

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA**

TESE DE DOUTORADO

**INTRODUÇÃO DE DADOS AUXILIARES NA CLASSIFICAÇÃO
DE IMAGENS DIGITAIS DE SENSORIAMENTO REMOTO
APLICANDO CONCEITOS DA TEORIA DA EVIDÊNCIA**

RODRIGO PEREIRA LERSCH

ORIENTADOR: PROF. VITOR HAERTEL, PhD.

PORTO ALEGRE, OUTUBRO DE 2008

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA**

**INTRODUÇÃO DE DADOS AUXILIARES NA CLASSIFICAÇÃO
DE IMAGENS DIGITAIS DE SENSORIAMENTO REMOTO
APLICANDO CONCEITOS DA TEORIA DA EVIDÊNCIA**

RODRIGO PEREIRA LERSCH

Orientador: Prof. Vitor Haertel, PhD.

Banca Examinadora:

Profa. Dra. Evlyn Moraes Novo (INPE)
Prof. Dr. Carlos Hartmann (FURG)
Profa. Dra. Nina Simone Fujimoto (UFRGS)
Prof. Dr. Sérgio Florêncio de Souza (UFRGS)

Tese apresentada ao
Programa de Pós-graduação
em Geografia como requisito
para obtenção do título de
Doutor em Geografia.

PORTO ALEGRE, OUTUBRO DE 2008

Lersch, Rodrigo Pereira

Introdução de dados auxiliares na classificação de imagens digitais de sensoriamento remoto aplicando conceitos da Teoria da Evidência. / Rodrigo Pereira Lersch. - Porto Alegre : IGEO/UFRGS, 2008.

[80] f. : il.

Tese (Doutorado) - Universidade Federal do Rio Grande do Sul. Instituto de Geociências. Programa de Pós-Graduação em Geografia, Porto Alegre, RS - BR, 2008.

1. Sensoriamento remoto. 2. Classificação de imagens. 3. Dados auxiliares. 4. Teoria da Evidência. 5. Fusão de informações. I. Título.

Catálogo na Publicação
Biblioteca Geociências - UFRGS
Luciane Scoto da Silva CRB 10/1833

AGRADECIMENTOS

Como este estudo possui enfoque principalmente teórico não houve interação com muitas pessoas, além das que estiveram diretamente ligadas ao mesmo. Apenas foram feitas algumas consultas (sem muito êxito) a pessoas e empresas (externas a Universidade) para auxílio, no que tange a imagens digitais de alta resolução. Por este motivo contribuições e ajudas referentes ao desenvolvimento desta tese foram mais ligadas às instituições (desta forma se agradece as pessoas que fazem parte destas instituições e principalmente para aquelas que tiveram influência mais direta para realização e desenvolvimento desta tese). Quanto às pessoas ligadas diretamente a esta pesquisa o principal agradecimento é direcionado:

Ao orientador, professor **Vitor Haertel**, PhD. pelo grande dedicação, capacidade acadêmica e auxílio durante todas as etapas da elaboração desta tese; além da minha aceitação como orientando em mais esta etapa (além do mestrado acadêmico).

Ao professor **Yosio Shimabukuro**, PhD. do Instituto Nacional de Pesquisas Espaciais (INPE), pela grande contribuição na apresentação desta pesquisa em eventos internacionais.

Quanto às instituições agradeço, principalmente:

Ao **Programa de Pós-graduação em Geografia (PPGGEA)**, pela minha aceitação e por toda liberdade dada, por parte deste programa de pós-graduação no desenvolvimento desta pesquisa e até mesmo na possibilidade de cursar disciplinas externas.

Ao **Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPSRM)**, por ceder o espaço físico e parte do equipamento utilizado nesta pesquisa, além da maioria do *Software* e dos materiais necessários (como imagens digitais, cartas e outros).

A **Coordenação de Aperfeiçoamento de Pessoas de Nível Superior (CAPES)** pelo fornecimento e manutenção da bolsa de estudos durante todo o período de elaboração desta tese, auxílio este que sem o qual tornaria completamente inviável a conclusão desta última etapa acadêmica.

Por fim (e não menos importante) à **Universidade Federal do Rio Grande do Sul (UFRGS)** pelo longo período de acolhimento possibilitando toda a estrutura e os meios para a realização de todas as fases acadêmicas, que assim como as agências de fomento a pesquisa (na fase de pós-graduação) possibilitaram a realização deste aperfeiçoamento profissional que seria impossível se realizado em outras condições que não a de uma Universidade pública. Desde o meu ingresso nesta Universidade muitos caminhos foram alterados e desviados (como o abandono de um curso de licenciatura faltando duas disciplinas para a conclusão) devido, principalmente, a alguns poucos indivíduos e não a esta Universidade, que é bem maior que pequenas mediocridades individuais. A intenção desde o meu ingresso era a formação em Física (bacharelado), visando uma possibilidade remota de um mestrado em Astronomia, chegando nesta fase me considero absolvido e só me resta agradecer a esta Universidade e dizer adeus após um longo convívio, e para mim a luta continua...

Introdução de Dados Auxiliares na Classificação de Imagens Digitais de Sensoriamento Remoto, Aplicando Conceitos da Teoria da Evidência¹

AUTOR: Rodrigo Pereira Lersch
ORIENTADOR: Vitor F. A. Haertel

RESUMO

Nesta tese investiga-se uma nova abordagem visando implementar os conceitos propostos na Teoria da Evidencia para fins de classificação de imagens digitais em Sensoriamento Remoto. Propõe-se aqui a utilização de variáveis auxiliares, estruturadas na forma de Planos de Informação (P.I.s) como em um SIG para gerar dados de confiança e de plausibilidade. São então aplicados limiares aos dados de confiança e de plausibilidade, com a finalidade de detectar erros de inclusão e de omissão, respectivamente, na imagem temática. Propõe-se nesta tese que estes dois limiares sejam estimados em função das acurácias do usuário e do produtor. A metodologia proposta nesta tese foi testada em uma área teste, coberta pela classe *Mata Nativa com Araucária*. O experimento mostrou que a metodologia aqui proposta atinge seus objetivos.

Palavras Chave: Sensoriamento Remoto, Classificação de Imagens, Dados Auxiliares, Teoria da Evidência, Fusão de Informações.

¹Tese de Doutorado em Geografia, Programa de Pós-Graduação em Geografia da Universidade Federal do Rio Grande do Sul, Porto Alegre novembro de 2008.

ABSTRACT

In this thesis we investigate a new approach to implement concepts developed by the Theory of Evidence to Remote Sensing digital image classification. In the proposed approach auxiliary variables are structured as layers in a GIS-like format to produce layers of belief and plausibility. Thresholds are applied to the layers of belief and plausibility to detect errors of commission and omission, respectively on the thematic image. The thresholds are estimated as functions of the user's and producer's accuracy. Preliminary tests were performed over an area covered by *natural forest with Araucaria*, showing some promising results.

Keywords: Remote Sensing, Image Classification, Auxiliary Data, Theory of Evidence, Merging of Information.

SÚMARIO

1 INTRODUÇÃO	07
2 REVISÃO BIBLIOGRÁFICA	09
3 METODOLOGIA	14
3.1 INTRODUÇÃO	14
3.2 A TEORIA DA EVIDÊNCIA	14
3.3 IMPLEMENTAÇÃO DOS CONCEITOS PROPOSTOS PELA TEORIA DA DA EVIDÊNCIA	19
3.3.1 Seleção e Organização das Variáveis Auxiliares	19
3.3.2 Estimação dos Valores para Incerteza Associados a cada Variável	20
3.3.3 Estimação das Evidências Associadas a Cada Pixel e a C/ Classe	21
3.3.4 Geração dos P.I.S de Confiança e Plausibilidade	24
3.4 PROPOSTA DE UTILIZAÇÃO DAS VARIÁVEIS CONFIANÇA E PLAUSIBILIDADE NA DETECÇÃO DE ERROS DE OMISSÃO E DE INCLUSÃO NA IMAGEM TEMÁTICA PRODUZIDA POR UM CLASSIFICADOR	25
4 EXPERIMENTOS	30
4.1 INTRODUÇÃO	30
4.2 FLORESTA OMBRÔFILA MISTA ALTO MONTANA OU MATA NATIVA COM ARAUCÁRIA	31
4.2.1 A <i>Araucaria angustifolia</i>	31
4.2.1.1 Distribuição	32
4.2.1.2 Meio Físico	34
4.3 ÁREA DE ESTUDO	36
4.4 MATERIAL UTILIZADO	37
4.5 ELABORAÇÃO DE P.I.S PARA VARIÁVEIS AUXILIARES	38
4.5.1 Temperatura Média Anual	39
4.5.2 Precipitação Média Anual	40

4.5.3	Altitude do Terreno	41
4.5.4	Classes de Solo	41
4.5.5	Probabilidade de Ocorrência de Mata Nativa com Araucária	41
4.5.6	Índice de Vegetação (NDVI)	43
4.5.7	Imagens de Fração de Vegetação e de Sombra	44
4.5.8	Textura da Imagem	45
4.6	AMOSTRAS DE TREINAMENTO: AVALIAÇÃO DA NORMALIDADE DAS CLASSES E VARIÁVEIS	50
4.7	ESTIMAÇÃO DO PODER DISCRIMINANTE DAS VARIÁVEIS AUX.	51
4.8	ESTIMAÇÃO DAS EVIDÊNCIAS E INTRODUÇÃO DAS INCERTEZAS	53
4.8.1	Variáveis Normalmente Distribuídas	56
4.8.2	Variáveis Não-Normalmente Distribuídas	57
4.9	GERAÇÃO DOS DADOS DE CONFIANÇA E PLAUSIBILIDADE	59
4.10	UTILIZAÇÃO DE DADOS DE CONFIANÇA E PLAUSIBILIDADE NA DETECÇÃO DE ERROS DE OMISSÃO E DE INCLUSÃO	59
5	CONCLUSÕES	65
	REFERÊNCIAS BIBLIOGRÁFICAS	67
	ANEXO I – Experimento Adicional	72
	ANEXO II – Programas Elaborados em MATLAB para esta Pesquisa	75

LISTA DE FIGURAS

FIGURA 1 – Possíveis Níveis de Informação Disponíveis	15
FIGURA 2 – Construção da Massa de Evidência e Introdução da Incerteza	22
FIGURA 3 – Exemplo do Algoritmo Soma Ortogonal	23
FIGURA 4 – Ex. de um Comp. padrão p/ Acurácias do Usuar., Prod. e Méd.	26
FIGURA 5 – Fluxograma da Metodologia	29
FIGURA 6 – Distribuição Natural da <i>Araucaria angustifolia</i> em 1953 e 1969	33
FIGURA 7 – Localização da Área de Estudo	37
FIGURA 8 – Forma Geral da Matriz de Co-Ocorrência	46
FIGURA 9 – Normalidade dos Histogramas p/ as Classes.....	51
FIGURA 10 – Funções de Pertinência	55
FIGURA 11 – Áreas de Treinamento e de Teste	61
FIGURA 12 – Pseudo Código	62
FIGURA 13 – Acurácias Obtidas na Área de Treinamento	63
FIGURA 14 – Resultado da Filtragem	64
FIGURA 15 – Evolução das Acurácias	73

LISTA DE TABELAS

TABELA 1 – Resultados do MVG e Dist. Euclidiana	52
TABELA 2 – Acurácias	63
TABELA 3 – Acurácias por Etapas.....	73

1 INTRODUÇÃO

Imagens digitais multiespectrais obtidas por sistemas sensores orbitais e, em menor escala, aéreo-transportados apresentam um grande potencial de contribuição para a análise ambiental. Especialmente em um país de dimensões continentais como o Brasil, com áreas extensas e muitas vezes de difícil acesso, técnicas de Sensoriamento Remoto são de grande valia, e vem sendo amplamente utilizados no monitoramento do território nacional. Ao longo das últimas décadas, um esforço continuado vem sendo feito pelo Governo Federal no sentido de disponibilizar dados de Sensoriamento Remoto às várias instituições nacionais, objetivando desenvolver e capacitar o país na utilização destas novas tecnologias.

Neste contexto, métodos para processamento e classificação de imagens digitais de Sensoriamento Remoto vem se constituindo em um tópico de grande importância, tendo como objetivo permitir um crescente aproveitamento de dados de Sensoriamento Remoto.

O estudo desenvolvido nesta tese insere-se neste contexto, objetivando a integração conjunta de técnicas de Sensoriamento Remoto e Sistemas de Informações Geográficas (SIG) para a análise da cobertura do solo.

No processo de classificação de imagens digitais em Sensoriamento Remoto, estão frequentemente presentes fatores diversos que contribuem para reduzir a acurácia (precisão) da imagem temática. Entre os fatores que mais frequentemente ocorrem pode-se mencionar a existência de uma similaridade espectral alta entre as classes consideradas, a não normalidade na distribuição dos dados nas classes em estudo, quando utilizando classificadores que pressupõe a distribuição normal, a não uniformidade na irradiação solar ao longo da área de estudo, causada pelo relevo do terreno, além de outros. Métodos visando minimizar estes problemas vem sendo objeto de investigação por vários autores.

A pesquisa desenvolvida aqui teve como objetivo investigar novas metodologias, visando incrementar a acurácia em imagens temáticas produzidas por classificadores paramétricos a partir de imagens digitais multiespectrais. Com este objetivo investigou-se uma nova metodologia visando à incorporação de dados auxiliares oriundos de fontes diversas ao processo de classificação de imagens multiespectrais.

A utilização conjunta de dados de fontes e naturezas diversas, incluindo aí variáveis numéricas juntamente com variáveis categóricas, constitui-se em um desafio. Nesta tese

foram utilizados conceitos propostos originalmente na Teoria da Evidência proposta por Dempster Shafer em 1976. Os conceitos desenvolvidos na Teoria da Evidência proporcionam uma ferramenta matemática que possibilita a fusão de informações originadas a partir de variáveis de natureza diversas, tanto quantitativas quanto qualitativas permitindo a utilização conjunta das informações fornecidas por estas variáveis. Uma vantagem adicional propiciada pela Teoria da Evidência consiste na introdução do conceito de incerteza (ou ignorância) no processo de extração de informações a partir de variáveis auxiliares, o que permite uma abordagem mais realista no processo de extração de informações. Na proposta desenvolvida nesta atual pesquisa, os conceitos de confiança (*belief*) e de plausibilidade (*plausibility*) são utilizados na detecção de erros de inclusão e de omissão na imagem temática produzida a partir de dados multiespectrais. Aqui ainda é proposta uma abordagem quantitativa para utilização das variáveis que expressam confiança e plausibilidade no processo de filtragem de possíveis erros na imagem temática.

Mais sucintamente se pode resumir o objetivo desta pesquisa dizendo que se pretende gerar uma metodologia para aumentar a acurácia de um processo de classificação digital, utilizando-se de dados auxiliares. Os dados auxiliares são por sua vez introduzidos com a utilização dos conceitos contidos na Teoria da Evidência

A utilização prática da metodologia proposta neste trabalho é ilustrada por meio de um experimento utilizando uma área teste localizada na região nordeste do Estado do Rio Grande do Sul. Além de dados multiespectrais coletados pelo sistema Landsat-TM, foram coletados dados adicionais, para serem utilizados como variáveis auxiliares. Estes dados incluem altitude do terreno, temperatura média anual, precipitação média anual, classes de solos, imagens de fração, índices de vegetação e dados de textura da imagem. Os resultados obtidos neste experimento servem para ilustrar o potencial da metodologia proposta.

O *software* necessário para o desenvolvimento deste experimento foi desenvolvido em MATLAB e encontra-se no Anexo II.

A pesquisa está organizada da seguinte forma. No Capítulo 2 é feita uma revisão de propostas desenvolvidas por outros pesquisadores neste tópico. No Capítulo 3 é apresentada em detalhes a metodologia proposta nesta tese. Um experimento desenvolvido com a finalidade de ilustrar e testar a metodologia proposta é apresentado no Capítulo 4. Finalmente, no Capítulo 5 são discutidas as principais conclusões que resultam deste trabalho.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo, é feita uma relação das diferentes abordagens propostas por vários autores, visando a introdução de variáveis auxiliares no processo de classificação de imagens digitais. O uso de variáveis auxiliares com o objetivo de incrementar a acurácia em imagens temáticas produzidas por classificadores diversos vem sendo investigado por autores diversos, conforme reportado na literatura.

Uma descrição bastante completa das possíveis abordagens visando incrementar a acurácia em imagens temáticas pode ser encontrada em Hutchinson (1982). Em seu trabalho, aquele autor investigou três possíveis abordagens gerais: (1) métodos pré-classificação, como a estratificação da cena a ser classificada, (2) métodos pós-classificação, nos quais processamentos adicionais são aplicados à imagem temática produzida pelo classificador e (3) métodos implementando etapas adicionais durante o próprio processo de classificação, como por exemplo, a atualização das probabilidades *a priori*. Outra possível abordagem foi proposta por Strahler (1980). Em sua proposta aquele autor examina pixels rotulados em classes espectralmente muito semelhantes e, portanto suscetíveis à confusão. Estes pixels são então re-classificados na classe mais provável com base em dados extraídos de variáveis auxiliares, como por exemplo, altitude do terreno, declividade e aspecto. A regra de decisão nestes casos são usualmente de natureza determinística. Este direcionamento envolve o uso de múltiplas fontes de dados, algumas vezes incluindo dados de natureza qualitativa, isto é, variáveis que originalmente não se encontram em forma numérica.

Na literatura são reportadas outras propostas visando à utilização das informações geradas por estes dados adicionais. Uma abordagem que vem demonstrando um bom potencial é aquela que emprega conceitos originalmente desenvolvidos pela Teoria da Evidência, proposta por Dempster e Shafer (Richards e Jia, 1999). A seguir são analisadas algumas das propostas mais relevantes.

O uso dos conceitos de confiança (*belief*) e plausibilidade (*plausibility*) desenvolvidas na Teoria da Evidência, originalmente propostos por Dempster e Shafer (Richards e Jia, 1999), foi investigada por Lee *et al.* (1987), com o objetivo de combinar dados originados de múltiplas fontes, adicionando-se uma ampla revisão dos conceitos básicos desta teoria, os autores exploraram os métodos estatísticos e evidências combinadas com fontes múltiplas de dados orbitais de Sensoriamento Remoto e dados gerais de origem espacial. Eles testaram ambos métodos, utilizando-se de dados do sensor MSS Landsat, com as bandas referentes ao

visível e infravermelho tratadas como duas fontes de dados distintas. Os resultados mostram que os métodos estatísticos apresentaram melhor resultado que os métodos empregando as técnicas da Teoria da Evidência. Note-se, contudo, que os dados utilizados neste experimento podem ser razoavelmente modelados por uma distribuição Gaussiana multivariada. Isto acaba por não aproveitar uma das melhores vantagens do método baseado nas evidências, isto é, que em realidade não necessita estar baseado neste tipo de distribuição.

Moon (1990) investigou a introdução do conceito de confiança conforme proposto pela Teoria da Evidência para integrar dados geofísicos e geológicos. Alguns anos depois, nesta mesma linha, Gong (1996) empregou também os conceitos de confiança e plausibilidade para integrar dados de várias fontes no processo de mapeamento geológico de uma determinada região.

Qian *et al.* (1990) utilizaram um sistema especialista denominado *Drainage Network Extraction System* (DNESYS), este sistema é destinada para determinação de redes de drenagem e bacias hidrográficas utilizando-se de uma base topográfica (MNT). Os autores combinaram este sistema a Teoria da Evidência, utilizando os conceitos de evidência e incerteza (desta teoria) em oposição à base de “inteligência” do sistema DNESYS. Esta combinação possibilitou a correção de informações errôneas e a introdução de informação perdida.

Kim e Swain (1995) relatam uma aplicação dos conceitos de evidência e confiança à classificação de dados obtidos pelo sistema HIRIS (*High Resolution Imaging Spectrometer*). As 201 bandas espectrais são divididas em sub-grupos, gerando desta forma múltiplas fontes de informação. Os conceitos de confiança e plausibilidade são então aplicados a cada uma destas fontes, para auxiliar no processo de classificação.

Um direcionamento um pouco distinto ao aplicado nesta pesquisa pode ser visto no estudo desenvolvido por Hégarat-Masclé *et al.* (1997). Estes autores utilizaram conceitos da Teoria da Evidência para melhorar a acurácia nos processos de classificação não-supervisionada. Naquele estudo, as fronteiras entre classes são tratadas como regiões de incerteza e os conceitos de confiança e plausibilidade são utilizados para decidir qual o rótulo mais adequado a ser aplicado a cada pixel situado nestas regiões. Naquele estudo, os dados de evidência que são normalmente estimados de uma forma supervisionada, isto é, para classes previamente definidas pelo analista, aqui são estimadas com base em *clusters*, dentro de um processo interativo.

A utilização de variáveis auxiliares tais como: altitude do terreno, declividade, aspecto e textura da imagem foi investigada por Bruzzone *et al.* (1997) com o objetivo de incrementar

a acurácia da imagem temática, empregando dados Landsat-TM em classificadores paramétricos e não paramétricos.

Ahmadzadeh e Petrou (2001), investigaram a implementação dos conceitos da Teoria da Evidência como parte integrante de um sistema especialista avaliação do risco de “desertificação” provocado por queimadas. Os conceitos de confiança e incerteza são implementados no sistema especialista para tomada de decisão.

Hégarat-Masclé, *et al.* (2002), em um estudo propõem o emprego da Teoria da Evidência, visando a utilização combinada de dados em diferentes escalas (multi-escala). No estudo, os autores, utilizaram dados NOAA/AVRR combinados a dados provenientes do sensor SPOT/HRV.

Em seu trabalho Briem *et al.* (2002) investigaram métodos combinando dados de sensoriamento remoto com dados geográficos no processo de classificação da cobertura do solo. Um outro estudo combinando dados de diversas fontes pode ser encontrado em Benediktsson e Sveinsson (2003). Em seu estudo aqueles autores investigaram diversos métodos de fusão de dados visando o uso combinado de dados de origens diversas. Métodos para corrigir variações na irradiância solar devido ao efeito do relevo do terreno, foi estudado por Zukowskyj (2003).

Encontra-se na literatura, também, propostas de combinação da Teoria da Evidência com os sistemas de redes neurais, como proposto por Jianjun Ni *et al* (2004). Os autores apresentam um novo método integrando os modelos de redes neurais múltiplas com a Teoria da Evidência (para fins de fusão de informações), com finalidade de melhorar o desempenho no reconhecimento de padrões contidos em imagens digitais. O experimento mostrou que a introdução de conceitos propostos pela Teoria da Evidência contribuiu para melhorar os resultados produzidos por classificações empregando sistemas de redes neurais múltiplas.

Uma nova abordagem visando o uso do conceito de evidência no processo de classificação de imagens digitais em sensoriamento remoto foi proposto por Zhu e Basir (2005). Em seu estudo os dois autores investigaram o uso dos conceitos originados da teoria da evidência juntamente com o classificador K-vizinhos mais próximos. Na abordagem proposta por aqueles autores, cada um dos K-vizinhos mais próximos é utilizado para estimar o grau de evidência relativo à pertinência de um pixel genérico às classes em consideração. Os autores testaram a sua metodologia utilizando imagens multiespectrais de Sensoriamento Remoto, obtendo resultados que mostram a adequação da metodologia proposta.

Uma nova abordagem para fins de classificação de classes de cobertura do solo utilizando dados multiespectrais foi proposta por Laha *et al.* (2007). Em seu trabalho, aqueles

autores propuseram e testaram uma metodologia, aplicando técnicas da lógica *fuzzy* em um classificador em estágio múltiplo. Na proposta dos autores, informação de vizinhança (contexto) é adicionada à informação espectral para fins de incrementar a acurácia da imagem temática produzida pelo classificador. Neste particular, os eles propõe, entre outras abordagens, o emprego de técnicas da Teoria da Evidência.

Um novo estudo é proposto utilizando os conceitos da Teoria da Evidência por Richards e Jia (2007). Naquele estudo, os autores propõe uma nova abordagem visando a utilização de informações de contexto (vizinhança) no processo de classificação. Os autores fazem uso de um processo iterativo de relaxação, no qual o valor estimado para incerteza conforme definido na Teoria da Evidência, é utilizado para ajustar o número adequado de iterações.

Com um enfoque muito semelhante ao utilizado nesta tese Momani *et al.* (2007) empregam a Teoria da Evidência para aumentar a precisão de um processo de classificação semi-supervisionado (SSC). No referido trabalho os autores utilizam-se de dados de contexto, que por sua vez são fundidos ao produto do processo de classificação semi-supervisionada. O dado de contexto utilizado naquele estudo restringiu-se a dados de elevação do terreno (MNT), que também foi utilizado nesta tese. Os mesmos autores sugeriram estender esta abordagem, com a inclusão de outras variáveis auxiliares, como por exemplo, classes de solos.

Bouakache *et al.* (2008) empregam os conceitos propostos na Teoria da Evidência para fins de fusão de imagens adquiridas por sensores diversos. O problema da fusão de imagens, de grande aplicação em sensoriamento remoto, constitui-se em mais uma área que pode se beneficiar dos conceitos propostos na Teoria da Evidência.

Nesta tese é proposta uma nova abordagem para a questão da utilização das informações extraídas de variáveis auxiliares no processo de imagens digitais em sensoriamento remoto, utilizando os conceitos estabelecidos na Teoria da Evidência. Na metodologia aqui proposta, variáveis auxiliares originadas de fontes diversas são organizadas na forma de planos de informação (P.I.s) em uma estrutura semelhante à utilizada em SIGs. Neste processo, cada uma das variáveis auxiliares é tratada independentemente das demais, e as contribuições individuais de cada uma são posteriormente combinadas na avaliação do rótulo atribuído a cada pixel na imagem temática. Nesta metodologia inicia-se pela estimação do grau de evidência fornecido por cada uma das variáveis auxiliares selecionadas. Esta evidência serve para estimar o grau de pertinência de cada pixel na imagem a cada uma das

classes em consideração. Neste processo, o déficit de evidência ou de confiança na informação fornecida pela variável em questão é quantificado sob a denominação de *incerteza*. No contexto desta pesquisa, a incerteza é estimada pelo complemento da acurácia do usuário na imagem temática produzida utilizando-se somente da variável em consideração, conforme proposta original de Lee *et al.* (1987).

3 METODOLOGIA

3.1 INTRODUÇÃO

Neste capítulo é apresentada a metodologia proposta nesta tese, visando à introdução de dados auxiliares no processo de classificação de imagens digitais em sensoriamento remoto. A contribuição para esta área de conhecimento proposta nesta pesquisa é descrita em detalhes neste capítulo. A aplicação prática dos conceitos propostos é ilustrada no Capítulo 4 por meio de um experimento utilizando dados reais.


Este capítulo está organizado da seguinte forma. Inicialmente é apresentada uma revisão dos principais conceitos propostos por Dempster e Shafer na Teoria da Evidência (Richards e Jia 1999), (Shafer 1976), tais como: evidência, plausibilidade (*plausibility*), confiança, também referido por alguns autores como crença (*belief*) e intervalo de confiança. Em seguida, são apresentadas as diversas etapas propostas nesta tese para implementação dos conceitos acima relacionados no processo de classificação de imagens digitais. São discutidas as abordagens adotadas para (i) seleção das variáveis relevantes ao processo, (ii) estimação dos graus de evidência em favor das classes em consideração, para cada uma das variáveis selecionadas, e (iii) estimação das incertezas associadas a estas variáveis. A seguir é apresentada e discutida a proposta para a utilização quantitativa dos valores de confiança e de plausibilidade no processo de detecção de erros na imagem temática produzida pelo classificador. Finalizando é apresentada a forma adotada nesta tese para a validação do modelo proposto, empregando-se uma área de treinamento para estimação dos limiares para os valores de confiança e de plausibilidade e uma área teste para estimação dos resultados da metodologia na acurácia da imagem classificada.

3.2 A TEORIA DA EVIDÊNCIA

Os princípios propostos na Teoria da Evidência fornecem uma maneira conveniente de introduzir de uma forma quantitativa, dados auxiliares no processo de classificação de

imagens digitais, inclusive dados originalmente de natureza qualitativa. Neste particular, o processo permite ao analista a flexibilidade de atribuir valores numéricos expressando o grau de evidência disponível referente à pertinência de um pixel genérico a cada uma das classes em consideração. Estes valores de evidência podem ser estimados por maneiras diversas, empregando funções de probabilidade ou outros critérios como, por exemplo, funções de pertinência semelhantes às utilizadas em lógica *fuzzy*. Um outro aspecto relevante na Teoria da Evidência consiste na possibilidade de introduzir o conceito de incerteza ou ignorância no processo. Isto significa que em lugar de trabalhar somente com um conjunto exaustivo de hipóteses ou classes mutuamente excludentes como no caso da abordagem Bayesiana, a teoria proposta por Dempster-Shafer permite ao analista expressar combinações entre as várias hipóteses, introduzindo desta forma no processo de classificação o conceito de incerteza ou ignorância. Cumpre aqui destacar que no presente contexto, o termo “hipótese” refere-se à pertinência de um pixel genérico a uma determinada classe. Esta possibilidade pode ser exemplificada melhor através de um exemplo, ilustrado na figura 1.

FIG. 1 – Possíveis Níveis de Informação Disponíveis



No exemplo ilustrado pela Figura 1 existem três classes (ou possíveis hipóteses), representadas aqui por $[A]$, $[B]$, e $[C]$. No classificador Bayesiano, o analista iria incorporar ao processo de classificação o conhecimento disponível (através das amostras disponíveis) a respeito de cada uma das três classes individuais, e todo o processo de classificação utilizaria exclusivamente as informações estimadas a partir destas classes individuais. A abordagem proposta pela teoria da evidência permite por outro lado, levar em consideração combinações ou uniões entre estas classes. As várias possibilidades com relação à disponibilidade de informações estão ilustradas na Figura 1. Desta forma, pode-se, por exemplo, introduzir no

processo conhecimentos ou evidências relativas à união entre duas classes como, por exemplo, $[A \cup B]$ estimando a evidência disponível com relação à pertinência de um pixel à união destas duas classes, mas sem nenhuma informação com respeito à pertinência deste pixel a cada uma das duas classes individualmente. Da mesma forma, a evidência relativa ao triplete $[A \cup B \cup C]$ representa a evidência existente com relação à pertinência de um pixel a uma combinação das três classes individuais $[A]$, $[B]$ e $[C]$, mas sem nenhuma distinção entre as classes individuais. Desta forma, a evidência atribuída ao triplete $[A \cup B \cup C]$ pode ser interpretada como uma medida de ignorância, isto é, existe informação disponível de que o pixel pertence à união das três classes, mas não com relação às classes individualmente. Neste contexto, os seguintes conceitos são importantes:

Evidência:

Dada uma determinada classe $[A]$, a evidência $m([A])$ associada a esta classe quantifica o grau de informação disponível em favor desta classe, isto é, o grau de certeza com que se pode afirmar que um determinado pixel pertence a esta classe. Pode-se também definir a evidência disponível em favor da união de duas ou mais hipóteses como $m([A \cup B])$, por exemplo. Em cada caso, os valores para a evidência podem ser estimados utilizando-se funções de probabilidade, ou empregando-se funções de pertinência estimadas empiricamente pelo analista, com base no conhecimento existente sobre o problema sendo analisado. O conjunto (Y) formado pelas classes individuais e por todas as possíveis combinações destas classes deve ser exaustivo, isto é, o somatório das evidências (1) estendido sobre todo o conjunto de hipóteses deve ser igual à unidade:

$$\sum_{\forall Y} m(Y) = 1 \quad (1)$$

No exemplo ilustrado na figura 1 esta condição pode ser expressa por:

$$m([A \cup B \cup C]) + m([A \cup B]) + m([A \cup C]) + m([B \cup C]) + m([A]) + m([B]) + m([C]) = 1$$

Na abordagem Bayesiana, somente as classes (ou hipóteses) $[A]$, $[B]$ e $[C]$ seriam aceitas e também deveriam ser exaustivas, isto é:

$$m([A]) + m([B]) + m([C]) = 1$$

Quando o conceito de incerteza ou ignorância [U] é introduzido, a equação (1) torna-se:

$$\sum_{\forall Y} m(Y) + U = 1 \quad (2)$$

Confiança ou crença (*belief*):

Esta variável estima a evidência total disponível em favor de uma dada classe (ou hipótese). Consiste na soma das evidências disponíveis em favor de uma classe (ou de um conjunto de classes) X e todas as subclasses aí incluídas. A confiança em X é representada na literatura (3), por $bel(X)$:

$$bel(X) = \sum_{Y \subseteq X} m(Y) \quad (3)$$

Utilizando como exemplo a situação ilustrada pela figura 1 tem-se que, se $X = [A \cup B]$, então:

$$X = \{ [A \cup B], [A], [B] \} \text{ e } bel(X) = m([A \cup B]) + m([A]) + m([B]).$$

Plausibilidade (*plausibility*):

Esta variável estima o grau de evidência ou a probabilidade segundo a qual, uma hipótese X (a pertinência de um pixel a uma classe) não pode ser descartada. Equivalentemente, a plausibilidade de uma hipótese (ou de pertinência a uma classe) pode ser estimada por 1 menos a soma das confianças (*belief*) em todas as hipóteses contrárias, conforme a equação (4):

$$pl(X) = \sum_{Y \cap X \neq \emptyset} m(Y) \quad (4)$$

ou

$$pl(X) = 1 - bel(\bar{X}) \text{ sendo } \bar{X} = NOT(X) \quad (5)$$

No exemplo acima, se $X = [A,B]$, então:

$$Y = \{ [A \cup B \cup C], [A \cup B], [A \cup C], [B \cup C], [A], [B] \}$$

e

$$pl(X) = 1 - bel(\bar{X}) = 1 - m[C] \quad (6)$$

Intervalo de confiança (belief interval):

Esta variável estima a diferença entre a plausibilidade de uma hipótese e a confiança nesta mesma hipótese. O intervalo de confiança pode ser interpretado, portanto, como um grau de incerteza com relação à aceitação ou rejeição de uma hipótese, isto é, a diferença entre o grau de informação que levaria o analista a não rejeitar a hipótese e o grau de evidência concreta que leva a aceitação da hipótese. Um valor alto para o intervalo de confiança pode ter várias aplicações interessantes como, por exemplo, indicar os locais mais adequados para investigar dados ou evidências adicionais que podem confirmar a hipótese.

Resumidamente pode-se, portanto, dizer que a confiança estima o grau de evidência concreta em favor de uma hipótese ou, no contexto desta tese, de que um determinado pixel pertença a uma determinada classe. A plausibilidade se constitui em uma estimativa ou uma avaliação do grau com que as condições favoráveis à hipótese existem, embora não se disponha de evidências concretas que levem a aceitação desta hipótese. No caso deste estudo, a plausibilidade quantifica o somatório das evidências disponíveis que levam a supor que um determinado pixel pertence a uma determinada classe. Desta forma a confiança e a plausibilidade definem um intervalo para a aceitação da hipótese de que um determinado pixel pertença a uma determinada classe: a confiança representa o limite inferior (o grau de evidência concreta que permite a aceitação desta hipótese) e a plausibilidade representa o limite superior deste intervalo (o grau com que as condições que indicariam a pertinência de um pixel em uma determinada classe existem, embora não se disponha de evidências concretas para tomar tal decisão). A amplitude entre estes dois limites se constitui no intervalo de confiança, que representa, portanto, o grau de incerteza entre a aceitação ou a rejeição da hipótese.

3.3 IMPLEMENTAÇÃO DOS CONCEITOS PROPOSTOS PELA TEORIA DA EVIDÊNCIA

Neste item são discutidos os processos para seleção das variáveis auxiliares que podem contribuir significativamente no processo de classificação de uma imagem, os métodos para estimação da evidência disponível em cada uma das variáveis selecionadas e a incerteza associada.

3.3.1 SELEÇÃO E ORGANIZAÇÃO DAS VARIÁVEIS AUXILIARES

A etapa inicial na metodologia proposta consiste na identificação das variáveis auxiliares a serem inseridas no processo de estimação dos valores para confiança e plausibilidade associadas a cada uma das classes individuais presentes na cena analisada e a cada pixel individualmente. Nesta etapa cabe ao analista identificar variáveis que apresentam potencialmente um poder discriminante com relação às classes de interesse na cena sendo analisada, isto pode ser feito através de pesquisa bibliográfica ou com uso de outras fontes que contenham informações confiáveis do ponto de vista técnico ou científico. Em uma etapa posterior (seção 3.3.2) este poder discriminante é quantificado e as variáveis que não contribuem significativamente ao processo de separação entre as classes são descartadas.

O conjunto das variáveis assim selecionadas é então estruturado na forma de P.I.s à semelhança de um SIG. Isto significa que a informação adicionada por cada variável individual é organizada na forma de um P.I. em formato raster, geo-referenciado, todos com idênticas características (número de linhas e colunas, dimensão do pixel e área de cobertura). Esta organização dos dados permite a combinação das informações relativas à confiança e plausibilidade, estimadas por cada variável individual, em uma estimativa combinada para confiança e plausibilidade.

3.3.2 ESTIMAÇÃO DOS VALORES PARA INCERTEZA ASSOCIADOS A CADA VARIÁVEL

A estimação dos valores para confiança e plausibilidade associados a cada uma das variáveis requer inicialmente a estimação dos valores para a evidência. Nesta tese é adotada a abordagem geral proposta originalmente por Lee *et al.* (1987). De acordo com a proposta daqueles autores, o processo inicia-se pela estimação do grau de incerteza associado a cada uma das variáveis auxiliares. O restante (1- incerteza) é então distribuído proporcionalmente como a evidência associada a cada uma das classes presentes na análise.

Nesta abordagem, a incerteza é estimada pelo complemento da acurácia na imagem temática produzida em um processo de classificação no qual somente a variável em questão é utilizada. Neste contexto, a acurácia utilizada é a acurácia do usuário (*user's accuracy*), a qual estima o grau de confiança que se pode ter de que o rótulo atribuído a um pixel genérico esteja correto (Congalton, 1996). Neste processo, o método de classificação utilizado para cada uma das variáveis auxiliares para fins de estimação da incerteza vai depender da distribuição apresentada pela variável. Para variáveis apresentando uma distribuição Normal, propõe-se aqui a utilização do classificador Máxima Verossimilhança Gaussiana. Para variáveis que não são Normalmente distribuídas, é proposta aqui a utilização do classificador Distância Euclidiana Mínima. Na literatura são propostos métodos para avaliar se uma variável pode ser considerada como Normalmente distribuída ou não. Neste estudo propõe-se a simples avaliação visual do histograma da variável.

O grau da contribuição individual de cada variável ao processo de separação entre as classes pode também ser estimado nesta etapa.

Conforme discutido na seção 3.3.1, as variáveis auxiliares que resultarem em um valor insatisfatório para a acurácia do usuário, isto é, em um valor alto para a incerteza, acima de um limiar pré-estabelecido pelo analista, mostrando, portanto, um baixo poder discriminante são descartadas nesta etapa. A implementação prática deste contexto está ilustrada no Capítulo 4.

3.3.3 ESTIMAÇÃO DAS EVIDÊNCIAS ASSOCIADAS A CADA PIXEL E A CADA CLASSE

Uma vez estimado o grau de incerteza associado a cada variável, pode-se estimar as evidências disponíveis para cada uma das hipóteses (classes) em consideração. Neste particular duas situações distintas podem ocorrer. Para variáveis que apresentam uma distribuição Normal com relação às classes em consideração, o grau de evidência pode ser estimado a partir de critérios probabilísticos. Para as demais variáveis, recorre-se a funções de pertinência, com características definidas pelo conhecimento do analista. Propõe-se aqui a seguinte expressão para estimar a evidência no caso de variáveis normalmente distribuídas:

Para variáveis normalmente distribuídas a evidência é estimada *a posteriori* $p(\omega_a/X)$, isto pode ser computacionalmente realizado através do teorema de Bayes (7):

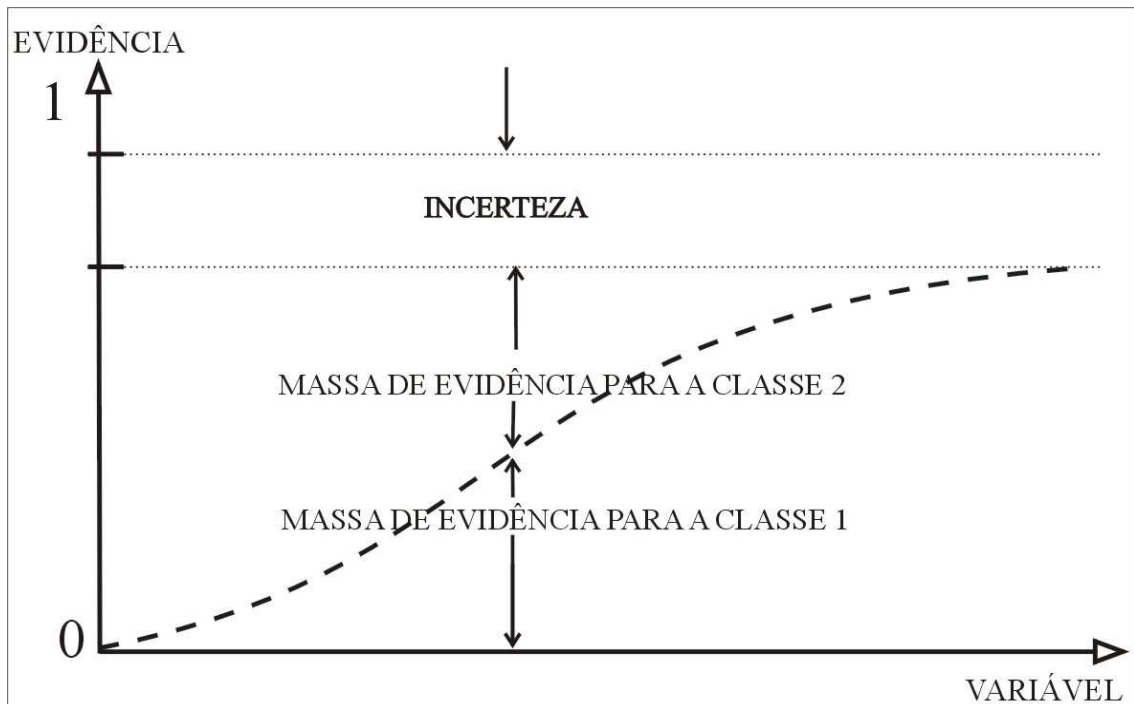
$$p(\omega_a / X) = \frac{p(X / \omega_a) P(\omega_a)}{\sum_{j=1}^m p(X / \omega_j) P(\omega_j)} \quad (7)$$

Onde: a probabilidade *a posteriori* $p(\omega_a/X)$ estima a evidência disponível para rotular o pixel X como pertencente à classe ω_a , $p(X/\omega_j)$ é a função de densidade de probabilidade condicional associada com a classe ω_j , $P(\omega_j)$ é a probabilidade *a priori* associada com a classe ω_j , e m é o número de classes em consideração.

Para os casos em que a distribuição não é conhecida propõe-se nesta tese utilizar funções de pertinência, definidas pelo conhecimento do analista. A função selecionada deve modelar a evidência que apóia cada uma das classes, como uma função da variável auxiliar sob consideração. Para cada pixel, as evidências devem somar (1-incerteza). Este processo está ilustrado na figura 2, neste exemplo considerando apenas as duas classes usado nos experimentos (Mata Nativa com Araucária e a classe outros).

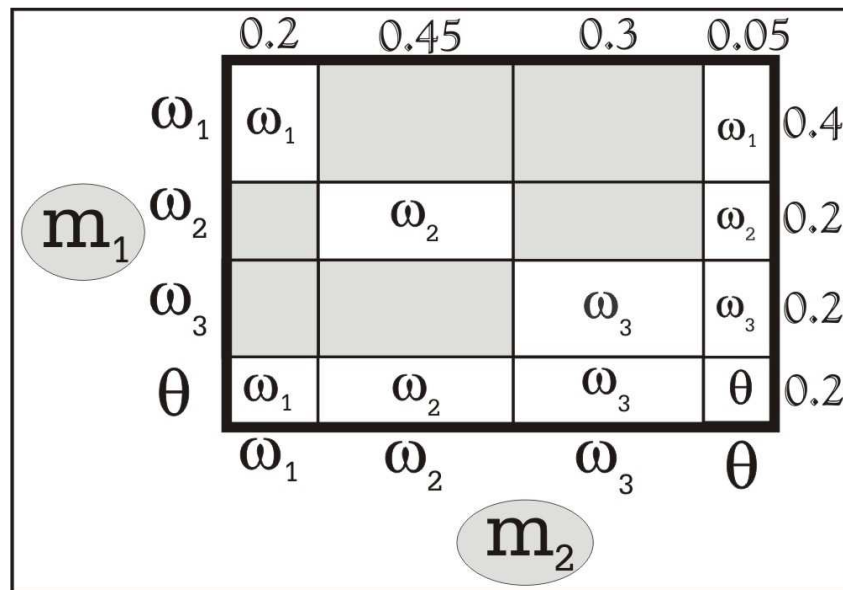
Estes valores estimados devem ser re-escalados para o intervalo (1 – incerteza), de tal forma que, para cada pixel individual o somatório das evidências mais o valor da incerteza seja igual à unidade. P.I.s de evidência associados as variáveis selecionadas são produzidos nesta etapa. Este processo novamente pode ser visto na figura 2, para o caso de duas classes.

FIG. 2 – Construção da Massa de Evidência e introdução da incerteza



Este processo é repetido para cada uma das variáveis, gerando desta forma P.I.s de evidência associados a cada uma das variáveis selecionadas. A etapa seguinte consiste em combinar estes P.I.s de evidência, produzindo um P.I. com as evidências combinadas. Para fins de combinação das evidências, é utilizado nesta tese o algoritmo denominado de soma ortogonal. Neste processo, a combinação das estimativas para evidência e incerteza é feita de uma forma iterativa, combinando as evidências e incertezas de duas variáveis a cada passo. Este algoritmo pode ser ilustrado através de um exemplo (Richards, 1999). Supondo a existência de três hipóteses (ou classes) ω_1 , ω_2 e ω_3 , a ignorância fica representada pelo triplete $[\omega_1 \cup \omega_2 \cup \omega_3]$, isto é, o analista não dispõe de nenhuma evidência que permita decidir por uma das classes relacionadas. Por razões de simplicidade, neste exemplo, são utilizadas somente duas variáveis.

FIG. 3 – Exemplo do Algoritmo Soma Ortogonal



As evidências (ω) e a incerteza (θ) estimadas para a primeira variável (m_1) são:

$$m_1(\omega_1) = 0.4$$

$$m_1(\omega_2) = 0.2$$

$$m_1(\omega_3) = 0.2$$

$$m_1(\omega_1 \cup \omega_2 \cup \omega_3) = 0.2$$

As evidências (ω) e a incerteza (θ) estimadas para a segunda variável (m_2) são:

$$m_2(\omega_1) = 0.2$$

$$m_2(\omega_2) = 0.45$$

$$m_2(\omega_3) = 0.3$$

$$m_2(\omega_1 \cup \omega_2 \cup \omega_3) = 0.05$$

Os segmentos resultantes das combinações das evidências associadas a cada uma das três classes e ainda da incerteza (figura 3), são utilizados para estimar o valor combinado das evidências e da incerteza. Nesta abordagem a evidência associada à uma classe é estimada pela área dos segmentos em que não ocorre contradição entre as informações contidas nas duas variáveis, isto é, ou a mesma classe ocorre em ambos os eixos ou em um dos eixos ocorre esta classe e no outro ocorre incerteza, representada na Figura 3 por θ . As áreas brancas presentes na figura 3 são, portanto, áreas nas quais há coesão de informações, por este motivo são somadas, as áreas cinza presentes na mesma figura 3 correspondem a áreas de

contradição (entre as duas variáveis) e portanto não são consideradas. A incerteza combinada é estimada pela área do segmento correspondente a incerteza em ambos os eixos. Estes valores são normalizados, isto é, a soma das evidências combinadas mais à incerteza deve ser igual à unidade. O fator de normalização é encontrado somando-se todas as áreas nas quais não haja contradição, para o exemplo ilustrado na figura 3 somam-se todas as áreas brancas e chega-se ao fator de normalização (que é igual a 0.47).

$$m(\omega_1) = (0.08 + 0.02 + 0.04) / 0.47 = 0.298$$

$$m(\omega_2) = (0.09 + 0.01 + 0.09) / 0.47 = 0.404$$

$$m(\omega_3) = (0.06 + 0.01 + 0.06) / 0.47 = 0.277$$

$$m(\omega_1 \cup \omega_2 \cup \omega_3) = 0.01/0.47 = 0.021$$

Em situações reais, várias fontes de informação (variáveis) são utilizadas. Neste caso, o algoritmo pode ser aplicado de uma forma recursiva, pois as propriedades associativa e comutativa são válidas.

3.3.4 GERAÇÃO DOS P.I.S DE CONFIANÇA E PLAUSIBILIDADE

O P.I. contendo as estimativas para as evidências combinadas é então utilizado para gerar os P.I.s de confiança e de plausibilidade, conforme definido na seção 3.2 Confiança, sendo a evidência concreta disponível em favor de cada classe é estimada pela evidência combinada resultante. Utilizando-se do mesmo exemplo da seção anterior (3.3.3), os valores estimados para a confiança, para cada uma das três classes são respectivamente:

$$bel(\omega_1) = 0.298$$

$$bel(\omega_2) = 0.404$$

$$bel(\omega_3) = 0.277$$

Plausibilidade estima a evidência máxima em favor de cada classe conforme definido na seção 3.2 Neste caso, plausibilidade pode ser estimada pela evidência associada à classe em questão, mais a incerteza. Os valores estimados para plausibilidade, no mesmo exemplo anterior são:

$$plau(\omega_1) = 0.319$$

$$plau(\omega_2) = 0.425$$

$$plau(\omega_3) = 0.298$$

3.4 PROPOSTA DE UTILIZAÇÃO DAS VARIÁVEIS CONFIANÇA E PLAUSIBILIDADE NA DETECÇÃO DE ERROS DE OMISSÃO E DE INCLUSÃO NA IMAGEM TEMÁTICA PRODUZIDA POR UM CLASSIFICADOR.

A utilização dos conceitos de confiança e plausibilidade no processo de classificação de imagens digitais em sensoriamento remoto constitui-se em um desafio. Na literatura podem-se encontrar algumas sugestões de aplicações destes conceitos, mas expressos dentro de uma abordagem mais qualitativa do que quantitativa. Nesta tese é proposta uma abordagem quantitativa destes dois conceitos com o objetivo de oferecer ao analista um certo controle sobre a acurácia da imagem temática produzida pelo classificador.

A informação contida nos dados de confiança e plausibilidade pode ser utilizada para a detecção de erros de omissão e inclusão contidos na imagem temática (classificada). Erros de omissão e de inclusão estão relacionados, respectivamente, a acurácia do produtor e a acurácia do usuário. Para corrigir ou minimizar estes erros (que são inerentes aos processos tradicionais de classificação digital) se propõe aqui estabelecer limiares de corte para os valores de confiança e de plausibilidade. Desta forma um limiar de confiança é utilizado para detectar erros de inclusão, enquanto que, um limiar de plausibilidade é utilizado para detectar erros de omissão. Pixels que para a classe em que estão rotulados na imagem temática, apresentam um valor para confiança inferior ao limiar fixado, podem ser interpretados como prováveis erros de inclusão. Da mesma forma pixels que apresentam um valor alto para plausibilidade, acima do limiar fixado, mas não estão rotulados nesta classe, se constituem em prováveis erros de omissão.

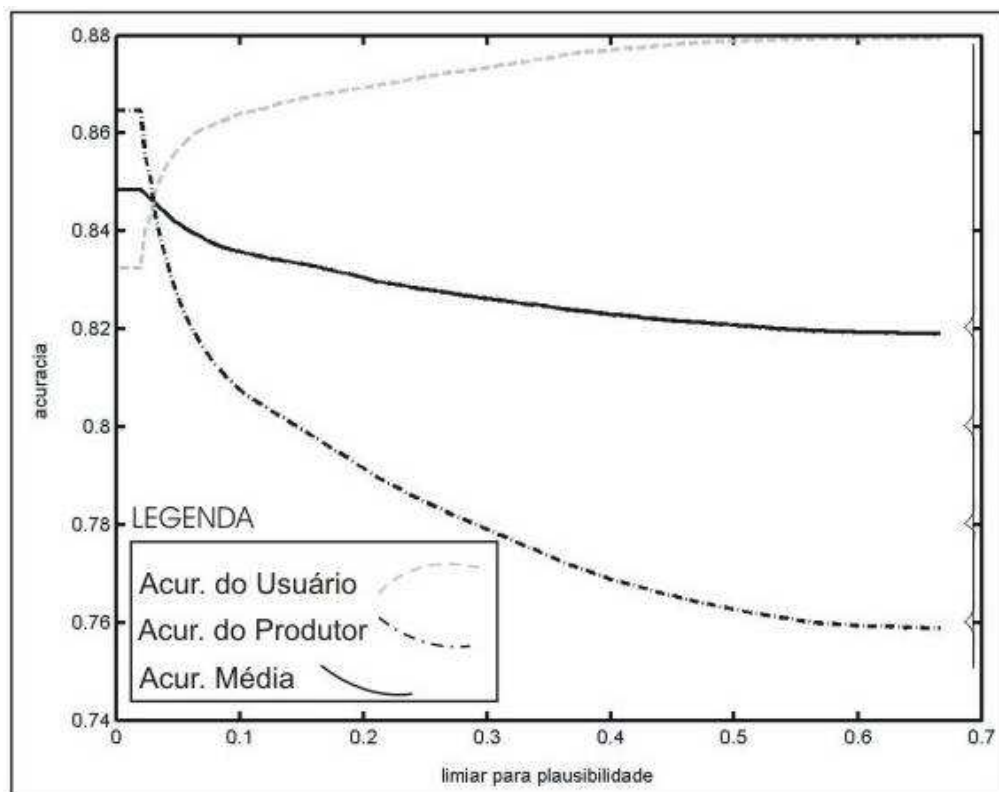
Neste estudo propõe-se a utilização destes dois limiares para controlar a ocorrência de erros de omissão e de inclusão na imagem temática, ajustando as acurácias do usuário e do produtor, permitindo ao analista ajustar cada uma delas de acordo com as necessidades particulares do estudo. A metodologia proposta requer, necessariamente, a disponibilidade de duas áreas contendo dados referente à verdade terrestre: uma para fins de treinamento e outra para fins de teste. A área destinada a treinamento tem como finalidade permitir a escolha dos dois limiares (um para confiança e outro para plausibilidade) que melhor se ajustem ao conjunto de exigências estipuladas pelo analista. As exigências neste caso consistem no

balanço entre a acurácia do usuário e a acurácia do produtor, priorizando-se uma ou outra em função do objetivo pretendido. Um aumento gradual no limiar para confiança resulta em uma redução no número de erros de inclusão, ocasionando em contrapartida um incremento no número dos erros de omissão. Assim ao aumentar-se o limiar para confiança incrementa-se a acurácia do usuário ocasionando, entretanto, uma redução na acurácia do produtor. Uma situação exatamente inversa ocorre com relação ao limiar definido para plausibilidade. Este comportamento encontra-se ilustrado na figura 4, gerada no experimento discutido no Capítulo 4. Desta forma ao selecionar-se um par de limiares o analista deve decidir-se por opção entre incrementar uma ou outra forma de acurácia, em detrimento da outra, conforme melhor se ajuste às necessidades do estudo. Com o par de limiares definidos aplicam-se estes limiares a toda a imagem.

Na abordagem proposta aqui, os dois limiares podem ser entendidos como desempenhando a função de filtros atuando sobre a imagem temática, alterando a relação entre erros de omissão e de inclusão.

A área teste serve para validar os resultados obtidos pela aplicação dos limiares estimados com o auxílio dos dados na área de treinamento.

FIG. 4 – Ex. de um compor. padrão para as acurácias do usuário, produtor e média



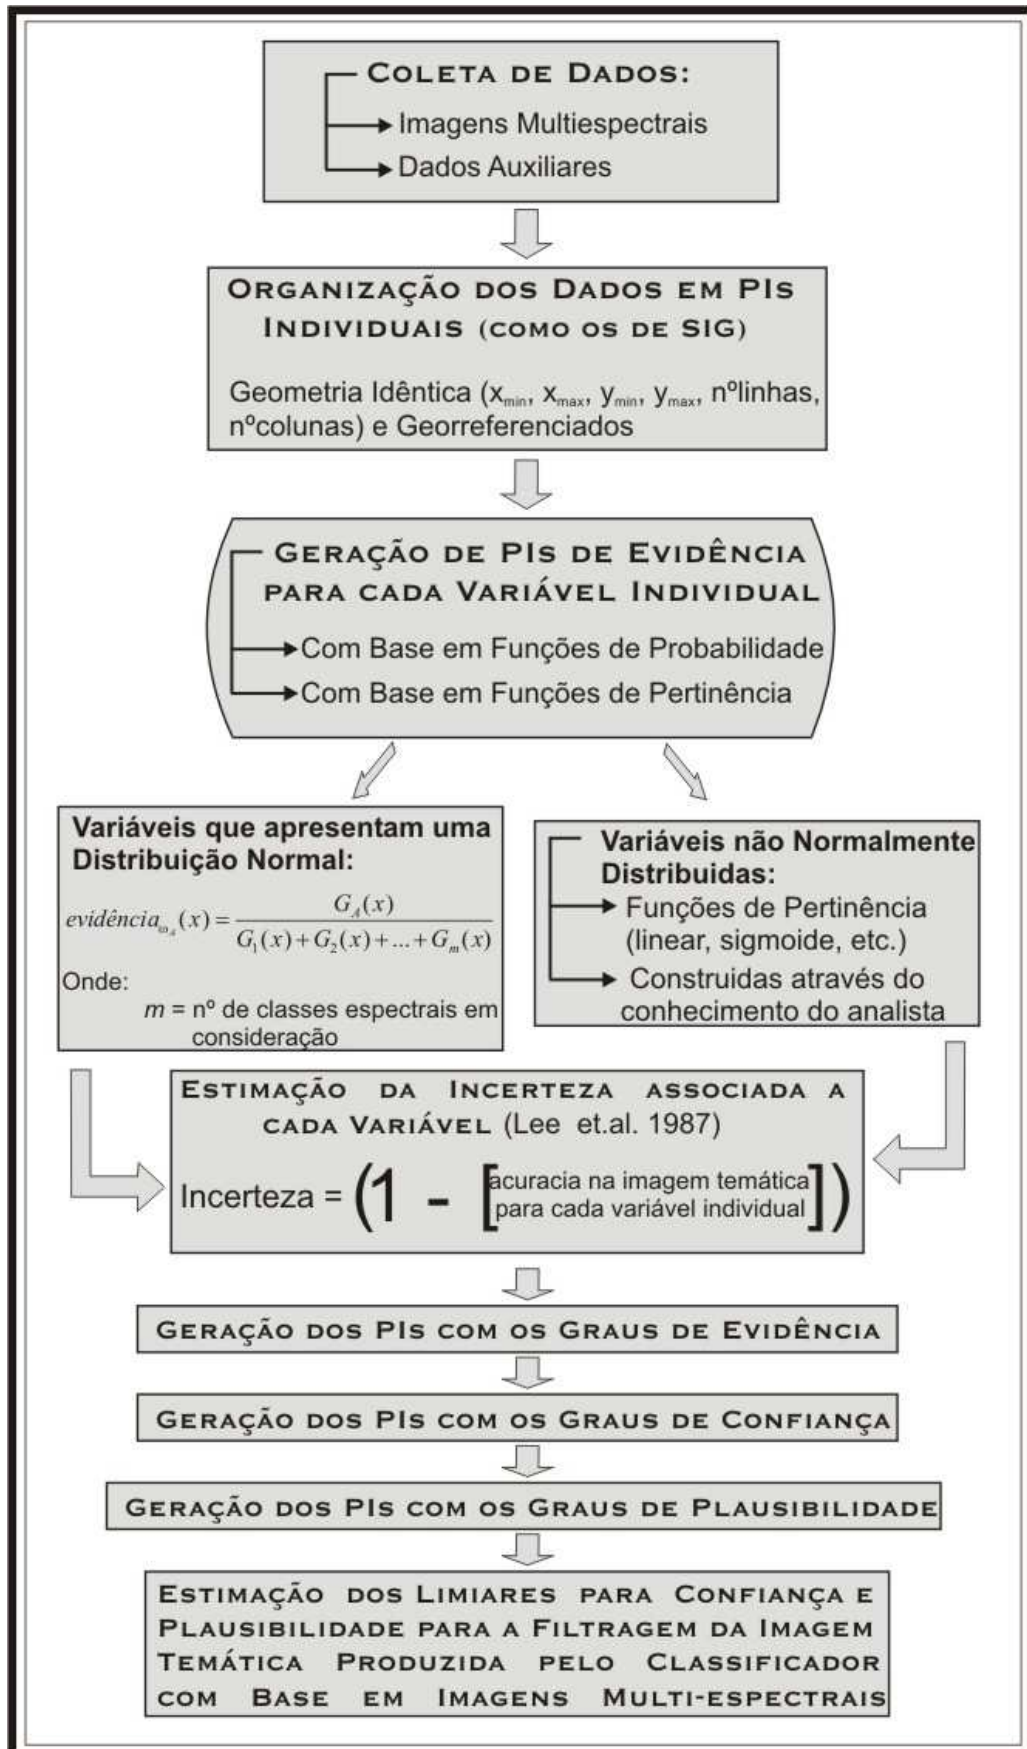
A proposta metodológica visando à introdução de dados auxiliares, dentro de um processo de classificação, pode ser resumida, basicamente, em oito passos:

- 1- O passo inicial consiste em gerar uma imagem temática a partir da aplicação de um classificador a um conjunto de dados multiespectral (imagens digitais em suas respectivas bandas).
- 2- Nesta etapa o pesquisador deve escolher o grupo de variáveis auxiliares, que devem ser selecionadas em função do fenômeno sob análise; entre estas variáveis podem estar, por exemplo: altitude, aspecto, declividade e muitas outras que possuam potencial para discriminar as classes de interesse presentes dentro da área de estudo. O poder de discriminação em cada variável pode ser estimado por uma medida estatística de distância entre as classes em consideração (como a distância de Bhattacharyya, por exemplo), e baseado, somente, em uma única variável.
- 3- As variáveis selecionadas (na etapa anterior) devem ser organizadas na forma de P.I.s, com cobertura sobre a área de estudo, como os utilizados em um SIG. Estes P.I.s devem estar registrados espacialmente de acordo com o conjunto de imagens multiespectrais (bandas).
- 4- Para cada variável estima-se, individualmente, a incerteza correspondente. Neste estudo a incerteza foi estimada a partir da adoção do valor complementar ao valor encontrado para a acurácia do usuário para cada variável (e para cada classe em consideração). Variáveis que apresentam um valor muito alto de incerteza e, portanto, um baixo valor registrado na acurácia do usuário, indicam que esta variável possui um baixo poder de discriminação para as classes em consideração, por este motivo elas devem ser descartadas.
- 5- Estima-se a evidência disponível para rotular cada pixel em consideração, isto é feito individualmente para todas as variáveis auxiliares e para todos os pixels do P.I. A informação relativa à incerteza (passo 4) é também incluída aqui, através do re-escalamento das evidências para o intervalo [1-incerteza]. Desta forma são criados P.I.s individuais de evidência, neste estágio. A combinação destes P.I.s de evidência produz um novo P.I. contendo a evidência combinada, mais a incerteza associada.
- 6- Para cada classe em questão (presente na cena) é gerado um P.I. contendo os dados de confiança e plausibilidade correspondentes. Estes planos são gerados, por sua vez, a partir dos dados contendo a evidência combinada, dados estes que foram gerados no passo anterior.

- 7- Usando a informação disponível para a área de treinamento, dois limiares são selecionados para detectar possíveis erros de classificação presentes na imagem temática, um limiar para confiança e outro para plausibilidade. A acurácia do usuário e a acurácia do produtor é utilizada para estimar estes dois diferentes limiares. O pesquisador precisa selecionar o par de limiares que melhor se ajuste às necessidades, baseado na acurácia do usuário e do produtor.
- 8- Nesta última etapa os limiares selecionados são utilizados para filtrar toda imagem temática. A área de teste é utilizada para estimar o efeito da filtragem sobre a nova imagem temática resultante.

Esta metodologia encontra-se representada na forma de um fluxograma, que pode ser visto na figura 5. Toda a metodologia aqui proposta é testada em um estudo de caso descrito no Capítulo 4.

FIG. 5 – Fluxograma da metodologia



4 EXPERIMENTOS

4.1 INTRODUÇÃO

O objetivo deste capítulo consiste em ilustrar através de um estudo de caso a metodologia proposta no Capítulo 3 utilizando dados de fontes diversas cobrindo uma cena natural. As diversas etapas propostas na metodologia são aqui avaliadas, os conceitos propostos são aplicados e os resultados produzidos são avaliados.

A área selecionada, para teste, está situada a noroeste do Estado do Rio Grande do Sul (RS) com ocorrência da Mata Nativa com Araucária. Além da espécie *Araucaria angustifolia*, esta formação florestal inclui várias outras espécies nativas, como *Podocarpus lambertii*, *Slonea monosperma*, *Symplocus uniflora*, *Ocotea pulchella*, *Rapanea venosa*, *Feijoa sellowiana*, *Eugenia opaca*, além de uma grande diversidade de líquens musgos e epifetas (e.g., *Polypodium squamulosum* e *Tillandsia tenuifolia*). Experiências anteriores nesta área, envolvendo o uso de imagens multiespectrais na produção de mapas temáticos de cobertura do solo, mostraram que Mata Nativa com Araucária constitui-se em uma classe de cobertura do solo difícil de ser identificada com um bom grau de acurácia. Embora Mata Nativa com Araucária não apresente problemas de confusão espectral com outras coníferas de origem exótica presentes na região como, por exemplo, diversas espécies de *Pinus*, tem-se observado a ocorrência de um alto grau de confusão com outras classes espectrais, como áreas sombreadas e áreas úmidas (banhado, turfeiras, entre outros). Estes problemas impedem a obtenção de mapas temáticos acurados nesta região, utilizando-se somente dados de imagens multiespectrais. Por esta razão, a tarefa de mapear manchas cobertas pela Mata Nativa com Araucária apresenta condições adequadas para testar a metodologia proposta no Capítulo 3. Deve-se aqui enfatizar que no experimento descrito neste Capítulo tem-se como objetivo mapear áreas cobertas pela classe Mata Nativa com Araucária, sendo as demais classes presentes na cena em estudo agrupadas sob o rótulo de “outros”.

4.2 FLORESTA OMBRÔFILA MISTA ALTO MONTANA (RADAM / BRASIL) OU MATA NATIVA COM ARAUCÁRIA

No sistema de classificação do projeto RADAM BRASIL a Mata Nativa com Araucária é denominada Floresta Ombrófila Mista Alto Montana. O sistema criado pelo projeto RADAM leva em conta diversos fatores físicos do ambiente natural para denominar uma determinada formação florestal, portanto o próprio nome adotado já demonstra características naturais diversas desta formação. No caso da Floresta Ombrófila Mista Alto Montana o termo Ombrófila designa o tipo de floresta que apresenta grande necessidade de água ou umidade (IBGE, 1986). O termo “mista” indica que esta floresta possui uma diversidade de espécies em sua formação, neste caso uma mistura de espécies angiospermas e gimnospermas (que é o caso da *Araucaria angustifolia*). O termo “Alto Montana” indica ser uma formação florestal que ocorre em regiões de maior altitude. Devido à espécie *Araucaria angustifolia* ocorrer geralmente misturada com outras espécies, esta formação florestal é mais popularmente conhecida por “Mata Nativa com Araucária”, nesta tese optou-se por utilizar-se este termo para designar a formação florestal.

4.2.1 A ARAUCARIA ANGUSTIFOLIA

Existem em todo o planeta 2 gêneros com 32 espécies de Araucária, todas provenientes da América do Sul ou Oceania, portanto apenas no hemisfério sul do planeta (RIZZINI, 1987). Essa configuração remonta a um passado paleontológico do gênero das *Araucariáceas* que já habitavam a Terra há milhões de anos atrás, época em que os continentes apresentavam uma configuração diferente da atual. A espécie que ocorre no Brasil é a *Araucaria angustifolia* (Bert. O. Kuntze) conhecida popularmente por: Pinheiro-Brasileiro, Pinheiro-do-Paraná, entre outros, podendo atingir em sua fase adulta uma altura de até 50 m, e mais de 400 anos de idade. A espécie se caracteriza ainda por ser dióica, ou seja, pela divisão entre indivíduos do sexo masculino e feminino. A *Araucaria angustifolia* habita preferencialmente a região sul do Brasil, sendo que a cidade de Curitiba (Paraná) poderia ser considerada como o ecocentro de distribuição da espécie. Observa-se ainda algumas

ocorrências na província de Misiones, Argentina. Esta região pode ser considerada como uma área marginal de dispersão da espécie (HUECK, 1972).

A *Araucaria angustifolia* junto com o *Podocarpus* são as únicas coníferas nativas do Brasil. O *Podocarpus* que ocorre no Brasil compreende duas espécies pertencentes a este gênero: *Podocarpus sellowii* (Klotzsch) e *Podocarpus lambertii* (Klotzsch), sendo o *Podocarpus lambertii* o mais comumente encontrado. Ao contrario do que ocorre com a *Araucaria angustifolia* o *Podocarpus* não possui interesse econômico por ser de porte inferior (12 a 15 m de altura) e de configuração, quanto ao tronco, não retilínea ou regular, o que torna sua madeira pouco atrativa para a exploração econômica. Esta espécie também sofreu um grande declínio em número por estar intimamente ligado a Floresta Ombrófila Mista. Existem focos de mata nativa apenas com presença de *Podocarpus* onde não ocorrem Araucárias. A Araucária existente no Brasil difere da maioria das outras espécies de coníferas devido ao seu porte, com um tronco retilíneo, sem ramificações, apresentando uma copa em forma radial em seu extremo, lembrando um enorme candelabro. Nos indivíduos masculinos os galhos desta copa apresentam-se mais retilíneos e paralelos uns em relação aos outros, já nos indivíduos femininos os galhos da copa apresentam-se curvados para cima, resultado da adaptação natural da árvore feminina para capturar com mais facilidade o pólen (que apenas é liberado pelos indivíduos machos). O formato do tronco, aliado à alta qualidade da madeira, foram às características que mais despertaram interesses para sua exploração. Existe outra espécie de Araucária com uma configuração semelhante no Chile, trata-se da *Araucaria araucana* (Mol. K. Koch), talvez a de origem mais próxima a da *Araucaria angustifolia*.

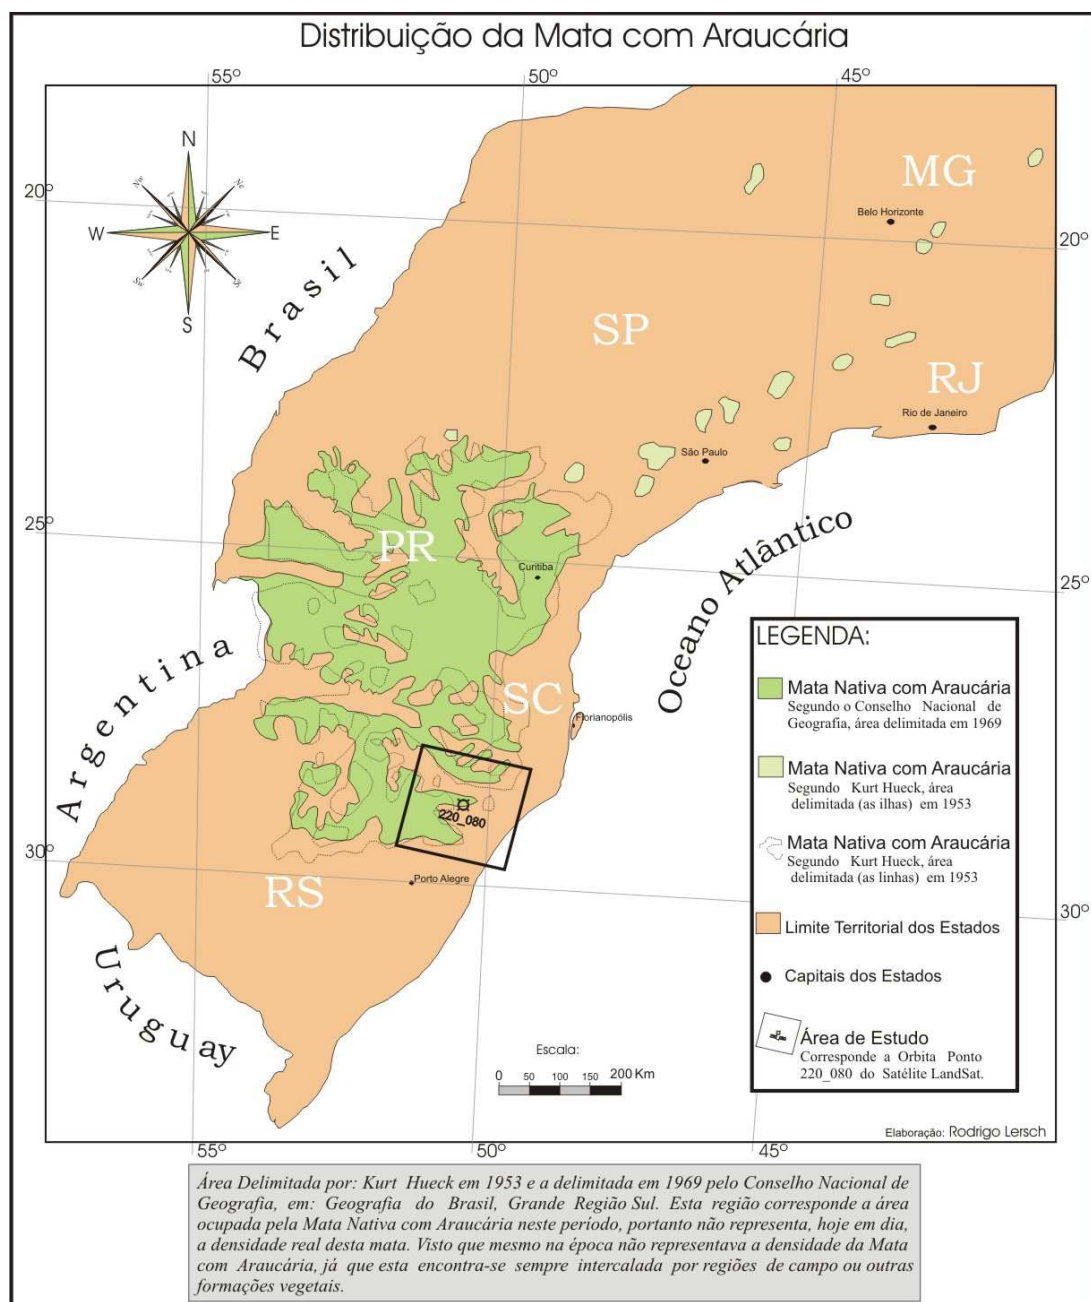
4.2.1.1 DISTRIBUIÇÃO

No Brasil a *Araucaria angustifolia* ocorre nos três Estados do sul (Paraná, Santa Catarina e Rio Grande do Sul) formando agrupamentos densos sobre o Planalto Meridional Sul Brasileiro (Serra Geral) em altitudes a partir de 500 m acima do nível do mar. Verificam-se ainda ocorrências na região da Serra da Mantiqueira (São Paulo e sul de Minas Gerais) e na Serra dos Órgãos (Rio de Janeiro) na forma de pequenas manchas esparsas e em altitudes mais elevadas do que no sul do Brasil. Conforme Oliveira (FUPEF 1979) as áreas extremas de ocorrência de *Araucaria angustifolia* podem ser definida pelas seguintes coordenadas:

Latitude: de 21° Sul a 30° Sul - Longitude: de 44° Oeste a 54° Oeste.

A distribuição da Mata Nativa com Araucária, conforme Kurt Hueck (1953) e Conselho Nacional de Geografia (1969), é ilustrada na Figura 6. Os dados levantados por Hueck referem-se à distribuição da espécie em 1953 ou anteriormente a esta data e são disponibilizados em uma forma bastante esquemática, sem maiores rigores quanto à precisão cartográfica. O levantamento feito pelo Conselho Nacional de Geografia, mostra a distribuição apenas nos 3 Estados do Sul, e embora sendo um levantamento mais recente possui menos rigor cartográfico que o de Hueck.

FIG. 6 – Distribuição Natural da *Araucaria angustifolia* em 1953 e 1969



4.2.1.2 MEIO FÍSICO

Existem diversos fatores físicos que caracterizam e condicionam o habitat da *Araucaria angustifolia*, como a altitude da região, o valor da precipitação media anual e da temperatura media anual, a categoria de solo, além de outros mais difíceis de serem avaliados quantitativamente, como a umidade do ar, a radiação solar, entre outros (IBDF, 1978; IBGE 1986; FUPEF, 1979).

Quanto ao substrato da região onde se distribui a *Araucaria angustifolia* pode-se dizer que ele assenta-se no Planalto do RS sobre rochas vulcânicas. Em outras regiões do Brasil a área de distribuição situa-se sobre litologias mais diversificadas, como rochas cristalinas ou metamórficas.

A *Araucaria angustifolia* é capaz de se desenvolver naturalmente em uma grande variedade de tipos de solos, contudo a espécie apresenta preferências por solos de composição argilosa ou síltica. Os solos provenientes dos processos de intemperismo em rochas vulcânicas apresentam estas características. Estes solos apresentam uma grande mistura de componentes minerais fazendo com que se pareçam muito com os solos humosos de regiões temperadas (Hueck, 1953).

Com relação aos fatores climáticos a região Sul do Brasil apresenta as 4 estações do ano melhor definidas e com chuvas bem distribuídas ao longo do ano, em comparação com o restante do País. Estas características se enquadram na categoria *CF*, segundo a classificação de Koppen. A *Araucaria angustifolia* ocorre em regiões que apresentam dois tipos climáticos: *CFA* e *CFB*. Na classificação de Koppen *C* designa climas com uma temperatura inferior a 18° C e superior a -3° C para o mês mais frio do ano. O *F* indica uma ausência de estações secas. O *B* indica verões frescos e o *A* verões quentes. Portanto *CFA* representa um clima subtropical sem estação seca e com verões quentes enquanto que *CFB* representa um clima subtropical sem estação seca e com verões frescos. A temperatura média anual nas áreas de ocorrência de Mata Nativa com Araucária fica entre 12 a 18° C, apresentando temperaturas mínimas, em alguns pontos, inferiores a -10° C no mês mais frio. Outra observação importante é que a isoterma de 13° C no mês de julho é considerado como um limite térmico natural para a distribuição da *Araucaria angustifolia*. Essa isoterma atua, portanto, como um delimitador natural da espécie.

Como na região de ocorrência de Mata Nativa com Araucária no Rio Grande do Sul não existe grandes variações de latitude, a altitude torna-se um dos fatores físicos que mais contribuem para as variações térmicas e com isto para delimitar o habitat natural da *Araucaria angustifolia*. A temperatura baixa aproximadamente 0,6° c a cada 100 m de altitude (modelo teórico). Estudos realizados, mostram que no Estado do Rio Grande do Sul não existem ocorrências **naturais** de *Araucaria angustifolia* em altitudes inferiores a 500 m, salvo em pequenas regiões influenciadas por fatores micro-climáticos (IBDF, 1978; IBGE 1986; RAMBO, 1942; HUECK, 1972).

À semelhança do que ocorre com a altitude do terreno, a precipitação é um outro fator físico que limita o habitat natural da *Araucaria angustifolia*, existindo também consenso entre os especialistas a respeito dos valores extremos que condicionam a sua ocorrência. A região de ocorrência da espécie situa-se em uma faixa onde a precipitação varia entre 1250 mm a 2450 mm (São Francisco de Paula) para a precipitação média anual. Não são registradas ocorrências de *Araucaria angustifolia* em regiões com valores inferiores a 1000 mm, para a precipitação média anual. Aliada à alta precipitação, a umidade relativa do ar também é bastante alta alcançando valores médios anuais entre 11 mm e 12,5 mm de tensão média anual de vapor, e uma umidade relativa média anual entre 75 % e 87 %, no Rio Grande do Sul. Nos outros dois Estados (Santa Catarina e Paraná), à umidade relativa é ainda mais alta (IBDF, 1978; IBGE 1986; RAMBO, 1942; HUECK, 1972).

A exploração madeireira que teve seu pico na década de 1960 e início da de 1970, quase dizimou a espécie. A este fator deve-se ainda acrescentar a expansão das áreas dedicadas à agricultura, que também contribuíram para a redução da espécie *Araucaria angustifolia*. Rambo (1942) estimava que originalmente 40 % do Estado do Rio Grande do Sul era coberto por florestas. Hoje, as florestas representam pouco mais de 1% do território do Estado. Segundo Hueck (1972) as áreas naturais de ocorrência da Mata Nativa com Araucária em finais da década de cinquenta eram as seguintes:

Paraná 73 780 Km²

Santa Catarina 56 693 Km²

Rio Grande do Sul 46 483 Km²

Rio de Janeiro, São Paulo e Minas Gerais continham mais 8 000 Km²

Atualmente estima-se 3166 km² para o Paraná, 1800 Km² para Santa Catarina e 657 Km² para o Rio Grande do Sul. A exploração econômica da *Araucaria angustifolia* pode ser considerada ainda mais devastadora devido ao fato de não ter ocorrido reposição desta espécie. O florestamento promovido por indústrias de papel celulose, madeireiras e outros, foi feito com a introdução de Pinus, mais frequentemente da espécie *Pinus elliottis* (Engelmann). O Pinus é uma espécie exótica escolhida por possuir rápido crescimento e fácil adaptação à maioria dos ambientes, visto que consegue sobreviver até mesmo em solos arenosos do litoral.

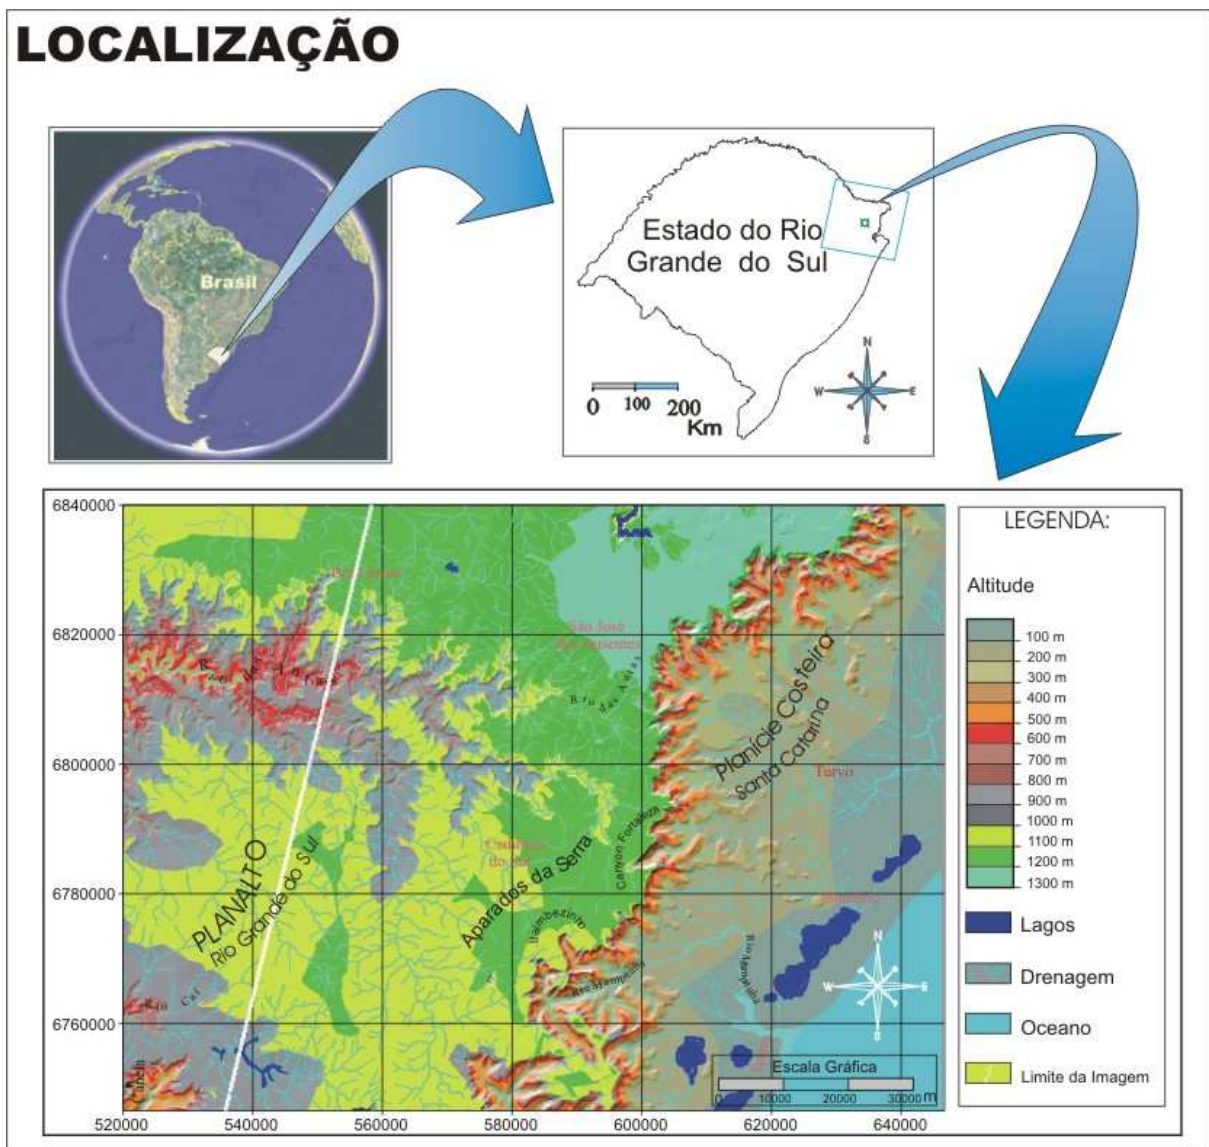
4.3 ÁREA DE ESTUDO

A área de estudo situa-se em uma na porção nordeste do Planalto Gaúcho (formação Serra Geral), coberta pela órbita ponto 220_080 do sistema LANDSAT. Esta região foi escolhida em razão da grande riqueza e variação Geomorfológica existente e das conhecidas dificuldades em se obter uma identificação acurada da classe Mata Nativa com Araucária por meio de dados multiespectrais somente. A região apresenta um grande contraste entre a Planície Costeira, onde, as altitudes chegam a apenas alguns metros acima do nível do mar, e o Planalto, onde as altitudes chegam a mais de 1300 m acima do nível do mar. Além desta quebra brusca de morfologia entre a Planície Costeira e o Planalto existe mais uma quebra sobre este planalto, ocasionada pelo do rio das Antas. Além destes acidentes geográficos existe ainda todos os conhecidos *Canyons*, localizados nos parques nacionais dos Aparados da Serra e da Serra Geral: Itaimbezinho, Fortaleza e outros, e ainda lagos, morros, praias, campos e o Oceano Atlântico. Os detalhes da região estão ilustrados no mapa exibido na figura 7.

Esta figura ilustra o grande contraste existente entre a Planície Costeira e o Planalto. A figura ilustra também a localização aproximada dos principais municípios da região, dos *canyons* e dos rios mais importantes, destacando-se o rio Mampituba que separa o Estado do Rio Grande do Sul do Estado de Santa Catarina, ao longo da Planície Costeira. A fronteira entre estes dois Estados no sentido Leste e Oeste ocorre ao longo da escarpa do planalto, a uma altitude aproximada de 900 m, que coincide com o início do Planalto. A linha branca, em diagonal, que aparece na porção oeste na figura 7, ilustra o limite alcançado pela imagem Landsat utilizada neste estudo. A abrangência desta imagem delimita a área utilizada para testar a metodologia investigada. Dentro desta área foram selecionadas duas áreas teste que

foram recobertas com informações mais precisas quanto a sua cobertura (verdade terrestre). Estas três áreas são utilizadas para avaliar quantitativamente a metodologia proposta.

FIG. 7 – Localização da área de estudo



Fonte: Cartas da DSG, na escala 1:250.000, elaboração: Rodrigo Lersch

4.4 MATERIAL UTILIZADO

Na realização destes experimentos foram utilizados os seguintes materiais:

- Imagem Landsat órbita ponto 220_080. Utilizando-se das 6 bandas reflexivas (1, 2, 3, 4, 5 e 7). Obtida em 01/02/2000. A localização desta órbita ponto pode ser vista no

mapa ilustrado na figura 7. Imagem landsat Pancromática banda 8 (05/07/2000), com resolução de 15 m.

- Imagem Áster, em três bandas reflexivas com resolução espacial de 15 m (2, 3 e 4).
- Cartas da Diretoria do Serviço Geográfico do Exército (DSG), na escala 1:250.000.
- Atlas Agroclimático do Rio Grande do Sul (IPAGRO). Sem escala definida.
- Mapa de Solos da Embrapa, em formato digital.
- Composição colorida sob imagens Quick Bird, visualizadas *on-line* com o uso do *Google Earth*.

O *software* necessário para implementar e testar a metodologia proposta foram desenvolvidos em MATLAB. Para fins de pré-processamento e outras operações auxiliares, foram empregados os softwares seguintes:

- Idrisi 32 v. 32.22.
- Carta Linx v. 1.2.
- Surfer v. 6.04 e 7.
- Envi v. 3.2.
- Multispec v. 2.8.
- Spring v. 4.0.
- eCognition v. 4.0.
- Google Earth.
- Corel Draw v. 9.

4.5 ELABORAÇÃO DE P.I.S PARA AS VARIÁVEIS AUXILIARES

Nesta seção são relacionadas as variáveis auxiliares utilizadas neste experimento. Neste processo são inicialmente identificadas as variáveis que apresentam potencialmente poder discriminante com relação à classe Mata Nativa com Araucária. Conforme a metodologia proposta no Capítulo 3, estas variáveis são investigadas individualmente com respeito à sua capacidade de separar a classe Mata Nativa com Araucária das demais classes presentes na cena.

As variáveis selecionadas e utilizadas podem ser enquadradas dentro de dois grandes grupos. Um primeiro grupo compreende variáveis que descrevem as características ambientais favoráveis ao desenvolvimento da Mata Nativa com Araucária, como precipitação média anual, temperatura média anual, altitude do terreno e tipo de solo. Em um segundo grupo

encontram-se incluídas variáveis que contém informações de natureza espectral e espacial, retratando características físicas desta formação florestal. Neste segundo grupo enquadram-se variáveis que podem ser estimadas a partir de imagens digitais de sensoriamento remoto, tais como textura, índices de vegetação (NDVI), frações de sombra e de vegetação em pixels, além de outras.

Conforme a metodologia proposta, estas variáveis são individualmente organizadas em formato imagem (*raster*), estruturados (computacionalmente) na forma de P.I.s em um SIG, para fins de estimação de seu poder discriminante com relação à classe Mata Nativa com Araucária e possível utilização na geração das variáveis de confiança e plausibilidade a serem posteriormente utilizadas no processo de classificação.

A seguir são descritas as variáveis (estruturadas na forma de P.I.s) utilizadas neste experimento.

4.5.1 TEMPERATURA MEDIA ANUAL

Os dados referentes à temperatura média foram extraídos do Atlas Agroclimático do Rio Grande do Sul, volume 3, elaborado pelo IPAGRO (Instituto de Pesquisas Agronômicas do Estado do Rio Grande do Sul, IPAGRO, 1989). Uma das dificuldades encontradas na elaboração deste P.I., refere-se ao fato de que aquele documento não possui as características de um documento cartográfico apresentando uma escala pequena para as finalidades deste experimento, aproximadamente: 1:2,000,000. Para verificar a confiabilidade dos dados fornecidos pelo Atlas Agroclimático, foram aplicados métodos de interpolação aos dados coletados pelas estações meteorológicas disponíveis no Estado do Rio Grande do Sul e também utilizados dados disponíveis para regiões limítrofes à área de estudo localizadas no Estado de Santa Catarina. Os resultados mostraram uma razoável concordância com os dados fornecidos pelo Atlas Agroclimático do Rio Grande do Sul, que foi então utilizado na elaboração do P.I referente à temperatura média anual.

Com as limitações impostas pela falta de dados adequados, o P.I. referente às temperaturas médias anuais foi então elaborado seguindo uma metodologia usual. A etapa inicial consistiu da digitalização do mapa base disponível em um *scanner* com uma resolução espacial de 300 DPI. A imagem em formato matricial assim obtida foi então georreferenciada

em coordenadas geográficas, sistema este utilizado pelo Atlas Agroclimático, e posteriormente convertida para o sistema UTM (Universal Transversa de Mercator), fuso cartográfico 22 S e Datum Horizontal SAD69.

As isotermas foram digitalizadas sobre esta base, gerando um mapa vetorial com a temperatura média anual. Este mapa foi posteriormente transformado para formato matricial por meio de métodos de interpolação (Kriging). Neste P.I. pode-se observar regiões de temperatura mais baixas (em torno de 14°C) situadas no Planalto, principalmente na região norte do Estado, devido a maior altitude. As temperaturas médias anuais aumentam com o decréscimo da altitude, atingindo o valor aproximado de 19°C junto à costa. Na região de estudo, é verificado, portanto, um gradiente de 5°C.

4.5.2 PRECIPITAÇÃO MÉDIA ANUAL

A metodologia empregada na elaboração deste segundo P.I. foi idêntica à utilizada no P.I. referente às Temperaturas Médias, inclusive, quanto à fonte (IPAGRO, 1989) e o processo de georreferenciamento, digitalização e interpolação, havendo sido utilizado novamente o interpolador Kriging. Como a fonte dos dados foi à mesma daquela utilizada na elaboração do P.I. de temperatura os problemas anteriormente relatados também foram os mesmos.

Os valores obtidos nestes procedimentos (tanto a Temperatura, quanto a Precipitação) apresentam boa concordância com valores encontrados em outras fontes que descrevem as características climáticas dos municípios situados na região de estudo (IBGE, 1978; DNPEA, 1973 e outros).

Este P.I. mostra que os valores mais altos para precipitação ocorrem no Planalto. Estes valores tendem a diminuir na região da Planície Costeira. Este fato comprova que as condições climáticas favoráveis para o desenvolvimento da *Araucaria angustifolia* encontram-se nesta área. A região ao sudoeste da imagem é a que apresenta a maior precipitação e, portanto, as condições mais favoráveis, segundo este critério, para o desenvolvimento desta espécie.

4.5.3 ALTITUDE DO TERRENO

A metodologia para a elaboração deste P.I. difere daquela empregada nos anteriores, tanto no que diz respeito à fonte de dados, quanto na metodologia utilizada em sua geração. Como fonte de dados foram utilizadas as cartas da Diretoria do Serviço Geográfico do Exército (DSG), na escala 1:250.000. Nesta escala as cartas Vacaria e Gravataí abrangem toda a área de estudo. Os dados necessários foram obtidos por digitalização das curvas de nível nestas duas cartas. O mapa em formato matricial foi então obtido aplicando-se um interpolador, neste caso a Triangulação de Delaunay (TIN).

4.5.4 CLASSES DE SOLO

Para a elaboração deste P.I. utilizou-se um mapa pedológico do Estado do Rio Grande do Sul em formato digital, elaborado pela Empresa Brasileira de Pesquisas Agropecuárias (EMBRAPA). Como passo inicial, foi necessário recortar o mapa pedológico ao longo do limite da área de estudo, posteriormente, foi realizado o processo de ajuste, fechamento e classificação dos polígonos.

4.5.5 PROBABILIDADE DE OCORRÊNCIA DE MATA NATIVA COM ARAUCÁRIA

Este P.I. consiste de uma imagem classificada (com o uso da função decisão MVG) da região de estudo, contendo a classe Mata Nativa com Araucária. Dentro do contexto deste estudo, o método de classificação genericamente denominado de *fuzzy* foi utilizado. Classificadores que implementam este conceito, não produzem uma única imagem classificada final, como ocorre com classificadores do tipo *hard*. Em lugar de uma classificação final, são produzidas imagens de probabilidade ou de grau de pertinência de cada pixel a cada uma das classes em consideração. O produto final de um classificador deste tipo consiste em uma série de imagens, cada uma delas associada a uma das classes envolvidas no processo de classificação. No classificador utilizado, o valor associado a cada

pixel em cada uma das imagens, é obtido pelo quociente da função decisão associada à respectiva classe, pelo somatório de todas as funções decisão, conforme a equação (8):

$$P_i(X) = \frac{G_i(X)}{G_1(X) + G_2(X) + \dots + G_n(X)} \quad (8)$$

onde, i é a classe em questão e n o número de classes.

Este valor está contido no intervalo [0,1]. O valor zero indica um valor nulo para a probabilidade de um particular pixel pertencer à classe em consideração e o valor 1 indica a probabilidade máxima. A abordagem *fuzzy* para o processo de classificação é especialmente adequada ao contexto deste estudo. A imagem de probabilidades (ou de grau de pertinência) associada à classe Mata Nativa com Araucária pode ser tratada dentro de um ambiente de um SIG como um P.I. adicional contendo dados de probabilidade de ocorrência da classe Mata Nativa com Araucária a partir de dados multiespectrais. Neste caso, pode-se tornar mais conveniente expressar esta imagem no intervalo [0,255] em lugar do intervalo [0,1]. No presente estudo, foram consideradas 19 classes de cobertura do solo para fins de classificação pelo classificador *fuzzy*:

- Mata Nativa com Araucária
- Campo
- Pinus
- Solo exposto 1
- Solo exposto 2
- Desmatamento 1
- Desmatamento 2
- Florestamento de Exóticas
- Área Urbana
- Lago
- Sombra
- Cultivo 1
- Cultivo 2
- Zona de arrebentação das ondas do mar
- Mar
- Morro (encosta SW)
- Mata de Encosta 1
- Mata de Encosta 2
- Mata de Encosta 3

4.5.6 ÍNDICE DE VEGETAÇÃO (NDVI)

O Índice de vegetação (ou NDVI) é um índice espectral utilizado para representar características da cobertura vegetal, tais como: área folhar, biomassa, peso da vegetação úmida, peso da vegetação seca, percentual de cobertura vegetal e outros. O valor do NDVI pode ser obtido a partir de medidas em campo ou através de dados orbitais. No caso de dados orbitais, a estimação do valor do NDVI requer uma banda na região do espectro eletromagnético compreendida entre 0.63 a 0.7 μm (faixa do vermelho visível) na qual os valores de radiancia refletida decrescem com o aumento da vegetação verde, e outra banda na região entre 0.7 e 1.1 μm (região do infra-vermelho próximo) na qual os valores de radiancia refletida aumentam na medida em que a concentração de vegetação verde também aumenta. A faixa compreendida dentro da faixa do vermelho visível é conhecida como banda de absorção provocada pela clorofila, constituindo-se em um indicador sensível da vegetação verde. A segunda região (0.7 e 1.1 μm) representa uma faixa na qual a vegetação verde apresenta uma alta reflectância em função da estrutura e dos componentes presentes na folha, constituindo-se em uma região também adequada para monitorar a vegetação. Neste estudo, o NDVI foi estimado por meio da relação:

$$NDVI = \frac{\mathcal{X}_{NIR} - \mathcal{X}_{RED}}{\mathcal{X}_{NIR} + \mathcal{X}_{RED}} \quad (9)$$

onde \mathcal{X}_{NIR} e \mathcal{X}_{RED} são os contadores digitais nas bandas no infra-vermelho e vermelho, respectivamente

Este índice foi desenvolvido por Deering e Hass (SPRING, 2004) durante um estudo de aplicação dos dados do Landsat 1 em 1973, o sensor empregado na época era o MSS, utilizando-se das faixas do vermelho e infra-vermelho próximo deste sistema sensor.

O procedimento para geração da imagem contendo o índice de vegetação é feito implementando equação anterior (9) dentro de qualquer *software* padrão. No caso deste estudo foram utilizadas imagens Landsat TM, os dados de entrada necessários são obtidos com utilização das bandas 3 e 4 deste sensor.

4.5.7 IMAGENS DE FRAÇÃO DE VEGETAÇÃO E DE SOMBRA

Estudos recentes tem demonstrado a utilidade do conceito mistura espectral no estudo de cenas naturais, Haertel e Shimabukuro (2004 e 2005), Shimabukuro e Smith (1991). Em cenas naturais, a grande maioria dos pixels podem ser considerados como abrangendo mais de uma classe de cobertura do solo. Uma vez identificadas às classes presentes na cena e que serão tratadas como componentes no problema da mistura (*endmembers*), o modelo de mistura espectral permite estimar para cada pixel, as frações ocupadas por cada uma das componentes. Com o objetivo de facilitar a utilização das informações relativas às frações, estes dados são comumente estruturados na forma de “imagens de fração”. As imagens de fração são organizadas em formato imagem (*raster*), nas mesmas dimensões da imagem multiespectral utilizada e em numero igual ao das componentes. Em cada imagem de fração, o valor associado a um pixel estima a fração deste pixel ocupada pela correspondente componente. O Modelo Linear de Mistura Espectral (MLME) vem sendo amplamente utilizado pela comunidade internacional na estimação das frações.

No MLME a resposta em cada pixel (contador digital, radiância ou reflectância) é modelada pela combinação linear da resposta de cada componente individual dentro do pixel:

$$\begin{aligned} r_1 &= a_{11} x_1 + a_{12} x_2 + \dots + a_{1n} x_n + e_1 \\ r_2 &= a_{21} x_1 + a_{22} x_2 + \dots + a_{2n} x_n + e_2 \\ &\dots \\ r_m &= a_{m1} x_1 + a_{m2} x_2 + \dots + a_{m2} x_n + e_m \end{aligned}$$

Ou, em uma notação mais sintética:

$$r_i = \sum_{j=1}^m a_{i,j} x_j + e_i \quad (10)$$

sendo:

$i = 1, \dots, m$ (número de bandas)

$j = 1, \dots, n$ (número de componentes)

r_i = resposta espectral na $i^{\text{ésima}}$ banda espectral de um pixel

$a_{i,j}$ = reflectância espectral conhecida do $j^{\text{ésimo}}$ componente na $i^{\text{ésima}}$ banda espectral.

x_j = valor a ser estimado de proporção do $j^{\text{ésimo}}$ componente dentro do pixel; e

e_i = erro de estimação para a $i^{\text{ésima}}$ banda espectral.

As j frações em cada pixel são estimadas resolvendo o sistema de m equações lineares acima (10). Como em situações práticas o número de equações (m) é maior do que o numero de

incógnitas (n), o sistema é resolvido pelo método dos mínimos quadrados. Par que a solução (frações) tenha sentido físico torna-se necessário à aplicação das seguintes restrições (11 e 12):

$$\sum_{j=1}^n x_j = 1 \quad (11)$$

$$0 \leq x_j \leq 1 \quad (12)$$

O emprego do MLME requer o conhecimento prévio das respostas espectrais das classes componentes em cada uma das bandas espectrais empregadas. Os valores das respostas espectrais das componentes podem ser obtidos ou de bibliotecas espectrais ou por meio dos chamados “pixels puros”. Pixels puros são pixels disponíveis na imagem e que podem ser assumidos como cobertos integralmente por uma única classe componente.

Estudos, realizados por vários autores, tem demonstrado ser adequado na investigação de cenas naturais à utilização de três classes componentes: vegetação, solo exposto e sombra. Neste estudo, estas três componentes são consideradas na geração de imagens de fração cobrindo a área de estudo. Estudos desenvolvidos por Shimabukuro (1987) mostraram que as frações de vegetação e sombra são adequadas à classificação de áreas com florestas.

Em termos operacionais existem três formas de se gerar imagens de mistura: a partir de uma biblioteca espectral, através de medidas em campo e com o auxílio de “pixels puros”, isto é, pixels disponíveis na imagem e que incluem apenas uma classe.

Nesta tese foi empregada a abordagem de “pixel puro” no MLME. Foram consideradas três componentes (*endmembers*), vegetação, sombra e solo exposto. As imagens de fração foram geradas utilizando-se o *software Spring*.

4.5.8 TEXTURA DA IMAGEM

Uma imagem digital contém basicamente três tipos de informação úteis ao processo de análise e classificação desta imagem: informações espectrais, espaciais e de contexto. As informações espectrais referem-se à resposta característica de cada tipo de cobertura do solo nas várias bandas espectrais disponíveis. As informações espaciais referem-se a dados tais

como forma, dimensão e textura de regiões ou objetos na cena em estudo. As informações de contexto dizem respeito à vizinhança do pixel em consideração e são devidas à correlação espacial que existe entre as classes presentes em cenas naturais. Tradicionalmente as informações espectrais tem sido as mais utilizadas para a análise de imagens com auxílio de computadores. Este fato deve-se à facilidade com que dados espectrais podem ser facilmente quantificados. Informações espaciais e de contexto são de quantificação mais difícil, razão pela qual sua implementação no processo de classificação tem sido mais limitada. Estudos desenvolvidos por alguns autores têm, entretanto demonstrado que informações espaciais e de contexto podem ser úteis no processo de classificação de imagens em sensoriamento remoto. Dados relativos à textura são, por exemplo, úteis na discriminação de tipos de cobertura florestal; Luckman, *et al.* (1994), Kurvonen e Hallikainen (1999), Oliver (2000) e Proisy, *et al.* (2007). Desta forma, imagens de textura forma também incluídas neste estudo.

Métodos para Quantificação de Textura

Vários pesquisadores tem investigando métodos adequados à quantificação do atributo textura em imagens digitais. Entre as várias propostas, as matrizes de co-ocorrência, originalmente propostas por Haralick, tem se mostrado adequada à captura de dados de textura. A matriz de co-ocorrência (ou de Haralick) representada por GLCM tem uma dimensionalidade igual ao numero de níveis de cinza (contadores digitais) presentes na imagem e cada elemento nesta matriz expressa o número de co-ocorrências de níveis de cinza entre pares de pixels vizinhos em uma região da imagem (Haralick, *et al.*, 1973 e Haralick, 1979). A forma geral destas matrizes está ilustrada na figura 8.

FIG. 8 – Forma Geral da Matriz de Co-Ocorrência

		Níveis de Cinza			
		0	1	...	Ng
0	0	# (0,0)	# (0,1)	...	# (0,Ng)
	1	# (1,0)	# (1,1)	...	# (1,Ng)
	⋮	⋮	⋮		⋮
	Ng	# (Ng,0)	# (Ng,1)	...	# (Ng,Ng)

Os elementos na matriz de co-ocorrência são geralmente normalizados, de acordo com a expressão (13):

$$P_{ij} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}} \quad (13)$$

onde:

- i : Representa o número da linha na matriz de co-ocorrência.
- j : Representa o número da coluna na matriz de co-ocorrência.
- $V_{i,j}$: Repres. o número de co-ocorrências no elemento (i,j) da matriz de co-ocorrência
- $P_{i,j}$: Representa o valor do elemento na posição (i,j), em termos de frequência.
- N : Número de linhas e colunas.

Várias estatísticas podem ser extraídas da matriz de co-ocorrência, servindo para quantificar as características texturais nas várias regiões da imagem. Neste ponto cabem duas considerações: (1) o método para extração de dados de textura deve ser invariante frente à rotação da imagem e (2) como a textura refere-se não a um pixel isolado, mas, a uma região da imagem, o processo de extração de textura deve ser precedido de uma segmentação da imagem. A solução para o primeiro item consiste em adotar-se quatro matrizes de co-ocorrência, com diferentes orientações (0°, 45°, 90° e 135°). As estatísticas que quantificam a textura são então estimadas pelas 4 matrizes. O segundo item é atendido implementando-se um processo de segmentação da imagem em sub-áreas texturalmente homogêneas. Na literatura podem ser encontradas diversas abordagens ao problema da segmentação (Chen *et al.*, 1998, Qiming and Khoshgoftaar, 2006, Awad *et al.*, 2007, Tabb and Ahuja, 1997). Uma revisão bastante abrangente das várias abordagens ao problema de segmentação de uma imagem pode ser encontrado em Gonzales e Woods (1992). A metodologia adotada em cada caso, deve atender aos objetivos da segmentação, isto é, deve produzir segmentos que sejam significativos para as finalidades a que o estudo se propõe. Um problema que frequentemente ocorre, quando se aplica métodos convencionais para segmentar uma imagem, consiste no fato de que os segmentos resultantes carecem de um sentido maior tendo em vista as finalidades da análise proposta. O processo conhecido como segmentação em múltipla resolução foi desenvolvido para superar este problema (Baatz et al., 2003, Navuluer, 2007). Este processo implementa basicamente o conceito de agrupamento de regiões semelhantes (*merging*), iniciando ao nível de um pixel e continuando formando regiões mais extensas. A cada passo neste procedimento, duas regiões podem ser agrupadas em segmentos mais

extensos, conforme os critérios de semelhança adotados. Esta abordagem apresenta a vantagem da flexibilidade, permitindo ao analista decidir sobre as características dos segmentos a serem formados. Uma descrição mais detalhada deste processo de segmentação pode ser encontrado em Baatz and Schäpe, (1999) e encontra-se implementado no *software* eCognition.

Uma vez segmentada a imagem, foi aplicada a metodologia empregando a matriz de co-ocorrência de Haralick, em suas quatro orientações (0°, 45°, 90° e 135°), gerando as seguintes estatísticas adotadas neste estudo:

Contraste

A variável contraste estima o grau de heterogeneidade em uma imagem, isto é, a ocorrência de valores muito distintos de brilho em pixels vizinhos. O grau de contraste em uma imagem pode ser estimado por meio da matriz de co-ocorrência. Pares de pixels que apresentam grandes diferenças de brilho, ocupam posições afastadas da diagonal principal. Pares de pixels com baixo contraste localizam-se próximos à diagonal principal. Esta diagonal principal é formada por pares de pixels com idêntico brilho, isto é, com contraste zero.

O contraste pode, portanto ser estimado por (14):

$$\sum_{i,j=0}^{N-1} P_{i,j} (i-j)^2 \quad (14)$$

Correlação

Este atributo de textura estima a dependência linear dos níveis de cinza (contadores digitais) dos pixels vizinhos, registrados na imagem. Pode ser estimado por (15):

$$\sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i-\mu_i)(j-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (15)$$

Dissimilaridade

É similar ao atributo textural contraste, porém aumenta linearmente com a distância à diagonal principal na matriz de co-ocorrência. Da mesma forma que no caso da variável contraste, a dissimilaridade (16) cresce com o numero de pares de pixels com brilho muito distinto, isto é, valores grandes para o valor absoluto da distancia ($i - j$) :

$$\sum_{i,j=0}^{N-1} P_{i,j} |i - j| \quad (16)$$

Entropia

A entropia pode ser entendida como uma medida do grau de uniformidade (ou não uniformidade) de uma região na imagem. O valor da entropia cresce com a uniformidade na região, isto é, a entropia é alta quando os elementos na matriz de co-ocorrencia estão distribuídos de uma maneira uniforme. Entropia é estimada com a seguinte equação (17):

$$\sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j}) \quad (17)$$

Homogeneidade

A homogeneidade nos valores de brilho em uma região pode ser estimada pela distribuição dos elementos na matriz de co-ocorrência. Pares de pixels com brilho idêntico ou muito próximo estarão localizados ao longo da diagonal principal da matriz de co-ocorrência. A homogeneidade apresenta, portanto, características inversas às de contraste. A homogeneidade é estimada por (18):

$$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2} \quad (18)$$

Média

Média é estimado por (19):

$$\mu_{i,j} = \frac{\sum_{i,j=0}^{N-1} P_{i,j}}{N^2} \quad (19)$$

Momento Angular

O atributo Momento Angular é estimado pela seguinte equação (20):

$$\sum_{i,j=0}^{N-1} P_{i,j}^2 \quad (20)$$

Desvio Padrão

A textura baseada em desvio padrão faz uso da matriz de co-ocorrência, portanto, muito especificamente ligado com as combinações referentes aos pixels vizinhos. Isto não é exatamente igual ao simples desvio padrão registrado nos contadores digitais da imagem original. Neste caso o calculo do desvio padrão, utilizando-se de i e j da o mesmo resultado pois a matriz de co-ocorrencia é simétrica. O desvio padrão mede a dispersão dos valores em torno da média, similarmente ao contraste e dissimilaridade. O desvio padrão é estimado por (21):

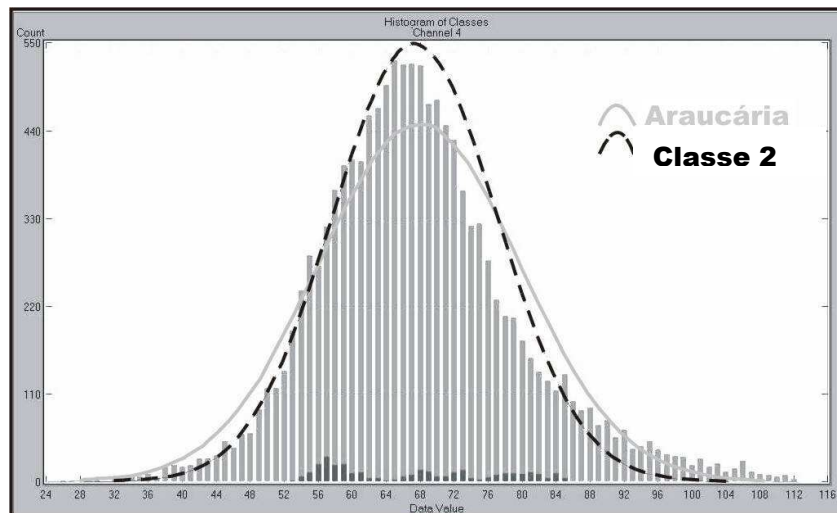
$$\sigma_{i,j}^2 = \left[\sum_{i,j=0}^{N-1} P_{i,j}(i, j) - \mu \right]^{1/2} \quad (21)$$

4.6 AMOSTRAS DE TREINAMENTO: AVALIAÇÃO DA NORMALIDADE DAS CLASSES E VARIÁVEIS

Durante a rotina padrão de tomadas de amostras de treinamento tomou-se o cuidado de analisar os histogramas de cada uma das classes selecionadas para verificar a normalidade de cada uma das classes, procedendo-se assim ajustes ou eliminação das classes que apresentavam pior desempenho, quanto a uma distribuição normal, como critério para avaliar a normalidade se utilizou a análise visual, na qual, buscou-se curvas com distribuição unimodal e simétrica, descrevendo a forma geral da curva de Gauss. A figura 9 apresenta um histograma que demonstra o comportamento das amostras de Mata Nativa com Araucária (com distribuição claramente normal) em relação a uma segunda classe (com distribuição distante de uma curva normal).

O critério de normalidade dos histogramas foi também avaliado com relação as variáveis, no caso de existir ausência, ou uma fraca tendência ao comportamento normal, verificado para todas as classes selecionadas em uma determinada variável (valido apenas para variáveis de origem espectral). Verificou-se que havia canais com bom comportamento (quanto a uma curva normal) para todas as classes e outros que apresentavam distribuições, razoavelmente, normais para várias classes. Com base na análise do critério da normalidade dos histogramas das variáveis optou-se por aceitar todos os canais envolvidos, uma ressalva neste sentido é que as variáveis referentes à textura foram sempre as que apresentaram o pior comportamento, principalmente a variável correlação que não apresentou comportamento normal para nenhuma classe, devido a este motivo esta variável foi então eliminada.

FIG. 9 – Normalidade dos Histogramas p/ as classes



4.7 ESTIMAÇÃO DO PODER DISCRIMINANTE DAS VARIÁVEIS AUXILIARES

As variáveis auxiliares relacionadas na seção 4.5 foram organizadas na forma de arquivos imagem em formato raster, cobrindo a área de estudo.

Conforme a metodologia proposta, a etapa seguinte consiste na avaliação do poder discriminante de cada uma das variáveis selecionadas na seção 4.5. O objetivo aqui consiste em reter apenas as variáveis que apresentam um poder discriminante razoável no processo de classificação. Neste experimento ilustrativo da metodologia proposta, busca-se, portanto, investigar quais as variáveis capazes de contribuir para a separação da classe Mata Nativa com Araucária.

É proposto aqui estimar este poder discriminante de cada variável individual, pela acurácia do usuário resultante da utilização de cada variável em separado na produção de um mapa temático para a classe Mata Nativa com Araucária. Cabe aqui recordar que a acurácia do usuário estima a confiabilidade na imagem temática produzida pelo classificador. Em outras palavras, dado um pixel rotulado como Mata Nativa com Araucária, a acurácia do usuário estima a probabilidade de que este pixel efetivamente corresponda a aquela classe.

Para cada variável individual gerou-se uma imagem temática cobrindo a área de estudo. Ao todo 19 classes de cobertura do solo foram identificadas na área de estudo. Amostras de treinamento e de teste foram extraídas para cada variável, para a produção de uma imagem temática e a correspondente estimação da acurácia do usuário para a classe Mata Nativa com Araucária. Dada a diversidade existente entre as variáveis, dois processos de classificação foram empregados. Para variáveis normalmente distribuídas como, por exemplo, variáveis espectrais e de textura, foi utilizado o classificador Máxima Verossimilhança Gaussiana (MVG). Para variáveis não normalmente distribuídas como, por exemplo, altitude e temperatura media anual, foi empregado o classificador Distância Euclidiana Mínima. Os valores obtidos estão relacionados na tabela 1.

TABELA 1 – Resultados do MVG e Dist. Eucl.

VARIÁVEIS:	Acurácia do Usuário p/ Araucária
1- Bandas espectrais TM	89.7
2- Altitude (Dist.Eucl.)	51
3- Temperatura (Dist.Eucl.)	51.5
4- Precipitação (Dist.Eucl.)*	0
5- Solos (Dist.Eucl.)*	0
6- NDVI (MVG)	46.3
Pixel Mistura	
7: Sombra (MVG)	51.3
8- Vegetação (MVG)	35.2
Textura	
9- Contraste (MVG)	33.8
10- Correlação (MVG)*	37.7
11- Dissimilaridade (MVG)	37.2
12- Entropia (MVG)	41.3
13- Homogeneidade (MVG)	45.4
14- Média (MVG)	61.3
15- Momento Angular (MVG)*	0
16- Desvio Padrão (MVG)	36

* Variáveis descartadas

Observa-se que das 16 variáveis inicialmente consideradas, apenas 13 apresentaram valores razoáveis para a acurácia do usuário relativa à classe Mata Nativa com Araucária, sugerindo um poder discriminante aceitável. Como a variável correlação já havia sido descartada na etapa anterior restaram 12 variáveis selecionadas, sendo as demais descartadas do processo.

4.8 ESTIMAÇÃO DAS EVIDÊNCIAS E INTRODUÇÃO DAS INCERTEZAS

Uma vez identificadas as variáveis auxiliares que apresentam condições para contribuir ao processo de identificação da classe Mata Nativa com Araucária, prossegue-se para a etapa seguinte na metodologia proposta, que consiste na geração das evidências fornecidas por cada variável na identificação da classe Mata Nativa com Araucária.

Os graus de evidência em favor da classe Mata Nativa com Araucária, associados a cada uma das variáveis selecionadas são estruturados na forma de P.I.s, em formato raster, registrados com a imagem multiespectral utilizada, cobrindo a área de estudo. Nestes P.I.s, o valor associado a cada pixel representa o valor estimado quantificando a evidência disponível em favor da classe Mata Nativa com Araucária.

Para fins de estimação destes graus de evidência foi utilizada a abordagem proposta por Lee *et al.* (1987). Inicialmente é estimada a incerteza existente quanto à pertinência do pixel à classe Mata Nativa com Araucária. Os valores estimados para as evidências são distribuídos no intervalo restante (1-incerteza), de tal forma que o somatório da incerteza mais as evidências deve ser igual à unidade (Figura 3).

Nesta tese a incerteza é estimada pelo complemento da acurácia do usuário resultante de cada uma das variáveis selecionadas (1). Deve-se recordar aqui que a acurácia do usuário estima a probabilidade de que um pixel rotulado pelo classificador em uma determinada classe, efetivamente pertença a esta classe. Valores muito baixos para a acurácia do usuário (com relação à classe Mata Nativa com Araucária) resultam, portanto, em valores altos para incerteza, justificando a decisão de descartá-las (as variáveis). O complemento restante é distribuído proporcionalmente entre a evidência disponível em favor da classe Mata Nativa com Araucária e da classe “outros”.

Uma vez estimados os valores para a incerteza, etapa seguinte consiste em estimar as evidências associadas à classe Mata Nativa com Araucária. Neste exemplo ilustrativo da metodologia proposta, três casos devem ser considerados:

- 1- Variáveis contínuas e que apresentam uma distribuição Normal com relação à classe Mata Nativa com Araucária (dados multiespectrais, NDVI, frações de Sombra e de Vegetação, variáveis associadas à textura da imagem).
- 2- Variáveis contínuas mas que não apresentam uma distribuição Normal para a classe Mata Nativa com Araucária (altitude, precipitação e temperatura media anual).
- 3- Variáveis Categóricas, tipicamente as de origem temática, dentro deste contexto nesta pesquisa investigou-se as classes de solos.

No primeiro caso, propõe-se nesta tese a utilização da função de decisão MVG (22) para estimar a evidência em cada pixel (X) em favor da classe Mata Nativa com Araucária:

$$m(X) = \frac{G_a(X)}{\sum_{j=1}^m G_j(x)} \quad (22)$$

Onde $m(X)$ representa a evidência associada ao pixel X em favor da classe Mata Nativa com Araucária, $G_a(X)$ representa a função decisão MVG para a classe Mata Nativa com Araucária para o pixel X e m representa o numero total de classes na cena.

No caso de variáveis não normalmente distribuídas para a classe Mata Nativa com Araucária, propõe-se aqui a utilização de funções de pertinência apoiadas pelo conhecimento do especialista.

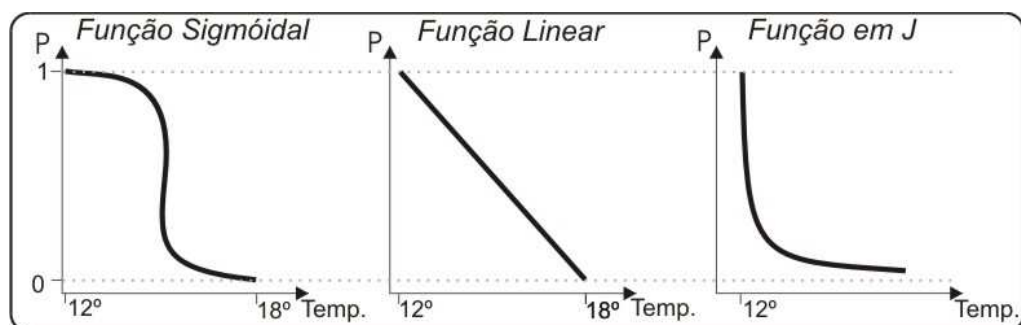
Uma função de pertinência serve para estimar o grau de certeza de um pixel pertencer a uma determinada classe. Funções de pertinência podem ter formas variadas, indicando a forma como o grau de pertinência associado a cada pixel varia, em função da variável em consideração. Uma vez definida a forma geral da função de pertinência, deve-se definir a sua forma particular. Esta etapa é realizada com o auxílio de pontos de controle. Pontos de controle relacionam valores da variável em análise com valores conhecidos para o grau de pertinência (ou de probabilidade). As funções de pertinência mais comumente utilizadas são as seguintes:

- **Sigmóide** - Esta é possivelmente a forma mais comumente utilizada para uma função de pertinência. Como ocorre com as demais formas, a função do tipo sigmoide pode ser do tipo crescente ou decrescente. Em sua forma geral (decrescente), está função

está ilustrada na figura 10. A forma específica que a função crescente assume, é definida por dois pontos de controle. O primeiro ponto de controle estipula o valor da variável independente para o qual o valor do grau de pertinência (ou de probabilidade) associada ao pixel em questão, passa a crescer a partir de um valor nulo. A característica da função sigmóide consiste em que este crescimento ocorre inicialmente a uma taxa baixa. Após, no seu segmento intermediário, o grau de pertinência (ou de probabilidade) passa a crescer a uma taxa mais rápida. No segmento final desta função, o crescimento passa a novamente se efetuar a taxas mais baixas, de uma forma simétrica ao que ocorre no segmento inicial, até atingir o valor integral para o grau de pertinência. Este ponto final é definido pelo segundo ponto de controle. Em sua forma decrescente, as características são semelhantes, mas em um modo decrescente, iniciando pelo valor integral para o grau de pertinência, definido pelo primeiro ponto de controle até um valor nulo, definido pelo segundo ponto de controle.

- **Linear** - é similar à função sigmóide, com a diferença de que neste caso, o grau de pertinência passa a ser uma função linear da variável independente. Como no caso da função sigmóide, a função linear pode ser do tipo crescente ou decrescente, sendo a sua forma particular em cada caso definida por dois pontos de controle. A forma geral (decrescente) da função pertinência linear está ilustrada na figura 10.
- **Em forma de J** - a forma geral (decrescente) desta função está ilustrada na figura 10. Como as funções sigmóide e linear, a função J pode assumir o modo crescente e decrescente. Um ponto que diferencia esta função de pertinência das duas anteriores consiste no fato de que esta função não atinge o valor zero para o grau de pertinência. Em outras palavras, o ramo inferior da função J é assintótico ao eixo da variável independente.

FIG. 10 – Funções de Pertinência



Nesta pesquisa optou-se pelo uso da função sigmóidal em todas as imagens de evidência que foram geradas, pois nenhuma das variáveis utilizadas apresenta um tipo de variação que adquire valores crescentes ou decrescentes indefinidamente até infinito, como a função em J representa. Além disso, as variáveis naturais não apresentam um gradiente de variação constante, como ocorreria se fosse utilizada uma função de pertinência linear. A função de pertinência sigmoidal representa melhor os fenômenos ambientais já que o gradiente mais suave de variação entre os valores extremos condizem melhor com o que de fato acontece na natureza.

No terceiro caso: para variáveis categóricas é necessário que o pesquisador elabore uma metodologia baseada no conhecimento existente a cerca do fenômeno sob análise a fim de transformar dados de origem temática em um novo conjunto de dados que representem valores de adequação para cada uma das classes sob estudo em relação a variável investigada. No caso deste estudo isto foi feito especificamente para a variável classe de solos. Para cada classe de solos existente (segundo as classes adotadas pela EMBRAPA) na região desenvolveu-se um sistema de adequação da espécie *Araucaria angustifolia* a cada classe de solo em função de critérios como: profundidade, granulometria e composição química dos solos. A esta adequação realizou-se uma hierarquização das classes mais aptas até as menos aptas ao desenvolvimento da espécie. Com base nesta hierarquização foi atribuído valores numéricos a cada uma das classes envolvidas. Optou-se por não detalhar aqui todo este procedimento, pois, esta variável acabou sendo cortada durante a fase de estimação das incertezas (capítulo 4.7).

4.8.1 VARIÁVEIS NORMALMENTE DISTRIBUIDAS

Conforme mencionado, na seção anterior, as evidências em favor da classe Mata Nativa com Araucária a partir de variáveis normalmente distribuídas, foram estimadas por meio da função de decisão MVG (22).

Na produção do P.I. relativo as variáveis espectrais foram empregadas as 6 bandas reflectivas de uma cena obtida pelo sistema Landsat-TM cobrindo a área de estudo. As amostras de treinamento extraídas para as 19 classes de cobertura do solo identificadas na cena serviram para a geração das correspondentes 19 funções de decisão $G(X)$, associadas a

estas classes. A equação (22) foi então empregada para estimar o valor da evidência em favor da classe Mata Nativa com Araucária a partir da informação contida na imagem multiespectral.

Procedimento semelhante foi aplicado às demais variáveis normalmente distribuídas (NDVI, fração de sombra e vegetação e as variáveis texturais).

4.8.2 VARIÁVEIS NÃO-NORMALMENTE DISTRIBUÍDAS

Para estas variáveis, as evidências disponíveis foram estimadas a partir de funções de pertinência, conforme mencionado na seção anterior. A seleção da natureza geral e da forma específica da função de pertinência a ser utilizada, requer em cada caso o conhecimento do especialista.

Possivelmente altitude seja a variável de origem física mais importante no contexto deste experimento, já que existem limites claros e bem definidos para a ocorrência da espécie *Araucaria angustifolia* segundo este parâmetro. Estes limites foram explorados e levados em conta durante a seleção da região de estudo, região esta que contempla perfeitamente estas características. A evidência foi gerada seguindo os seguintes critérios: a *Araucaria angustifolia* tende a necessitar de uma maior altitude para compensar uma menor latitude. O Rio Grande do Sul é, assim, o Estado brasileiro que apresenta o mais baixo limite altimétrico onde a conífera consegue chegar. Isto ocorre tipicamente em torno dos 500 m acima do nível do mar, existe consenso entre os pesquisadores que em altitudes muito abaixo deste limite é completamente improvável a dispersão ou aparecimento, de forma natural, da espécie. Na região de estudo existe um gradiente de altitudes que vai de zero metros, até 1300 m acima do nível do mar. Baseando-se nestas características adotou-se como primeiro ponto de controle para uma função de pertinência sigmoïdal crescente, a altitude de 480 m acima do nível do mar, e como segundo ponto de controle a altitude máxima verificada na região (1300 m acima do nível do mar).

Sabe-se que as áreas com ocorrência da *Araucaria angustifolia* se caracterizam por uma temperatura média anual no intervalo entre 12°C a 18°C, sendo que nos meses mais frios algumas regiões podem atingir temperaturas de até -10°C. Com base nestes dados, selecionou-se uma função de pertinência sigmoïdal decrescente para modelar a evidência de um pixel pertencer à classe Mata Nativa com Araucária em função da temperatura média

anual. O primeiro ponto de controle, a partir do qual a função sigmoideal passa a decrescer, foi selecionado como 14.64 °C (mínimo registrado para região de estudo) para a temperatura média anual. O segundo ponto de controle foi escolhido como 18 °C, valor máximo para a temperatura média anual em que se verifica ocorrência de Mata Nativa com Araucária.

Para precipitação média anual, procedimento idêntico ao adotado para a geração da evidência para temperatura média anual foi utilizado para esta variável. Utilizando-se da bibliografia extraiu-se as seguintes informações. A espécie *Araucaria angustifolia* é encontrada em um intervalo de precipitação que vai de 1250 mm a 2450 mm ao ano (que é o máximo no Estado do Rio Grande do Sul). Em áreas condicionadas a menos de 1100 mm ao ano, a ocorrência natural de Mata de Araucária é praticamente inexistente. Analisando-se os dados referentes à precipitação média anual que ocorre na área do experimento, observam-se valores bem superiores a este mínimo exigido pela *Araucaria angustifolia*. Este fato explica o valor igual a zero obtido para a acurácia do usuário quando se emprega somente esta variável, contudo, esta variável foi inicialmente introduzida no modelo por ser uma variável que apresenta grande correlação com a formação florestal estudada, imaginava-se que a sua utilização servisse apenas para gerar um incremento um pouco maior nas áreas de maior precipitação, já que não existiam regiões que inviabilizassem o surgimento da formação florestal.

A evidência relacionada a esta variável foi modelada por uma função sigmoideal crescente, com o primeiro ponto de controle (a partir do qual a evidência cresce) em 1100mm de média anual e o segundo ponto de controle, quando a máxima evidência é atingida, em 2015mm, valor máximo para a precipitação média anual verificada na area deste estudo.

As evidências assim estimadas, em apoio a classe Mata Nativa com Araucária, são combinadas com a incerteza gerando os dados finais de evidência. A evidência relativa à classe “outros” é estimada pelo complemento da evidência estimada para a classe Mata Nativa com Araucária. Após, a soma dos valores estimados para evidência em favor da classe Mata Nativa com Araucária e evidência em favor da classe “outros” são normalizados dentro do intervalo [1-incerteza]. Desta forma, a soma dos três parâmetros (evidências e incerteza) tem valor unitário para cada pixel. Este processo está ilustrado na Figura 2.

4.9 GERAÇÃO DOS DADOS DE CONFIANÇA E PLAUSIBILIDADE

As operações descritas nas seções anteriores resultam na produção de informações relativas às evidências e à incerteza, para cada pixel na cena, em cada uma das variáveis utilizadas. A etapa seguinte na metodologia descrita no Capítulo 3 consiste na estimação dos valores de confiança e plausibilidade associados a cada pixel em cada uma das variáveis selecionadas. Conforme a metodologia descrita no Capítulo 3, a confiança em um pixel pertencer à classe Mata Nativa com Araucária com base em uma determinada variável é quantificada pelo grau de evidência estimado em favor da classe Mata Nativa com Araucária. A plausibilidade deste mesmo pixel pertencer a esta classe é estimada pelo valor da evidência adicionada da incerteza. Quando várias variáveis estão simultaneamente presentes, os valores combinados de evidência e plausibilidade podem ser estimados, para cada pixel individualmente pelo algoritmo da Soma Ortogonal, conforme descrito no Capítulo 3.

4.10 UTILIZAÇÃO DE DADOS DE CONFIANÇA E PLAUSIBILIDADE NA DETECÇÃO DE ERROS DE OMISSÃO E DE INCLUSÃO

Nesta seção, é analisada a contribuição principal desta tese: a utilização, dentro de critérios quantitativos, das informações originadas das variáveis confiança e plausibilidade para fins de uma melhor adequação da acurácia da imagem temática produzida pelo classificador às necessidades do analista.

Confiança estima a evidência sólida que existe em favor de uma determinada classe. Desta forma, pixels que no processo de classificação foram rotulados como pertencendo a uma determinada classe, mas que apresentam um baixo valor para a variável confiança associada a esta classe, devem ser investigados como possíveis erros de inclusão. Por outro lado, plausibilidade estima o grau máximo de evidência em favor da classe correspondente, isto é, a evidência que não justificaria excluir um pixel como pertencente a esta classe. Pixels que apresentam um alto valor para a variável plausibilidade, mas não foram rotulados naquela classe, constituem-se, portanto, em possíveis erros de omissão.

Erros de inclusão afetam diretamente a acurácia do usuário, enquanto erros de omissão afetam a acurácia do produtor para a classe em consideração. Uma utilização adequada de

dados de confiança e de plausibilidade permite ajustar estas duas formas de acurácia em uma imagem classificada de modo a melhor adequa-la aos objetivos do analista.

No presente estudo se propõe a utilização de limiares aplicados às variáveis de confiança e plausibilidade, para fins de filtragem da imagem temática produzida pelo classificador. Erros de inclusão podem ser controlados atribuindo-se um limiar inferior à variável confiança. Pixels rotulados na classe em consideração (neste experimento, a classe Mata Nativa com Araucária), mas que apresentam um valor para confiança abaixo deste limiar pré-estabelecido são assumidos como prováveis erros de inclusão e, portanto, removidos da imagem temática. Da mesma forma, pixels não rotulados na classe Mata Nativa com Araucária, mas que apresentam um valor para plausibilidade acima deste limiar, são assumidos como erros de omissão e portanto incluídos na classe em questão. A imagem temática pode, assim, ser ajustada por meio de uma escolha adequada destes dois limiares. Deve-se aqui observar que um incremento no limiar de confiança tende a incrementar a acurácia do usuário, mas causa também um decréscimo na acurácia do produtor, ao remover pixels corretamente classificados. Uma situação oposta ocorre com o limiar em plausibilidade. Uma redução neste limiar tende a aumentar a acurácia do produtor, mas tende também a reduzir a acurácia do usuário. Nesta tese, propõe-se a utilização conjunta destes dois limiares para ajustar estas duas medidas de acurácia às necessidades do analista.

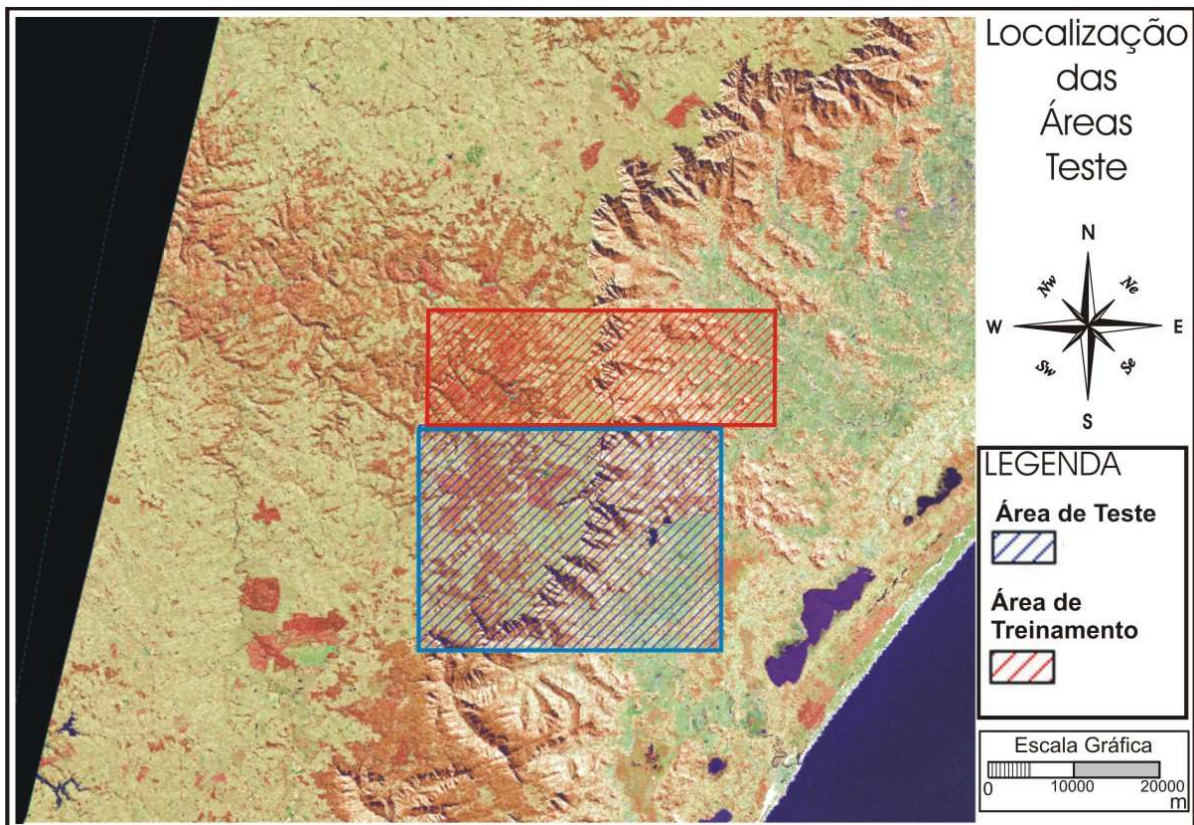
Esta proposta está ilustrada neste experimento, que busca identificar áreas cobertas por Mata Nativa com Araucária. Duas áreas, com verdade terrestre conhecida foram selecionadas para desenvolver este experimento: uma para ser utilizada como área de treinamento e a segunda como área de teste dos resultados obtidos.

Como seria muito difícil dispor de dados reais de verdade terrestre (devido a extensão da área haveria uma grande demanda por recursos financeiros e humanos) os dados que aqui são mencionados como verdade terrestre em realidade se tratam de dados gerados em gabinete utilizando-se de imagens de sensores com resolução espacial muito maior do que a do sensor Landsat TM. Para tanto utilizou-se de uma pequena área no entorno do município de Cambará do Sul. Esta área foi escolhida por contar com uma cobertura de dados de alta resolução espacial (Quick Bird de 2.4 m) disponíveis para visualização (*on-line*, apenas) com a utilização do *software Google Earth*. Primeiramente se gerou uma imagem sintética utilizando-se das bandas 3, 4 e 5 do sensor TM fundidas a imagem pancromática (com 15 m de resolução), deste mesmo sensor. A imagem sintética foi colocada como pano de fundo para digitalização das áreas cobertas com Mata Nativa com Araucária, esta mesma imagem podia ser então confrontada visualmente com a mesma região utilizando-se das composições

coloridas do sensor Quick Bird, isto serviu para tomar decisões, no momento da digitalização, a respeito do real tipo de cobertura presente naquela cena, já que com o uso das imagens do sensor Quick Bird se pode distinguir facilmente áreas de Mata Nativa de todas as demais áreas (inclusive de áreas florestadas com espécies exóticas).

A localização destas duas áreas pode ser vista na figura 11. A figura 11 mostra as duas áreas inseridas dentro da grande área de estudo.

FIG. 11 – Áreas de treinamento e de teste



A área de treinamento serve para definir os limiares de confiança e plausibilidade, conforme um critério pré-estabelecido. A área de teste é utilizada para fins de verificação dos resultados obtidos com a aplicação destes dois limiares. Com a finalidade de procurar o par de limiares que melhor se ajusta aos objetivos do analista, propõe-se nesta tese o uso de dois laços encadeados. O pseudo-código que implementa este procedimento está ilustrado na Figura 12. No laço externo, é testado um conjunto de valores para o limiar de plausibilidade. A cada passo neste laço externo, pixels que apresentam um valor para plausibilidade mais alto do que o limiar, mas não estão rotulados como Mata Nativa com Araucária, são adicionados à imagem temática. No laço interno, são testados valores para o limiar de confiança. Neste laço interno, pixels rotulados como Mata Nativa com Araucária, mas que apresentam um

valor para confiança abaixo deste limiar, são removidos da imagem temática. As acurácias do usuário, do produtor e a acurácia média são estimadas para cada par de limiares, e o par que melhor se ajusta aos objetivos do analista, é selecionado. As curvas ilustrando os valores estimados para estas acurácias são apresentadas na Figura 13.

FIG. 12 – Pseudo Código

```

Selecionar um limiar para plausibilidade

-Adicione pixels que possuem um valor para
plausibilidade maior do que o limiar

        -Selecione um limiar para confiança
        -Remova pixels que apresentam um
        valor para confiança menor do que o
        limiar

        -Estimar as acuracias do usuário e do
        produtor

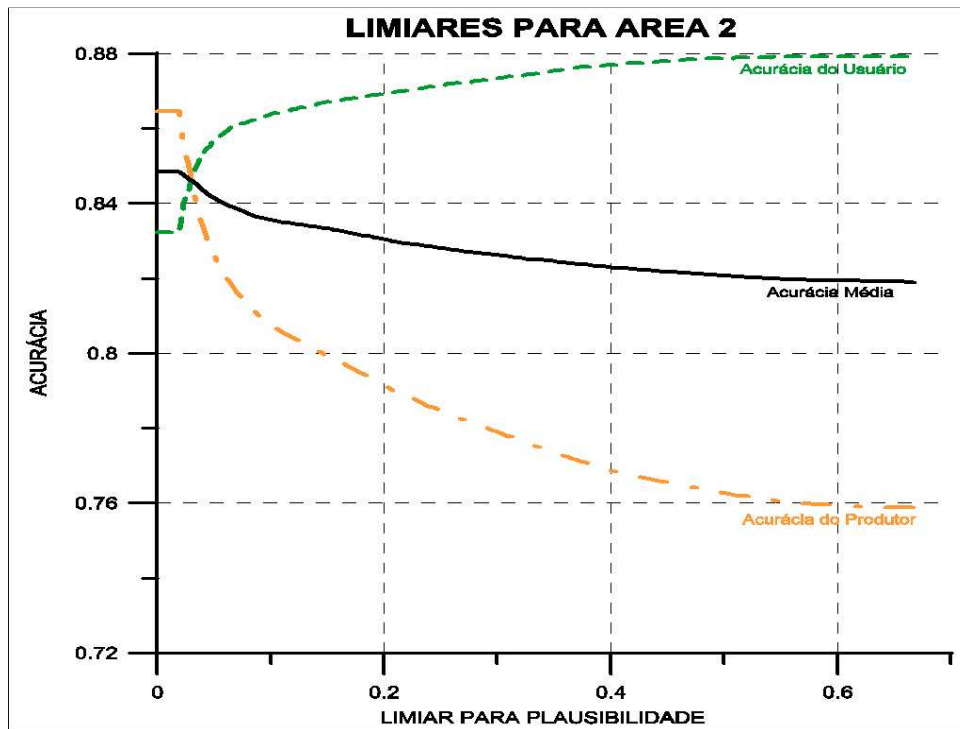
        Fim

Fim

```

As curvas ilustradas na Figura 13 apresentam a configuração esperada. O número de erros de omissão aumenta na medida em que o limiar de plausibilidade também aumenta, resultando em um decréscimo no valor estimado para a acurácia do produtor. Uma situação oposta ocorre com relação ao limiar aplicado à variável confiança, com uma progressiva redução no número de erros de inclusão e um correspondente incremento na acurácia do usuário. O par de valores para estes limiares, que melhor atende aos objetivos do analista é então selecionado e aplicado à totalidade da imagem temática. Neste experimento, o critério adotado consistiu em buscar um equilíbrio entre as acurácias do produtor e do usuário. Com este objetivo selecionou-se o par de limiares correspondente ao ponto de intersecção entre as curvas, isto é, a situação em que os valores estimados para a acurácia do produtor e do usuário são idênticos. No caso deste experimento, o valor do limiar para plausibilidade foi igual a 0.0314 e o limiar para confiança foi de 0.0275. Estes dois valores foram então aplicados à totalidade da imagem temática, produzida pelo classificador MVG, empregando dados Landsat-TM.

FIG. 13 – Acurácias obtidas na área de treinamento



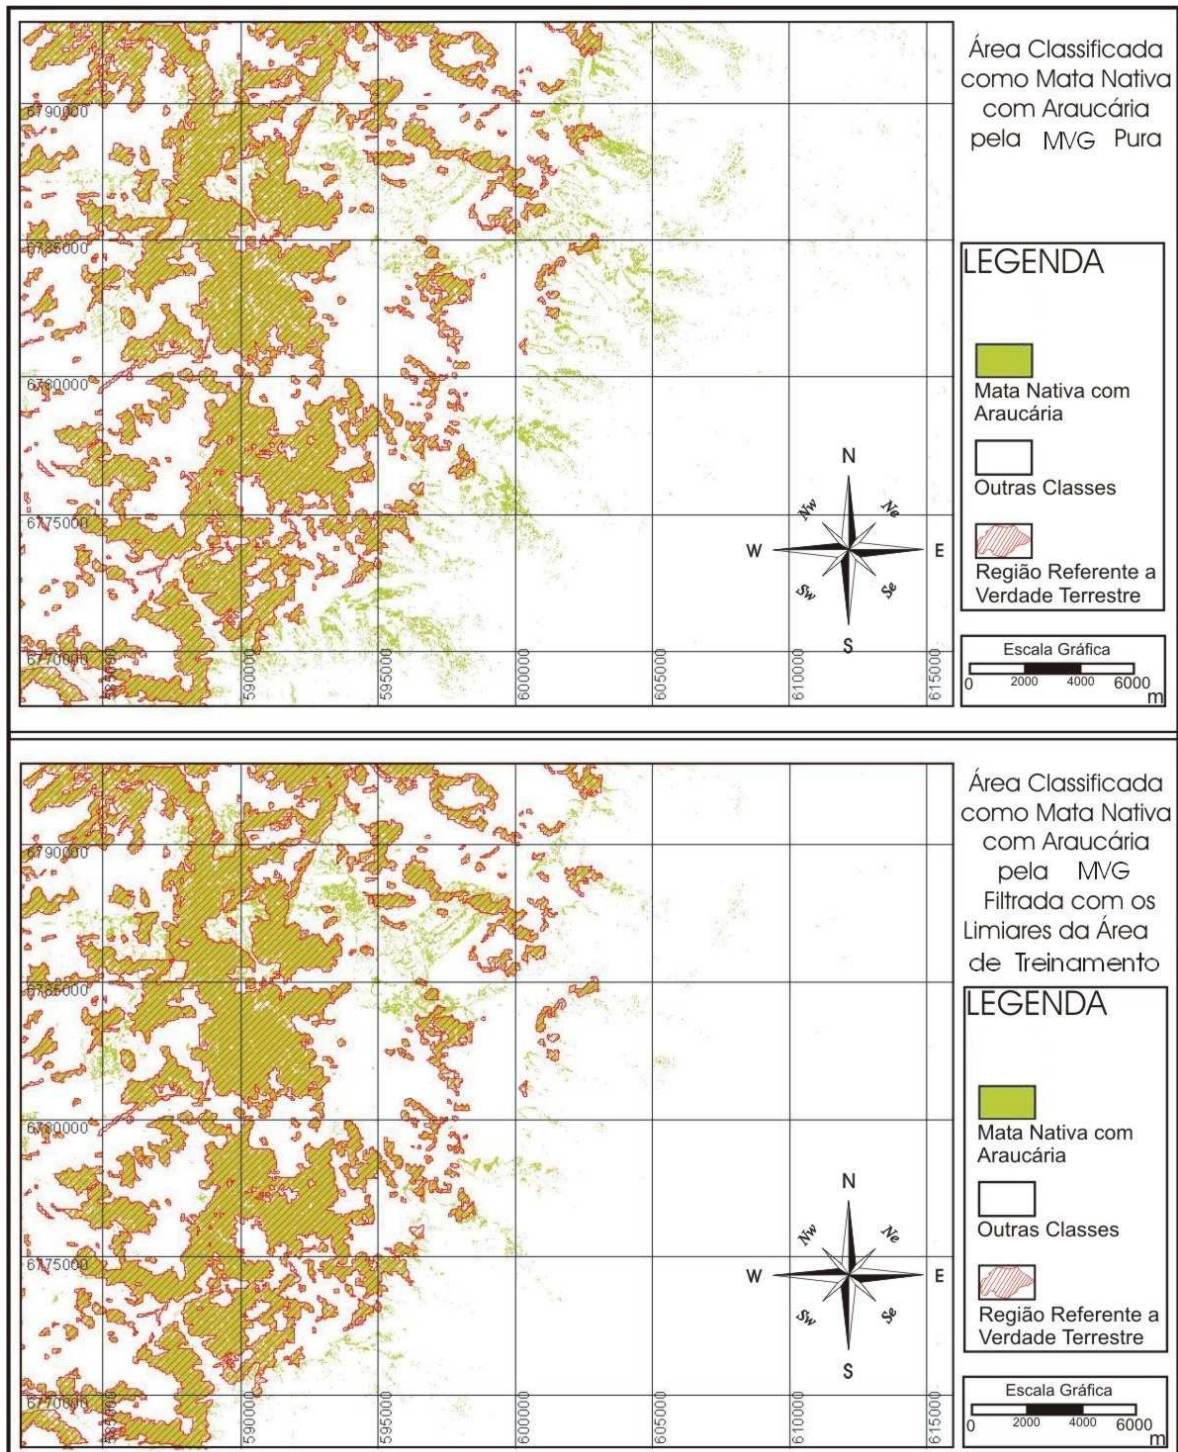
A área de teste foi utilizada para avaliar o efeito deste processo na imagem temática. Os valores para as acurácias do produtor e do usuário estimados nesta área de teste, antes e após a aplicação da metodologia proposta estão apresentados na Tabela 2. Este experimento mostrou um incremento significativo na acurácia da imagem temática, sugerindo assim a adequação da metodologia proposta nesta tese que visa à introdução de variáveis auxiliares no processo de classificação de imagens digitais.

TABELA 2 – Acurácias

	MVG PURA	MVG FILTRADA
Acurácia do Usuário	0.8129	0.8788
Acurácia do Produtor	0.7534	0.8264
Acurácia Média	0.7831	0.8526

O resultado numérico obtido pode também ser ilustrado de forma gráfica, através da figura 14, nesta figura é possível perceber visualmente (principalmente quanto aos erros de inclusão) que houve um ganho após o processo de filtragem.

FIG. 14 – Resultado da filtragem



Os polígonos vermelhos presentes na figura 14, delimitam a região coberta por verdade terrestre, desta forma infere-se que as áreas fora dos polígonos vermelhos representam erros de classificação (erros de inclusão), da mesma forma as áreas com vazios dentro dos polígonos vermelhos (sempre tomando-se como base o primeiro mapa, resultante da MVG pura) representavam possíveis erros de omissão.

5 CONCLUSÕES

Nesta tese foi proposta e avaliada uma metodologia visando à introdução de variáveis auxiliares no processo de classificação de imagens digitais em sensoriamento remoto. Por vezes ocorre em cenas naturais, com o emprego de dados multiespectrais isoladamente, uma imagem temática cuja acurácia está aquém do desejado. Entre as possíveis alternativas para minimizar este problema, encontra-se a introdução de variáveis auxiliares no processo de classificação. Conforme extensivamente reportado na literatura, experimentos desenvolvidos por vários pesquisadores tem mostrado que o uso de variáveis auxiliares apresenta um potencial grande de incremento na acurácia da imagem temática produzida por um classificador.

Por esta razão este tema vem sendo objeto de estudos por vários pesquisadores na comunidade internacional. Várias propostas neste sentido vem sendo apresentadas e relatadas na literatura. O objetivo desta tese consistiu portanto em dar uma contribuição adicional a esta área de pesquisa.

Conceitos originalmente propostos na Teoria da Evidência oferecem uma possível abordagem ao problema de combinar dados oriundos de fontes diversas, tanto de natureza numérica quanto temática. Nesta tese foi proposta uma nova abordagem a este tema, dentro de um critério quantitativo.

Se propôs que as variáveis auxiliares com potencial discriminante relativo as classes presentes na cena, sejam estruturadas em forma de P.I.s à semelhança de um SIG. Em uma etapa seguinte estas variáveis são individualmente testadas com relação a este poder de separação das classes na cena. Nesta etapa as variáveis que apresentam um poder discriminante não significativo são descartadas. Os dados calculados nesta etapa servem também para estimar o valor da incerteza associada a cada uma das variáveis auxiliares. A metodologia prossegue com a estimação das evidências fornecidas pelas variáveis auxiliares em apoio a cada uma das classes presentes na cena. Estes dados permitem a elaboração dos PIs quantificando os valores estimados para confiança e plausibilidade associados a cada pixel em cada uma das classes.

A utilização quantitativa dos valores estimados para confiança e plausibilidade para fins de controle das acurácias do usuário e do produtor foi a principal contribuição original nesta tese. Foi proposta e testada aqui a utilização conjunta destes dois conceitos, como filtros para detecção de erros de inclusão e de omissão. Com esta finalidade foi proposta aqui a

criação de dois limiares, um para confiança e um segundo para plausibilidade, conforme critérios previamente definidos pelo analista. Estes dois limiares servem para definir um intervalo de aceitação para o rótulo atribuído a cada pixel pelo classificador. O limiar em confiança define um valor mínimo para aceitação do rótulo, servindo para detectar possíveis erros de inclusão. O limiar em plausibilidade é utilizado para definir uma fronteira para a introdução de novos pixels, originalmente atribuídos pelo classificador a uma outra classe, detectando, portanto, possíveis erros de omissão. Como os erros de inclusão e de omissão respondem principalmente pelas acurácias do usuário e do produtor, foi proposto nesta tese que o critério para escolha destes dois limiares sejam as acurácias do usuário e do produtor. Desta forma, cabe ao analista adequar os valores destes limiares de forma a melhor atender aos seus objetivos.

Esta metodologia foi testada utilizando dados extraídos de uma cena real. Em adição aos dados multiespectrais obtidos pelo sistema Landsat-TM, foram introduzidas 12 variáveis auxiliares. Estas variáveis auxiliares compreendem tanto dados de natureza física (altitude e temperatura média anual entre outros), quanto dados extraídos da própria imagem (variáveis de textura, índice de vegetação, outros). A metodologia proposta foi aplicada a estes dados gerando as informações finais de confiança e plausibilidade. Com a finalidade de selecionar limiares para confiança e plausibilidade, optou-se neste experimento pelo critério de igualdade entre as acurácias do usuário e do produtor.

Os resultados mostraram que a metodologia proposta atende aos objetivos esperados, servindo para filtrar a imagem temática produzida por um classificador, adequando-a as necessidades do analista.

REFERÊNCIAS BIBLIOGRÁFICAS:

ABKAR, Ali-Akbar, SHARIFI, Mohammed Ali, MULDER, Nanno J., “Likelihood-based image Segmentation and classification: a Framework for the integration of expert knowledge in image classification procedures.” – *Jag – volume 2, Issue 2 –2000*.

AHMADZADEH, Mohammad Reza e PETROU, Maria, “An Expert System With Uncertain Rules Based on Dempster-Shafer Theory” – *Geoscience and Remote Sensing Symposium, 2001 - IGARSS '01. IEEE 2001 International, Julio de 2001 – vol.2 p.861-863 (Digital Object Identifier 10.1109/IGARSS.2001.976661)*.

AWAD, M., CHEHDI, K., e NASRI, A., “Multicomponent Image Segmentation Using a Genetic Algorithm and Artificial Neural Networks” – *IEEE Geoscience and Remote Sensing Letters*, Vol. 4, No. 4, pp. 571-575, 2007.

BAATZ, M. e SCHÄPE, A., “Multiresolution Segmentation: an Optimization Approach for High Quality Multi-scale Image Segmentation” – *AGIT Symposium, 1999*.

BAATZ, M., BENZ, U., DEGHANI, S., HEYNEN, M., HÖLTJE, A., HOFMANN, P., LINGENFELDER, I., MIMLER, M., SOHLBACH, M., WEBER, M., WILLHAUCK, G., “eCognition User Guide 3” – *Definiens Imaging GmbH –München, Germany, 2000, 2003*.

BENEDIKTSSON, J.A., SWAIN, P., ERSOY, O., “Neural Network Approaches Versus Statistical Methods in Classification of Multisource Remote Sensing Data” – *IEEE - Transactions on geoscience and Remote Sensing, vol 28, no 4, july 1990*.

BENEDIKTSSON, J.A. e SVEISSON, J.R., “Multisource Remote Sensing Data Classification Based on Consensus and Pruning” – *IEEE Transactions on Geoscience and Remote Sensing, vol. 41, No. 4, p. 932-936*.

BRIEM, G.J, BENEDIKTSSON, J.A. e SVEINSSON, J.R., “Multiple Classifiers Applied to Multisource Remote Sensing Data” – *IEEE Transactions on Geoscience and Remote Sensing, vol. 40, No. 10, 2002, p. 2291-2299*.

BOUAKACHE, A., KHEDAM, R., ABBAS, N., AIT ABDESSELAM, Y. e BELHADJ-AISSA, A., “Multi-scale Satellite Images Fusion using Dempster Shafer Theory” – *3rd International Conference on Information and Communication Technologies: From Theory to Applications, 2008. ICTTA, 2008, 7-11 April 2008, p. 1-6*.

BRUZZONE, L., CONESE, C., MASELLI, F. e ROLI, F., “Multisource classification of complex rural areas by statistical and neural network approaches” – *Photogrammetric Engineering and Remote Sensing, 1997. 63(5), p. 523-533*.

CHEN, C.W., LUO, J., e PARKER, K.J., “Image Segmentation Via Adaptive K-Mean Clustering and Knowledge-Based Morphological Operations with Biomedical Applications” – *IEEE Transactions on Image Processing, Vol. 7, No. 12, pp. 1673-1683, 1998*.

COGO, S.E., “Feições de Textura para Classificação de Imagens” – *CEPSRM – Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (Dissertação de Mestrado)*, Janeiro de 1994.

CONGALTON, R., “A review of assessing the accuracy of classification of remotely sensed data” – *Remote Sensing of Environment*, 1991 - 37, p. 35-46.

DENOEU, T., “Analysis of Evidence-Theoretic Decision Rules for Pattern Classification” – *Pattern Recognition Society - vol 30, no 7, p. 1095-1107, 1997.*

DNPEA, “Levantamento de Reconhecimento de Solos do Rio Grande do Sul - Boletim Técnico nº30” – *DNPEA (Divisão de Pesquisas Pedológicas)*, *IPEAS (Instituto de Experimentação Pedológica)*, *DRNR (Departamento de Recursos Naturais Renováveis da Sec. da Agricultura do Estado do RS)*; Recife (1973).

EASTMAN, J.R., “Guide to GIS and Image Processing” – *Vol. 2., Idrisi Productio, Clark University, 1999.*

FUPEF, “Problemas Florestais do Gênero Araucária” – *FUPEF, Curitiba - PR (1979/1980).*

GAHEGAM, M. e FLACK, J., “A Model to Support the Integration of Image Understanding Techniques Within a GIS” – *Photogrammetric Engineering & Remote Sensing - vol 62, no 5, p. 483-490, may 1996.*

GARVEY, T.D., LOWRANCE, J. D. e FISHER, M., “An Inference Technique for Integrating Knowledge from Disparate Sources” – *Proceedings 7th International Conference on Artificial Intelligence, Vancouver, p. 319-325, 1981.*

GONG, P., “Integrated Analysis of Spatial Data from Multiple Sources: Using Evidential Reasoning and Artificial Neural Network Techniques for Geological Mapping” – *Photogrammetric Engineering & Remote Sensing - vol 62, no 5, p. 513-523, may 1996.*

GONZALES, R. e WOODS, R., “Digital Image Processing” – *Addison-Wesley, 1992.*

HEGARAT-MASCLE, Sylvie Le, BLOCH, Isabelle e VIDAL-MADJAR D., “Application of Dempster-Shafer Evidence Theory to Unsupervised Classification in Multisource Remote Sensing” – *IEEE Transactions On Geoscience And Remote Sensing, Vol. 35, No. 4, July 1997, p. 1018-1031.*

HEGARAT-MASCLE, Sylvie Le, RICHARD, D. e OTTLÉ, C., “Multi-scale Data Fusion Using Dempster-Shafer Evidence Theory” – *IEEE International Geoscience And Remote Sensing Symposium, 2002, IGARSS ‘02.2002 IEEE International Digital Object Identifier 10.1109/IGARSS.2002.1025726*

HAERTEL, Victor F. A. e SHIMABUKURO, Yosio Edemir, “Spectral Linear Mixing Model in Low Spatial Resolution Image Data” – *IEEE Transactions On Geoscience And Remote Sensing, vol. 43, n°. 11, November 2005, p. 2555-2562.*

HAERTEL, Victor F. A. e SHIMABUKURO, Yosio Edemir, “Fraction Images in Multitemporal Change Detection” – *International Journal of Remote Sensing*, vol. 25, n° 23, December 2004, p. 5473-5489.

HARALICK, R., “Statistical and Structural Approaches to Texture” – *Proceedings of IEEE*, Vol. 67, No. 5, pp. 786-804, 1979.

HARALICK, R., SHANMUGAN, K. and DINSTEN, I., “Textural Features for Image Classification” – *IEEE Transactions on Systems, Man and Cybernetics*, Vol. SMC-3, No. 6, pp. 610-621, 1973.

HUECK, K., “As Florestas da América do Sul” – *Editora Polígono S.A. (editora da Universidade de Brasília), SP, 1972.*

HUTCHINSON, C.F., “Techniques for combining Landsat and ancillary data for digital classification improvement” – *Photogrammetric Engineering and Remote Sensing*, 1982. 48(1), p. 123-130.

IBDF, “Inventário Florestal do Pinheiro no Sul do Brasil” – *Instituto Brasileiro do Desenvolvimento Florestal – FUFEP- Fundação de Pesquisas Florestais do Paraná (Relatório Final), Curitiba (1978).*

IBGE, “Levantamento de Recursos Naturais (Projeto RADAM-BRASIL)” – *Folha SH. 22, Porto Alegre 1986.*

IPAGRO, “Atlas Agroclimático do Estado do Rio Grande do Sul – volume 3” – *Governo do Estado do Rio Grande do Sul - Secretaria de Agricultura e Abastecimento - Instituto de Pesquisas Agronômicas, Porto Alegre (1989).*

JARENKOW, J.A., “Composição Florística e Estrutura da Mata com Araucária na Estação Ecológica de Aracuri, Esmeralda, RS” – *Dissertação de Mestrado em Ciências Biológicas – Ênfase em Botânica, 1985.*

KIM, Hakil e SWAIN, Philip H., “Evidential Reasoning Approach to Multisource-Data Classification in Remote Sensing” – *IEEE Transactions On Systems, Man, And Cybernetics*, Vol. 25, No. 8, August 1995, p. 1257-1265.

KURVONEN, L. e HALLIKAINEN, M.T., “Textural information of multitemporal ERS-1 and JERS-1 SAR images with applications to land and forest type classification in boreal zone” – *IEEE Transactions On Geoscience And Remote Sensing*, Vol. 37, N°. 2 (part 1), March 1999, p. 680-689.

LAHA, Arijit, PAL, Nikhil R. e DAS, Jyotirmoy, “Land Cover Classification Using Fuzzy Rules and Aggregation of Contextual Information Through Evidence Theory” – *IEEE Transactions On Geoscience And Remote Sensing*, Vol. 44, No. 6, June 2006, p. 1633-1641.

LEE, T.J., RICHARDS, J.R., SWAIN, P.H., “Probabilistic and Evidential Approach for Multisource Data Analysis” – *IEEE Transactions on Geoscience and Remote Sensing*, vol. 35, pp. 283-293, 1987.

LUCKMAN, A., GROOM, G. e BAKER, J., “Forest age discrimination from texture measures of SAR imagery” – *International Geoscience and Remote Sensing Symposium, 1994. IGARSS '94. Surface and Atmospheric Remote Sensing: Technologies, Data Analysis and Interpretation. Vol. 1, 8-12 Aug. 1994 p.104-107.*

MOMANI, Bilal Al, MORROW, Philip e McCLEAN, Sally, “Knowledge-Based Semi-Supervised Satellite Image Classification” – *9th International Symposium on Signal Processing and Its Applications, 2007. ISSPA 2007. 12-15 Feb. 2007, p.1-4.*

MOON, W.M., “Integration of geophysical and geological data using evidential belief function” – *IEEE Transactions on Geoscience and Remote Sensing, 1990 - 28(4), p. 711-720.*

NAVULUER, K., “Multispectral Image Analysis Using the Object-Oriented Paradigm” – *CRC Press, 2007.*

NI, Jianjun, MA, Xiaoping, XU, Lizhong e WANG, Jianying, “An Image Recognition Method Based on Multiple BP Neural Networks Fusion” – *Proceedings of 2004 International Conference On Information Acquisition, p.323-326.*

OLIVER, C.J., “Rain forest classification based on SAR texture” – *IEEE Transactions on Geoscience and Remote Sensing, Volume 38, Issue 2, Part 2, March 2000, p.1095 – 1104.*

PAL, N. e GHOSH, S., “Some Classification Algorithms Integrating Dempster-Shafer Theory of Evidence with the Rank Nearest Neighbor Rules” – *IEEE - Transactions on Systems, Man, and Cybernetics – part A: Systems and Applications, vol. 31, no 1, january 2001.*

PROISY, C., COUTERON, P., PELISSIER, R., BARBIER, N. e ENGEL, J., “Monitoring canopy grain of tropical forest using Fourier-based textural ordination (FOTO) of very high resolution images” – *IEEE International Geoscience and Remote Sensing Symposium, 2007. IGARSS 2007. 23-28 July 2007, p.4324–4326.*

QIAN, Jianzhong, EHRICH, Roger W. e CAMPBELL James B., “DNESYS - An Expert System For Automatic Extraction of Drainage Networks From Digital Elevation Data” – *IEEE Transactions On Geoscience And Remote Sensing, Vol. 28, No. 1. January 1990, p. 29-45.*

QIMING, L., e KHOHGOFTAAR, T. M., “Unsupervised Multiscale Color Image Segmentation Based on MDL Principle” – *IEEE Transactions on Image Processing, Vol. 15, No. 9, pp. 2755-2761, 2006.*

RAMBO, P. Balduino, “A Fisionomia do Rio Grande do Sul” (Ensaio de monografia natural) – *Gráfica da Imprensa Oficial / Porto Alegre (1942).*

RICHARDS, John R. e JIA, Xiuping, “Remote Sensing Digital Image Analysis: An Introduction”, – *Springer, 3^a edição, 1999.*

RICHARDS, John R. e JIA, Xiuping, “A Dempster–Shafer Relaxation Approach to Context Classification” – *Ieee Transactions On Geoscience And Remote Sensing, Vol. 45, No. 5, May 2007, p. 1422-1430.*

RICHARDS, J.R., “Remote Sensing Digital Image Analysis” – 20ª edição, Springer-Valey, 1992 (capítulo 12).

RICHARDS, J.R., GUBLER, Nicolin B., “A Knowledge Based System for the Analysis of Aerial Images” – *IEEE Transactions on Geoscience and Remote Sensing*, vol 25 - nº 3, maio de 1987.

RIZZINI, C.T., “Fitogeografia do Brasil” – *Âmbito Cultural Edições Ltda, RJ, 1997.*

SHAFER, G., “A Mathematical Theory of Evidence” – *Princeton University Press, 1976.*

SHIMABUKURO, Yosio Edemir e SMITH, J. A., “The Least-Squares Mixing Models to Generate Fraction Images Derived from Remote Sensing Multispectral Data” – *IEEE Transactions on Geoscience and Remote Sensing*, vol 29, 1991, p. 16-20.

SPRING 4.1, “Manual do Usuário” – *Instituto Nacional de Pesquisas Espaciais (INPE) – DPI Divisão de Processamento de Imagens; julho 2004.*

STRAHLER, A. H., “The use of Prior Probabilities in Maximum Likelihood Classification of Remotely Sensed Data” – *Remote Sensing of Environment, Vol. 10, pp. 135-163, 1980.*

TABB, M.M. e AHUJA, N., “Multiscale Image Segmentation by Integrated Edge and Region Detection” – *IEEE Transactions on Image Processing, Vol. 6, No. 5, pp. 642-655, 1997.*

UCHÔA, J.Q., PANANTIM, S.M., NICOLETTI, M.C., “Elementos da Teoria da Evidência de Dempster-Shafer” – *Departamento de computação da Universidade Federal de São Carlos, 2002.*

WANG, Fangju, “Integrating GIS’s and Remote Sensing Image Analysis Systems by Unifying Knowledge Representation Schemes” – *IEEE Transactions on Geoscience and Remote Sensing*, vol 29 - nº 4, julho de 1991.

YAGER, R.R., “On Ordered Weighted Averaging Aggregation Operators in Multicriteria Decisionmaking” – *IEEE Transactions on Systems, Man, and Cybernetics – vol. 18, no 1, january 1988.*

ZHU, Hongwei e BASIR, Otman, “An Adaptive Fuzzy Evidential Nearest Neighbor Formulation for Classifying Remote Sensing Images” – *IEEE Transactions On Geoscience And Remote Sensing, Vol. 43, No. 8, August 200, p. 1874-1889.*

ZUKOWSKYJ, P.M., TEEUW, R. e BUSSEL M.A., “Validation of a novel classification system: the Integrated Digital Elevation Model Image Classification System” – *Proceedings of the Annual Conference of the Remote Sensing and Photogrammetric Society, The University of Nottingham, U.K - 2003.*

ANEXO I – Experimento Adicional

EVOLUÇÃO DAS ACURÁCIAS COM O ACRÉSCIMO DE VARIÁVEIS

Este tópico foi desenvolvido com a intenção de investigar o ganho obtido, em termos de acurácia, com o acréscimo gradual de variáveis no modelo. Como algumas das variáveis investigadas, tipicamente as variáveis referentes à textura, apresentavam distribuição dos pixels um pouco distantes de uma curva normal, para grande parte das classes inicialmente selecionadas (inclusive para a classe alvo do estudo), surgiu uma certa dúvida se a sua introdução trouxe algum ganho ao modelo ou até mesmo se não acabou por causar uma redução do ganho inicial obtido na acurácia.

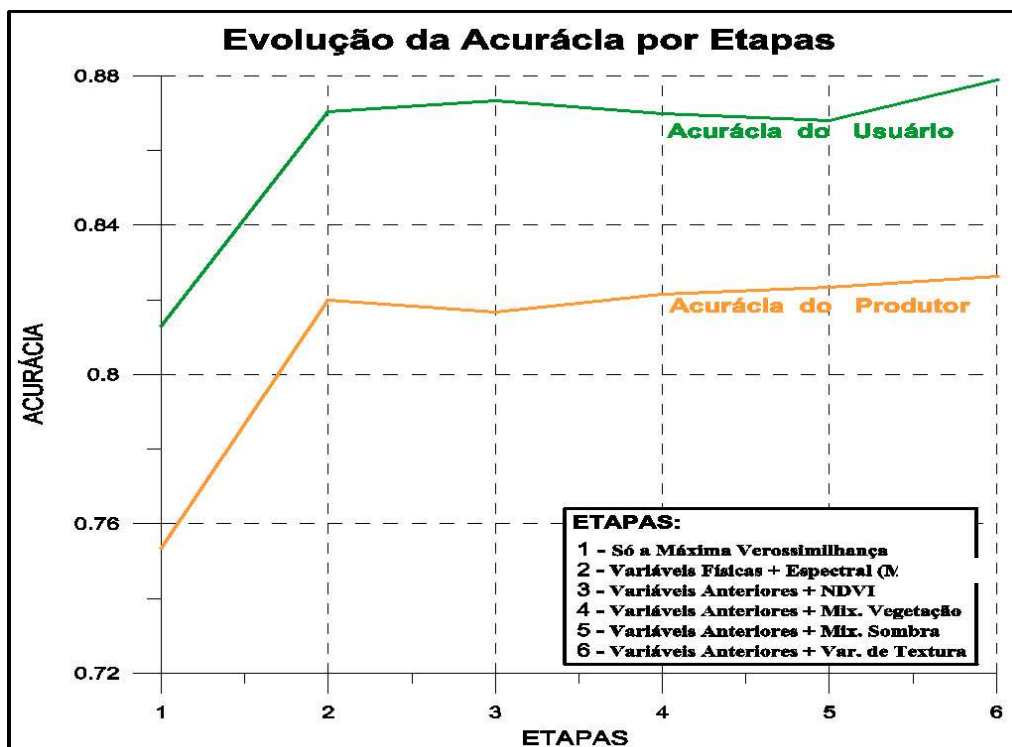
Para a realização deste experimento seguiu-se exatamente a mesma metodologia utilizada para a geração do resultado final desta pesquisa. Gerou-se uma imagem de confiança e sua respectiva imagem de plausibilidade para cada um dos conjuntos de variáveis selecionadas. Estas imagens foram então recortadas segundo a cobertura das duas áreas (teste) de verdade terrestre. Gerou-se os limiares com a utilização da área teste de treinamento e aplicou-se estes limiares na área de teste (área 2) a fim de quantificar o resultado obtido na referida etapa, o mesmo procedimento foi então realizado acrescentando-se um novo grupo de variáveis e assim sucessivamente até que todas as variáveis fossem introduzidas (o que gera o resultado final desta pesquisa) e quantificadas. O critério para determinação do limiar também foi o mesmo adotado no resultado final desta tese: o ponto no qual as acurácias do usuário e do produtor são iguais (área de intersecção nas duas curvas).

Foram discriminadas e quantificadas seis diferentes etapas de análise. Para formar conjuntos de variáveis gerou-se grupos que continham a mesma familiaridade (variáveis de textura e variáveis físicas), no caso de variáveis autônomas de relação com as demais gerou-se um novo resultado com a introdução desta única variável, caso da variável NDVI, por exemplo, para as duas variáveis de mistura adotou-se este mesmo procedimento (pois as duas quantificam classes distintas). Os grupos formados e processados individualmente são os seguintes:

1. Resultado da MVG pura.
2. Função decisão MVG mais as var. de origem física (MNT e Temperatura).
3. Variáveis da etapa anterior mais NDVI.
4. Variáveis da etapa anterior mais variável de mistura da componente vegetação.
5. Variáveis da etapa anterior mais variável de mistura da componente sombra.
6. Variável da etapa anterior mais as variáveis de textura.

Se pode ver graficamente o resultado da introdução de cada um destes conjuntos de variáveis, através da figura 15.

FIG. 15 – Evolução das acurácias



Numericamente se obteve os seguintes valores:

TABELA 3 – Acurácias por Etapas

	A. Usuário	A. Produtor
1 – Apenas com a MVG	0.8129	0.7534
2 - V. Físicas + Espectral	0.8705	0.8198
3 -V. da Etapa Ant. + NDVI	0.8733	0.8168
4 -V. da Etapa Ant. + Mix. Veg.	0.8699	0.8215
5 -V. da Etapa Ant. + Mix. Som.	0.8681	0.8234
6 -V. da Etapa Ant. + V. Textura	0.8788	0.8264

O experimento mostrou que na etapa 2, introdução da função decisão Máxima Verossimilhança acrescida das variáveis físicas, foi a etapa onde houve o incremento mais significativo de todo o experimento, tanto na acurácia do usuário quanto na acurácia do produtor. Na etapa seguinte (introdução do NDVI) houve uma pequena queda na acurácia do produtor e um conseqüente aumento na acurácia do usuário. Este fato sugere que esta variável conseguiu cortar erros de inclusão porém causou um pequeno aumento nos erros de omissão. A introdução da segunda variável (etapa 4), mistura para vegetação, causou um efeito exatamente inverso ao NDVI, ou seja causou um aumento nos erros de inclusão e uma queda nos erros de omissão. Na etapa 5 a introdução da variável mistura para sombra apresentou exatamente o mesmo efeito da variável anterior, porém, desta vez com uma piora quase imperceptível para a acurácia do usuário. Esta etapa demonstra que as variáveis referentes a pixel mistura se prestaram melhor a corrigir erros de omissão mas se mostraram menos eficazes para corrigir erros de inclusão. A etapa final do experimento corresponde à introdução de todo o conjunto de variáveis referentes à textura, a desconfiança (devido à fraca normalidade observada nos dados) com relação à utilização deste grupo de variáveis em relação a esta pesquisa especificamente, foi desfeita, verificou-se que às seis variáveis de textura introduzidas conseguiram causar mais um ganho nos valores de acurácia, obtidos tanto na acurácia do usuário quanto do produtor. Conclui-se com este último experimento que para todas as variáveis investigadas obteve-se algum tipo de contribuição para o resultado final, mesmo as variáveis que causara um decréscimo para a acurácia do usuário houve um incremento de maior proporção para a acurácia do produtor.

ANEXO II – Programas Elaborados em MATLAB para esta Pesquisa

Exemplo da estrutura destes códigos fonte (OBS. as fontes das letras estão alteradas de forma estilizada para facilitar o entendimento do leitor):

```
% nonon nononon -> Estas linhas correspondem a comentários sobre o programa
                (o sinal %, faz com que a linha não seja processada).
name_prob = name_prob * prob; -> Corresponde as linhas de comando que são,
                efetivamente, processadas.
```

CODIGO FONTE 1

```
function x = source_files (name_prob,prob)
%
% A função source_file criada é multiplicada pela evidência encontrada
% para a variável em questão.
%
name_prob = name_prob * prob;
%
% A imagem é processada em quatro partes (por razões de hardware)
%
source_file = name_prob(1:3000000,1);
% source_file = name_prob(3000001:6000000,1);
% source_file = name_prob(6000001:9000000,1);
% source_file = name_prob(9000001:size(name_prob,1),1);
%
% Cria a segundo coluna do novo arquivo, referente à classe outros
%
source_file(:,2) = prob - source_file(:,1);
%
% Cria a terceira coluna do novo arquivo, referente às incertezas
%
source_file(:,3) = 1 - prob;
%
% salva o novo arquivo com o nome de souce_file
%
save source_file source_file
```

CODIGO FONTE 2

```

function x = orthogonal_sum (source_A, source_B)
%
% Esta função implementa o processo de soma ortogonal, responsável por
% calcular a massa de evidência combinada para duas diferentes fontes de
% dados, ou variáveis (Richards p. 297)
%
% Entrada: Variável A (source_A) & Variável B (source_B)
% Os dados referentes às duas fontes (variáveis) são introduzidos em formato
% ERDAS 78, contendo três colunas:
% (1) Massa de evidência para a classe 1 - (2) Massa de evidência para
% classe outros - (3) Incerteza
%
% Saida: O arquivo final processado é salvo com o nome: bpa_sum
% Este arquivo também contém 3 colunas. Referindo-se agora a: evidência
% combinada das duas fontes para a classe 1, para classe outros e incerteza
%
bpa_sum = [];
%
% Os comandos, a seguir, geram uma rotina (loop) para recorrer todos os
% pixels
% presentes nas duas fontes de informação. Realizando uma multiplicação e
% uma soma pixel a pixel entre as duas variáveis (source_a e source_b).
% A variável nf criada ira acumular o resultado destas operações. NF será
% utilizada como fator de normalização
%
nf = (source_A(:,1) .* source_B(:,1)) + (source_A(:,1) .* source_B(:,3)) + ...
      (source_A(:,2) .* source_B(:,2)) + (source_A(:,2) .* source_B(:,3)) + ...
      (source_A(:,3) .* source_B(:,1)) + (source_A(:,3) .* source_B(:,2)) + ...
      (source_A(:,3) .* source_B(:,3));
%
% A seguir gera-se a evidência combinada para classe 1 (Araucária)
%
bpa_sum_1 = ((source_A(:,1) .* source_B(:,1)) + (source_A(:,1) .* source_B(:,3)) + ...
            (source_A(:,3) .* source_B(:,1))) ./ nf;
%
% A evidência combinada para classe 2 (outros)
%
bpa_sum_2 = ((source_A(:,2) .* source_B(:,2)) + (source_A(:,2) .* source_B(:,3)) + ...
            (source_A(:,3) .* source_B(:,2))) ./ nf;
%
% A incerteza combinada
%
bpa_sum_3 = (source_A(:,3) .* source_B(:,3)) ./ nf;
%
% O resultado das 3 etapas de processamento são atribuídas a var. bpa_sum,
% no qual, a coluna 1 conterà os dados (combinados) para classe 1, a coluna 2
% os dados para classe 2 e a coluna 3 os dados referentes as incertezas.
%
bpa_sum = [bpa_sum_1 bpa_sum_2 bpa_sum_3];
%
% A variável bpa_sum é então salva em um arquivo de mesmo nome
save bpa_sum bpa_sum

```

CODIGO FONTE 3

```

function x = bel_plau_threshold_user_prod(nrow,ncol,lower_plau,upper_plau,lower_bel,upper_bel)
%
% Este programa foi criado para estimar a acurácia do produtor e usuário
% obtidas na imagem temática (classificada) em função do limiar adotado
% para confiança dentro de um valor fixo mantido para plausibilidade.
%
% % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % %
% % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % %
%
% O comando a seguir lê o arquivo contendo a imagem referente à verdade
% terrestre para uma das áreas teste.
%
gt_arauc = loadimage('gt_test_area_2.lan',[1:nrow],[1:ncol],[1:1],'unsign');
%
% Lê os arquivos referentes à confiança e plaus. para a mesma área teste
%
bel = loadimage('bel_test_area_2.lan',[1:nrow],[1:ncol],[1:1],'unsign');
plau = loadimage('plau_test_area_2.lan',[1:nrow],[1:ncol],[1:1],'unsign');
%
% Lê o arquivo referente à imagem temática (classificada via MVG) para a
% mesma área teste.
%
thematic_arauc = loadimage('thematic_test_area_2.lan',[1:nrow],[1:ncol],[1:1],'unsign');
%
% Limiares para área teste.
% Esta operação inclui pixels com alta plausibi. de pertencer a classe 1
% (Araucária) que são, assim, adicionados a imagem temática original
%
list_accuracy_bel_plau=[];
%
% É criada uma rotina (loop) p/ testar diferentes valores de plausibilidade
%
for threshold_plau=lower_plau:upper_plau
  threshold_plau
  plau_thresholded = plau >= threshold_plau;
  %
  % Adicionam-se pixels que apresentam alto grau de plausibilidade.
  %
  filtered_image_plau = thematic_arauc | plau_thresholded;
  list_accuracy=[];
  for threshold_bel=lower_bel:upper_bel
    bel_thresholded = bel >= threshold_bel;
    %
    % Filtra-se a imagem temática
    %
    filtered_image_bel=filtered_image_plau & bel_thresholded;
    %
    % Computa-se o número de pixels corretamente classificados na imagem
    % filtrada
    %
    correct_arauc=sum(filtered_image_bel & gt_arauc);
    %
    % Acumula as acurácias obtidas na imagem temática filtrada
    %

```



```

user_accuracy = correct_arauc/sum(filtered_image_bel);
producer_accuracy = correct_arauc/sum(gt_arauc);
%
% Acumula as acuracias médias
%
list_accuracy=[list_accuracy;[threshold_bel user_accuracy producer_accuracy...
((user_accuracy+producer_accuracy)/2)];
end
list_accuracy(:,1)=list_accuracy(:,1)/255;
%
% Seleciona o maior valor obtido para acurácia média
%
[Y,I]=max(list_accuracy(:,4));
%
% Adiciona este valor a variável denominada: list_accuracy_bel_plau
%
list_accuracy_bel_plau=[list_accuracy_bel_plau;[(threshold_plau/255) list_accuracy(I,:)];
%
end
%
% Salva o resultado em um arquivo de mesmo nome
%
save list_accuracy_bel_plau list_accuracy_bel_plau

```