobreposição adequada. O resultado deveria ser uma imagem dos corpos d'água, dos cursos d'água e dos banhados onde os três elementos têm o valor de 1 e as áreas restantes o valor 0.

Finalmente, para calcular uma faixa tampão de áreas protegidas em WATRWETL, execute o módulo BUFFER. Especifique WATRWETL como a imagem de feições, WATRPROT como imagem de saída e uma faixa tampão de 50 metros de largura. Para tornar a imagem de saída um mapa *Booleano* de áreas inviáveis para o desenvolvimento imobiliário, especifique o valor 1 para as áreas originais, 1 para a faixa tampão e 0 para as áreas além da faixa tampão.

A imagem resultante está praticamente no formato apropriado para uma restrição. Ela é uma imagem *Booleana* onde o 1 representa corpos d'água, cursos d'água e banhados, com uma faixa tampão de 50 metros. Estas são áreas que pela legislação urbana não estão disponíveis para o desenvolvimento imobiliário. Para colocar esta restrição em conformidade com nossa escala

padrão de restrições, invertemos os valores de tal forma que as áreas disponíveis ao desenvolvimento imobiliário tenham o valor 1 e as inviáveis o valor 0. Use EDIT e ASSIGN para inverter os valores em WATRPROT e denomine o resultado WATRCON, nossa primeira restrição ao desenvolvimento imobiliário.

#### Restrição uso do solo

Nossa segunda restrição ou barreira, com as categorias de uso do solo não disponíveis para o desenvolvimento residencial, é derivada do mapa de uso do solo.

- c) Visualize WESTLUSE novamente. Claramente algumas destas classes são inviáveis ao desenvolvimento residencial. Áreas que já estão construídas, corpos d'água e amplos corredores de transporte não podem ser considerados como aptos à construção de casas sob hipótese alguma.
3. Quais os valores de atributo das classes de uso do solo que são inaptas ao desenvolvimento imobiliário? Use a tabela a seguir.

Áreas aptas	Atributo	Áreas inaptas	Atributo
Agricultura		Já desenvolvidas	
Pecuária		Residencial, multi-familiar	
Floresta		Residencial, lotes pequenos	
Campo aberto/natural		Residência, lotes médios	
		Residencial, lotes grandes	
		Comercial	
		Industrial	
		Transporte	
		Corpos d'água	

Use novamente EDIT e ASSIGN para alterar o valor das classes na imagem WESTLUSE de tal modo que áreas aptas tenham o valor 1 e áreas inaptas o valor 0. Use a tabela para orientar sua reclassificação e denomine a imagem resultante LUSECON (Você também pode usar RECLASS para realizar essa tarefa).

Uma vez tendo desenvolvido nossas restrições *Booleanas*, podemos agora dirigir nossa atenção ao desenvolvimento de nossos mapas de fatores. Dos cinco fatores a seguir, os primeiros três são referentes aos custos de construção enquanto os dois restantes têm relação com a preservação de habitats.

#### Fator uso do solo

Os incorporadores apontaram áreas de agricultura e de pecuária como de alto custo de aquisição; florestas são menos caras e oferecem retorno com o valor comercial da madeira das áreas desmatadas, sendo as áreas de campo aberto as mais baratas, embora menos atrativas que as áreas com floresta. Eles ordenaram estes quatro usos em termos de custos globais e retorno, na seguinte sequência das áreas mais aptas às menos aptas: campo aberto, florestas, pecuária e agricultura.

- d) Para desenvolver este critério, isolaremos todas as áreas que são próprias para o desenvolvimento urbano. Entretanto, diferente de nossa imagem LUSECON, conservaremos os códigos das diferentes classes de uso do solo. Use RECLASS para reclassificar as classes de uso do solo impróprias para o valor 0, isto é, todos os valores da imagem superiores a 4. As categorias restantes (agricultura, pecuária, florestas e campo aberto) manterão seus identificadores originais. Denomine a imagem resultante LANDAVAL.

### Fator distância de rodovias

A distância de rodovias é um importante fator em nossa MCE, pois é um dos custos básicos levados em consideração pelos incorporadores. Edificações distantes de rodovias são proibitivamente caras. Necessitamos criar agora uma imagem de distâncias a partir de rodovias. Entretanto, como não temos uma versão *raster* de nosso mapa de rodovias, temos que rasterizar o arquivo vetorial de rodovias sobre uma nova imagem de rodovias.

- e) O primeiro passo é executar LINERAS a partir do arquivo WESRDS. Execute LINERAS, especificando WESRDS como o arquivo vetorial de linhas e WESRDS como a imagem a ser atualizada. Como a imagem WESRDS ainda não foi criada, LINERAS automaticamente inicializará esta imagem para você através do módulo INITIAL. Na caixa de diálogo de INITIAL, escolha copiar os parâmetros espaciais da imagem WESTLUSE. A imagem resultante já estará sendo denominada de WESRDS. Dê um título a ela e acione OK.

Finalmente, execute a rotina DISTANCE sobre a imagem WESRDS. Indique o nome da imagem de feições como sendo WESRDS e o nome da imagem de saída como ROADDIST. A imagem resultante terá em cada *pixel* um valor que representa a sua distância em metros das rodovias.

### Fator distância até o centro da cidade

Assim como a distância simples foi usada como base para os dois fatores acima, também é possível usar a distância de custo. No nosso problema a distância de custo a partir do centro da cidade será uma consideração importante para os incorporadores. Novos moradores querem estar próximos aos serviços oferecidos no centro da cidade e eles pagarão mais para residências a partir das quais possam alcançar o centro urbano mais rapidamente.

Superfícies de custo são criadas não apenas a partir de feições mas a partir de uma superfície de atrito representando atritos relativos, ou barreiras ao deslocamento, associados à travessia de um *pixel*. Em nosso exemplo assumiremos que as rodovias são a única via de transporte para o centro urbano. Por isso, construiremos primeiramente uma superfície de atrito onde todas as rodovias atuais têm um mesmo valor básico igual a 1 e áreas além das rodovias um valor igual a 3. Áreas além das rodovias apenas serão conectadas com rodovias existentes por novas rodovias de acesso construídas como parte do desenvolvimento imobiliário. Essas novas rodovias de acesso terão limites de velocidade muito menores (tempo de viagem seria em torno de 3 vezes maior do que aquele válido para as rodovias já existentes). Após especificar a superfície de atrito, aplicaremos o algoritmo de esforço de custo disponível no módulo COST (Para uma discussão mais detalhada sobre COST, veja a descrição do módulo no sistema de ajuda do IDRISI for Windows e no exercício com distâncias de custo dos exercícios tutoriais introdutórios). O resultado será a distância a partir do centro da cidade em equivalentes de células de grade, aqui interpretadas como uma medida de tempo relativo de viagem ao longo de rodovias existentes e potenciais.

- f) O primeiro passo para a obtenção de um mapa de distâncias de custo é criar uma superfície de atrito. Produziremos uma superfície de atrito a partir da imagem WESRDS criada há pouco. Use EDIT e ASSIGN para criar uma nova imagem, derivada de WESRDS, chamada TOWNFRIC, onde todas as áreas além das rodovias recebem um valor igual a 3 e todas as rodovias existentes um valor igual a 1.
- g) Finalmente, execute COST. Especifique que você deseja usar a opção Esforço de custo, especifique WESTCENT, o centro da cidade de Westboro, como a imagem com feições de origem e TOWNDIST como a imagem de saída.

Quando COST tiver concluído, você pode visualizar TOWNDIST. Use a Composição para adicionar o arquivo vetorial WESRDS e interprete o resultado.

### Fator declividade

O último dos nossos fatores relevantes para custos das edificações é a declividade. Construir edificações é menos oneroso em declives suaves. Declividades são facilmente calculadas a partir de modelos digitais de elevação.

- h) Execute o módulo SURFACE. Especifique WESTELEV como modelo digital de elevação de entrada e escolha calcular declividades. Selecione o cálculo em porcentagem e um fator de conversão igual a 1 (uma vez que as unidades já são metros). Denomine a imagem de saída de SLOPES. A nova imagem é uma superfície contínua de declividades em porcentagem.

### Fator distância da água

Os ambientalistas estão preocupados com a contaminação do lençol freático pelos sistemas sépticos e outras fontes não pontuais de poluição doméstica. Embora não tenhamos dados sobre a água subterrânea, podemos usar os corpos d'água, os banhados e os cursos d'água como informação. A distância destas feições irá constituir um dos nossos dois fatores restantes, ambos relevantes do ponto de vista ambiental.

Para desenvolver este critério usaremos a imagem WATRPROT criada anteriormente. Ambientalistas insistem que novas áreas residenciais deveriam estar o mais afastadas possível de áreas de banhados e de corpos d'água já protegidos. Por isso calcularemos a distância a partir de áreas protegidas em torno de corpos d'água e áreas de banhado.

- i) Execute DISTANCE, especifique WATRPROT como a imagem de feições e denomine a imagem resultante de PROTDIST.

O resultado final PROTDIST terá um valor no qual cada *pixel* representa a distância em metros das áreas protegidas que circundam a água.

### Fator distância de áreas já urbanizadas

O último dos nossos fatores também envolve a preocupação ambiental. Os planejadores urbanos gostariam de ver novas áreas residenciais o mais próximo possível de áreas construídas já existentes. Isto faria com que áreas isoladas, adequadas à vida selvagem, ficassem distantes de qualquer área construída. Primeiro, criaremos uma imagem de feições que contém as áreas atualmente edificadas, a partir das quais calcularemos um mapa de distâncias.

- j) A imagem de feições será constituída de todas as áreas construídas do mapa de uso do solo WESTLUSE, as categorias 5 a 12 da legenda. Reclassifique WESTLUSE de modo que essas áreas já construídas recebam o valor 1 e as demais áreas o valor 0. Denomine a nova imagem de DEVELOPD. Execute então DISTANCE usando DEVELOPD como imagem de feições e especifique DEVLDIST como arquivo de saída.

Desenvolvemos agora os oito critérios que serão usados na identificação de áreas próprias ao desenvolvimento residencial. Os primeiros dois são barreiras que representam as restrições ao desenvolvimento impostas pela legislação da cidade e as áreas que já estão construídas e não podem ser consideradas para novo uso residencial. Os demais critérios são fatores que determinam a aptidão relativa de áreas ainda não construídas, quatro deles relevantes ao custo das edificações e três relevantes à preservação de habitats.

### MCE usando operadores Booleanos

Agora que as imagens dos fatores foram criadas, o primeiro método de agregação de critérios que examinaremos é uma abordagem MCE *Booleana* simples. Esta abordagem é largamente utilizada e é a base de muitas análises centradas em SIG. Muitas vezes denominada de mapeamento de restrições, ela é vista aqui como um caso especial de MCE. Entretanto, antes que os critérios possam ser combinados e comparados entre si em qualquer MCE, eles necessitam ser padronizados para alguma escala de aptidão.



### Padronização de fatores (o caso Booleano)

Padronização, no caso *Booleano*, significa reduzir todos os fatores a imagens *Booleanas* com áreas aptas e não aptas -- essencialmente transformando todos os nossos fatores em restrições. Reduzir todos os critérios a imagens *Booleanas* (com valores de 1 e 0) nos permitirá facilmente agregá-los em uma solução final usando álgebra *Booleana* básica. O método mais comum de combinação é a operação AND (mínimo). Esta técnica deve ser muito familiar a qualquer usuário de SIG. Usaremos os mapas de restrições que criamos, LUSECON e WETLCON, tal como estão. Entretanto, temos que reduzir nossos fatores a mapas *Booleanos*, isto é, a restrições. Para converter os mapas de fatores iremos estender o roteiro apresentado acima para sua criação e tomar decisões rígidas para áreas aptas ao desenvolvimento urbano. As regras de decisão para nossos critérios são as seguintes:

#### Fator uso do solo

Sabemos que há quatro tipos de cobertura do solo disponíveis para o desenvolvimento urbano, as quais foram ordenadas em termos de aptidão. Entretanto teremos que tomar uma decisão rígida para os tipos que são aptos ao desenvolvimento urbano e aqueles que não são aptos. Como mencionado acima, áreas com floresta e campo são as menos caras para o desenvolvimento. De toda a terra disponível, estas serão consideradas aptas ao desenvolvimento urbano.

#### Fator distância das rodovias

Para manter o custo das construções residenciais baixo, é importante que as obras ocorram próximo a rodovias já existentes. Assim, áreas próximas a rodovias são mais aptas do que aquelas que estão distantes. Entretanto, para uma análise *Booleana*, teremos que reclassificar nossa imagem contínua de distância de rodovias para definir um limite da faixa tampão. Reclassificaremos nossa imagem de distância de rodovias de tal forma que áreas a menos de 400 metros de qualquer rodovia sejam aptas e aquelas além de 400 metros não sejam.

#### Fator distância até o centro da cidade

Presume-se que residentes de Westboro gostariam de estar próximos das facilidades do centro urbano. Casas próximas ao centro trarão lucros maiores aos incorporadores. A distância até o centro da cidade é uma função de tempo de viagem sobre as rodovias da área (ou rodovias de acesso potenciais) as quais calculamos usando a função de distância de custo. Como os incorporadores estão mais interessados nas áreas a menos de 10 minutos de tempo ao volante até o centro da cidade, estimamos que isto equivale a aproximadamente 400 células na imagem de distância de custo. Reclassificaremos a superfície de distância de custo de tal modo que qualquer local é apto se estiver a 10 minutos ou 400 células do centro da cidade. Aqueles locais situados além de 400 células do centro da cidade não são aptos.

#### Fator declividade

Devido ao fato de que declividades suaves tornam a construção de casas e rodovias mais barata, reclassificaremos nosso mapa de declividades de modo que qualquer área com declividade igual ou inferior a 15% será considerada apta e com declividade superior a 15% será considerada não apta.

#### Fator distância da água

Como o lençol freático local está ameaçado pela poluição oriunda do sistema séptico e do escoamento superficial, os ambientalistas ressaltam que áreas distantes de corpos d'água e banhados são mais aptas do que aquelas mais próximas. Embora os corpos d'água e banhados já sejam protegidos por uma faixa tampão de 50 metros, os ambientalistas gostariam de ver esta área expandida em mais 50 metros. Neste caso, áreas aptas para o desenvolvimento urbano terão que estar no mínimo 100 metros afastadas de qualquer corpo d'água ou banhado, isto é, 50 metros além das áreas já protegidas atualmente.

#### Fator distância de áreas já urbanizadas

Finalmente, as áreas num raio de até 300 metros de distância das áreas já construídas são consideradas as melhores para novo desenvolvimento pelos ambientalistas interessados na preservação de habitats de vida selvagem isolados.

### Criando mapas dos fatores Booleanos

- k) Dos mapas de fatores criados anteriormente, use qualquer combinação de RECLASS ou EDIT e ASSIGN para criar um novo conjunto de imagens de fatores *Booleanos*. Dê a elas os nomes de

saída indicados na tabela a seguir. Dê para todas as áreas aptas o valor 1 e às áreas não aptas o valor 0.

Mapa de fator	Mapa de fator <i>Booleano</i>	Regra de decisão
LANDAVAL	LUSECOST	Florestas e campos
ROADDIST	ROADBUFF	num raio de 400 m de rodovias
TOWNDIST	TOWNBUFF	a 10 min ou menos do centro da cidade (400 células)
SLOPE	BESTSLOP	declividades inferiores a 15%
PROTDIST	PROTBUFF	afastadas mais de 50 m de áreas tampão já existentes
DEVLDIST	DEVLBUFF	a menos de 300 m de áreas já construídas

### A abordagem Booleana para MCE

Agora que todos os nossos fatores foram transformados em imagens *Booleanas*, podemos combiná-las no módulo MCE. MCE permite a você escolher entre três procedimentos MCE diferentes: *Booleano*, Combinação linear ponderada e Média ponderada ordenada. Para esta parte do exercício usaremos a opção *Booleana*. Esta opção permite a entrada de qualquer número de restrições que serão multiplicadas entre si para produzir uma imagem única de aptidão. Este procedimento é equivalente a uma operação lógica AND e pode ser também realizada usando uma série de operações de multiplicação da rotina OVERLAY.

- l) Abra MCE no submenu Análise/Apoio à decisão. Selecione a opção *Booleana*. Especifique a seguir que você usará oito restrições e indique os nomes dos arquivos (refira-se à lista abaixo). Chame o arquivo de saída de MCEBOOL e selecione OK.

#### Critérios de restrição

LUSECON  
WATRCON  
LUSECOST  
ROADBUFF  
TOWNBUFF  
BESTSLOP  
PROTBUFF  
DEVLBUFF

Compararemos o resultado com os arquivos de entrada usando o modo expandido de consulta do cursor. Isto nos permitirá consultar uma imagem (MCEBOOL) usando o cursor para visualizar o valor z de várias imagens (nossos critérios) no mesmo local. Um arquivo de grupo de imagens (.igf) é criado usando EDIT no IDRISI for Windows.

- m) Execute EDIT e especifique que você quer criar um novo arquivo de grupo de imagens. Denomine-o MCEBOOL e selecione para usar o editor de arquivos de grupo. Pressione OK. Adicione os oito critérios de restrição e o próprio resultado de MCE (adicione a lista a seguir marcando cada arquivo no editor e selecionando Adicionar).

#### MCECBOOL.IGF

LUSECON  
WATRCON  
LUSECOST  
ROADBUFF  
TOWNBUFF  
BESTSLOP  
PROTBUFF  
DEVLBUFF

- n) Para acionar o modo expandido de consulta do cursor vá ao submenu Visualização/Preferências de visualização e especifique que você deseja usar o modo expandido. Especifique o arquivo de grupo de imagens denominado MCEBOOL. Finalmente, visualize MCEBOOL com a tabela de cores Qualitativa 16. Esta imagem tem o valor 1 nas áreas aptas em todos os critérios e o valor zero para áreas que não são aptas em pelo menos um critério. Selecione o modo de consulta do cursor a partir do ícone correspondente na barra de ferramentas e explore a imagem clicando em vários locais.

Deve estar claro que um valor de 1 apenas é possível nas áreas em que os oito critérios tiveram valor 1 e o resultado é um valor 0 se numa dada posição a célula recebeu o valor 0 em pelo menos um dos critérios. Aptidão em um critério não pode compensar a ausência de aptidão em qualquer outra imagem. Adicionalmente, por ser a análise MCE *Booleana* uma operação lógica AND (mínimo), ela é muito conservadora em termos de risco. Por satisfazer todos os critérios, o resultado é a melhor localização possível para o desenvolvimento urbano residencial.

Estas propriedades de não compensação e aversão ao risco podem ser apropriadas para muitos projetos, mas no nosso caso podemos imaginar que nossos critérios deveriam compensar uns aos outros e que não estamos somente interessados em evitar riscos extremos. Por exemplo, um local distante do centro urbano (não apropriado quando considerado apenas este critério) pode representar uma excelente área em todos os demais aspectos. Nós poderíamos por isso considerá-la apta em algum grau.

- o) Como uma análise final usando o resultado da MCE *Booleana*, identificaremos aquelas áreas que possuem 20 hectares ou mais. Ao examinar a imagem MCEBOOL podemos verificar que existem várias áreas de aptidão contíguas. Entretanto a maioria parece ser muito pequena para um projeto de desenvolvimento residencial. Use uma combinação dos módulos GROUP e AREA e encontre as áreas do resultado final da análise MCE *Booleana* que tem 20 hectares ou mais. Salve a sua imagem de áreas contíguas maiores que 20 hectares como HT20BOOL. Visualize esta imagem com o arquivo vetorial WESRDS usando o arquivo de símbolos Qualitativa 16.

4. Quantas áreas aptas contíguas maiores que 20 hectares existem em seu resultado?

## **9. Avaliação por critérios múltiplos -- Combinação linear ponderada**

Nosso segundo método de agregação por critérios múltiplos é denominado de Combinação Linear Ponderada (*Weighted Linear Combination* - WLC). Neste método os fatores não são reduzidos a simples restrições *Booleanas*. Ao invés disso, eles são padronizados para uma escala contínua de aptidão de 0 (menos apto) a 255 (mais apto). Reescalonar os fatores para uma escala contínua permite-nos compará-los e combiná-los, como no caso *Booleano*. Entretanto, no caso contínuo, evitaremos as decisões *Booleanas* rígidas de definição de uma área em particular como absolutamente apta ou não apta. Com WLC usaremos o conceito relativo ou *fuzzy* para definir aquelas áreas que são aptas e para definir o limite entre o apto e o inapto para os nossos fatores. Nossas restrições manterão seu caráter *Booleano* rígido.

Como veremos, WLC permite não apenas reter toda a variabilidade dos nossos dados contínuos mas oferece também a possibilidade de nossos fatores compensarem-se uns com os outros. Um escore de aptidão baixo em um fator para uma área qualquer pode ser compensada por um escore alto de aptidão em outro fator. A forma como ocorre a compensação de um fator com o outro será determinada por um conjunto de pesos dos fatores que indica a importância relativa de cada fator. Adicionalmente, este procedimento de agregação afasta a análise do extremo de aversão ao risco da operação AND. Como veremos, WLC é uma técnica baseada nas médias e que coloca nossa análise exatamente a meio caminho das operações AND (mínimo) e do OR (máximo), isto é, nenhum risco extremo e nenhum extremo de aversão ao risco.

### **Padronização de fatores (*Fuzzy*)**

O procedimento de padronização de WLC é um pouco mais complexo que no caso *Booleano*. Os fatores não são apenas reclassificados em 0 e 1, mas reescalonados de acordo com alguma função para um intervalo particular comum. Para usar fatores *fuzzy* com o módulo MCE eles devem ser padronizados para um intervalo em nível de byte entre 0 e 255. As restrições originais de nosso exemplo, os corpos d'água e os banhados (WATRCON) e certos usos do solo (LUSECON), serão mantidas como imagens *Booleanas* que atuarão simplesmente como uma máscara no último passo de WLC, isto é, serão critérios de restrição.

Vamos reconsiderar nossos fatores originais, rotinas de padronização e regras de decisão. Estas regras de decisão estavam anteriormente na forma de decisões rígidas. Nossos fatores foram reduzidos a restrições *Booleanas* usando funções de associação a conjuntos fixos, 0 e 1. Agora nossos fatores serão considerados à luz de regras de decisão *fuzzy* onde áreas aptas e inaptas constituem medidas contínuas. Os fatores contínuos resultantes a serem produzidos serão desenvolvidos usando funções de associação a conjuntos *fuzzy*.

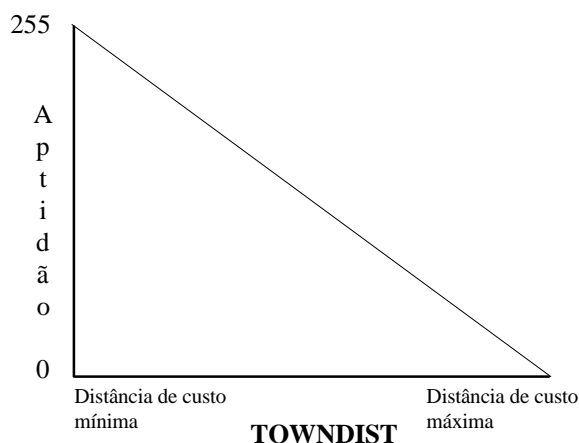
#### Fator uso do solo

Em nossa MCE *Booleana* reclassificamos nossos quatro tipos de uso do solo disponíveis para desenvolvimento residencial urbano em aptos (florestas e campos) e inaptos (agricultura e pecuária). Entretanto, de acordo com os incorporadores todos os quatro tipos de uso do solo possuem diferentes níveis de aptidão para desenvolvimento residencial. Conhecendo a aptidão relativa de cada categoria podemos reescalóná-la em intervalos de 0 a 255. Enquanto a maioria dos fatores pode ser reescalónada automaticamente usando-se alguma função matemática, reescalónar dados discretos para dar um determinado índice subjetivo para cada categoria deve se basear em algum conhecimento. Neste caso, a ordem hierárquica foi especificada pelos incorporadores.

- a) Na escala de 0 a 255 atribuiremos o índice de aptidão 255 para os campos, 200 para áreas com floresta, 125 para áreas de pecuária e 75 para áreas de agricultura. Use EDIT e ASSIGN para alterar os identificadores das classes na imagem de feições WETLUSE para os novos escores de aptidão relativa, atribuindo zero a todas as demais categorias. Denomine de LANDFAC o mapa de fatores padronizados derivado do mapa de uso do solo.

#### Fator distância até o centro da cidade

A função de reescalónamento mais comum toma um intervalo original de dados e efetua um realce linear simples. Por exemplo, medidas de distância relativa do centro da cidade, um determinante importante de lucro para os incorporadores, serão reescalónadas para um índice de aptidão onde a maior distância possui o menor escore de aptidão (0) e a menor distância de custo tem o maior escore de aptidão (255). Uma função de decréscimo linear simples é apropriada para este critério, isto é, à medida que a distância de custo do centro da cidade aumenta, a aptidão diminui (veja a figura abaixo).




- b) Para reescalónar nosso fator distância de custo usando essa função linear simples, usaremos o módulo FUZZY. Necessitaremos indicar pontos de controle que reflitam a função de decréscimo linear e a aptidão decrescente à medida que nos afastamos do centro da cidade. Neste caso, os pontos de controle são os pontos extremos da reta, os valores mínimos e máximos de distância encontrados em nossa imagem de distâncias de custo.
1. Execute DESCRIBE para encontrar os valores mínimos e máximos de distância na imagem TOWNDIST. Registre estes valores para usá-los como pontos de controle.

2. A seguir, execute o módulo FUZZY com TOWNDIST como a imagem de entrada e especifique uma função linear. Ajuste a função para monotonicamente decrescente, já que a aptidão decresce com o aumento da distância até o centro da cidade. Em seguida, indicaremos os valores mínimos e máximos da imagem TOWNDIST respectivamente como o ponto de controle  $c$  e o ponto de controle  $d$ . Ajuste o formato de dados de saída para byte (0-255). Denomine este segundo mapa de fatores de TOWNFAC.
3. Explique por que o resultado não mostra anéis concêntricos perfeitos de aptidão emanando do centro da cidade?

#### Fator distância de corpos d'água

Outros fatores, como a nossa distância de corpos d'água, não possuem um decréscimo ou acréscimo constante de aptidão baseado apenas na distância. Nós sabemos, por exemplo, que a legislação urbana de Westboro permite o desenvolvimento residencial com afastamento mínimo de 50 metros de corpos d'água e banhados e que os ambientalistas preferem ver o desenvolvimento residencial ocorrer ainda mais distante destes corpos d'água. Entretanto, uma distância de 800 metros pode ser tão boa quanto uma distância de 1.000 metros, pois a aptidão não aumenta com a distância de forma constante.

Em nosso estudo de caso, a aptidão é muito baixa a menos de 100 metros da água como vimos no exemplo *Booleano*. Além dos 100 metros, todas as partes concordam que a aptidão cresce com a distância. Os ambientalistas, entretanto, colocam que os benefícios ambientais obtidos com a distância dos corpos d'água atingem um máximo aos 800 metros. Além dos 800 metros a aptidão para desenvolvimento residencial mantém-se constante. Esta função não é uma função linear simples como aquela usada no fator anterior. Ela é melhor descrita por uma curva sigmoidal crescente (veja o gráfico abaixo).



- c) Usaremos uma função sigmoidal para reescalonar os valores na nossa imagem de distância de áreas protegidas PROTDIST.
  1. Execute o módulo FUZZY com PROTDIST como nossa imagem de entrada e especifique uma função sigmoidal monotonicamente crescente. Para acomodar os dois valores-limite de 100 e 800 metros em nossa função, os pontos de controle não serão mais o mínimo e o máximo dos nossos valores de entrada. Ao contrário, eles serão equivalentes aos pontos de inflexão na curva sigmoidal. No caso de uma função crescente, o primeiro ponto de controle ( $a$ ) é o valor no qual a aptidão começa a subir abruptamente acima de zero e o segundo ponto de controle ( $b$ ) onde a aptidão começa a manter-se constante e aproxima-se de um valor máximo de 255. Lembre-se também que PROTDIST representa a distância da faixa tampão de 50 metros já protegida em torno de corpos d'água e banhados. Por isto, para este fator indique um valor de 50 para o ponto de controle  $a$  e um valor de 750 para o ponto de controle  $b$ . Novamente,

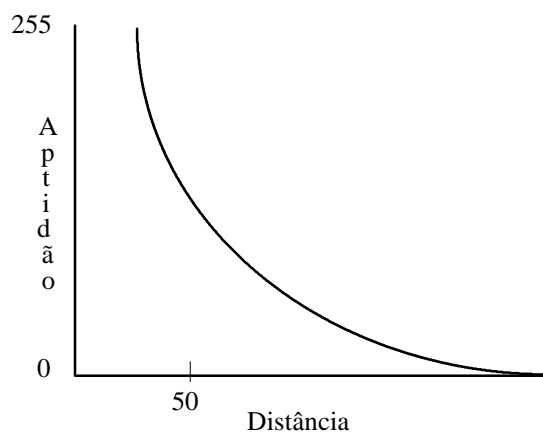
ajuste o formato dos dados de saída para byte, denominando o resultado de WATRFAC.

Para compreender melhor o resultado do mapa de aptidão *fuzzy*, é útil examiná-lo em perspectiva ortográfica com uma imagem de cobertura contendo os mesmos dados. Para fazer isto no IDRISI for Windows necessitamos fazer primeiro uma cópia de WATRFAC que será usada como imagem de cobertura.

2. Na Manutenção de arquivos, copie WATRFAC e denomine o novo arquivo de WATRFACD.
3. A seguir, execute ORTHO, especifique WATRFAC como a imagem de relevo e WATRFACD como imagem de cobertura. Selecione um fator de exagero vertical igual a 0,3 e uma resolução de saída compatível com o seu monitor. Aceite as demais opções padrão e pressione OK. Após a imagem ter sido visualizada, amplie uma janela no canto extremo direito de nossa área de estudo. Você verá nitidamente um perfil indicando o caráter sigmoidal dos dados recém escalonados. Na base da curva visível (mostrada em preto e em azul escuro) estamos a menos de 100 metros do corpo d'água mais próximo, enquanto no topo da curva (mostrado em verde escuro) estamos além dos 800 metros do corpo d'água mais próximo.
4. Quais são os valores no topo e na base da curva? O que eles representam? Os que os valores intermediários a eles representam?

#### Fator distância das rodovias

Da mesma forma que o nosso fator de distância de corpos d'água, a distância das rodovias é um fator contínuo a ser reescalado de 0 a 255. Nas operações anteriores, os incorporadores identificaram apenas áreas a menos de 400 metros de rodovias como aptas. Entretanto, dada a possibilidade de determinar um intervalo de aptidão, eles identificaram áreas a até 50 metros de rodovias como as *mais* aptas e áreas além dos 50 metros como tendo um decréscimo contínuo de aptidão que se aproxima de 0. Esta função é descrita adequadamente por um curva decrescente em forma de J (veja figura abaixo).



- d) Para reescalonar nosso fator distância das rodovias para esta curva em forma de J usaremos novamente o módulo FUZZY.
  1. Execute FUZZY com ROADDIST como imagem de entrada e selecione uma função monotonicamente decrescente em forma de J. O primeiro ponto de controle é o valor no qual a aptidão começa a declinar do valor máximo e o segundo ponto de controle é o valor estimado do ponto de inflexão na curva, ou o ponto intermediário até a base da curva onde a associação ao conjunto começa a se aproximar de zero. No nosso caso, o primeiro ponto de controle (*c*) será 50 e o segundo (*d*) será 400 metros. Ajuste o

formato dos dados de saída para byte e especifique ROADFAC como nome da imagem de saída.

Você poderá visualizar o resultado usando ORTHO. Para tal, siga os mesmos passos utilizados para essa finalidade nos passos 2 e 3 do item “c”, indicando como imagem de relevo ROADFAC e como nova imagem de cobertura ROADFACD (deve ser copiada antes de executar ORTHO).

2. Em que a curva em forma de J difere da curva sigmoidal? Sugestão: Observe, tanto na Visualização das imagens quanto nos produtos de ORTHO, que não existem valores representando áreas absolutamente inaptas.

#### Fator declividades

Sabemos, das nossas discussões anteriores, que áreas com declividades inferiores a 15% são as de melhor eficiência de custo. Entretanto, as declividades mais baixas são as melhores e qualquer declividade acima de a 15% é igualmente inapta. Usaremos novamente a função sigmoidal para reescalonar nossos dados para o intervalo de 0 a 255.

- e) Ao executar FUZZY neste caso, o primeiro ponto de inflexão, onde a curva começa a decrescer abaixo do máximo de aptidão, será nosso valor mínimo de declividade (0%), enquanto nosso segundo ponto de controle será a declividade de 15%, a aptidão mínima.
  1. Execute FUZZY e especifique SLOPES como a imagem de entrada, selecione uma função monotonicamente decrescente e indique o valor zero para o ponto de controle *c* e o valor 15 para o ponto de controle *d*. Ajuste o formato dos dados de saída para byte e chame o resultado de SLOPFAC.
  2. Desenhe e lende o gráfico que mostra os pontos extremos da curva que descreve essa função sigmoidal para o fator SLOPFAC.

#### Fator distância de áreas já urbanizadas

Finalmente, nosso último fator, importante para os ambientalistas, será também reescalonado usando-se uma função de decréscimo linear com a distância. Áreas próximas a locais já urbanizados serão mais aptas do que áreas mais distantes destas, isto é, a aptidão decrescerá com a distância.

- f) Execute FUZZY com DEVLDIST como imagem de entrada e especifique uma função linear. Ajuste para função monotonicamente decrescente, já que a aptidão decresce com a distância. Use o valor mínimo de distância como o primeiro ponto de controle e o máximo como o segundo. Ajuste o formato dos dados de saída para byte (0-255) e denomine o arquivo de saída DEVLFAC.

#### Ponderação de fatores

Uma das vantagens do método WLC é a capacidade de dar diferentes pesos relativos para cada um dos fatores no processo de agregação. Os pesos dos fatores, algumas vezes chamados de pesos de compensação, são atribuídos a cada fator; eles indicam a importância relativa de cada fator em relação aos demais e controlam como os fatores irão compensar-se uns aos outros. No caso da WLC, onde os fatores se compensam totalmente, fatores com aptidão elevada em um local podem compensar outros fatores com baixa aptidão neste mesmo local. O grau com que um fator pode compensar o outro é determinado pelo seu fator, ou peso de compensação.

No IDRISI for Windows o módulo WEIGHT utiliza uma técnica de comparação pareada para desenvolver um conjunto de pesos de fatores. As comparações referem-se à importância relativa dos dois fatores na determinação de sua aptidão para o objetivo determinado. O módulo informa os novos pesos juntamente com uma razão de consistência. A razão de consistência tem a intenção de instruir o usuário sobre quaisquer inconsistências ocorridas durante o processo de comparação pareada. O módulo permite um processo iterativo de exploração, onde o usuário ou grupo de usuários pode experimentar uma variedade de esquemas de ponderação (atribuição de pesos).



- g) Execute WEIGHT e especifique que você quer usar o arquivo de comparação pareada (.pcf) RESDEV, existente em seu diretório de exercícios. Especifique também que você deseja produzir um arquivo de apoio à decisão de saída com o mesmo nome, RESDEV. Pressione a seguir o botão Continuar. A segunda caixa de diálogo mostra uma matriz de comparação pareada que contém a informação armazenada no arquivo .pcf RESDEV. Esta matriz indica a importância relativa de qualquer fator em relação aos demais. Ela é o resultado de longas discussões entre planejadores urbanos e seus parceiros. Entretanto, deve-se observar que é muito difícil cotejar fatores relevantes para os ambientalistas com aqueles relevantes para os incorporadores. Trataremos desse tema no Exercício 10.


Após a matriz estar completa, os pesos dos fatores podem ser calculados acionando-se a opção Calcular pesos. Você pode fazer isto várias vezes, sempre retornando à matriz de comparação pareada, ajustando os escores e calculando pesos até que uma razão de consistência aceitável seja alcançada. Convém observar que você pode aceitar a comparação pareada a qualquer momento, independente da razão de consistência obtida, e então usar os pesos resultantes para ponderar seus fatores. Optaremos por aceitar a matriz de comparação pareada tal como foi desenvolvida. Pressione OK. Os pesos resultantes devem coincidir com os da tabela abaixo. Você pode sempre retornar ao módulo de ponderação e tentar alterar qualquer das comparações pareadas já feitas.

Fator	Peso do fator
LANDFAC	0,06
TOWNFAC	0,09
WATRFAC	0,11
ROADFAC	0,32
SLOPFAC	0,32
DEVLFAC	0,11

### Execução de MCE (WLC)

Um dos procedimentos mais comuns de agregação de dados é a Combinação Linear Ponderada (*Weighted Linear Combination* - WLC). No IDRISI for Windows isto é feito multiplicando-se cada fator padronizado pelo seu peso correspondente (em nosso caso pesos derivados através do módulo WEIGHT, mas de nenhum modo limitados a essa única técnica) e somando-se a seguir todos os fatores. Uma vez somados os fatores, o último passo no WLC é multiplicar nossas restrições *Booleanas* (em nosso exemplo, LUSECON e WATRCON) para eliminar as áreas que não são aptas em grau algum. A imagem final é uma medida de aptidão agregada com valores entre 0 e 255. Este procedimento pode parecer tedioso, mas é executado facilmente através do módulo MCE. Embora assumamos que o leitor esteja familiarizado com estas técnicas, uma revisão sobre WLC no capítulo *Apoio à decisão* será bastante útil.

O procedimento WLC permite uma completa compensação entre todos os fatores. O grau com que um fator pode compensar outro, entretanto, é determinado pelo seu peso. Em nosso exemplo, um alto escore de aptidão em SLOPFAC pode facilmente compensar um baixo escore de aptidão de LANDFAC em um mesmo local. Na imagem resultante este local terá uma aptidão elevada. No cenário inverso, um alto escore de aptidão em LANDFAC pode compensar um baixo escore de aptidão em SLOPFAC. O grau com que essa compensação irá impactar o resultado final é muito limitado pelo seu baixo peso. Em termos de risco relativo, vimos anteriormente como uma MCE *Booleana* que usa a operação AND é essencialmente uma operação muito conservadora ou contrária a riscos e que a operação OR aceita riscos. Estes são os extremos de um contínuo de aceitação de risco (*ANDness*). A WLC, entretanto, está exatamente no meio deste contínuo, sendo caracterizada, portanto, por uma compensação plena e risco médio (veja a figura a seguir).



- h) Execute MCE usando a opção de Combinação Linear Ponderada. Recupere o arquivo de parâmetros dos seis fatores e seus respectivos pesos chamado RESDEV que você criou no item anterior. Especifique ainda o uso de duas restrições, LUSECON e WATRCO. Denomine a imagem resultante de MCEWLC e salve novamente o arquivo de parâmetros. Mais uma vez iremos comparar o resultado com os arquivos de entrada usando a consulta expandida do cursor. Use EDIT e escolha criar um novo arquivo de grupo de imagens chamado MCEWLC. Adicione ao grupo os sete arquivos a seguir:

**MCEWLC.IGF**

MCEWLC  
LANDFAC  
WATRFAC  
ROADFAC  
TOWNFAC  
SLOPFAC  
DEVLFAC

Visualize MCEWLC e use a consulta expandida do cursor para explorar a imagem. Assegure-se de ter redefinido o arquivo de grupo nas Preferências de visualização, e acione também a opção Mostrar gráfico. Examinando os resultados deve estar claro a você que áreas com aptidão similar não possuem necessariamente a mesma combinação de escores de aptidão para cada fator. Os fatores compensam uns aos outros através da imagem. Qual o fator mais determinante do caráter do mapa de aptidão resultante? Por que?

- i) Como no exemplo anterior de MCE *Booleana*, estamos mais interessados nas áreas de aptidão elevada que possuem um tamanho superior a 20 hectares, a área mínima a ser considerada para desenvolvimento residencial urbano. Necessitamos identificar primeiro aquelas áreas que têm maior aptidão. Um dos vários métodos que existem consiste em segmentar arbitrariamente o nosso mapa de aptidão de tal modo que apenas áreas com a maior aptidão permaneçam disponíveis para consideração. Posteriormente temos que agrupá-las, tal como foi feito no exemplo *Booleano*, para encontrar as áreas com 20 hectares ou mais. Usaremos o histograma de MCEWLC para determinar o valor de limiar para a segmentação do mapa de aptidão. Poderíamos também usar o módulo RANK para ordenar o mapa de aptidão e então reclassificar esta imagem para alguma percentagem arbitrária dos *pixels* de ordem hierárquica mais elevada.

1. Execute HISTO com MCEWLC como imagem de entrada com um valor mínimo igual a 1. Observe a mudança na frequência no valor 175. Este ponto será nosso valor de limiar.
2. Execute RECLASS e especifique MCEWLC como imagem de entrada e MCEWLCH (para áreas mais aptas) como imagem de saída. Reclassifique MCEWLC de modo que todas as áreas com escore de aptidão superior a 175 recebam um novo valor de 1 e todas as demais áreas um novo valor igual a 0. Para explorar este resultado mais tarde,

adicione MCEWLCH ao arquivo de grupo MCEWLC usando EDIT e examine cada um dos novos grupos de alta aptidão com o cursor. Finalmente, use o mesmo esquema de agrupamento discutido anteriormente para isolar áreas contíguas maiores que 20 hectares. Salve sua imagem de áreas contínuas maiores que 20 hectares como HT20WLC. Visualize esta imagem e adicione o arquivo vetorial WESRDS usando o arquivo de símbolos Qualitativa 16.

3. Estas são as mesmas áreas do que as do exercício de MCE *Booleana*? Por que não? Quais os grupos que possuem o grau médio de aptidão mais elevado? E o mais baixo? Que fatores podem explicar esta diferença? Sugestão: use os módulos GROUP e EXTRACT e explore sua imagem resultante adicionando-a ao arquivo de grupo MCEWLC.

## **10. Avaliação por critérios múltiplos -- Média ponderada ordenada**

O último método de agregação de critérios em nossa MCE é a Média Ponderada Ordenada (*Ordered Weighted Average* - OWA). Esta técnica é similar à WLC vista há pouco, uma vez que os critérios são padronizados e ponderados do mesmo modo, restrições são máscaras *Booleanas* e fatores são mapas contínuos de aptidão que são ponderados de acordo com sua importância relativa. Por isso, não iremos ponderar ou padronizar nossos fatores novamente para este método de MCE. Entretanto, no caso da OWA, um segundo conjunto de pesos, agora pesos de ordenação, serão aplicados a nossos fatores. Pesos de ordenação nos darão um maior grau de controle sobre o nível global de compensação entre fatores, assim como do nível de risco na determinação da aptidão.

Nosso primeiro método de agregação, o método *Booleano*, demandou que reduzíssemos nossos fatores a simples restrições que representam decisões rígidas sobre a aptidão. O mapa final de aptidão para desenvolvimento residencial foi o produto da operação lógica AND (mínimo), isto é, ela foi uma solução que evitou o risco, não deixando nenhuma possibilidade para que os critérios compensem uns aos outros. Caso um local não fosse apto para todos os critérios, este local não poderia ser apto no mapa final.

A WLC, entretanto, permite-nos usar todo o potencial de nossos fatores como superfícies contínuas de aptidão. Lembre que após identificar os fatores, eles foram padronizados usando-se funções *fuzzy*, ponderados e combinados usando a técnica das médias. Os pesos dos fatores usados expressaram a importância relativa de cada critério para o objetivo global e determinaram como os fatores foram compensados entre si. O mapa final de aptidão contínua para desenvolvimento residencial (MCEWLC) foi o resultado de uma operação que está exatamente no meio do caminho entre as operações AND e OR, ela não foi nem totalmente aversa ao risco nem aceitou um risco exagerado. Adicionalmente, permitiu-se que todos os fatores pudessem ser totalmente compensados. Qualquer fator poderia compensar qualquer outro de acordo com o seu peso.

Assim, os procedimentos de MCE que usamos nos dois exercícios anteriores situam-se ao longo de um contínuo entre o AND e o OR. O método *Booleano* nos dá acesso aos extremos, enquanto a WLC coloca a operação exatamente no meio desses extremos. Em ambos os extremos do contínuo não é possível uma compensação, mas no meio existe um potencial para compensação total. A OWA, entretanto, nos dará um controle tanto sobre as posições da MCE ao longo de um contínuo, como sobre o nível global de compensação. Isto é, ela nos permitirá controlar o nível de risco (*ANDness*) que desejamos assumir em

nossa MCE e o grau com que os pesos dos fatores (pesos de compensação) irão influenciar o mapa final de aptidão. A OWA oferece uma variedade de soluções possíveis para nosso problema de desenvolvimento residencial.

O controle sobre o nível de risco e sobre a compensação é feito especificando-se um conjunto de pesos de ordenação para as diferentes posições de ordem hierárquica dos fatores em cada local (*pixel*). Os pesos de ordenação governarão primeiramente o grau com o qual os pesos dos fatores terão influência no procedimento de agregação. Após a aplicação dos pesos dos fatores (em algum grau) aos fatores originais, os resultados são ordenados da aptidão mais baixa à mais elevada em cada local. Ao fator com o escore de menor aptidão é dado o primeiro peso de ordenação, ao fator com o segundo valor mais baixo o segundo peso de ordenação e assim por diante. Isto tem o efeito de ponderar fatores com base em sua ordem do valor mínimo ao valor máximo para cada local. O deslocamento relativo em direção ao mínimo ou ao máximo dos pesos de ordenação controla o nível de risco (*ANDness*) e o próprio risco, enquanto o grau com o qual os pesos de ordenação estão uniformemente distribuídos ao longo de todas as posições controla o nível de compensação global, isto é, o grau com o qual os pesos dos fatores influenciam. O usuário deve revisar o capítulo *Apoio à decisão* no Manual do Usuário do IDRISI for Windows para maiores informações sobre OWA.

### Execução de OWA -- Risco médio e compensação plena

Em nosso exemplo necessitamos especificar seis pesos de ordenação porque temos seis fatores que serão ordenados para cada local após a aplicação dos pesos dos fatores. Caso queiramos produzir um resultado idêntico àquele do nosso exemplo de WLC, onde nosso nível de risco situou-se exatamente entre AND e OR, nosso nível de compensação é pleno e no qual os pesos dos fatores são usados plenamente, teremos que especificar os seguintes pesos de ordenação:

	Nível médio de risco -- compensação plena					
Pesos de ordenação:	0,16	0,16	0,16	0,16	0,16	0,16
Ordem:	1°	2°	3°	4°	5°	6°

No exemplo acima, o peso é distribuído regularmente entre todos os fatores independente de sua posição ordenada do mínimo ao máximo para qualquer local. Eles não tendem nem em direção ao mínimo (operação AND) nem em direção ao máximo (operação OR). Como no procedimento WLC, nosso resultado estará exatamente no meio em termos de *ANDness* e de risco<sup>12</sup>. Adicionalmente, como todas as posições de ordem hierárquica recebem o mesmo peso, nenhuma posição ordenada terá maior influência sobre a outra no resultado final. Haverá compensação plena entre fatores permitindo que os pesos dos fatores sejam plenamente usados. Para ver o resultado de um esquema de ponderação destes, e um intervalo de outras soluções possíveis para nosso problema de desenvolvimento residencial urbano, usaremos novamente o módulo MCE.

- Execute MCE e selecione a operação Média ponderada ordenada. Recupere seu arquivo de parâmetros .dsf salvo durante o procedimento WLC, chamado RESDEV. Adicionalmente aos parâmetros salvos anteriormente, um novo conjunto de pesos, pesos de ordenação, aparece na base da caixa de diálogo de OWA. As definições padrão para estes pesos são iguais para todos - compensação plena e risco médio. Denomine a imagem de saída MCEAVG para operação OWA de risco médio. Salve os parâmetros com o nome MCEAVG<sup>13</sup>. Pressione OK.

Visualize a nova imagem MCEAVG e o resultado de WLC anteriormente criado, MCEWLC. Estas imagens são idênticas. Use EDIT com o arquivo de grupo MCEWLC utilizado anteriormente para consulta expandida do cursor. Adicione MCEAVG ao arquivo de grupo e salve-o com o novo nome MCEOWA. A exploração de cada imagem mostrada deve revelar que elas são iguais, cada uma

<sup>12</sup> É importante lembrar que a ordem hierárquica para um conjunto de fatores para um dado local pode não ser a mesma de outro local: pesos de ordenação são específicos da hierarquia e não dos fatores.

<sup>13</sup> Sugerimos que você sempre salve um arquivo de parâmetros .dsf com o mesmo nome da sua imagem de saída toda vez que executar o módulo OWA.

possuindo o mesmo nível de compensação e de risco. Adicionalmente, caso queiramos identificar as áreas mais aptas ao desenvolvimento residencial com mais de 20 hectares, teremos um resultado igual ao do nosso exemplo de WLC. Como vimos, a técnica WLC é um subconjunto da técnica OWA.

### Execução de OWA -- Baixo risco e nenhuma compensação

Caso quiséssemos produzir um resultado com baixo risco para nosso problema de desenvolvimento residencial, algo próximo ao AND (mínimo) no nosso contínuo de *ANDness*, daríamos maior peso de ordenação aos fatores mais próximos do valor mínimo. De fato, caso atribuíssemos peso total ao fator individual com o escore de aptidão mínimo, nosso resultado seria muito parecido com o obtido na operação AND usada em nossa MCE *Booleana*. Adicionalmente, tal ponderação resultaria em nenhuma compensação. Os pesos de fatores desenvolvidos por nós anteriormente simplesmente não teriam influência em nossa saída final. Os pesos de ordenação que usaríamos para essa operação AND seria os seguintes:

Baixo nível de risco -- nenhuma compensação						
Pesos de ordenação:	1	0	0	0	0	0
Ordem:	1°	2°	3°	4°	5°	6°

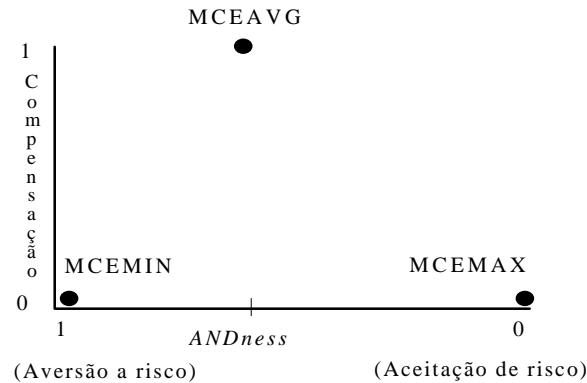
Neste exemplo de operação AND todo o peso é dado à primeira posição hierárquica, o fator com o escore de aptidão mínimo para um dado local. Nitidamente, este conjunto de pesos de ordenação está deslocado em direção a AND, o fator com o valor mínimo ganha todo o peso. Adicionalmente, como não é dado qualquer peso a nenhuma outra posição de ordem hierárquica além do mínimo, não pode haver compensação entre fatores, o fator mínimo sozinho determina o resultado final.

- b) Execute MCE usando a operação OWA e recupere o arquivo de parâmetros MCEAVG. Denomine o arquivo de saída MCEMIN, modifique os pesos de ordenação de tal forma que eles produzam a operação mínimo, conforme ilustrado na tabela acima. Salve os parâmetros para MCEMIN e então execute o módulo. Adicione a imagem com o resultado ao seu arquivo de grupos MCEOWA (você já pode remover MCEWLC), visualize o resultado e explore a imagem usando seu cursor. Que fator teve maior influência no resultado final para cada local na imagem? Que influência tiveram os pesos dos fatores nesta operação? Por que?
- c) Para comparação, visualize seu resultado *Booleano*, MCEBOOL, ao lado de MCEMIN. Como é possível ver claramente, estas imagens têm muitas áreas em comum. Explique por que há áreas de alta aptidão que não correspondem ao resultado *Booleano*?

Uma diferença importante entre o resultado mínimo de OWA e o resultado *Booleano* é evidente em áreas em que a aptidão é elevada em ambas as imagens. Diferente do resultado *Booleano*, as áreas escolhidas como aptas na operação OWA têm graus variáveis de aptidão.

- d) Execute OVERLAY e multiplique MCEBOOL por MCEMIN, denominando o resultado RANGE. A imagem resultante irá mostrar um intervalo contínuo de aptidão dentro de áreas aptas da nossa análise *Booleana* original. Apesar de ambas serem resultados de risco extremamente baixo, MCEMIN oferece mais informação que pode ser importante para a seleção de áreas residenciais.
- e) Agora, crie uma imagem denominada MCEMAX que represente a operação de máximo, usando o mesmo conjunto de fatores e restrições. Que pesos de ordenação você usou? Que nível de compensação existe em sua operação de máximo? Que nível de risco?

Os resultados de mínimo e máximo estão localizados nos pontos extremos de nosso contínuo de *ANDness*, mas compartilham a mesma posição de não compensação.



### Execução de OWA -- Variando níveis de risco e compensação

Está claro que a técnica OWA pode produzir resultados que são muito similares aos resultados de AND, OR e WLC. De certo modo eles são todos subconjuntos de OWA. Entretanto, como podemos alterar os pesos de ordenação em termos de seu deslocamento e dispersão, podemos produzir uma série quase infinita de soluções possíveis para nosso problema de desenvolvimento residencial, isto é, soluções que situem-se em qualquer lugar ao longo de um contínuo entre AND e OR e que possui níveis variáveis de compensação.

Por exemplo, em nosso problema de desenvolvimento residencial os planejadores urbanos podem estar interessados em uma solução conservadora ou de baixo risco para identificar áreas próprias para uso residencial. Entretanto, eles também sabem que suas estimativas de como os fatores podem ser compensados com os demais também são importantes e deveriam ser consideradas. A operação AND não permitirá considerar nenhuma compensação, e a operação WLC, onde eles teriam uma compensação plena, é muito liberal em termos de admissão de risco. Os planejadores procurarão então desenvolver um conjunto de pesos de ordenação que lhes dê alguma quantia de compensação mas que mantenha o nível de risco baixo na solução.

1. Que conjunto de pesos você pode sugerir aos planejadores urbanos para manter um baixo nível de risco com alguma compensação?
- f) Execute MCE e escolha recuperar parâmetros do arquivo de apoio à decisão .dsf denominado MCEMIDA. Observe que este conjunto de parâmetros tem pesos de ordenação que especificam uma operação a meio caminho entre o extremo de AND e a posição de risco médio de WLC. Adicionalmente, estes pesos de ordenação definem o nível de compensação para ficar a meio caminho entre a situação de nenhuma compensação da operação AND e a situação de compensação plena de WLC. Estes pesos devem ser similares ao conjunto que você recém desenvolveu.

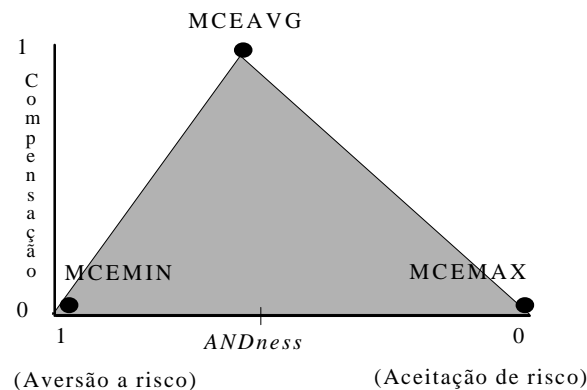
Agora execute MCE novamente, mas use agora o arquivo .dsf chamado MCEMIDO e denomine o resultado MCEMIDO.

1. Como os resultados de MCEMIDO diferem de MCEMIDA em termos de compensação e risco? O resultado de MCEMIDO atenderia às necessidades dos planejadores urbanos? Usando o mesmo gráfico anterior, localize as posições de MCEMIDA e MCEMIDO.

A seguir, visualize MCEMIDA e MCEMIDO juntamente com os resultados anteriores de OWA, e adicione-os ao arquivo de grupo denominado MCEOWA. Inclua todos os cinco resultados do procedimento OWA no arquivo de grupo de imagens numa ordem de AND para OR. Usando o modo de consulta expandida do cursor, explore pelo menos uma destas imagens. Você pode constatar que, enquanto a aptidão geralmente aumenta de AND para OR em qualquer local, o caráter deste incremento entre quaisquer das duas operações é diferente para cada local.

Os extremos de AND e OR são definidos pelos valores máximos e mínimos dos fatores, mas os resultados das três operações com compensação entre esses extremos são determinados por uma média dos fatores que depende de uma combinação dos valores dos fatores, dos pesos dos fatores e dos pesos de ordenação. Geralmente em locais onde os fatores com pesos elevados (declividades e rodovias) tem escores similares de aptidão, os três resultados com compensação serão muito similares. Em locais onde estes fatores não possuem escores de aptidão similar, os três resultados com compensação serão mais influenciados pela diferença na aptidão (em direção ao mínimo, à média ou ao máximo).

Nos exemplos OWA explorados até agora variamos nosso nível de risco e de compensação juntos. Isto é, à medida que nos movemos de AND para OR, a compensação aumentou de nenhuma para compensação total com WLC, decrescendo novamente para nenhuma compensação em OR. Nossa análise, colocada no gráfico abaixo em termos de compensação e *ANDness*, moveu-se ao longo do lado externo ao perímetro do triângulo. Entretanto, caso tivéssemos variado a *Andness* independente da compensação, poderíamos ter posicionado nossa análise em qualquer lugar no interior do triângulo, o *Espaço de estratégia de decisão*.



Podem ter sido impossível harmonizar a compensação entre fatores com relação a custos de desenvolvimento e fatores relacionados a preocupações ambientais. Por exemplo, nenhum nível de aptidão para distância de rodovias poderia compensar uma distância inadequada dos corpos d'água e banhados, etc. Entretanto, as posições sem compensação que vimos, o mínimo e o máximo, não são apropriadas em termos de risco. Em uma situação como esta os planejadores urbanos querem uma solução sem compensação mas que ainda mantenha um nível médio de risco.

2. Que conjunto de pesos de ordenação poderiam produzir um risco médio sem compensação (observe que com um número par de fatores definindo pesos de ordenação para absolutamente nenhuma compensação é impossível na posição de risco médio)? Onde uma análise destas estaria localizada em nosso espaço de estratégia de decisão?
- g) Execute MCE com este conjunto de pesos de ordenação e denomine o resultado com risco médio e sem compensação de MCEART. Visualize o resultado juntamente com MCEAVG e adicione-o ao arquivo de grupo MCEOWA. Estas imagens são visivelmente bastante diferentes uma da outra mesmo tendo níveis de risco idênticos. Sem compensação, a solução com risco médio MCEART está próxima da mediana ao invés da média ponderada, como em MCEAVG (e MCEWLC). Como você pode ver, ela contrasta significativamente da tendência suave de AND para OR que exploramos anteriormente. Variar a compensação independentemente do risco aumenta o número de saídas possíveis bem como o potencial de modificar análises para contemplar situações específicas.
  - h) Finalmente, como nas seções anteriores, estamos interessados em áreas de alta aptidão cuja área seja de pelo menos 20 hectares, a área mínima a ser considerada para uso residencial. Como



antes, examinaremos os histogramas para determinar limites de alta aptidão para nossas imagens resultantes, reclassificaremos nosso mapa de aptidão para este limite com RECLASS, agruparemos as imagens de alta aptidão com GROUP, calcularemos a superfície de cada grupo de *pixels* independente com AREA e usaremos RECLASS novamente para reclassificar apenas os grupos com mais de 20 hectares.

1. Examine os histogramas de MCEMIDA e MCEARNT. Execute HISTO com um valor mínimo igual a 1 para cada imagem. Observe a mudança na frequência no valor 100 para MCEMIDA e, um pouco menos nítido, no valor 230 para MCEARNT. Estes pontos serão nossos valores de limiar de alta aptidão.
2. Execute RECLASS em cada imagem de modo que todas as áreas com um escore de aptidão acima dos respectivos valores de limiar recebam um novo valor igual a 1 e todas as demais áreas recebam um valor igual a 0. Use então o mesmo esquema de agrupamento discutido anteriormente para isolar áreas contíguas maiores que 20 hectares. Salve suas novas imagens de áreas contíguas maiores que 20 hectares como HT20MIDA e HT20ARNT. Visualize estas imagens juntamente com HT20BOOL e HT20WLC usando a tabela de cores Qualitativa 256 e adicionando o arquivo vetorial WESRDS com o arquivo de símbolos Qualitativa 16.
3. Compare HT20MIDA com HT20BOOL e HT20WLC. Observe que existem áreas de alta aptidão em comum nos resultados *Booleano* e WLC. O que pode explicar esta mistura de áreas com alta aptidão *Booleana* e WLC?
4. Compare HT20ARNT com HT20WLC e observe como os resultados são diferentes mesmo ambos compartilhando o mesmo nível de risco. De fato, o resultado de risco médio e nenhuma compensação é muito diferente de todos os demais resultados. O que pode explicar esta diferença?

### Agrupamento de fatores de acordo com a compensação

Nossa análise até agora tem levado em consideração que todos os fatores devem compensar-se de acordo com o mesmo nível prescrito por um conjunto de pesos de ordenação. Entretanto, conforme discutido anteriormente neste exemplo, nossos fatores são de dois tipos distintos: fatores relevantes ao custo do empreendimento e fatores relevantes às preocupações ambientais. Estes dois conjuntos não têm necessariamente o mesmo nível de compensação. Fatores relevantes aos custos de empreendimento claramente podem compensar-se plenamente. Onde o custo financeiro é senso comum, uma economia nos custos de desenvolvimento em um fator pode compensar altos custos em outro. Fatores relevantes aos ambientalistas, por outro lado, não se compensam tão facilmente. Manter a fauna silvestre longe de novos loteamentos não compensa facilmente o *runoff* (escoamento superficial) da água e a preocupação com a contaminação.

Para lidar com esta discrepância trataremos nossos fatores como dois conjuntos distintos com diferentes níveis de compensação, especificados por dois conjuntos de pesos de ordenação. Isto irá gerar dois mapas de aptidão intermediários, um com o resultado da combinação de todos os fatores financeiros e o outro com o resultado da combinação dos fatores ambientais. Combinaremos então estes resultados intermediários usando uma terceira operação MCE.

Para combinar o primeiro conjunto de fatores, aqueles relevantes ao custo, usaremos o procedimento WLC, já que queremos um resultado de compensação plena e risco médio. Existem quatro fatores de custo a considerar: o uso atual do solo, a distância até o centro da cidade, a distância de rodovias e a declividade. O procedimento WLC permite que os pesos dos fatores influenciem plenamente o resultado, e que os fatores de custo já tenham sido ponderados junto com os fatores ambientais de modo que os pesos dos seis fatores originais somem 1. Entretanto, necessitaremos criar novos pesos para os quatro fatores de custo de modo que a soma dos pesos totalize 1 sem os fatores ambientais. Para este exemplo, ao invés de ponderar nossos quatro fatores novamente, simplesmente reescalaremos os pesos previamente calculados para que somem 1.

	<u>Pesos originais</u>	<u>Pesos reescalados</u>
LANDFAC	0,0620	0,0791
TOWNFAC	0,0869	0,1108
ROADFAC	0,3182	0,4057
SLOPFAC	0,3171	0,4044

Execute MCE e escolha a opção WLC. Especifique que você quer usar duas restrições e quatro fatores. Indique as restrições LUSECON e WATRCON e os quatro fatores, bem como seus pesos reescalados listados acima. Denomine a imagem intermediária resultante de INTRCOST.

Para o segundo conjunto de fatores, aqueles relevantes às preocupações ambientais, usaremos um procedimento OWA que irá produzir um resultado com baixo risco e nenhuma compensação. Há dois fatores a considerar: a distância de corpos d'água e de banhados e a distância de áreas já urbanizadas. Novamente reescalaremos os pesos dos fatores originais de modo sua soma totalize 1.

	<u>Pesos originais</u>	<u>Pesos reescalados</u>
WATRFAC	0,1073	0,4972
DEVLFAC	0,1085	0,5028

- i) Execute MCE e escolha a opção OWA. Indique que você quer usar duas restrições e dois fatores e escolha LUSECON e WATRCON e os dois fatores, bem como os pesos reescalados listados acima. Que pesos de ordenação resultarão num baixo risco e nenhuma compensação?

Entre com os pesos de ordenação e denomine a imagem intermediária resultante que combina todos os fatores relevantes às preocupações ambientais de INTRENV. Visualize o resultado juntamente com INTRCOST. Como você pode ver, estas imagens são muito diferentes uma da outra, mas observe como INTRCOST é similar a MCEWLC.

1. O que essa similaridade nos diz a respeito de nossa análise anterior de risco médio? Que fatores mais influenciam os resultados nestas imagens?

O passo final neste procedimento é combinar nossos dois resultados intermediários usando uma terceira operação MCE. Não existe uma regra clara sobre como combinar estes dois resultados. Assumiremos que os planejadores urbanos do nosso exemplo estão relutantes em dar um peso maior aos fatores de interesse dos incorporadores ou aos de interesse dos ambientalistas. Os pesos dos fatores serão iguais. Adicionalmente, eles não permitirão que os dois novos fatores consolidados se compensem, nem desejam outro nível de risco que não o menor possível quando combinarem os dois resultados intermediários.

2. Que conjunto de fatores e pesos de ordenação poderão nos dar este resultado?

- j) Execute MCE e escolha a operação OWA. Especifique LUSECON e WATRCON como as restrições, INTERCOST e INTRENV como dois fatores, indique os pesos dos fatores e de ordenação apropriados e denomine o resultado MCEFINAL.

Como último passo nesta análise iremos isolar novamente áreas com 20 hectares ou mais que têm alto escore de aptidão final. O valor limite que usaremos para alta aptidão é o valor de 145 (veja o histograma da imagem MCEFINAL). Use o mesmo conjunto de passos das seções anteriores e salve sua imagem de área contígua com mais de 20 hectares como HT20FIN. Visualize esta imagem e adicione o arquivo vetorial WEARDS usando o arquivo de símbolos Qualitativa 16.

1. Quantas áreas aparecem após esta última análise? Por que não existem mais áreas com pelo menos 20 hectares?

2. Compare este resultado final com os resultados anteriores (especialmente HT20BOOL e HT20WLC). Que resultados anteriores têm a mesma área de alta aptidão? Por que?

OWA oferece uma ferramenta extraordinariamente flexível para MCE. Como as técnicas WLC tradicionais, ela nos permite combinar fatores com pesos de fatores variáveis, mas prossegue com outro passo permitindo controlar o grau de compensação entre fatores e o nível de risco que cada um deseja assumir. Finalmente, nos casos em que conjuntos de fatores nitidamente não têm o mesmo nível de compensação, OWA permite-nos tratá-los temporariamente em análises independentes e então combinar os resultados.

## **11. Tomada de decisão com objetivos múltiplos**

Nos exercícios anteriores introduzimos o caso de avaliação por critérios múltiplos para atingir um objetivo, aquele de aptidão para áreas residenciais. Mais comum é necessitarmos tomar uma decisão que satisfaça múltiplos objetivos. O processo de tomada de decisão com objetivos múltiplos, entretanto, freqüentemente deve atender perspectivas complementares e conflitantes.

Objetivos complementares não representam um grande problema já que podem ser identificadas áreas com alta aptidão para qualquer número de objetivos. O caso de objetivos conflitantes, entretanto, é mais complicado pois ele exige a identificação de terras que maximizem as regras de decisão que são parte da estratégia de decisão para um único objetivo. Neste exercício iremos estender a análise feita nos três exercícios anteriores e apresentar o caso de objetivos conflitantes para definição de terras entre áreas que são aptas ao desenvolvimento residencial e aquelas que são aptas ao desenvolvimento industrial. Estes dois objetivos podem ser considerados claramente objetivos conflitantes. Caso você ainda não o tenha feito, revise o capítulo *Apoio à decisão* e o item *Tomada de decisão com objetivos múltiplos* no Manual do Usuário do IDRISI for Windows.

O primeiro passo na resolução do problema com objetivos múltiplos é estabelecer mapas de aptidão para cada objetivo. Recorde os vários mapas de aptidão residencial que foram produzidos usando vários procedimentos OWA no exercício 10. Usaremos o mapa de aptidão média MCEFINAL. Obviamente qualquer número de possíveis mapas de aptidão pode ser usado, dependendo primeiramente da estratégia global de decisão.

O segundo objetivo que a cidade de Westboro está considerando é a identificação de áreas que são aptas ao desenvolvimento industrial. Para os planejadores urbanos e para a comunidade o zoneamento para estas áreas em associação com o desenvolvimento residencial é mutuamente exclusivo. Assim, a tarefa não constitui apenas identificar áreas que são mais aptas para cada objetivo mas também identificar aquelas áreas que maximizem a aptidão para cada objetivo através de uma solução de consenso. Encontrar a solução que contemple essas tarefas será facilitada com o uso do módulo MOLA.

O objetivo dos planejadores urbanos constituirá identificar 1600 hectares para desenvolvimento residencial juntamente com 600 hectares para expansão industrial. Para melhor entender o problema de objetivos múltiplos necessitamos antes ter uma idéia daquelas áreas que serão conflitantes.

- a) A solução para o problema de objetivos múltiplos e o uso de MOLA requer que tenhamos criado mapas de aptidão para cada objetivo. Vamos examinar os dois mapas de aptidão. Usaremos o mapa produzido com MCEFINAL no exercício anterior. Usaremos também o mapa de aptidão industrial, INDSUIT, produzido usando as mesmas técnicas de ponderação e de avaliação tratadas aqui. Nós o fornecemos pronto a você para este exercício. Usando o Lançador de visualização, visualize ambos os mapas com a tabela de cores padrão Idrisi 256 e coloque-os lado a lado. Você pode ainda adicionar o arquivo vetorial de cursos d'água e rodovias em cada um.

1. Que áreas parecem ter melhor aptidão para desenvolvimento residencial?  
Que áreas parecem ter melhor aptidão para desenvolvimento industrial?

Caso fosse apenas um problema com um único objetivo, ou se estivéssemos considerando cada um dos objetivos por si só, a solução seria relativamente simples. A solução seria ordenar cada mapa de aptidão e então selecionar as *melhores* áreas, ou as células que possuem a hierarquia mais elevada até atingirmos nosso objetivo de 1600 ou 600 hectares. Podemos fazer isso se ordenarmos hierarquicamente os mapas de aptidão e então selecionarmos aquelas células com a ordem hierárquica mais alta que satisfazem nosso objetivo em área. Usaremos a combinação dos módulos RANK e RECLASS para realizar este conjunto de tarefas. Entretanto, como os objetivos são conflitantes, devemos esperar que as soluções iniciais sejam áreas conflitantes. Assim, iremos identificar quaisquer áreas conflitantes antes de desenvolver a solução final de resolução dos conflitos.

- b) Execute RANK, encontrado no submenu Análise/Apoio à decisão. Especifique a imagem de entrada como MCEFINAL e escolha classificar em ordem descendente (isto é, a célula com o maior valor de aptidão terá o menor número de ordem hierárquica -- 1). Frequentemente várias células terão o mesmo grau de aptidão para um dado objetivo. Nestes casos temos a possibilidade de estabelecer um ordenamento arbitrário ou olhar o valor das células em questão em outra imagem para determinarmos sua ordem hierárquica. Neste caso escolheremos o mapa de aptidão do outro objetivo como base para resolver impasses. Assim, podemos solucionar impasses na aptidão para desenvolvimento residencial dando hierarquia maior para células que são menos aptas para desenvolvimento industrial. Especifique que você quer usar um segundo arquivo de classificação, INDSUIT, com classificação ascendente. Denomine o arquivo de saída de RESRANK.

1. Visualize RESRANK com a tabela de cores Idrisi 16. Use a seguir DESCRIBE e veja os valores mínimos e máximos da imagem. Qual é o máximo? Qual a relação entre o valor máximo e o tamanho da imagem (em linhas e colunas)?

- c) Agora que o mapa de aptidão residencial foi ordenado hierarquicamente, qualquer número das melhores células pode ser identificado usando RECLASS. No nosso caso queremos identificar os melhores 1.600 hectares para desenvolvimento residencial. Entretanto, como RESRANK tem valores que indicam ordem hierárquica, necessitamos converter esta área em número de células. Nosso conjunto de dados tem resolução de 20 metros ou 0,4 hectares por célula (um hectare contém 10.000 metros quadrados). Como resultado, 1.600 hectares equivalem a 40.000 células.

Agora execute RECLASS com a imagem de entrada RESRANK. Selecione a reclassificação personalizada. Indique que você quer atribuir um novo valor de 1 a todas as células de hierarquia 1 até 40000 e o valor 0 para aquelas que vão de 40000 até 99999 (todos os demais valores acima de 40000). Denomine o arquivo de saída de BESTRES. Quando o processamento houver terminado, você poderá visualizar o resultado usando a tabela de cores Qualitativa 16.

- d) Agora use os mesmos procedimentos RANK e RECLASS para produzir um mapa com as melhores áreas para desenvolvimento industrial. Crie INDRANK a partir de INDSUIT (descendente) usando MCEFINAL (ascendente) como a imagem de classificação secundária. A seguir use RECLASS para criar a partir de INDRANK o mapa BESTIND, que identifica as

melhores 15000 células (o equivalente a 600 hectares). Finalmente, use CROSSTAB, encontrado no submenu Análise/Consulta ao banco de dados para produzir a imagem de classificação cruzada denominada CONFLICT. Visualize o resultado usando a tabela de cores Qualitativa 16 e use a legenda.

1. Que classe mostra áreas que são as mais aptas para desenvolvimento residencial? Que classe mostra áreas que são melhores para desenvolvimento industrial? Que classe mostra aquelas áreas que estão em conflito de objetivos?

A imagem CONFLICT ilustra a natureza do problema de objetivos múltiplos com objetivos conflitantes que competem entre si. Como esta solução provisória não soluciona conflitos, nós ainda temos que identificar áreas para atingir nossos objetivos de 1.600 hectares para desenvolvimento residencial e 600 hectares para desenvolvimento industrial. Este conflito necessita ser resolvido e irá requerer uma técnica específica para o problema de objetivos que competem entre si. MOLA é do mesmo modo uma técnica que emprega uma heurística de decisão para encontrar as melhores áreas para qualquer objetivo dado. Mas antes de podermos usar objetivos que competem entre si neste procedimento eles devem ser padronizados de modo a tornarem-se comparáveis. Este passo já foi dado através do uso da operação de hierarquização com o módulo RANK.

- e) Para completar o processo de decisão com objetivos múltiplos, execute o módulo MOLA a partir do submenu Análise/Apoio à decisão. Especifique o número de objetivos como dois e o nome do arquivo de saída como FINAL. Especifique também uma área de tolerância de 500. Isto permitirá que o procedimento pare quando ele estiver dentro dos 20 hectares da solução desejada.

A seguir, especifique o nome de cada objetivo, o peso a atribuir a cada objetivo, os mapas de aptidão ordenados associados a cada objetivo e as áreas a serem definidas para cada um. Você pode especificar qualquer nome para o objetivo. Para o primeiro objetivo dê o nome de Residencial, com um peso de 0,5 (peso igual para dois objetivos), use a imagem RESRANK para o mapa de ordenação e especifique um requisito em área de 40000 células (1600 hectares). Pressione o botão com uma seta à direita para especificar o segundo objetivo, o desenvolvimento industrial. Especifique o nome do objetivo como Industrial, atribua também um peso de 0,5, indique INDRANK como o nome do mapa de ordenação e especifique um requisito em área de 15000 células. Finalmente, dê um título e pressione OK. MOLA irá agora buscar uma solução iterativa e resolverá qualquer conflito.

1. Quantas iterações foram feitas por MOLA para encontrar a solução? Qual foi a área definida para cada objetivo? Por que este número é diferente da solução exata especificada para os objetivos?

A solução apresentada em FINAL mostra apenas uma das soluções possíveis para os dois objetivos. Além disso, não há limite para o número de objetivos que podem ser resolvidos. O usuário é estimulado a experimentar com vários mapas de aptidão e objetivos. Se o usuário quiser continuar sua exploração no processo de tomada de decisão com critérios múltiplos/objetivos múltiplos, com exemplos trabalhados usando SIG, consulte o livro de trabalho do UNITAR *GIS and Decision Making* (1993), disponível ao público para aquisição através do Projeto IDRISI.

## **12. Modelagem de peso de evidência com BELIEF**

Este exercício irá concluir a série de exercícios de apoio à decisão examinando outro método para a agregação de dados, conhecido como modelagem de peso de evidência *Dempster-Shafer*. Será usado o módulo BELIEF encontrado no IDRISI for Windows. Esse módulo possui uma grande variedade de aplicações, já que é uma ferramenta que pode agregar muitas fontes de informação diferentes para prever a probabilidade com a qual qualquer fenômeno pode ocorrer. Como a ferramenta oferece ao usuário um método para revisar a força relativa da informação coletada com a finalidade de estabelecer valores de confiança, ela é útil para aplicar conhecimento informal em uma análise uma vez que é possível reconhecer ignorância no resultado final produzido. Com esta flexibilidade torna-se possível estabelecer e avaliar o risco relativo de decisões feitas com base no total de informação que está disponível. O usuário deve rever o capítulo *Apoio à decisão* e o item sobre *Dempster-Shafer* na seção **TÓPICOS ESPECIAIS** do Manual do usuário do IDRISI for Windows para obter mais informações.

Como uma introdução ao módulo, este exercício irá demonstrar como avaliar evidência amostral para a qual a aplicação de conhecimento especialista é importante e então derivar superfícies de probabilidade de forma a demonstrar esse conhecimento. Este exercício também irá demonstrar como combinar evidência para prever a confiança em um fenômeno ocorrendo sobre uma superfície *raster* completa.

O usuário irá avaliar a evidência existente usando conhecimento especialista para transformar a evidência em probabilidades para sustentar certas hipóteses que, representadas como superfícies de probabilidade, serão então agregadas no módulo BELIEF. O objetivo é avaliar a probabilidade com que um sítio arqueológico pode ser encontrado em cada *pixel* de uma superfície representando o Canyon Piñon, localizado no sudoeste dos Estados Unidos<sup>14</sup>. Dado o conhecimento sobre sítios arqueológicos existentes e dado o conhecimento especialista sobre a cultura, cada linha de evidência é transformada em um plano de informação representando a probabilidade de ocorrência de um sítio. A evidência agregada produz resultados que são usados para prever a presença de sítios arqueológicos, avaliar o impacto de cada linha de evidência no corpo total de conhecimento e identificar áreas para pesquisa adicional.

---

<sup>14</sup> Kenneth Kvamme, Department of Archaeology of Boston University, Boston, Massachusetts, EUA, doou estes dados amostrais. Nós fizemos um exemplo hipotético a partir deste conjunto de dados.

O interesse da pesquisa nos guia na definição da rede de discernimento -- ela inclui dois elementos básicos: [sítio] e [não sítio]. A combinação hierárquica de todas as hipóteses possíveis inclui portanto [sítio], [não sítio] e [sítio, não sítio]. Nós estamos mais interessados nos resultados produzidos para a hipótese [sítio]. A evidência existente que usamos, no entanto, pode sustentar qualquer uma das hipóteses possíveis. O resultado final produzido para a hipótese [sítio] é dependente de como *toda* a evidência está relacionada entre si no processo de agregação. Mesmo que a evidência possa sustentar outras hipóteses, ela afeta indiretamente a confiança total em [sítio].

Nós coletamos evidência indireta que está relacionada à probabilidade de que um sítio arqueológico existe. Essa evidência constitui os sítios conhecidos, a frequência de artefatos (fragmentos contados), a água permanente e as declividades. A evidência é derivada de diferentes fontes que são independentes umas das outras. Cada linha de evidência está associada com as hipóteses apenas indiretamente, por isso a ignorância é um fator importante a considerar na análise. Devemos ser explícitos sobre o que conhecemos e o que não conhecemos.

Os arquivos de dados para este exercício consistem de:

SITES:	arquivo vetorial contendo sítios arqueológicos conhecidos;
WATER:	arquivo imagem com água permanente;
SHARD_S:	imagem de probabilidade em suporte à hipótese [sítio], derivada da frequência de fragmentos contados;
SLOPE_NS:	imagem de probabilidade em suporte à hipótese [não sítio], derivada das declividades.

Primeiro necessitamos derivar, para cada linha de evidência, imagens de probabilidade para as hipóteses que a evidência sustenta. Decidir qual hipótese sustenta dada uma evidência nem sempre está muito claro. Frequentemente a distinção da hipótese que a evidência sustenta é muito sutil. Para cada linha de evidência que desenvolvemos, devemos decidir onde reside nosso conhecimento sobre a relação entre a evidência e as hipóteses. Isto determina em parte qual hipótese a evidência sustenta, bem como a forma como desenvolvemos valores de probabilidade para cada hipótese sustentada. No caso das declividades, por exemplo, estamos menos seguros sobre como as declividades atraem povoamentos do que sobre quais declividades são inabitáveis. Declividades suaves parecem sustentar a hipótese de que exista um sítio. Entretanto, como declividades suaves são apenas uma condição necessária mas não suficiente para que um sítio exista, eles constituem apenas uma plausibilidade e não uma confiança para [sítio]. Portanto, eles sustentam a hipótese [sítio, não sítio]. Declividades elevadas, por outro lado, indicam uma alta probabilidade de que um local NÃO é um sítio. Assim, estas declividades sustentam a hipótese [não sítio].

Em muitos casos a evidência que temos apenas sustenta a plausibilidade ou negação da hipótese primária de interesse. Isto significa que a evidência sustenta as hipóteses [sítio, não sítio] ou [não sítio] ao invés de [sítio]. Nosso conhecimento sobre uma hipótese é maior quando o suporte para a hipótese pela evidência é indistinguível do suporte para outras hipóteses. Da mesma forma, se a evidência somente sustenta o complemento da hipótese, o contrário também é verdadeiro. Frequentemente a evidência mais clara e forte que temos sustenta apenas a negação da hipótese de interesse. Mesmo com nosso corpo total de conhecimento à mão, podemos produzir apenas imagens de evidência que estabelecem uma falta de evidência geral para sustentar a hipótese de interesse. Isto, entretanto, não significa que esta informação não seja útil. De fato significa justamente o contrário. Ao produzir estas imagens de evidência, procuramos refinar a hipótese do local em que um fenômeno espacial tem probabilidade de ocorrer através da aplicação da evidência que reduz a probabilidade de que o fenômeno NÃO irá existir. Agregando diferentes fontes de informação da probabilidade podemos diminuir o intervalo de probabilidades para a hipótese de interesse, tornando assim possível tanto fazer uma predição para a hipótese quanto diminuir o número de locais selecionados para coleta adicional de informações.



### Criando imagens de probabilidade da evidência “água permanente”

Dados de água permanente representam informação indireta da qual se pode estimar a probabilidade de um sítio existir ou não. Usamos esta evidência como um exemplo para demonstrar um processo de raciocínio para decidir que hipóteses a evidência sustenta e então derivar as imagens de probabilidade correspondentes. Necessitamos primeiro examinar a evidência e ver como ela está relacionada com as hipóteses.

- a) Visualize a imagem denominada WATER usando a tabela de cores Qualitativa 16. Ela representa os corpos d'água permanentes na área. Adicione o arquivo vetorial denominado SITES com o arquivo de símbolos padrão. Este arquivo mostra os sítios arqueológicos conhecidos existentes na área.

A associação da maioria dos sítios com água permanente sugere que os rios são um fator determinante para a presença dos sítios. Podemos ver que a maioria dos sítios (se não todos) estão próximos à água permanente. Nosso conhecimento sobre esta cultura indica que a água é uma condição necessária para viver, mas não é por si só suficiente, já que outros fatores como as declividades também afetam os povoamentos. Por causa disso a proximidade da água indica a plausibilidade para um sítio. Locais mais afastados da água, por outro lado, nitidamente sustentam a hipótese [não sítio], pois sem água ou sem acesso a ela as pessoas não podem sobreviver. A distância de água permanente é importante na compreensão da relação desta evidência com a nossa hipótese de interesse [sítio]. Para olhar a relação entre a distância da água e os locais com sítios conhecidos devemos seguir os seguintes passos:

- b) Execute DISTANCE sobre a imagem WATER e chame o resultado de WATDIST.
- c) Execute POINTRAS a partir do submenu Conversão raster/vetor no menu Reformatação. Indique SITES como o arquivo vetorial de entrada e SITES como o arquivo imagem de saída. Use os identificadores dos pontos como os valores a atribuir às células da nova imagem. Pressione OK. Como o arquivo imagem SITES não existe, você será solicitado a criar a imagem com INITIAL. Escolha sim. Indique WATER como a imagem da qual copiar os parâmetros e especifique o valor inicial como zero. Visualize depois SITES com a tabela de cores Qualitativa 16.

Agora temos uma imagem denominada SITES, que contém os sítios arqueológicos conhecidos, e uma imagem com distâncias a partir da água.

Para estabelecer inicialmente a relação entre os sítios e sua distância da água será usada uma combinação dos módulos QUERY e HISTO. QUERY é projetado para extrair informação de planos de dados para efetuar análise estatística em *pixels* selecionados. Ele cria um arquivo com uma extensão .IMG, mas impróprio para visualização. Ele apenas lista os valores de *pixels* extraídos do plano de dados original.

- d) Execute QUERY a partir do menu Análise/Consulta ao banco de dados. O arquivo de entrada do qual extrairemos a consulta é WATDIST. O arquivo máscara com os *pixels* para os quais será extraída a informação é SITES. Denomine o arquivo de saída de SAMPLE, aceite o formato padrão do arquivo de saída e então execute QUERY. Uma mensagem de atenção aparecerá dizendo que este é um arquivo de consulta e não tem finalidade de visualização.
- e) Execute agora HISTO com o arquivo SAMPLE. Observe que o intervalo de classe deve ser modificado já que o intervalo dos valores de distância é grande. Entre o valor 100 (100 representa a resolução da célula dos dados) para o intervalo de classe. Aceite a opção de saída gráfica.

O histograma gráfico mostra a frequência com que diferentes valores de distância ocorrem entre os sítios arqueológicos existentes. Uma amostra como esta descreve a relação entre os valores de distância e a probabilidade com a qual um sítio pode ocorrer. Observe que quando a distância é maior do que 800 metros, raramente há qualquer sítio conhecido. Podemos usar esta informação para derivar probabilidades para a hipótese [não sítio].

- f) Execute FUZZY a partir do menu Análise/Apoio à decisão. Use WATDIST como a imagem de entrada, escolha a função sigmoïdal com curva monotonicamente crescente. Entre 800 e 2000 como pontos de controle *a* e *b* respectivamente. Escolha dados de saída reais e denomine o resultado WATERTMP. Visualize o resultado.

WATERTMP contém as probabilidades para a hipótese [não sítio]. A imagem mostra que quando a distância da água permanente é de 800 metros, a probabilidade para [não sítio] começa a crescer seguindo uma curva de forma sigmoïdal até 2000 metros, quando a probabilidade atinge 1. Há, entretanto, um problema com esta avaliação de probabilidade. Quando a probabilidade alcança 1 para a hipótese [não sítio] ela não deixa nenhum espaço para a ignorância de outros tipos de corpos d'água (tais como água subterrânea e água não permanente). Para incorporar esta incerteza, iremos reescalonar a probabilidade para baixo.

- g) Execute SCALAR a partir do menu Análise/Operadores matemáticos e multiplique WATERTMP por 0,8 para produzir um resultado denominado WATER\_NS.

Na imagem WATER\_NS, o intervalo de probabilidade está entre 0 e 0,8 em suporte à hipótese [não sítio]. Ela continua sendo uma função sigmoïdal, mas a associação *fuzzy* é reduzida ou achatada<sup>15</sup>. A evidência restante (1-WATER\_NS) produz as probabilidades que sustentam a hipótese [sítio, não sítio]. Isto é conhecido como ignorância e é calculado automaticamente pelo módulo BELIEF.

### Criando imagens de probabilidade a partir das outras linhas de evidência

De modo similar, imagens de probabilidade podem ser criadas a partir das outras três linhas de evidência.

Para sítios conhecidos, temos uma razão para especular que quanto mais próximo um local estiver de um sítio conhecido, maior a probabilidade de encontrarmos outros sítios. Isto está baseado na premissa de que as condições de vida são espacialmente correlacionadas e que as pessoas tendem a viver dentro de uma vizinhança umas das outras de modo a proteger melhor a comunidade. À medida que a distância dos sítios conhecidos aumenta, entretanto, a probabilidade para a hipótese [sítio] declina rapidamente. Para definir a probabilidade usando o módulo FUZZY, a função em forma de J é a que melhor descreve esta curva.

- h) Execute DISTANCE sobre a imagem SITES e chame o resultado de SITEDIST. Execute a seguir FUZZY com a função em forma de J e escolha uma curva monotonicamente decrescente, com 0 e 350 (metros) como pontos de controle *c* e *d*, respectivamente. Denomine o resultado de SITE\_S. Estas são as probabilidades de suporte para a hipótese [sítio] dada a evidência "sítios conhecidos".

Não possuímos informação para sustentar a hipótese [sítio] para locais distantes de sítios conhecidos, o que poderia refletir simplesmente que a pesquisa ainda não se estendeu sobre estas áreas. Por isto ela não sustenta a hipótese [não sítio]. Ela indica ignorância (probabilidade para a hipótese [sítio, não sítio]), que é calculada internamente pelo módulo BELIEF.

Para a evidência representando contagens de fragmentos, usamos um raciocínio similar àquele usado para a evidência de sítios conhecidos e derivamos a imagem SHARD\_S como suporte da hipótese [sítio]. A imagem representa a probabilidade de um sítio ocorrer em dado local em função da frequência de fragmentos descobertos. Da mesma forma que fizemos para a evidência declividades, derivamos uma imagem de probabilidade chamada SLOPE\_NS, a qual sustenta a hipótese [não sítio]. Esta linha de evidência representa a probabilidade de um sítio não ocorrer dada uma declividade elevada. Nós já criamos estas duas imagens para você.

---

<sup>15</sup> Você também pode usar a opção personalizada do módulo FUZZY para produzir resultados similares e para realizar os dois passos de f) e g) em um passo apenas, caso você possa definir pontos de controle suficientes para a curva *fuzzy* com intervalo entre 0 e 0,8.

### Agregando linhas diferentes de evidência

Agora que temos todas as imagens de probabilidade para cada linha de evidência, retornamos ao módulo BELIEF para agregá-las.

- i) Execute o módulo BELIEF a partir do submenu Apoio à decisão. Substitua o título *Knowledge base* por: “Sítios arqueológicos”. Na lista de classes, desejamos indicar os elementos básicos da rede de discernimento: sítio e não sítio. Na caixa de lista de classes indique a palavra SITIO e então pressione o botão Adicionar. A seguir indique a palavra NAOSITIO e pressione o botão Adicionar novamente. Tão logo você tiver entrado ambos os elementos, uma lista de hipóteses hierarquizada será criada automaticamente na lista de hipóteses. Neste exemplo temos três hipóteses: [sítio], [não sítio] e [sítio, não sítio].

Agora necessitamos introduzir informação para cada linha de evidência.

- j) Pressione o botão Adicionar nova linha de evidência. Indique a legenda “Distância da água” e entre o nome da imagem WATER\_NS. Escolha [naositio] como a hipótese sustentada. Pressione então o botão Adicionar. Observe que o nome do arquivo e sua hipótese sustentada serão mostrados na caixa Hipótese/Imagem. Caso você tivesse mais imagens (probabilidade para outra hipótese sustentada diferente da ignorância) desta linha de evidência, você as indicaria aqui, juntamente com a sua hipótese sustentada. Mas em nosso caso, uma vez que esta é a única imagem que necessitamos indicar, pressione OK para completar a entrada. Observe que a legenda é mostrada na caixa do Estado de conhecimento atual.

Faça o mesmo com as outras três linhas de evidência:

Legenda	Nome da imagem	Hipótese sustentada
Declividades	SLOPE_NS	[naositio]
Sítios conhecidos	SITE_S	[sitio]
Frequência de fragmentos	SHARD_S	[sitio]

Você poderá modificar a informação associada com qualquer linha de evidência pressionando Modificar/Ver evidência selecionada.

Toda a informação acima introduzida na interface de BELIEF pode ser salva em um arquivo de Base de conhecimento, com extensão .IKB. Após você ter concluído a entrada de toda a informação, selecione Arquivo/Salvar base de conhecimento atual e salve a base de conhecimento como ARCH.

- k) No módulo BELIEF, selecione Análise/Construir base de conhecimento. O programa combina toda as evidências e cria as atribuições de probabilidade básica (BPA) resultantes para cada uma das hipóteses. Uma vez concluído, escolha Extrair sumário a partir do menu Análise e crie os arquivos com a CONFIANÇA, PLAUSIBILIDADE e INTERVALO DE CONFIANÇA para a hipótese. Escolha extrair os arquivos da confiança, da plausibilidade e do intervalo de confiança para a hipótese SITE e denomine-os respectivamente de BEL\_S, PLAUS\_S e BELINT\_S.
- l) Visualize cada uma das imagens recém criadas usando a tabela de cores Idrisi 256. Explore visualmente os padrões nestes resultados. Adicione o arquivo vetorial dos sítios existentes (SITES) para auxiliá-lo na interpretação visual.
- m) Para facilitar esta exploração posteriormente usaremos o modo expandido de consulta do cursor com um arquivo de grupo de imagens. Para tal, usaremos EDIT. Selecione Arquivo de grupo de imagens e indique como nome do arquivo SITES. Selecione Usar editor de arquivos de grupo e pressione OK. Adicione os arquivos BEL\_S, PLAUS\_S, BELINT\_S da Lista de arquivos para a Lista de saída marcando cada arquivo e pressionando Adicionar.

A seguir entre no menu Visualização/Preferências de visualização e acione Usar modo expandido de consulta do cursor com o arquivo de grupo de imagens SITES. Acione a opção

Mostrar gráfico do valor z, pressione OK e acione o modo de consulta do cursor na barra de ícones. Com qualquer uma das imagens listadas no arquivo de grupo de imagens, consulte qualquer célula e o gráfico do valor z do cursor aparecerá no canto inferior direito do monitor. Preste atenção às áreas que têm uma alta probabilidade na imagem BELINT\_S e explique a relação entre confiança, plausibilidade e o intervalo de confiança. Considere esta questão: que áreas deveriam ser escolhidas para pesquisa adicional?

- n) Para explorar a relação entre os resultados e os planos de evidência, crie com EDIT outro arquivo de grupo de imagens denominado EVID que contenha os arquivos:

WATER\_NS  
SLOPE\_NS  
SITE\_S  
SHARD\_S  
BEL\_S  
PLAUS\_S  
BELINT\_S

Altere então para EVID o nome do arquivo de grupo de imagens nas Preferências de visualização. Consulte vários locais nas imagens BEL\_S, PLAUS\_S e BELINT\_S. Qual é a relação delas com a evidência? Quando tiver terminado, feche todos os arquivos.

- o) No módulo BELIEF, execute Análise/Extrair sumário e escolha extrair confiança (BEL\_NS), plausibilidade (PLAUS\_NS) e intervalo de confiança (BELINT\_NS) para a hipótese [não sítio]. Crie outro arquivo de grupo com EDIT denominado EVID2. Indique os mesmos nomes de arquivos de evidência anteriores mas altere os arquivos de confiança, plausibilidade e intervalo de confiança correspondentes para aqueles recém extraídos. Visualize estas três imagens e use o modo expandido de consulta do cursor para explorar a relação existente entre elas e entre os resultados e a evidência.

O que você deveria observar imediatamente é que a imagem BEL\_S contém a probabilidade agregada para [sítio] de sítios conhecidos e contagens de fragmentos, e representa a probabilidade mínima de consenso para esta hipótese [sítio]. A confiança é maior ao redor de pontos onde existe evidência dando suporte. A imagem PLAUS\_S, por outro lado, mostra áreas mais extensas ao longo de corpos d'água permanentes que têm alta probabilidade. Esta imagem representa a maior probabilidade possível para [sítio] se toda a probabilidade associada com esta hipótese demonstra sustentar a hipótese. A imagem BELINT\_S mostra a probabilidade de potenciais -- quanto maior a probabilidade, mais valor terá a informação adicional em um dado local. A imagem também insinua o valor de coletar mais informação e tem assim potencial para identificar áreas para pesquisa adicional.

É óbvio a partir dos resultados deste conjunto de dados que nossa ignorância foi maior onde não tínhamos informação amostral. Decidir onde seria melhor concentrar recursos para novas escavações arqueológicas iria depender do risco relativo que desejaríamos aceitar. Podemos decidir por continuar a selecionar áreas próximas dos rios onde a probabilidade de encontrar um sítio é maior. Por outro lado, caso acreditemos que, por razões não representadas em nossa análise, os sítios possam ocorrer em toda a região, podemos decidir termos a necessidade de entender mais sobre sítios que estão afastados de rios e expandir nossa base de conhecimento antes de aceitar nossas previsões. É possível examinar uma linha de evidência de cada vez para revisar os efeitos de cada linha de evidência sobre a confiança final e o nível de ignorância. Para fazer isso é necessário adicionar uma linha de evidência de cada vez e reconstruir a base de dados antes de extrair as novas imagens de sumário. Desta forma, BELIEF torna-se uma ferramenta para explorar forças e fragilidades individuais de cada evidência em combinação com as outras linhas de evidência.

**Passo opcional:**

Considere que necessitamos selecionar 5 km<sup>2</sup> para coletar mais evidência. Como a resolução do *pixel* é de 100 metros por 100 metros, deveríamos selecionar 50 *pixels* para constituir 5 km<sup>2</sup>.

- p) Execute um realce linear com STRETCH em BELINT\_S para transformar os valores para o intervalo de 0 a 255. A seguir, a partir do menu Análise/Apoio à decisão, execute RANK (ordem de classificação descendente) sobre o resultado do realce. Denomine de RANK a imagem ordenada de saída. Visualize a imagem.

Como uma área muito grande de BELINT\_S tem valores iguais a 1, *pixels* que tecnicamente têm igual hierarquia são ordenados de acordo com a ordem de leitura pelo programa: do topo para a base e da esquerda para a direita.

- q) Execute RECLASS para classificar os primeiros 50 *pixels* e crie uma imagem CHOICE1 na qual o valor de 1 é atribuído a todas as células cujos valores vão de 1 a 51 e o valor de zero é atribuído a todas as células com valores maiores do que 51. Visualize o resultado.

Observe que CHOICE1 contém áreas com valores de intervalo de confiança elevados. Observe que áreas com alto potencial para um sítio arqueológico representam possíveis escolhas para futura coleta de informação. Todavia, devido à grande porção dos dados originais com intervalo de confiança igual a 1, esta reclassificação apenas seleciona aqueles que foram arbitrariamente ordenados sobre os demais. Muito provavelmente mais variáveis ou outro conhecimento especialista é necessário para futuramente reduzir o conjunto de possibilidades para a ocorrência de sítios arqueológicos.

### Conclusão

A caracterização simultânea do que sabemos e do que não sabemos permite-nos entender os riscos relativos que tomamos nas decisões que fazemos sobre recursos. Uma vantagem adicional de caracterizar variáveis como confianças é a oportunidade de incorporar vários tipos diferentes de informação, incluindo conhecimento especialista, conhecimento informal, probabilidades e dados de satélite classificados, entre outros tipos de dados.

## **13. Incerteza no banco de dados e risco na decisão**

Os exercícios anteriores sobre Apoio à decisão trataram basicamente da incerteza na decisão. Neste exercício iremos focar a incerteza nos dados e, mais especificamente, na regra de decisão. A incerteza em qualquer plano de dados irá se propagar através da análise e se combinar com outras fontes de erro, incluindo a relação incerta do plano de dados em questão com o conjunto de decisão final. Este exercício aborda a propagação do erro de mensuração através de uma regra de decisão. Em particular, estudaremos uma simulação do aumento do nível do mar e estabeleceremos decisões sobre os impactos modelados. A principal questão de interesse é como dar reconhecimento pleno para o risco na decisão gerado por duas incertezas -- incerteza no dado e incerteza na regra de decisão propriamente dita, neste caso a estimativa do nível do mar aplicada.

Aumentos antecipados do nível do mar associados com aquecimento global levaram algumas nações a estimar impactos e a desenvolver estratégias de adaptação a mudanças no uso do solo e na população. Para ilustrar, usaremos dados da vizinhança do estuário de Cua-Lo próximo a Vinh, no centro-norte do Vietnam<sup>16</sup>.

- a) Execute ORTHO usando o modelo de elevação VINHDEM. Especifique a imagem de cobertura como VINH345 e use a tabela de cores Composição colorida 256. Denomine a imagem de saída de ORTHO1. Escolha a resolução de saída mais apropriada para seu monitor e aceite os demais valores padrão.

A imagem de composição colorida do satélite foi criada a partir das bandas 3, 4 e 5 do sensor Thematic Mapper do satélite LANDSAT para enfatizar variação relativa em biomassa e níveis de umidade. As grandes áreas de planície são ocupadas por agricultura de arroz irrigado, que é um produto de exportação de valor econômico considerável.

---

<sup>16</sup> O estudo de caso descrito aqui é parte do material preparado para o Spatial Information Systems for Climate Change Analysis, Vietnamese National Workshop, Hanoi, Vietnam, 18-22 de setembro de 1995. Uma descrição adicional de como o modelo foi desenvolvido para projetar modificações no uso do solo como resultado de mudanças ambientais está em *Spatial Information Systems and Assessment of the Impacts of Sea Level Rise*. J. Ronald Eastman e Stephen Gold, United Nations Institute for Training and Research, Palais des Nations, CH 1211 Geneva 10, Switzerland.

Como na maioria dos mapas as elevações são medidas com relação ao nível médio do mar, uma abordagem comum para simular inundação ou um novo nível do mar é subtrair um valor referente ao nível estimado da água de todas as altitudes de um modelo digital de elevação. Áreas que possuem um valor resultante dessa subtração igual ou inferior a 0 são consideradas como sendo inundadas. Isto no entanto é um pouco problemático, pois não leva em consideração a incerteza nas medidas das altitudes do modelo de elevação e da projeção do nível do mar.

### Incorporando incerteza no banco de dados

Nossa tarefa é avaliar tanto o erro de medida quanto o de projeção e seus erros combinados em termos de risco de decisão.

As estimativas do nível do mar variam. Seguindo as taxas atuais de aumento do nível do mar, a estimativa projetada de mudança por volta do ano 2100 é de 0,21 metros. As estimativas, entretanto, são maiores para condições de aquecimento global acelerado relacionado a emissões de gases de efeito estufa. Elas oscilam entre 0,32 e 0,64 metros<sup>17</sup>. Uma estimativa do nível médio, portanto, seria 0,48 metros com um desvio padrão de 0,08 metros.

O desvio padrão de 0,08 metros pode ser diretamente aplicado como uma estimativa de incerteza para a projeção do aumento do nível do mar. O valor é uma expressão do afastamento dos valores estimados de seu valor verdadeiro (o desvio padrão dos erros). Em dados quantitativos, este erro frequentemente é expresso como erro médio quadrado (RMS - *Root-Mean-Square Error*). Caso o RMS não seja informado para um plano de dados é necessário calculá-lo. Este é o caso do modelo de elevação que temos.

- b) Visualize a imagem VINHDEM com a tabela de cores Idrisi 256.

Para criar este modelo de elevação, primeiramente as curvas de nível foram digitalizadas a partir de uma carta topográfica em escala 1:25.000. As cartas apresentam uma equidistância de 1 metro entre as curvas de nível até a altitude de 15 metros. A partir desta altitude as curvas de nível têm equidistância de 5 metros. O módulo INTERCON foi usado para interpolar a superfície completa com uma resolução de 30 metros a partir das curvas de nível rasterizadas. A resolução foi escolhida de modo a registrá-la de acordo com os dados de uso do solo derivados da imagem de satélite.

Devido à importância das altitudes abaixo de 1 metro para a estimativa de inundações, dados adicionais de altitude foram necessários. Pontos de altitude conhecida foram avaliados com relação a quatro categorias significativas de cultura de arroz encontradas no mapa de uso do solo. Associações estreitas entre os pontos e estas categorias tornaram possível modelar altitudes abaixo de um metro com base no uso do solo. Da mesma forma, o mesmo processo foi aplicado para níveis de profundidade e turbidez associado com a reflexão da energia solar no rio e banhados adjacentes.

Os mapas produzidos pelas principais agências de topografia a partir da metade do século dezanove usualmente têm 90% de todos os locais situados na metade do valor da equidistância entre as curvas. Levando-se em consideração que o erro na altitude é aleatório<sup>18</sup> é possível contornar o erro RMS usando a seguinte lógica<sup>19</sup>:

- i. Para uma distribuição normal, 90% de todas as medidas deveriam cair dentro de 1,645 desvios padrão da média (valor obtido de tabelas estatísticas).
- ii. Como o erro RMS equivale ao desvio padrão para o caso onde a média é o valor verdadeiro, então a metade da equidistância entre as curvas abrange 1,645 erros RMS.

<sup>17</sup> Asian Development Bank. 1994. *Climate Change in Asia: Vietnam Country Report*. ADB, Manila.

<sup>18</sup> Estudos adicionais são necessários para determinar a significância de erros sistemáticos de altitudes interpoladas em função da distância a partir das curvas de nível. Para este exercício, apenas o erro para os cálculos hipsométricos originais foi determinado.

<sup>19</sup> O erro RMS também está demonstrado em Eastman, J.R.; Kyem, P.A.K.; Toledano, J.; Jim, W. 1993. *GIS and Decision Making*. UNITAR, Geneva. p.24. (Explorations in Geographic Information Systems. Technology. United Nations Institute for Training and Research. v.4).

$$\text{i.e., } 1,645 \text{ RMS} = C/2 \quad \text{onde: } C = \text{equidistância das curvas}$$

Solucionando para RMS, então:

$$\text{RMS} = C/3,29$$

$$\text{i.e., } \text{RMS} = 0,30C$$

Portanto, o erro RMS pode ser estimado tomando-se 30% da equidistância entre as curvas. No caso das baixas altitudes de VINHDEM, o RMS é 0,30 metros. Embora seja possível obter uma estimativa mais detalhada para altitudes inferiores a 1 metro, aplicaremos neste caso um RMS de 0,30 para todas as altitudes do modelo digital de elevação.

#### Simulando o novo nível do mar

Antes de simular a inundação por aumento do nível do mar incorporando a incerteza, começaremos do modo mais usual. Devemos subtrair um aumento estimado do nível do mar de todas as altitudes do modelo digital de elevação.

- c) Use SCALAR para subtrair um valor de 0,48 metros de VINHDEM e denomine a imagem resultante de LEVEL1. Visualize o resultado com a tabela de cores Idrisi 256. Selecione o modo de consulta do cursor na barra de ícones para examinar o valor z das áreas mais baixas.

Áreas que possuem uma diferença menor ou igual a 0 são consideradas inundáveis por nossa estimativa inicial. Como esta imagem foi derivada tanto do modelo de elevação quanto do aumento projetado do nível do mar, ele possui incertezas de ambos. No caso da subtração, os procedimentos propagação padrão produzem um novo nível de incerteza como:

$$\sqrt{((0,30)^2 + (0,08)^2)} = 0,31$$

Como descrito no tópico **Gerenciamento de incertezas** do capítulo *Apoio à decisão* da seção **TÓPICOS ESPECIAIS** do Manual do Usuário, esta informação pode ser inserida na documentação do arquivo e então posteriormente usada no módulo PCLASS para calcular a probabilidade das terras estarem abaixo do nível do mar, dadas as altitudes do modelo de elevação e o nível combinado de incerteza.

- d) Caso você ainda não tenha feito feche todos os arquivos. Execute DOCUMENT em LEVEL1. Indique 0,31 como o erro dos valores e pressione OK.
- e) Execute PCLASS a partir do menu Análise/Apoio à decisão. Indique LEVEL1 como a imagem de entrada e PROBL1 como a imagem de saída. Calcule a probabilidade das altitudes estarem abaixo do valor limite de 0 e visualize o resultado com a tabela de cores Idrisi 256. Examine os valores de z usando o modo de consulta do cursor.

Áreas que aparecem em preto têm uma probabilidade de ser inundadas igual a 0, enquanto aquelas que estão em verde aproximam-se de uma probabilidade igual a 1. Existe um intervalo de cores entre esses extremos onde os valores de probabilidade são menos precisos. Um valor de 0,45, por exemplo, indica uma probabilidade de que a célula tem 45% de chance de ser inundada, ou inversamente, 55% de chance de continuar acima da água.

Um mapa de probabilidades expressa a probabilidade de cada *pixel* estar inundado se alguém quisesse afirmar que ele não estaria. Isto é uma expressão direta do risco na decisão. É possível agora estabelecer um limite de risco -- um limiar acima do qual o risco de inundação é muito alto para ser ignorado.

- f) Execute RECLASS em PROBL1. Chame a imagem de saída de RISK10. Atribua um novo valor de 1 aos valores entre 0 e 0,10 (áreas esperadas de terra não inundada) e um valor de 0 aos valores entre 0,10 e 1 (zona de inundação esperada).



- g) Use OVERLAY para multiplicar VINH345 com RISK10 para produzir uma imagem denominada LEVEL2.
- h) Execute ORTHO com VINHDEM usando LEVEL2 como imagem de cobertura e denomine a imagem de saída ORTHO2. Use a tabela de cores Composição colorida 256 e selecione a resolução mais apropriada para seu sistema gráfico. Após visualizar o resultado, visualize também a imagem ORTHO1 para fazer algumas comparações entre as duas.

Em análises tradicionais em SIG, não levamos em consideração a incerteza no banco de dados. Como resultado, decisões rígidas são feitas com muito pouco conhecimento do risco envolvido nestas decisões. Este exercício demonstra como pode ser simples trabalhar com a mensuração do erro e sua propagação na regra de decisão. A tarefa do tomador de decisão é avaliar um mapa de probabilidades relativas e definir um nível aceitável de risco com o qual ele se sinta confortável. Conhecendo a qualidade do dado, o tomador de decisão pode ver o risco de decisão através de toda a superfície e fazer julgamentos e escolhas sobre este risco. Finalmente, qualquer análise ou modelagem de simulação de impactos adicional com tais dados também aumenta a precisão dessas decisões.

## 14. Regressão múltipla em SIG

No exercício 9, exploramos o conceito de regressão linear bivariada para estimar temperaturas a partir da altitude. Naquela análise, apenas duas variáveis foram envolvidas. Neste exercício e no próximo iremos explorar regressão linear múltipla e regressão logística, que são duas técnicas importantes para análise das relações entre múltiplas variáveis. Em ambos os casos, existem diversas variáveis explicativas (ou independentes) que auxiliam na predição da variável de interesse, a variável dependente.

Na regressão múltipla, é assumido existir uma regressão linear entre a variável dependente e as variáveis independentes. No caso de três variáveis independentes, por exemplo, a equação da regressão linear múltipla pode ser escrita como:

$$Y = a + b_1 * x_1 + b_2 * x_2 + b_3 * x_3$$

onde Y é a variável dependente;  $x_1$ ,  $x_2$  e  $x_3$  são as variáveis independentes; a é o *intercepto*; e  $b_1$ ,  $b_2$  e  $b_3$  são os *coeficientes* das variáveis independentes  $x_1$ ,  $x_2$  e  $x_3$ . O intercepto representa o valor de Y quando os valores das variáveis independentes forem 0 e o parâmetro coeficientes indica a mudança em Y para um incremento de uma unidade na variável independente correspondente.

As variáveis independentes podem ser contínuas (p. ex., intervalo, razão ou ordinal) ou discretas, mas as variáveis dependentes devem ser contínuas e não delimitadas. Algumas suposições embasam o uso de regressão linear múltipla, tais como:

- i. As observações são feitas independentemente da população e a variável dependente tem distribuição normal;
- ii. O número de observações deve ser maior do que o número de variáveis independentes;
- iii. Não existe uma relação linear exata ou próxima da linear entre as variáveis independentes.

A regressão logística é um caso especial de regressão múltipla na qual a variável dependente é discreta, tal como tipos de cobertura do solo (por exemplo, florestas, pastagem, urbano, etc.). Caso a variável dependente seja dicotômica, Y leva apenas dois valores em consideração: 1 e 0. Na predição de mudanças nas florestas, Y=1 representa o caso das florestas terem sido modificadas e Y=0 representa o caso das florestas terem permanecido inalteradas.

No caso de três variáveis independentes, a equação da regressão logística pode ser expressa como:

$$\text{logit}(p) = \ln(p/(1-p)) = a + b_1 * x_1 + b_2 * x_2 + b_3 * x_3$$

onde  $p$  é a variável dependente expressando a probabilidade de  $Y=1$ . Os outros componentes têm o mesmo significado da equação linear múltipla acima. A relação entre a variável dependente e as variáveis independentes segue a curva logística. A transformação logit da equação acima lineariza o modelo, fazendo com que a variável dependente da regressão seja contínua no intervalo de 0 a 1.

No exemplo que segue veremos a técnica de regressão linear múltipla. Há vários casos em que uma simples variável pode ser uma composição dos efeitos de um conjunto de variáveis. No presente exemplo, examinaremos estimativas de preços em mercados agrícolas locais da Etiópia como uma função de distância ao mercado central, precipitação média e número de bois por proprietário. A superfície de estimativa de preços foi computada usando-se aproximadamente 100 meses de uma série temporal de preços em 50 mercados da Etiópia. Um dos resultados derivados da análise foi o valor de repasse dos preços do mercado central aos mercados locais. Os valores para os mercados locais variaram de 0 a 100%. Um mercado local com um valor de 65% significa que se houvesse aumento de \$100,00 no preço do mercado central, o preço no mercado local teria um acréscimo de \$65,00. Mercados bem integrados (valores próximos a 100) são geralmente um indicador de economias eficientes. Assim, seria de considerável interesse político compreender as variáveis que influenciam a integração dos mercados.

- a) Visualize a imagem MKTINTEG com a tabela MKTINTEG. Esta é uma imagem de valores de repasse dos preços interpolados de 36 mercados<sup>20</sup>. Adicione o arquivo vetorial ETRDCLS com o arquivo de símbolos ETRDCLS e MARKETS com o arquivo de símbolos BIGPTS. ETRDCLS é um mapa das principais estradas, caminhos e trilhas da Etiópia<sup>21</sup>. MARKETS representa os mercados usados na análise de dados de preço. Use o modo de consulta do cursor para examinar os valores na Etiópia, especialmente ao longo das rodovias principais (linhas espessas).

A interpolação foi feita para melhorar a interpretação visual. Observe que a maioria dos valores de integração elevados ocorrem ao longo das principais rodovias (linhas espessas) ligando Addis Abeba com Asmara e Djibuti. Aparentemente a rede viária tem um papel importante na integração dos mercados.

Compreendendo-se a real contribuição do fator distância das rodovias (baseado na rede viária), podemos fazer conclusões acerca dos custos e benefícios da construção de novas estradas e seu efeito no melhoramento dos níveis de integração dos mercados. Incluiremos também na regressão duas outras variáveis para explicar melhor a natureza global da integração dos mercados: uma variável de riqueza (propriedade de bois<sup>22</sup>) e outra de precipitação<sup>23</sup>.

- b) Visualize a composição de mapa OXNOWN. Examine a porcentagem de propriedade de bois nos polígonos administrativos usando o modo de consulta do cursor<sup>24</sup>.

Como este mapa foi criado a partir de dados de distritos administrativos de terceiro nível, os dados referem-se a informações em nível destes polígonos. Não podemos executar uma regressão múltipla diretamente sobre arquivos imagem usando a propriedade de bois como uma das variáveis porque o tamanho da Awraja influenciaria o número de observações introduzidas na regressão. Adicionalmente, a integração dos mercados e as superfícies de precipitação foram interpoladas a partir de arquivos de

<sup>20</sup> Apenas 36 de 50 mercados analisados têm validade estatística significativa para uso nesta etapa.

<sup>21</sup> Para ter uma melhor representação visual da área de estudo, visualize a composição de mapa MKTINTEG.MAP. Esta composição pode não ser visualizada adequadamente em alguns sistemas devido a limitações de *hardware* (recomenda-se uma máquina Pentium).

<sup>22</sup> Economias domésticas de maior poder aquisitivo geralmente estão normalmente mais envolvidas em atividades mercantis.

<sup>23</sup> A precipitação foi usada como uma variável de "incentivo ao comércio". Áreas com maior precipitação terão relativamente menor incentivo ao comércio do áreas de precipitação baixa, áreas de déficit hídrico.

<sup>24</sup> Você pode observar as grandes disparidades na propriedade de bois nos diversos distritos administrativos. Além disso, parte de Harerghe e todo o Tigray não possuem nenhum dado sobre o rebanho bovino.

pontos. Extrairemos dados punctuais baseados nos mercados para cada uma das quatro variáveis (repasso de preços, distância de custo, propriedade de bois e precipitação média). Assim que tivermos dados comparáveis, poderemos executar uma regressão múltipla usando estas variáveis.

- c) Visualize a imagem ETRDCOST com a tabela de cores Idrisi 256. Esta é uma superfície de distâncias de custo derivada para cada um dos *pixels* em relação ao seu mercado central correspondente. Adicione o arquivo vetorial MARKETS (com o arquivo de símbolos MARKETS). Esses são os pontos para os quais extrairemos valores de cada uma das variáveis. Execute EXTRACT usando MARKETS como imagem de definição de feições e ETRDCOST como a imagem a ser processada. Aceite a opção MIN. Denomine o arquivo de valores de saída de DISTANCE. De modo similar, extraia valores punctuais de mercados a partir de MKTINTEG<sup>25</sup>, AVGRAIN<sup>26</sup> e OXENOWN e crie três arquivos de valores com os mesmos nomes.
1. Se tivéssemos que extrair informação em nível de Awraja (polígonos de limites administrativos de terceiro nível) para os mesmos quatro planos de informação, como faríamos isso?

Já criamos os quatro arquivos de valores necessários para executarmos a regressão múltipla: Y1PRICE (variável dependente) e X1DIST, X2RAIN e X3OXEN (variáveis independentes).

- d) Execute MULTIREG a partir do menu Análise/Estatística. Escolha a opção arquivos de valores e selecione Y1PRICE como variável dependente e X1DIST, X2RAIN e X3OXEN como variáveis independentes. Denomine o arquivo de predição de saída de PREDICT e o arquivo de resíduos de RESID.
2. O que você pode afirmar sobre o potencial desta regressão em explicar os valores de repasse de preços na Etiópia? Qual a proporção da variação no repasse dos preços (variável dependente) não é explicada (reporte-se ao parágrafo sobre R e R<sup>2</sup> abaixo)?

#### Resultados da regressão múltipla

Equação de Regressão:

$$Y1PRICE = 87,0431 - 0,0992 * X1DIST - 0,0253 * X2RAIN + 0,2424 * X3OXEN$$

Estatística da Regressão:

$$\begin{aligned} R &= 0,630161 & R^2 &= 0,397102 \\ R \text{ ajustado} &= 0,600469 & R^2 \text{ ajustado} &= 0,360563 \\ F(3,32) &= 7,02566 \end{aligned}$$

Tabela de regressão ANOVA

	Graus de liberdade	soma dos quadrados	desvio quadrado
Regressão	3	7741,41	2581,47
Resíduo	32	11757,90	367,43
Total	35	19502,31	

<sup>25</sup> O valor para *pixels* que não são mercado é zero e isto também retornará um valor no arquivo de valores. Isto não tem nenhuma relevância para a análise e por isso necessita ser excluído da variável dependente. Use EDIT para editar o arquivo de valores MKTINTEG e exclua a linha 0 0. Caso queira, você pode executar a regressão múltipla usando os arquivos prontos fornecidos juntamente com este exercício.

<sup>26</sup> Se você visualizar a imagem AVGRAIN, você poderá ver a escassez de dados. Esta imagem foi derivada de uma imagem com *pixels* de 111x111 km (a resolução atual é de aproximadamente 6 km). Isso foi feito em função da inexistência de dados melhores que fossem comparáveis ao longo do espaço e do tempo.

## Coeficientes de regressão individuais

	Coeficiente	Teste t (32)
Intercepto	87,04	6,01
x1dist	-0,10	-2,54
x2rain	-0,03	-3,04
x3oxen	0,24	1,41

Segue uma breve nota sobre os resultados:

## Equação de regressão:

A equação de regressão tem como saídas os coeficientes de regressão para cada uma das variáveis independentes e o intercepto. O intercepto pode ser imaginado como o valor da variável dependente quando cada uma das variáveis independentes assume o valor zero. Os coeficientes indicam o efeito de cada uma das variáveis independentes sobre a variável dependente. Por exemplo, se o valor da distância de custo de uma área ao seu mercado central decresce em 100 unidades devido à construção de uma nova estrada, então a porcentagem de integração de mercados aumenta em 9,92% (isto é,  $-100$  multiplicado por  $-0,992 = 9,92\%$ ).

R, R ajustado,  $R^2$ ,  $R^2$  ajustado

R representa o coeficiente de correlação múltipla entre as variáveis independentes e a variável dependente.  $R^2$  representa a parcela da variabilidade na variável dependente explicada por todas as variáveis independentes. Em nosso caso, cerca de 40% da variância no repasse de preço é explicada pelas nossas variáveis independentes. O R ajustado e o  $R^2$  ajustado são o R e o  $R^2$  após ajuste para os efeitos do número de variáveis<sup>27</sup>.

## Valor F

O valor F indica a significância global da regressão (isto é, se as variáveis independentes, tomadas em conjunto, contribuem significativamente ou não para a predição da variável dependente). Um valor F significativo, em nosso caso  $F(3, 32)$  com 99% de intervalo de confiança, é  $6,94^{28}$ . O valor F nesta regressão (7,03) é maior que o valor F dado na tabela e, portanto, a regressão global é significativa. Caso nosso valor F fosse menor necessitaríamos repensar nossa seleção de variáveis independentes.

## Tabela ANOVA (Análise de Variância)

Uma regressão simples de duas variáveis pode ser entendida como a linha de melhor ajuste entre duas variáveis plotadas em um gráfico XY. A diferença entre o valor estimado para um ponto e o valor real para este ponto (sobre a linha de melhor ajuste) é o resíduo para este ponto ou a variação não explicada. Isto é elevado ao quadrado para resolver tanto os desvios positivos quanto os negativos. A soma dos resíduos quadrados subtraído da soma total dos quadrados nos dá a parte explicada da regressão (ou aquilo que é chamado de soma dos quadrados da regressão). Você poderia também calcular a soma dos quadrados da regressão e então subtraí-la do total para obter a soma dos quadrados dos resíduos. A parte explicada dividida pela soma total dos quadrados resulta no  $R^2$ . A regressão múltipla apenas amplia a mesma idéia para um cenário de variáveis múltiplas (a linha de melhor ajuste em um espaço multidimensional).

## Coeficiente de regressão individual

Como mencionado no parágrafo anterior sobre equação de regressão, os coeficientes expressam a contribuição individual de cada variável independente para a variável dependente. A significância do coeficiente é expressa na forma de um t estatístico. O t estatístico verifica a significância das variáveis partindo do zero (isto é, nenhum efeito). No nosso caso, o t estatístico não excedeu os seguintes valores críticos<sup>28</sup> para que nenhuma variável independente fosse considerada significante:

<sup>27</sup> Reveja qualquer texto introdutório sobre estatística para uma explicação detalhada de  $R^2$ , teste F e teste t.

<sup>28</sup> Tabelas do F estatístico e do t estatístico estão disponíveis no final da maioria dos livros de estatística.

nível de significância de 99% com 32 graus de liberdade = 2,45

nível de significância de 85% com 32 graus de liberdade = 1,055

O coeficiente da distância tem um t estatístico de 2,54, o t estatístico da precipitação é 3,04 e o t estatístico de propriedade de bois é 1,41. Isso indica que as variáveis de distância e de precipitação são altamente significantes (99%) enquanto a propriedade de bois tem uma significância relativa menor (85%). O t estatístico e o F estatístico combinados são os testes mais comuns usados para estimar o sucesso relativo do modelo e para adicionar e excluir variáveis independentes de um modelo de regressão.

A saída também produz dois arquivos de valores denominados PREDICT e RESID. Eles são o modelo de regressão dos valores de repasse de preço estimados e os valores residuais. Retornaremos os resíduos ao arquivo de pontos dos mercados e faremos uma rápida análise.

- e) Execute ASSIGN a partir do menu Entrada de dados e selecione MARKETS como a imagem de definição de feições. Especifique o arquivo de valores de atributo como RESID para criar uma imagem de saída também denominada RESID. Visualize esta imagem usando a tabela de cores Idrisi 256 e use o modo de consulta do cursor para examinar os pontos. Nós criamos um arquivo vetorial com uma legenda para melhor visualização dos resíduos (item f).
3. Caso um mercado tenha apresentado um valor de 30% e outro um valor de -30% nos resíduos, o que isto significa para estes mercados em termos das variáveis independentes do modelo? Como você procederia para corrigir este problema?
- f) Visualize a composição de mapa RESIDCLS. Estes são resíduos plotados para os mercados a partir dos quais rodamos a regressão. Eles foram classificados em seis categorias para facilitar a visualização.

A análise dos resíduos identifica problemas com o modelo em certas áreas. Quatro dos seis mercados em Shewa e os dois mercados de Gonder mostram altos resíduos positivos. Isto significa que o modelo está subestimando os valores de repasse de preços para estas áreas (i.e., o valor real é maior do que o valor estimado pelo modelo). A presença de uma grande população urbana em Shewa pode contribuir para o excesso de atividades mercantis em relação ao que seria normal para qualquer outra área. A análise dos resíduos nos remete a questões interessantes, tais como “que outras variáveis poderiam influenciar tais províncias”. Por exemplo, mercados em Welo mostram altos resíduos negativos. (i.e., o repasse real dos preços é menor do que o valor estimado). Isto pode estar relacionado à insegurança devido à guerra civil, colapso do sistema de mercados durante a fome de 1984 ou outras causas ainda não estudadas. Embora nenhuma análise formal tenha sido feita nesta frente, o potencial para ampliar nossa compreensão sobre a variável dependente aumentou a partir da análise dos resíduos.

## **15. Variáveis dicotômicas e regressão logística**

Neste exercício ilustraremos o uso de regressão logística. Como discutido anteriormente, a regressão logística é aplicável quando a variável dependente é discreta e sua relação com as variáveis independentes segue uma curva logística. Para resolver a regressão logística no IDRISI for Windows, refira-se aos procedimentos documentados no sistema de ajuda on-line do módulo LOGITREG.

Este exercício explora o uso da regressão logística para analisar e prever alterações em florestas. A cidade de Westboro em Massachusetts, EUA, experimentou alterações na cobertura do solo nas últimas décadas e alterações na cobertura florestal são assunto de particular interesse. Obtivemos dados de uso do solo de Westboro de 1971, 1985 e 1991, bem como dados de cursos d'água e estradas, para analisar estas alterações. Os seguintes dados estão disponíveis para este exercício:

LU71 - Imagem de cobertura do solo em 1971  
LU85 - Imagem de cobertura do solo em 1985  
LU91 - Imagem de cobertura do solo em 1991  
WESTSMDS - Imagem de distância dos cursos d'água  
WESTRDDS - Imagem de distância das estradas  
WESTRDS - Arquivo vetorial de estradas  
WESTSTRM - Arquivo vetorial dos cursos d'água

Dois planos de dados adicionais foram criados e incluídos no conjunto inicial de dados para análise no final:

FORCHG2A - Alteração na área florestal no período 1985-1991 (excluídas alterações na água e nos banhados);  
FCAREA2A - Áreas de alteração florestal estimadas para 1991, usando 1985 como ano base.

Nosso objetivo é usar estes dados para analisar a alteração florestal bem como para prever tendências futuras. Nosso questionamento sobre os processos de alteração florestal na área revelaram que as variáveis que influenciam são as seguintes: proximidade de áreas urbanas existentes, proximidade de

estradas, distância da borda das florestas existentes e distância dos cursos d'água. Experiência anterior mostrou que quanto mais próximo estiver um local de áreas urbanas e estradas mais provável é seu desflorestamento. Experiências também mostraram o desflorestamento tende a iniciar na borda de florestas existentes e, assim, quanto mais próximo da borda de uma floresta maior a probabilidade de vir a ser desflorestado. A quarta variável, distância dos cursos d'água, parece não ter uma significância clara para a alteração florestal -- a incluímos na análise de regressão para determinar a significância desta variável.

Primeiro, faremos uma regressão logística para alteração florestal entre 1971 e 1985. Neste caso, necessitamos utilizar 1971 como ano base para criar quatro imagens de distância (as variáveis independentes) e uma imagem de probabilidade (a variável dependente).

### Criando imagens de probabilidade para a variável dependente

Como estamos examinando dois tipos de eventos (isto é, floresta permanece floresta e floresta altera para outros tipos de cobertura do solo), necessitaremos criar uma imagem de probabilidades para cada evento (Você pode usar um procedimento similar para analisar outros tipos de alteração, incluindo áreas florestas que se modificam para floresta).

Para criar uma imagem de probabilidades para o primeiro tipo de evento (floresta continua floresta), usaremos o seguinte procedimento:

- a) Visualize as imagens LU71 e LU85 com a tabela de cores Qualitativa 256, legenda e título. Use o modo de consulta do cursor sobre a área em marrom claro (floresta) em ambas as imagens -- o valor é três para ambas. Reclassifique (usando RECLASS) as imagens para FOR71 e FOR85, respectivamente, atribuindo um novo valor de 1 para os valores antigos de 3 até 4 e 0 para todos os demais valores (Observe que você também poderia usar EDIT/ASSIGN para fazer isso). Use CROSSTAB, a partir do menu Análise/Estatística, sobre as duas imagens resultantes para criar uma imagem de tabulação cruzada FOR7185. Use a tabela de cores Qualitativa 256 e uma legenda para visualizar FOR7185. Observe que nesta imagem, o valor 2 representa áreas que sofreram mudança, enquanto um valor igual a 3 representa áreas que permaneceram florestadas nesse período.
  1. Compare as imagens LU71 e FOR7185. Qual é a relação provável entre a alteração nas florestas e a distância de um local a áreas urbanas e a estradas (Nota: você poderá adicionar o arquivo vetorial WESTRDS para auxiliá-lo na resposta a esta questão).
- b) Reclassifique FOR7185 para criar duas imagens *Booleanas*: FORFOR1 (na qual áreas onde floresta mudou para outros tipos de cobertura do solo têm valor igual a 1 e o resto tem valor 0).

Agora que temos uma imagem *Booleana* para áreas onde floresta permaneceu floresta necessitamos criar a imagem de probabilidades correspondente. Note que na maioria dos casos, a probabilidade é obtida da frequência de um evento em sua amostra. Em nosso caso, entretanto, temos apenas um caso para cada *pixel* (isto é, houve alteração ou não). Assim, necessitamos usar um método alternativo para calcular a probabilidade.

Na maioria dos casos, eventos são espacialmente autocorrelacionados, significando que se um *pixel* permaneceu floresta, os *pixels* adjacentes tenderão a permanecer também floresta devido a suas condições similares. Neste caso, para cada *pixel* consideraremos seus *pixels* vizinhos como seus pontos de amostragem e calcularemos a probabilidade para esta amostra. O módulo FILTER pode ser usado para esta tarefa.

- c) Use EDIT para criar um arquivo filtro personalizado FILTER.FIL (selecione a opção "outro arquivo no diretório de dados") com os valores a seguir:



```

9
9
111111111
111111111
111111111
111111111
111111111
111111111
111111111
111111111
111111111
111111111
111111111
111111111

```

Este é um filtro de médias 9x9. Execute FILTER a partir do menu Análise/Operadores de contexto e use FORFOR1 como arquivo de entrada. Escolha a opção personalizada e especifique FILTER.FIL como o arquivo filtro. Selecione a opção Normalizar para que a soma dos valores no *kernel* do filtro totalize 1 (uma condição requerida para cálculos de probabilidade). Denomine a imagem resultante FFPROB1. Esta imagem de probabilidades usou 81 *pixels* como amostra aproximada para o *pixel* central do *kernel* do filtro. Neste caso, o tamanho da amostra é 81. Um *kernel* de filtro 9x9 foi selecionado com base no entendimento de que ele reflete variação suficiente nas áreas vizinhas de um *pixel*. Dependendo da resolução dos seus dados e do propósito de sua análise, você poderá escolher outros tipos de filtros e/ou tamanhos de filtros.

- d) Use a mesma operação FILTER (com FILTER.FIL) para criar uma imagem de probabilidades FCPROB1 a partir de FORCHG1. Valores nesta imagem resultante representam a probabilidade de um *pixel* mudar de floresta para outro tipo de cobertura do solo.
2. Visualize FFPROB1 e FCPROB1 (com a tabela de cores Idrisi 256) e compare-as, respectivamente, com FORFOR1 e FORCHG1. O que você pode dizer sobre a relação entre os dois conjuntos de imagens?

### Criando imagens para as variáveis independentes

Inicialmente criaremos uma imagem mostrando a distância à borda das áreas com floresta:

- e) Execute PATTERN, a partir do menu Análise/Operadores de contexto, em FOR71 e escolha CVV (Centro versus vizinhos) e um tamanho de janela 3x3. Denomine o resultado FORPAT71. Visualize o resultado com a tabela de cores Qualitativa 256 e ative o modo de consulta do cursor. Os valores na imagem resultante mostram o número de *pixels* que possuem valores diferentes do *pixel* central da janela móvel 3x3 na imagem FOR71. Você pode observar que apenas áreas nas bordas das florestas têm valores diferentes de zero.
- f) Execute OVERLAY (com a opção de multiplicação) com as imagens FORPAT71 e FOR71 e denomine o resultado FOREDG71. Visualize o resultado com a tabela de cores Qualitativa 256. Observe que agora apenas as bordas estreitas (ao invés de áreas largas de bordas) de áreas florestadas são mostradas.
- g) Execute DISTANCE usando FOREDG71 como a imagem de feições e denomine a imagem de saída FORDIS71 para distâncias da borda de florestas existentes.

A seguir, criaremos uma imagem mostrando distâncias de áreas urbanas.

- h) Execute RECLASS sobre a imagem LU71 para criar uma imagem *Booleana* URBAN71, na qual o valor 1 representa áreas urbanas e 0 o restante. Execute DISTANCE usando URBAN71 como a imagem de feições e denomine o resultado URBDIS71. Esta imagem representa distâncias de áreas urbanas.

Para ganhar tempo, preparamos imagens para as outras duas variáveis independentes: distância de estradas (WESTRDDS)<sup>29</sup> e distância dos cursos d'água (WESTSMDS)<sup>30</sup>.

- i) Em LOGITREG usaremos FOR71 como uma máscara para incluir apenas áreas com floresta em 1971. Para tal, execute CONVERT para converter FOR71 em uma imagem Byte/Binária (este formato é requerido pelo módulo LOGITREG). Use o mesmo nome para a imagem de saída.

Agora temos todas as quatro imagens para as variáveis independentes, bem como a imagem de probabilidades para a variável dependente, estamos prontos para executar a regressão logística.

Observe que podemos usar o resultado da regressão para fazer novas previsões em uma série temporal, se tivermos variáveis independentes para os novos períodos de tempo. Das quatro variáveis, duas modificaram suas condições entre 1985 e 1991: distância da borda das florestas e distância das áreas urbanas. Refira aos passos e) até g) para criar uma nova imagem FORDIS85 (distância da borda das florestas em 1985) e refira ao passo h) para criar uma URBDIS85 (distância das áreas urbanas em 1985). Use LU85 como a imagem base. Para as outras duas variáveis independentes, a distância das estradas e dos cursos d'água, não temos informação sobre modificações nas estradas e cursos d'água neste período de tempo. Assim, assumiremos que eles permaneceram inalterados e, portanto, usaremos as mesmas imagens de distância WESTRDDS e WESTSMDS para a nova previsão.

- j) Execute LOGITREC a partir do menu Análise/Estatística e escolha regressão entre imagens. Use FFPROB1 como a variável dependente e as imagens FORDIS71, URBDIS71, WESTRDDS e WESTSMDS como as variáveis independentes. Denomine a imagem de previsão de saída de FFPR85 e a imagem de resíduos de FFRES85. (Observe que estamos predizendo alterações nas florestas para o ano de 1985). Para o tamanho da amostra de probabilidades, indique 81 (veja o item c). Escolha FOR71 como máscara porque apenas em 1971 as áreas florestais têm pontos com dados válidos.

O nível de confiança representa sua confiança de que eventos futuros ocorrerão de acordo com a imagem de probabilidade. Observe que embora um certo evento possa ter ocorrido em um determinado local, isto não significa que a probabilidade desse evento foi de 100%. De fato, ele pode ter sido de 60% ou 80%, por exemplo. Pela forma como obtivemos a imagem de probabilidades usando o módulo FILTER, o resultado representa mudanças passadas. Mesmo que uma área não tenha tido alteração florestal no passado, isto não significa que a probabilidade de mudança seja de 0%. Do mesmo modo, para áreas que sofreram alteração, não significa que sua probabilidade é de 100%. Se você estabelecesse uma confiança de 100%, você excluiria áreas que não experimentaram um evento destes no passado de terem esta possibilidade no futuro. Para contemplar a incerteza de eventos futuros, sugerimos que você estabeleça um nível de confiança menor do que 1,0. Neste exercício, usaremos um nível de confiança de 0,8 (representando uma probabilidade de que 80% dos eventos futuros seguirão exatamente o mesmo padrão do passado).

Opte por produzir uma nova previsão com as variáveis independentes seguintes FORDIS85, URBDIS85, WESTRDDS e WESTSMDS e denomine a nova imagem de previsão de NFFPR91.

Após o final da execução do módulo devemos ter a probabilidade de previsão de floresta permanecer floresta para 1985 e 1991. LOGITREG também produz uma tabela sumário após a regressão ter sido executada.

---

<sup>29</sup> Esta imagem foi criada com o módulo DISTANCE usando um arquivo vetorial de estradas rasterizado (WESTRDS) como a imagem de feições.

<sup>30</sup> Esta imagem foi criada com o módulo DISTANCE usando um arquivo vetorial de cursos d'água rasterizado (WESTSTRM) como a imagem de feições.

## Resultados da regressão múltipla:

Equação da Regressão:

$$\text{Logit(ffprob1)} = 1,969488 + 0,000808 * \text{fordis71} - 0,0000192 * \text{urbdis71} + 0,0001973 * \text{westrdds} - 0,0000464 * \text{westsmds}$$

Estatística da regressão:

$$\begin{aligned} R \text{ aparente} &= 0,247129 & R^2 \text{ aparente} &= 0,061073 \\ R \text{ ajustado} &= 0,247023 & R^2 \text{ ajustado} &= 0,061020 \\ F(4, 53727) &= 873,671509 \end{aligned}$$

## Coeficientes de regressão individuais

	Coefficiente	Teste t (53727)
Intercepto	1,969488	53,610519
fordis71	0,000808	46,878914
urbdis71	-0,000019	-11,629278
westrdds	0,000197	21,779564
westsmds	-0,000046	-18,343569

Estes resultados correspondem à regressão linear transformada. Como é usado um método de mínimos quadrados ponderados para estimar os parâmetros, o uso de  $R^2$  como uma medida de bondade do ajuste para a regressão logística é questionável. Entretanto, um valor alto de  $R^2$  geralmente indica uma predição melhor do que um valor baixo. Da mesma forma, o teste t para cada variável independente também é questionável e deveria ser usado apenas para comparação entre variáveis. Como a probabilidade é transformada e as observações ponderadas, os coeficientes dos parâmetros (positivos ou negativos) na equação não são indicadores de uma relação positiva ou negativa entre a probabilidade e as variáveis independentes.

Quando fazemos uma regressão de imagens, necessitamos lembrar que existe uma autocorrelação espacial entre *pixels* vizinhos. Em alguns casos poderemos estar tratando com dados interpolados, onde a autocorrelação espacial é inerente. Portanto, um tamanho de amostra válido é desconhecido. Por isso usamos R “aparente” e graus de liberdade “aparentes”.

- k) Execute LOGITREG novamente, mas desta vez use FCPR01 como variável dependente e as mesmas variáveis independentes usadas no passo j) para produzir FCPR85 e FCRES85 como imagens de predição e de resíduos. Adicionalmente, escolha por produzir uma nova predição usando as mesmas variáveis independentes para a nova predição (como no passo j) e denomine a nova imagem de predição NFCPR91.

Sua tabela sumário deveria se parecer com esta:

## Resultados da regressão múltipla:

Equação da regressão:

$$\text{Logit(fcprob)} = -6,274255 + 0,000969 * \text{fordis71} + 0,0000342 * \text{urbdis71} - 0,0000383 * \text{westrdds} - 0,0000934 * \text{westsmds}$$

Estatística da regressão:

$$\begin{aligned} R \text{ aparente} &= 0,379565 & R^2 \text{ aparente} &= 0,144069 \\ R \text{ ajustado} &= 0,379502 & R^2 \text{ ajustado} &= 0,144021 \\ F(4, 53727) &= 2260,817139 \end{aligned}$$

Coefficientes de regressão individuais

	Coefficiente	Teste t (53727)
Intercepto	-6,274255	-235,652649
fordis71	0,000969	70,522499
urbdis71	0,000034	21,524868
westrdds	-0,000038	-4,308343
westsmds	0,000093	41,376640

Você tem agora a probabilidade de predição de que florestas mudaram para outros tipos de cobertura do solo para 1985 e 1991.

- Baseado nos resultados da regressão dos passos j) e k), a distância dos cursos d'água é uma variável significativa se comparada com as outras três variáveis? Por que ou por que não? (Observação: para comparação visual, você pode adicionar o arquivo vetorial WESTSTRM a uma imagem produzida a partir de CROSSTAB sobre áreas com florestas em 1985 e áreas com florestas em 1991).

Observe que as probabilidade para os dois eventos acima (isto é, floresta permanece floresta e floresta mudou) devem somar 1. Portanto, necessitamos padronizar os resultados para 1985 e 1991 de modo que eles preencham esta condição.

- Ative a Calculadora para imagens na barra de ícones e execute as seguintes equações:

$$\begin{aligned} [\text{SUMPR85}] &= [\text{FFPR85}] + [\text{FCPR85}] \\ [\text{FFPRST85}] &= [\text{FFPR85}] / [\text{SUMPR85}] * [\text{FOR71}] \\ [\text{FCPRST85}] &= [\text{FCPR85}] / [\text{SUMPR85}] * [\text{FOR71}] \end{aligned}$$

Observe que você necessita multiplicar FOR71 pela razão de cada probabilidade à soma, de modo que apenas áreas que foram floresta em 1971 sejam consideradas para análise posterior.

Realize a mesma operação para as novas imagens (NFFPR91 e NFCPR91) para produzir as probabilidades padronizadas NFPRST91 e NCPRST91. Certifique-se de usar FOR85 para definir as áreas florestadas.

- Visualize FCPRST85 e compare as duas imagens. Onde você encontrou a maior inconsistência entre as duas imagens? Qual foi a transformação na cobertura do solo para esta área? Por que há inconsistência?

Observe que na área em torno da coluna 110 e linha 210, foi calculada uma alta probabilidade de alteração da área florestal em FCPRST85 e na realidade toda a área alterou de floresta para outra classe. Na imagem de predição FCPRST85, entretanto, esta área tem uma baixa probabilidade de alteração. Comparando as imagens LU71 e LU85 você verá que esta área mudou de floresta para água. Trabalhos de campo nos mostraram que uma barragem foi construída nesta área, criando assim a alteração. Esta alteração não foi parte do processo normal de desflorestamento e as razões do processo também não representam condições normais de alteração florestal. Interessante é que os resultados da regressão logística detectaram esta diferença!

- Execute CROSSTAB sobre LU71 e LU85 para produzir uma imagem denominada LU7185. Visualize LU7185 com a tabela de cores Quantitativa 256, legenda e título. Investigue que tipos de alteração ocorreram na floresta. Especificamente, determine que tipo de alteração, diferente da conversão floresta-água e alterações induzidas pelo homem ocorreram. Isto nos leva à classe 15 (floresta mudou para banhado). Esta mudança foi causada basicamente pela modificação nas condições do regime de água do que pelas atividades humanas prolongadas.

Se eliminarmos as duas alterações anteriores (floresta mudou para água e para banhado), todas as demais alterações foram causadas pela invasão de atividades humanas sobre áreas com floresta.

- n) Produza uma imagem *Booleana* FORCHG1A a partir de LU7185 de modo que áreas com invasão de atividades humanas relativas a alterações nas florestas tenham um valor de 1 e o restante um valor de 0. Em LU7185 estas categorias são: 6, 10, 18, 22, 29, 38, 49, 53 e 61. Use EDIT para criar um arquivo de valores que atribua o valor de 1 a estas categorias. A seguir execute ASSIGN para criar FORCHG1A. Execute então AREA sobre FORCHG1A para encontrar o número total de *pixels* que tiveram esta alteração. Deveriam ser 4201 (ao invés de um total de alteração nas florestas de 6630).
- o) Baseado nas probabilidades estimadas de FCPRST85, crie uma imagem FCAREA1 para incluir 4201 *pixels* com a maior probabilidade de alteração florestal. Para tal, você necessita primeiro executar um STRETCH linear em FCPRST85 para acomodar os valores no intervalo de 0 a 255. A seguir execute RANK (classificação descendente) sobre a imagem resultante e finalmente use RECLASS para selecionar os primeiros 4201 *pixels*.
5. Compare FCAREA1 com FORCHG1A usando CROSSTAB (opte por criar uma imagem de classificação cruzada e tabulação cruzada e selecione Imprimir índice Kappa de concordância dos valores por categoria. Denomine a imagem resultante de CROSS. Qual é a concordância entre as modificações nas florestas previstas e as mudanças reais? (Você pode julgar isto pelo índice Kappa de concordância para a categoria 1, usando FORCHG1A como referência.)
6. Visualize CROSS usando a tabela de cores Qualitativa 256. Examine áreas de grande inconsistência (por exemplo, áreas em torno da coluna 130 e linha 120, ou coluna 150 e linha 245) e verifique por que existem inconsistências.
- p) Refira aos passos n) e o) para criar NFCAREA que contém áreas estimadas de alteração florestal a partir das novas previsões NFCPR91. (Sugestão: o número total de *pixels* que mudaram deveria ser 3906.) Use CROSSTAB para comparar este resultado com FORCHG2A (alterações nas florestas durante 1985-1991, excluindo alterações para água e banhados) que já foi criada para você.
7. A mesma regressão logística de 1971-1985 é válida para o período de 1985 a 1991? (Isto pode ser analisado olhando-se o índice Kappa de concordância para a categoria alteração florestal.)

Como alternativa para as probabilidades previstas para 1991, você pode usar dados de 1985 para executar duas outras regressões logísticas, respectivamente com a probabilidade de alteração florestal e com a probabilidade de floresta permanecer floresta como a variável dependente. Para tal, você necessitará repetir os passos a) até k), usando dados de 1985 e 1991. Observe que neste caso, 1985 é o ano base. Use as mesmas quatro variáveis independentes: distância da borda das áreas florestadas, distância das estradas, distância dos cursos d'água e distância das áreas urbanas. Observe que a distância da borda das áreas florestadas e a distância das áreas urbanas são diferentes em 1985 e em 1971 e, portanto, você necessita criar novas imagens FORDIS85 e URBDIS85. Como não temos novos dados para estradas e cursos d'água, assumiremos que a distância às estradas e a distância aos cursos d'água não alteraram e usaremos as mesmas imagens WESTRDDS e WESTSMDS. Use o mesmo nível de confiança (80%).

Se desejar pular estes passos e olhar os resultados, visualize FCAREA2 (a alteração florestal estimada, baseada nestas regressões) e FORCHG2A (alterações reais entre 1985-1991, excluindo alterações por água e banhados), as quais estão incluídas neste conjunto de dados.

8. Compare FORCHG2A usando CROSSTAB. Qual é a acurácia desta predição? Compare ela com a predição anterior, baseada nas alterações de 1971 a 1985. Qual delas é a melhor predição para alterações florestais em 1991? Por que?