

SELMA REGINA ARANHA RIBEIRO


**INTEGRAÇÃO DE IMAGENS LANDSAT TM E DADOS AUXILIARES PARA A
DELIMITAÇÃO AUTOMÁTICA DE UNIDADES FISIONÔMICAS (PAISAGEM)
E GEOLÓGICAS USANDO REDES NEURAIS ARTIFICIAIS**

Tese apresentada ao Curso de Pós-Graduação
em Ciências Geodésicas, Setor de Ciências da
Terra da Universidade Federal do Paraná, como
requisito parcial à obtenção do título de Doutor.

Orientadores;
Prof. Dr. Jorge Antonio Silva Centeno
Prof. Dr. -Ing. Habil. Hans Peter Bähr

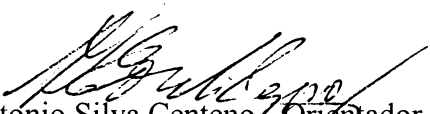
CURITIBA

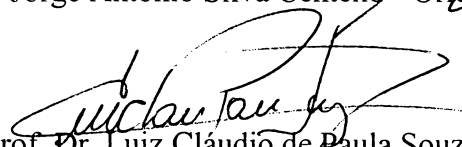
2003




Ata da sessão pública de defesa de Tese para obtenção do grau de Doutora em Ciências Geodésicas. Aos vinte e oito dias do mês de agosto de dois mil e três, na sala PI-13 do Centro Politécnico da Universidade Federal do Paraná, às 14:00 horas, reuniu-se em sessão pública a Banca Examinadora da prova de Defesa de Tese da candidata ao Título de Doutora em Ciências **SELMA REGINA ARANHA RIBEIRO**, composta pelos seguintes membros: o Prof. Dr. Jorge Antonio Silva Centeno como orientador e presidente (UFPR) e os Prof. Dr. Luiz Cláudio de Paula Souza (UFPR), Prof^ª. Dr^ª. Maria de Lourdes Bueno Trindade Galo (UNESP), Prof. Dr. Hélio Olympio da Rocha (UFPR), Prof. Dr. Francisco José Fonseca Ferreira (UFPR) e Prof^ª. Dr^ª. Márcia Cristina Lopes Quintas (UFPR), como membros. Após os esclarecimentos prestados pela candidata às arguições feitas pelos membros da Banca, o Sr. Presidente suspendeu temporariamente a sessão a fim de que a Banca se reunisse em sessão secreta para deliberar sobre o resultado. Reaberta a sessão, o Sr. Presidente deu conhecimento a candidata que de conformidade com o Art. 28º da Resolução 45/90 do CEP, a Tese foi **aprovada**, apenas condicionada à apresentação, no prazo de sessenta dias, da redação final com as alterações sugeridas.

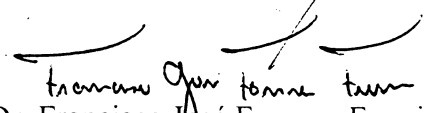
Curitiba, 28 de agosto de 2003.


Prof. Dr. Jorge Antonio Silva Centeno - Orientador e Presidente (UFPR)


Prof. Dr. Luiz Cláudio de Paula Souza - Membro (UFPR)


Prof.ª Dr.ª Maria de Lourdes Bueno Trindade Galo - Membro (UNESP)


Prof. Dr. Hélio Olympio da Rocha - Membro (UFPR)


Prof. Dr. Francisco José Fonseca Ferreira - Membro (UFPR)


Prof.ª Dr.ª Márcia Cristina Lopes Quintas - Membro (UFPR)

Título da Tese: "INTEGRAÇÃO DE IMAGENS LANDSAT TM E DADOS AUXILIARES PARA A DELIMITAÇÃO AUTOMÁTICA DE UNIDADES FISIONÔMICAS USANDO REDES NEURAIS ARTIFICIAIS"

DEDICATÓRIA

Aos meus pais, José e Madiana.

Dedico

Aos meus filhos Fernando Henrique, Mariana e Juliana.

Por todo o apoio, incentivo e amor.

AGRADECIMENTOS

Ao professor Jorge Antonio Silva Centeno, pelo apoio, dedicação, ensinamentos e amizade.

Aos membros da banca examinadora Professores Doutores: Maria de Lourdes Bueno Trindade Gallo, Helio Olympio da Rocha, Francisco José Fonseca Ferreira, Luiz Cláudio de Paula Souza e Márcia Cristina Lopes Quintas.

À Universidade Federal do Paraná, mediante o Curso de Pós – Graduação em Ciências Geodésicas, e à Universität Fridericiana de Karlshue - Alemanha, pela oportunidade de frequentar o curso de doutoramento e pelas instalações e laboratórios.

À Universidade Estadual do Oeste do Paraná – UNIOESTE, pela liberação das atividades no curso de Engenharia Agrícola.

À Coordenação de Aperfeiçoamento de Nível Superior (CAPES), pela concessão de bolsa de estudos necessária no apoio e desenvolvimento da pesquisa.

A todos os professores do CPCCG e do Departamento de Geomática da UFPR.

À Secretária do Curso de Pós – Graduação em Ciências Geodésicas– CPCCG, Verali Mônica Kleuser pela disposição, amizade e dedicação.

Aos colegas Curso de Pós – Graduação em Ciências Geodésicas, pelo companheirismo, incentivo permanente, amizade em todos os momentos e horas certas. Especialmente agradeço aos amigos: Patricio Jaime Alcota Aguirre, Moisés Ferreira Costa, Isabel do Franco Lago, Elaine Cristine Barros de Souza, Cláudia Costantina Santarelli Saraiva, Silvia Regina Nunes de Souza.

A todos que direta ou indiretamente contribuíram para a realização deste trabalho.

SUMÁRIO

LISTA DE QUADROS	vi
LISTA DE TABELAS	vii
LISTA DE FIGURAS	ix
LISTA DE GRÁFICOS	xii
RESUMO	xiii
ABSTRACT	xv
1 INTRODUÇÃO	1
1.1 CONSIDERAÇÕES	1
1.2 OBJETIVOS	3
1.3 MOTIVAÇÃO	3
1.4 ESTRUTURAÇÃO	4
2 REVISÃO DA LITERATURA	6
2.1 ANÁLISE FISIONÔMICA	6
2.2. INTERPRETAÇÃO DE IMAGENS	7
2.2.1 Interpretação Visual de Imagens	7
2.2.2 Interpretação Digital de Imagens	9
2.2.3 Segmentação	11
2.3 INTEGRAÇÃO DE DADOS	13
2.4 INTELIGÊNCIA ARTIFICIAL	15
3 MATERIAIS E MÉTODOS	21
3.1 DESCRIÇÃO DAS CARACTERÍSTICAS FÍSICAS DA ÁREA	21
3.1.1 Localização	21
3.1.2 Relevo	22
3.1.3 Clima	22
3.1.4 Hidrografia	23
3.1.5 Vegetação	23
3.1.5 Geologia	24
3.2. MATERIAIS	27
3.3 MÉTODOS	28
3.3.1 Fotointerpretação de Unidades Fisionômicas e Mapa Geológico	32

3.3.2 Variáveis de Entrada -----	36
3.3.2.1 Variáveis que Representam o Relevo-----	36
3.3.2.1.1 Modelo Digital do Terreno -----	37
3.3.2.1.2 Gradiente da Encosta e Exposição da Rampa -----	41
3.3.2.2 Variáveis que Representam a Drenagem -----	45
3.3.2.3 Imagens Artificiais -----	47
3.3.2.3.1 Índice de Vegetação da Diferença Normalizada (NDVI)-----	48
3.3.2.3.2 Transformação de Componentes Principais (CP) -----	49
3.3.2.3.3 Transformação “Tasseled Cap” (TCap) -----	55
3.3.2.3.4 Transformação IHS Gerada a Partir de Atributos do Relevo -----	57
3.3.2.4 Tratamento Gamaespectrométrico-----	59
3.3.2.4.1 Potássio-----	64
3.3.2.4.2 Tório -----	66
3.3.2.4.3 Urânio -----	67
3.3.2.5 Segmentação -----	69
3.3.3 Redes Neurais -----	73
3.3.4 Método para a Coleta das Amostras -----	85
3.3.5 Verificações -----	86
3.3.5.1 Matriz de Confusão-----	87
3.3.5.2 Avaliação da Influência das Variáveis de Entrada -----	88
3.3.5.3 Coeficiente de Correlação (Coeficiente de Cramer’s V) -----	88
4 EXPERIEMENTOS -----	90
4.1 DEFINIÇÃO DA ARQUITETURA DAS REDES E ALGORITMO DE TREINAMENTO -----	90
4.2 TESTES: UNIDADES FISIONÔMICAS A PARTIR DA FOTOINTERPRETAÇÃO E DA GEOLOGIA (“PIXEL” E SEGMENTOS)-----	93
4.2.1 Identificação das Melhores Variáveis de Entrada da Primeira Série - Fotointerpretação (“Pixel” e Segmentos) e Segunda Série - Mapa Geológico e Segmentos-----	94
5 RESULTADOS E DISCUSSÕES -----	97
5.1 REDES NEURAS -----	97
5.1.1 Resultado do Treinamento da Rede Neural-----	98
5.2 VERIFICAÇÃO E CLASSIFICAÇÃO -----	103

5.2.1 Fotointerpretação-----	103
5.2.2 Mapa Geológico -----	110
5.3 SIMULAÇÕES ALTERANDO-SE UMA DAS VARIÁVEIS DE ENTRADA PARA A MESMA MODELAGEM DA REDE -----	114
5.3.1 Simulação - Fotointerpretação-----	114
5.3.1.1 Simulação em Nível de Abstração do "Pixel"-----	114
5.3.1.2 Simulação em Nível de Abstração de Segmentos -----	123
5.3.2 Simulação – Mapa Geológico-----	129
5.3.2.1 Simulação em Nível de Abstração de Segmentos -----	129
6 CONCLUSÕES -----	138
6.1 REDES NEURAIIS -----	138
6.2 INTEGRAÇÃO DE DADOS -----	139
6.3 SEGMENTOS VERSUS "PIXELS" -----	140
6.4 VARIÁVEIS DE ENTRADA-----	140
7 RECOMENDACÕES -----	143
REFERÊNCIAS BIBLIOGRÁFICAS -----	144
APÊNDICE I -----	154
APÊNDICE II -----	156
APÊNDICE III -----	166

LISTA DE QUADROS

QUADRO 2. 1 – VANTAGENS E DESVANTAGENS DAS REDES NEURAIIS APLICADAS AO SENSORIAMENTO REMOTO -----	16
QUADRO 3.1 – AMOSTRAS NÃO ALTERNADAS E ALTERNAADAS-----	86

LISTA DE TABELAS

TABELA 3.2 – DADOS ESTATÍSTICOS DA TRANSFORMAÇÃO CP	52
TABELA 3.3 – COEFICIENTES DA TRANSFORMAÇÃO TCAP	57
TABELA 4.1 – TESTES EXECUTADOS PARA O AJUSTE DA RNA, ELEMENTO MÍNIMO DA IMAGEM “PIXEL” E AMOSTRAS BASEADAS NA FOTOINTERPRETAÇÃO	92
TABELA 4.2 (A) – EXPERIMENTOS REALIZADOS COM A VARIAÇÃO DAS ENTRADAS E DA REALIDADE DE CAMPO (FOTOINTERPRETAÇÃO) E RESPECTIVO DO ÍNDICE DE CRAMER’S V	94
TABELA 4.2 (B) – EXPERIMENTOS REALIZADOS COM A VARIAÇÃO DAS ENTRADAS E DA REALIDADE DE CAMPO (FOTOINTERPRETAÇÃO) E RESPECTIVO DO ÍNDICE DE CRAMER’S V	95
TABELA 4.2 (C) – EXPERIMENTOS REALIZADOS COM A VARIAÇÃO DAS ENTRADAS E DA REALIDADE DE CAMPO (MAPA GEOLÓGICO) E RESPECTIVO DO ÍNDICE DE CRAMER’S V	96
TABELA 5.1 (A) – TREINAMENTO DAS RNA EM NÍVEL DE “PIXEL”, NA FASE DE TREINAMENTO, CONSIDERANDO COMO REFERÊNCIA A IMAGEM GERADA DA FOTOINTERPRETAÇÃO	99
TABELA 5.1 (B) - TREINAMENTO DA RNA EM NÍVEL DE SEGMENTO, NA FASE DE TREINAMENTO, CONSIDERANDO COMO REFERÊNCIA A IMAGEM GERADA DA FOTOINTERPRETAÇÃO	100
TABELA 5.1 (C) - TREINAMENTO DA RNA EM NÍVEL DE SEGMENTO, CONSIDERANDO COMO REFERÊNCIA O MAPA GEOLÓGICO.	102
TABELA 5.2 - OS MELHORES RESULTADOS ANALISANDO-SE O ÍNDICE DE CRAMER’S V PARA A PRIMEIRA SÉRIE DE EXPERIMENTOS	103
TABELA 5.3 PERCENTUAIS DE ACERTOS	106
TABELA 5.4 PERCENTUAIS DOS ÍNDICES DE ACERTOS	109
TABELA 5.5 - OS MELHORES RESULTADOS ANALISANDO-SE O ÍNDICE DE CRAMER’S V PARA A SEGUNDA SÉRIE DE EXPERIMENTOS	110
TABELA 5.6 PERCENTUAIS DE ACERTOS	113

TABELA 5.7. PERCENTUAIS DOS ÍNDICES DE ACERTOS COM TODAS AS VARIÁVEIS DE ENTRADA E COM SUBSTITUIÇÃO DAS MESMAS. TOTAL DE "PIXELS" COINCIDENTES COM A VERDADE DE CAMPO -----	115
TABELA 5.8. PERCENTUAIS DOS ÍNDICES DE ACERTOS COM TODAS AS VARIÁVEIS DE ENTRADA E COM SUBSTITUIÇÃO DAS MESMAS. TOTAL DE "PIXELS" COINCIDENTES COM A VERDADE DE CAMPO -----	123
TABELA 5.9. PERCENTUAIS DOS ÍNDICES DE ACERTOS COM TODAS AS VARIÁVEIS DE ENTRADA E COM ALTERNAÂNCIA DAS MESMAS. TOTAL DE "PIXELS" COINCIDENTES COM A VERDADE DE CAMPO -----	130

LISTA DE FIGURAS

FIGURA 2.1 - ESQUEMA DE UM NEURÔNIO BIOLÓGICO -----	17
FIGURA 3.1 – LOCALIZAÇÃO DA ÁREA-----	21
FIGURA 3.2 – DIAGRAMA DE BLOCO – SEQUÊNCIA DOS PROCESSAMENTOS -----	31
FIGURA 3.3 (A)– REPRESENTAÇÃO DAS SETE UNIDADES FISIONÔMICAS SEPARADAS POR MEIO DA FOTOINTERPRETAÇÃO -----	33
FIGURA 3.3 (B) – REPRESENTAÇÃO DAS SEIS UNIDADES SELECIONADAS A PARTIR DO MAPA GEOLÓGICO.-----	35
FIGURA 3.4 - PROCESSO DE GERAÇÃO DO MDT-----	39
FIGURA 3.5 - IMAGEM DO MODELO DIGITAL DO TERRENO – MDT-----	41
FIGURA 3.6 (A)- IMAGEM DO GRADIENTE DA ENCOSTA -----	43
FIGURA 3.6 (B) - IMAGEM DA EXPOSIÇÃO DA RAMPA -----	44
FIGURA 3.7 - IMAGEM DAS MICROBACIAS-----	47
FIGURA 3.8 - IMAGEM DO ÍNDICE DE VEGETAÇÃO DA DIF. NORMALIZADA (NDVI)-----	49
FIGURA 3.9 - IMAGEM DA PRIMEIRA COMPONENTE PRINCIPAL-----	53
FIGURA 3.10 - IMAGEM DA SEGUNDA COMPONENTE PRINCIPAL-----	54
FIGURA 3.11 - IMAGEM DA TERCEIRA COMPONENTE PRINCIPAL -----	55
FIGURA 3.12 - IMAGEM DA BANDA ARTIFICIAL IHS (Gradiente \MDT Gradiente)59	
FIGURA 3.13 - IMAGEM DO POTÁSSIO -----	65
FIGURA 3.14 - IMAGEM DO TÓRIO -----	67
FIGURA 3.15 - IMAGEM DO URÂNIO-----	69
FIGURA 3.16 - ARQUITETURA DAS REDES NEURAIS FEEDFORWARD -----	74
FIGURA 3.17 - EXEMPLO DE UM NEURÔNIO-----	74
FIGURA 3.18 – ESQUEMA DE UMA REDES NEURAIS DE UMA CAMADA COM VÁRIAS ENTRADAS E UMA SAÍDA -----	76
FIGURA 3.19 – ESQUEMA DE UMA REDE NEURAL MOSTRANDO O TREINAMENTO-----	79
FIGURA 3.20– SUPERFÍCIE DO ERRO MÉDIO QUADRÁTICO COM INFINITOS PONTOS DE MÍNIMO -----	80

FIGURA 5.1 (A)- IMAGEM CLASSIFICADA CP (3), MICROBACIAS, MDT E K----	104
FIGURA 5.1 (B)- IMAGEM DA TABULAÇÃO CRUZADA (CRAMER'S V=0,4347)	105
FIGURA 5.2 (A) - IMAGEM CLASSIFICADA – TRÊS CP, MICROBACIAS E MDT (CRAMER'S V =0,4767)-----	107
FIGURA 5.2 (B)- IMAGEM DA TABULAÇÃO CRUZADA (CRAMER'S V=0,4767)	108
FIGURA 5.3 (A) - IMAGEM CLASSIFICADA MDT, MICROBACIAS, BANDA 4, GRADIENTE DA ENCOSTA, TH, K E U -----	111
FIGURA 5.3 (B)- IMAGEM DA TABULAÇÃO CRUZADA (CRAMER'S V=0,6051)	112
FIGURA 5.4 (A) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DAS INFORMAÇÕES GAMAESPECTROMÉTRICAS DO ELEMENTO POTÁSSIO (K)	116
FIGURA 5.4 (B) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DAS MICROBACIAS-----	117
FIGURA 5.4 (C) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DO MDT	119
FIGURA 5.4 (D) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA TERCEIRA COMPONENTE DA TRANSFORMAÇÃO TERCEIRA CP -----	120
FIGURA 5.4 (E) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA SEGUNDA COMPONENTE DA TRANSFORMAÇÃO SEGUNDA CP-----	121
FIGURA 5.4 (F) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA PRIMEIRA COMPONENTE DA TRANSFORMAÇÃO PRIMEIRA CP-----	122
FIGURA 5.5 (A) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA SEGUNDA COMPONENTE DA TRANSFORMAÇÃO CP-----	124
FIGURA 5.5 (B) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA PRIMEIRA COMPONENTE DA TRANSFORMADA CP -----	125
FIGURA 5.5 (C) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA TERCEIRA COMPONENTE DA TRANSFORMAÇÃO CP -----	126
FIGURA 5.5 (D) – IMAGEM GENERALIZADA SEM A INFERÊNCIA DAS INFORMAÇÕES DE ENTRADA DO MDT -----	127
FIGURA 5.5 (E) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DAS INFORMAÇÕES REFERENTES AS MICROBACIAS -----	128
FIGURA 5.6 (A) – IMAGEM GENERALIZADA SEM A INFERÊNCIA DAS INFORMAÇÕES DE ENTRADA DO MDT -----	131
FIGURA 5.6 (B) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DO GRADIENTE DA RAMPA (GRADIENTE DA ENCOSTA)-----	132

FIGURA 5.6 (C) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA PRIMEIRA COMPONENTE DA IMAGEM DAS MICROBACIAS -----	133
FIGURA 5.6 (D) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DO DADO GAMAESPECTROMÉTRICO TH-----	134
FIGURA 5.6 (E) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DO DADO GAMAESPECTROMÉTRICO U -----	135
FIGURA 5.6 (F) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DO DADO GAMAESPECTROMÉTRICO K-----	136
FIGURA 5.6 (G) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DAS INFORMAÇÕES REFERENTES A IMAGEM BANDA 4 -----	137

LISTA DE GRÁFICOS

GRÁFICO 5.1 – COMPARAÇÃO ENTRE O ERRO MÉDIO QUADRÁTICO MÍNIMO REFERENTE ÀS TABELAS 5.1 (A E B)----- 101

RESUMO

Com o propósito de classificar digitalmente, isto é, separar automaticamente unidades fisionômicas e geológicas, o presente estudo utiliza a técnica das redes neurais artificiais para a integração de dados originários do sensoriamento remoto, imagens digitais, e informações a respeito dos agentes formadores das paisagens, tais como o relevo, a rede de drenagem, geologia, etc.

O sensoriamento remoto, por meio das imagens digitais, tem sido nas últimas décadas, uma das técnicas utilizadas para suprir a escassez dos mapeamentos temáticos, utilizando as técnicas convencionais de classificação, paramétricas. Para a separação de fisionomias esta classificação não permite a integração de informações de diferentes origens e escalas, associação esta crucial para que se possa classificar tais fisionomias, haja vista que, a compreensão da estrutura, caracterização e delimitação, das paisagens demandam uma abordagem interdisciplinar, isto é, o problema dos aspectos fundamentais dos ambientes e das paisagens integrados, leva a uma abordagem e discussão dos elementos de formação dos ambientes os quais são caracterizados pelas estruturas geológicas, pela organização morfológica do relevo, pelos aspectos pedogenéticos (de formação dos solos) e pelo clima.

Ainda pode-se salientar que a utilização da metodologia embasada na imitação do raciocínio do comportamento humano e a integração de dados procuram executar uma classificação digital levando em consideração os elementos de formação das paisagens assim como o ser humano intuitivamente classifica uma cena por meio destes elementos formadores das paisagens, gerando produtos subjetivos. Sendo a separação destas unidades fisionômicas automática pode-se minimizar a subjetividade que cada analista utiliza na sua interpretação sobre características únicas da paisagem (fisionomias).

Pode-se afirmar que com a técnica das redes neurais artificiais foi possível a separação das unidades fisionômicas/ geológicas e que esta permitiu a associação de dados de diferentes origens e escalas.

Para a separação das unidades fisionômicas as informações mais relevantes, associadas às imagens digitais, foram o relevo, representado pelo modelo digital do terreno, a rede de drenagem, discriminadas por meio das microbacias. Na classificação digital das unidades geológicas as informações importantes foram o modelo digital do terreno, as microbacias e representando a geologia o elemento Tório.

ABSTRACT

The present study uses the technique of artificial neural networks for the integration of data from remote sensing, digital images and information regarding the landscape formation agents, such as relief, drainage net, geology, etc. in order to perform a digital classification, that is, to automatically detect physiognomic and geological units.

Remote Sensing images have been, in the past decades, used to fulfill the lack of thematic data, through common classification parametric techniques. However, the Integration of information from different origins and scales is not possible with that technique, since an understanding of the structure, characterization and delimitation of the landscape demands an interdisciplinary approach, that is, an analysis of the elements that form the environment, such as the geological structures, the morphological organization of the relief, the pedogenetic aspects (soil formation) and the climate.

The use of a methodology based on the simulation of the reasoning of the human being behavior and the integration of data attempts to perform a digital classification considering the forming elements of landscape similarly to how a human being intuitively would classify a scene, generating subjective products. Since the detection of these physiognomic units is automatic, one can lower the subjectivity level on how an analysis would be made, based on the landscape unique characteristics (physiognomies).

With the aid of the technique of artificial neural networks, the separation of the physiognomic /geological units was possible, which allowed the association of data from different origins and scales.

In order to distinguish physiognomic units, the most relevant information associated to the digital images was relief, represented by the digital terrain model, drainage, discriminated by the micro basins. For the digital classification of the geological units, the relevant information was the digital terrain model, the micro basins and to represent the geology, the element Thorium.

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES

Reconhecer e delimitar áreas sempre foram grandes desafios e uma necessidade para o homem. O reconhecimento e detalhamento do espaço físico territorial tornam-se fundamentais para subsidiar ações de planejamento e administração pública. Os mapeamentos aplicados ao planejamento regional e urbano utilizam dados do meio físico, com a finalidade de orientar o uso da terra, a análise ambiental e as obras civis (engenharia, arquitetura) entre outras.

A compreensão da estrutura, caracterização e delimitação, das paisagens demandam uma abordagem interdisciplinar. O problema dos aspectos fundamentais dos ambientes e das paisagens integrados, leva a uma abordagem e discussão dos elementos de formação dos ambientes os quais são caracterizados pelas estruturas geológicas, pela organização morfológica do relevo, pelos aspectos pedogenéticos (de formação dos solos), pelo clima e pela ação antrópica.

O mapeamento da cobertura existente sobre determinada área pode ser executado através de métodos de classificação de imagens digitais. A classificação é um processo de generalização de dados coletados sobre certos fenômenos para que estes sejam reconhecidos.

Várias técnicas vêm sendo empregadas para a análise e classificação de imagens digitais, dentre as quais pode-se citar os métodos já consagrados de classificação como máxima verossimilhança e mínima distância. Ultimamente vem-se utilizando técnicas da Inteligência Artificial para reconhecimento de padrões e classificação de imagens digitais associadas a dados auxiliares como geomorfologia, geologia e outros.

No que se refere à ocupação do espaço, observa-se à tendência de utilização inadequada do mesmo. O processo de ocupação do solo nas cidades brasileiras é influenciado pelo crescimento da população urbana e vem se caracterizando por desobedecer a critérios de planejamento que considerem os recursos naturais existentes e o interesse maior coletivo. Desse modo, a ocupação do solo tem se

processado de maneira desordenada. O alto custo de levantamentos de campo para a execução de mapas de solos em grandes escalas gera, cada vez mais, a escassez dessas informações, acarretando um grande problema na consecução de políticas de planejamento e recuperação de áreas degradadas do meio físico.

Nas duas últimas décadas o sensoriamento remoto tem sido a principal fonte de informação temática para escalas 1:70.000 à 250.000. A extração de informação baseia-se em técnicas, algoritmos paramétricos, tentando suprimir a escassez da cartografia temática, como a do uso e ocupação do solo, da aptidão agrícola das terras, da caracterização de unidades fisionômicas, dentre outras.

A utilização de metodologias embasadas na imitação do raciocínio humano, utilizando dados oriundos de sensoriamento remoto vêm crescendo e a estes, dados complementares podem ser acrescentados. Esta integração de dados de diferentes origens associados aos dados de imagens digitais tem obtido sucesso fornecendo indicações necessárias para se racionalizar o uso do solo, dando o suporte necessário à tomada de decisões técnicas.

A associação de dados de diferentes origens à classificação digital é importante, pois estes permitem incrementar a análise quantitativa e qualitativa de maneira similar a análise visual, onde o intérprete com seu conhecimento, sobre sua realidade, tem a habilidade de diferenciar visualmente os diferentes tipos de relevo, a rede de drenagem e outras feições que caracterizam a região. Vale ressaltar que, métodos convencionais de classificação, baseados na hipótese de normalidade das variáveis, dificultam que informações complementares sejam agregadas aos dados originários do sensoriamento remoto, uma vez que essas informações podem não respeitar a distribuição normal.

A integração de dados baseada em inteligência artificial, tal como a rede neural artificial é vantajosa para o desenvolvimento de metodologias que, automatizem e otimizem a produção de mapas temáticos, agilizando e melhorando a acurácia dos mesmos. A automatização e otimização da integração de dados para a separação de unidades fisionômicas são cruciais em relação aos levantamentos de campo, pois podem minimizar os custos dos mesmos.

Portanto nesse contexto, o presente estudo visa separar automaticamente unidades fisionômicas (de paisagem) e unidades geológicas utilizando a técnica de redes neurais artificiais para a integração de dados de sensoriamento remoto e

informações do espaço físico que auxiliam na separação das unidades mencionadas.

1.2 OBJETIVOS

O objetivo geral desta pesquisa é propor uma metodologia para separar, automaticamente, unidades fisionômicas (de paisagem) e unidades geológicas; utilizando-se de dados de imagens digitais adquiridas por sensoriamento remoto (SR) e dados auxiliares derivados de outras fontes.

Os objetivos específicos são:

- a) Verificar o desempenho das Redes Neurais (RNA) na separação das unidades fisionômicas (de paisagem) e unidades geológicas;
- b) Associar as informações dos agentes que podem atuar nos processos de formação das unidades fisionômicas, tais como: o relevo e a rede de drenagem;
- c) Verificar quais são os dados auxiliares (complementares) que, associados às imagens digitais, influenciam na separação das unidades em estudo.

1.3 MOTIVAÇÃO

O uso do solo inadequado e muitas vezes indiscriminadamente utilizado é uma realidade no país. A escassez de mapas temáticos, devido ao alto custo de levantamento de campo, é um problema para que se possa executar um planejamento e recuperação de áreas de interesse do espaço físico territorial.

As técnicas de Sensoriamento Remoto, desde algumas décadas, vêm tentando suprir a escassez de mapeamento do espaço físico, tais como uso e ocupação do solo, aptidão agrícola das terras, caracterização de unidades fisionômicas, dentre outros, utilizando algoritmos estatísticos.

Apesar das metodologias já desenvolvidas para a interpretação e classificação de imagens adquiridas por meio do sensoriamento remoto, os mapeamentos temáticos, dentre estes a separação de unidades fisionômicas, ainda são subjetivos, pois a análise das imagens executada pelo fotointérprete é intuitiva e qualitativa. Uma abordagem automática e sistemática, utilizando os dados obtidos das imagens digitais espectrais integradas as informações que auxiliem na representação do espaço físico, pode vir a gerar produtos menos subjetivos e analisados quantitativamente.

A utilização de metodologias calcadas na imitação do comportamento humano vem avançando nas últimas décadas em diversas áreas. No SR o conexionismo tem sido utilizado na integração de dados de diferentes escalas e origens por meio da técnica de RNA, para a classificação da cobertura e uso do solo. A integração de dados é primordial já que esses dados podem fornecer informações do espaço físico, complementando os dados espectrais. É pertinente salientar que, a associação desses dados é uma tentativa de melhorar a análise quantitativa de maneira similar à análise visual, onde o intérprete, intuitivamente ou por seu conhecimento, pode detectar fisionomias da cena por meio de dados espectrais, de relevo, drenagem, etc.

A técnica de RNA apresenta-se como uma alternativa, neste contexto, pois possibilita associar aos dados oriundos de sensoriamento remoto, outros dados de diferentes origens, minimizando a subjetividade que cada analista utiliza na sua interpretação sobre características únicas da paisagem (fisionomias). Tal complementação de informações seria inviável utilizando os métodos convencionais.

1.4 ESTRUTURAÇÃO

O estudo está estruturado em sete (7) capítulos. O primeiro capítulo consta da introdução, dos objetivos e motivação.

No segundo capítulo estão relatadas as questões relacionadas ao Sensoriamento Remoto, a Análise Fisionômica, a Integração de Dados, Segmentação e a Inteligência Artificial – Redes Neurais. Na seção referente ao

Sensoriamento Remoto estão incluídos os processos de interpretações visual e digital de imagens. Em se tratando da técnica de Inteligência Artificial, constam os conceitos fundamentais das Redes Neurais, as características de Redes Neurais Biológicas, a Arquitetura das Redes Neurais, o funcionamento de um neurônio, o treinamento da Rede Neural e os algoritmos de treinamento utilizados.

O capítulo 3 diz respeito aos materiais e métodos. Neste, é feita a descrição da área de estudo e suas características quanto à localização, relevo, vegetação, hidrologia, geologia, solos e descrição das unidades fisionômicas (baseando-se na fotointerpretação e no mapa geológico), além dos materiais: “software”, mapas, imagens, etc. Nos métodos são explicados como foram processados todos os dados originários do SR (correção geométrica das imagens orbitais, Índice Normalizado de Vegetação, as transformações em Componentes Principais, a IHS e “Tasseled Cap” e dos dados gamaespectrométricos), além dos auxiliares (modelo digital do terreno, gradiente da encosta, exposição da rampa, microbacias). Consta ainda do procedimento aplicado para a definição das unidades fisionômicas e geológicas, isto é, duas séries de testes: a primeira tendo como verdade de campo uma imagem gerada por meio da fotointerpretação e a segunda série adotando-se como realidade o mapa geológico. Neste capítulo têm-se, ainda, as verificações por meio da matriz de confusão, importância das variáveis e coeficiente de correlação.

No capítulo 4 são apresentados os experimentos para a definição da arquitetura da RNA, testes executados para a modelagem da Rede Neural e os testes para a separação das unidades fisionômicas.

No capítulo 5 estão os resultados e discussões, das variáveis que melhor caracterizam as unidades fisionômicas, do desempenho das Redes Neurais para a classificação e a caracterização dessas fisionomias.

No capítulo 6 e 7 são relatadas as conclusões e recomendações, respectivamente, finalizando-se com as referências bibliográficas.

2 REVISÃO DA LITERATURA

O tema proposto neste trabalho aborda técnicas das áreas da Inteligência Artificial, do Sensoriamento Remoto e de Geologia no que diz respeito à separação de unidades fisionômicas. Assim sendo, alguns conceitos introdutórios serão descritos nas seções 2.1 a 2.4.

2.1 ANÁLISE FISIONÔMICA

As formas e paisagens da superfície Terrestre são de importância para estudos científicos em setores das Ciências da Terra como a geomorfologia, a geologia, a pedologia, o planejamento urbano e regional, além de outros que desejam utilizar adequadamente o espaço físico territorial.

A Geomorfologia estuda as formas e paisagens da superfície Terrestre, incluindo sua descrição, tipo e gênese. A forma da Terra é o produto final resultante de interações de agentes naturais da superfície e tipos de rochas. Estas interações dependem do clima, do tipo de rocha e estrutura, bem como do espaço de tempo (GUPTA, 1991, p. 225).

BIGARELLA et al. (1994, p. 16), enfatizam que a problemática integrada dos aspectos fundamentais dos ambientes e das paisagens implica na abordagem e discussão da estrutura geológica, da evolução climática regional (atual e pretérita), bem como da análise dos principais eventos que conduziram à organização morfológica do relevo. São igualmente importantes os aspectos pedológicos e biogeográficos. Em síntese, a compreensão da estrutura e da origem das paisagens necessita de abordagem interdisciplinar objetiva, considerando seu desenvolvimento no espaço e no tempo.

A análise fisionômica pode ser entendida como o reconhecimento de diferentes ou principais tipos de formas, relevo, padrão de drenagem natural,

vegetação natural, uso da terra, condições da drenagem e outros elementos como erosão, superfície do solo e estrutura geológica. As unidades são regiões que possuem padrões que podem caracterizá-las. São unidades “homogêneas” que apresentam características físicas similares, tais como, relevo, vertentes, declividade, padrão da rede de drenagem, estrutura geológica, cobertura vegetal e ação antrópica (MULDERS, 1982, p. 1 -36).

As principais características que podem ser avaliadas por meio de dados capturados por Sensoriamento Remoto são os padrões associados aos tipos de rochas, formas do terreno, textura do solo, condições da rede de drenagem, suscetibilidade ao escoamento e materiais inconsolidados sobre as rochas. De acordo com OLIVEIRA et al. (1992, p.15) a experiência tem demonstrado que nenhum componente da natureza pode ser compreendido quando estudado isoladamente.

2.2. INTERPRETAÇÃO DE IMAGENS

A delimitação de unidades fisionômicas é tradicionalmente executada por meio da interpretação visual, na qual o analista utiliza experiência e conhecimento para a separação das mesmas. O objetivo da automatização na separação das unidades é tornar o processo sistemático e, portanto, menos subjetivo.

2.2.1 Interpretação Visual de Imagens

A interpretação visual de imagens é o ato de identificar objetos na cena e discernir seu significado. Esta é executada qualitativamente, observando-se e identificando-se as feições do terreno, por meio de características encontradas na cena, padrões de reconhecimento, como a forma, o tamanho relativo, a sombra, a tonalidade, a textura, as localidades e as adjacências e incluindo o conhecimento do

comportamento espectral de feições quando a interpretação visual é em imagens digitais (WOLF, 1983, p. 514).

A análise visual de uma imagem não se restringe apenas às propriedades espectrais armazenadas sob a forma de valores digitais em cada "pixel". Entre outros aspectos que podem ser explorados encontram-se a textura e a forma dos objetos, bem como a associação espacial entre os objetos que compõem a cena (CENTENO et al. 2001).

BÄHR (2002, p. 6) descreve um exemplo mostrando a dificuldade de comparação de componentes espaciais em uma sobreposição ("overlay") de uma fotografia aérea e linhas digitalizadas. O autor cita que, o intérprete humano é capaz de discriminar componentes combinados, como construções no centro da cidade, tem a capacidade de verificar que as construções e linhas não se encontram geometricamente ajustadas e notar também que a imagem fotográfica possui muito mais riquezas de detalhes que às apresentadas pelo mapa.

A interpretação visual demanda conhecimento e experiência. O sucesso da análise visual é dependente da experiência do intérprete, que identifica objetos avaliando suas características, tais como a tonalidade, tamanho, adjacências, sombras, textura e forma, e agrupa esses elementos em regiões com a mesma propriedade e generaliza o resultado, tornando a informação mais legível para os usuários. Esses processos envolvem um alto grau de subjetividade, pois a cada etapa, decisões são tomadas e estas são calcadas em critérios do intérprete. Um analista bem treinado e familiarizado com a área de estudo tem critérios definidos, enquanto um intérprete menos experiente poderá tomar decisões menos seguras, em função da falta de conhecimento e prática na interpretação visual.

Portanto, processos que reduzam o grau de subjetividade da análise visual são almejados e uma forma de alcançá-los é por meio da implementação de regras em algoritmos automáticos de processamento de imagens.

2.2.2 Interpretação Digital de Imagens

O interesse em métodos de processamento digital de imagens decorre de duas áreas principais de aplicação: melhoria de informação visual para a interpretação humana e o processamento de dados de cenas para análise automática de imagens.

A imagem é uma representação do “mundo real” que registra exclusivamente o aspecto espectral dos objetos presentes na cena, por isso não contém uma descrição completa do mundo real (CENTENO, 2000, p. 17). A realidade tridimensional é projetada no espaço bidimensional da imagem e apenas determinada característica espectral dos pontos associados aos “pixels” são registradas e armazenadas.

O intuito, na interpretação das imagens digitais, é encontrar uma relação entre valores nela armazenados e o mundo real, representado sob a forma de um modelo. Para estimar esta relação, a informação contida na imagem pode ser representada de diferentes maneiras. No Processamento Digital de Imagens (PDI), a representação da informação é dividida em quatro grandes grupos, variando em função do nível de abstração (SONKA et al., 1998, p. 41).

Os dois níveis de interesse no estudo são “iconic image” e “segmented image”. Na primeira representação a imagem é analisada como um conjunto de observações (“pixels”) onde o elemento objeto da análise é o “pixel”, descrito por suas leituras nas diferentes bandas espectrais, isto é, matrizes de números inteiros representando os níveis digitais do “pixel”. No segundo nível, partes da imagem são reunidas em grupos que provavelmente pertencem ao mesmo objeto e o resultado é uma reunião de “pixels” formando uma única região homogênea. Neste caso, os elementos da análise são agrupamentos de “pixels”, também denominados de segmentos, que podem ser descritos em termos espectrais e espaciais. Estas representações são convenções num baixo nível de abstração para descrever o que o ser humano pode perceber (SONKA et al., 1998, p. 42). Existem ainda dois níveis mais complexos, “geometric representation” e “relational models”, que não serão aqui abordados.

Dentre as técnicas que se preocupam com a análise digital de imagens, pode-se destacar a classificação digital. A classificação digital de imagens consiste em alojar uma classe determinada para cada "pixel" ou região existente na imagem, isto é, associar o elemento da imagem a determinada categoria por meio de critérios estabelecidos (LILLESAND et al., 2000, p. 534). Os critérios podem ser puramente espectrais ou incluir critérios espaciais, no caso segmentos.

Dentre os métodos de classificação, a classificação supervisionada de imagens digitais é uma das técnicas mais amplamente utilizada na análise de dados gerados por sensoriamento remoto (FOODY et al., 1995, p. 391).

A classificação da cobertura de determinada área é um passo fundamental na análise de imagens, capturada por sensoriamento remoto, para diversas aplicações (KARTIEKEYAN et al., 1996, p. 483).

Atualmente, com a disponibilidade de imagens com resoluções espectrais e espaciais variadas e com a difusão do uso dos Sistemas de Informações Geográficas (SIG), podendo agregar dados de diferentes origens em um sistema georreferenciado, cientistas das mais diversas áreas vem pesquisando, desenvolvendo metodologias e aplicando diferentes técnicas, na utilização das imagens digitais integradas a dados que possam auxiliar na classificação digital, complementando informações de diferentes fontes, escalas e formatos. Estes dados auxiliares são de suma importância na extração de informações de uma área, pois a distribuição de feições sobre a superfície da Terra é inter-relacionada com outros fenômenos espaciais como a geologia, a topografia, os tipos de solos e as características hidrográficas. A próxima seção discorre sobre o nível de representação de imagens digitais "segmented image", ou seja, imagem segmentada. O nível de abstração "iconic image", onde o elemento mínimo da imagem digital é o pixel", não será apresentado, nesse estudo, por se entender que essa representação já encontra-se assimilada pelos usuários de imagens digitais.

2.2.3 Segmentação

O processo de segmentação representa um passo no sentido de preparar as imagens digitais para uma futura classificação temática em nível de segmentos, onde os elementos analisados são regiões resultantes do agrupamento de “pixels”, espacialmente próximos e com características espectrais similares (VENTURIERI et al., 1998, p. 360). A segmentação divide uma imagem em partes ou objetos que a constituem. O processo de segmentação ideal é finalizado quando os objetos de interesse, na aplicação, estiverem isolados.

SOLBERG et al. (1996, p. 105) enfatizam que a interpretação da cena, em nível de segmentos, onde é possível a inclusão de informação (espectral e espacial) é importante, pois mais parâmetros podem ser derivados para descrever os elementos. A dimensão espectral se refere às diferentes bandas do espectro eletromagnético e o contexto espacial é definido pela correlação espacial entre os “pixels” adjacentes e as suas vizinhanças (FAN et al., 2001, p. 2682). Basicamente, a segmentação consiste em direcionar o crescimento das regiões anexando “pixels” espectralmente similares e verificando se, as regiões semelhantes obedecem a certos critérios espaciais fixados pelo usuário. Assim, o critério de uniformidade é o resultado da combinação de um critério espectral (cor) e outro espacial (forma). A vantagem desta abordagem é que os segmentos resultantes podem ser mais compactos comparando-se ao crescimento de regiões puramente espectral.

Os algoritmos de segmentação para imagens monocromáticas são geralmente baseados nas propriedades básicas de valores de níveis digitais, ou seja, a descontinuidade e a similaridade. No primeiro caso, a abordagem é particionar a imagem baseando-se em mudanças bruscas nos níveis de digitais. As principais áreas de interesse nessa categoria são a detecção de bordas e pontos isolados e a detecção de linhas e bordas na imagem. As principais abordagens, no segundo caso, são baseadas em limiarização, crescimento de regiões e divisão e fusão de regiões. O crescimento de regiões é um procedimento que agrupa “pixels” ou sub-regiões em regiões maiores. A abordagem mais simples é a agregação de “pixels”, que inicia com um conjunto de pontos intitulados de “semente” e, a partir deles, as regiões vão crescendo, anexando a cada ponto “semente” aqueles “pixels”

adjacentes que possuem propriedades similares, tais como níveis de cinza, textura, cor, etc (GONZALES e WOODS, 1998, p. 213).

Ainda segundo GONZALES e WOODS (1998, p. 213), dois problemas devem ser questionados no caso da abordagem de crescimento de regiões: a seleção da "semente", que representa adequadamente as regiões de interesse a serem agregadas, e a seleção de propriedades apropriadas para a inclusão de pontos nas várias regiões durante o processo de crescimento das mesmas.

KOK et al. (1999, p. 111) salientam que o procedimento de segmentação deve ser moldado de acordo com a resolução da imagem e com a escala (tamanho) que se deseja dos objetos.

Uma das técnicas de segmentação, por crescimento de regiões, é a multi-resolução, FNEA ("Fractal Net Evolution Approach"). Esta segmentação é executada utilizando as propriedades básicas de valores de níveis digitais, (características espectrais das bandas ETM+ e das imagens gamaespectrométricas e os valores dos níveis digitais das imagens referentes as informações auxiliares), bem como as propriedades espaciais como a forma, a compacidade e a suavidade do contorno dos grupos formados a cada iteração.

De acordo com BAATZ et al. (2001) a abordagem FNEA é semelhante ao crescimento de regiões que agrupa "pixels" ou sub-regiões em regiões maiores; segmenta a imagem de maneira fina e grosseira gerando assim escalas de segmentação.

A segmentação multi-resolução, em uma primeira instância, é determinada por um certo grau de heterogeneidade que permite o agrupamento de "pixels" de acordo com uma resolução (WILLHAUCK, et al., 2000). Dois critérios de semelhança são usados para descrever a separação de objetos da imagem, os critérios de cor e de forma, e ambos controlam a homogeneidade dos segmentos (BLASCHE et al., 2002).

A segmentação funciona como um processo de otimização heurística, o qual minimiza a heterogeneidade média dos objetos da imagem para alcançar uma resolução para toda a cena, isto é, os "pixels" adjacentes e similares são agregados por segmentos onde o crescimento da heterogeneidade no domínio espectral e espacial é minimizado. Segmentos vizinhos são "fundidos", formando novo segmento. A definição de heterogeneidade é flexível e pode ser entendida como

uma permuta entre a homogeneidade no domínio espectral (espalhamento de níveis digitais de vários canais espectrais) e no domínio espacial (compacidade e suavidade) (ANTUNES, 2003, p. 47-49).

2.3 INTEGRAÇÃO DE DADOS

A tentativa de se estudar um sistema ou um fenômeno de vários ângulos é utilizar várias abordagens e tantos atributos quanto possível ou considerados razoáveis, para a obtenção de uma descrição mais compreensiva e clara da realidade. A principal vantagem de uma abordagem analítica da integração multidisciplinar é que ambigüidades, que podem aparecer devido ao uso de somente um tipo de dado, podem ser freqüentemente resolvidas por meio da combinação de vários conjuntos de dados que expliquem o fenômeno de interesse.

A integração significa que diferentes componentes serão agrupados e os mesmos cooperaram para a obtenção de um melhor resultado, que não seria obtido se estes dados fossem utilizados separadamente. As principais vantagens da estratégia de combinação de vários conjuntos de dados, na análise de imagens de sensoriamento remoto são:

- Usando de informações multidisciplinares, o número de atributos ou canais de informação é ampliado;
- Os dados auxiliares, podem incluir informações a respeito de agentes formadores do espaço físico (geologia, rede de drenagem, altitudes, dentre outros) que podem viabilizar a quantificação apropriada da categoria em estudo;
- A interpretação de todos os conjuntos de dados agrupados pode resultar em uma análise coerente (BALTSAVIAS et al., 1999, p. 4).

A integração de dados de diferentes origens, associada a informações oriundas de imagem capturadas por técnicas de Sensoriamento Remoto, tem se mostrado uma ferramenta de grande utilidade em mapeamentos temáticos. Cientistas da área das Ciências da Terra, tais como WARNER et al., 1997 (p. 1285 – 1294); HARRIS et al., 1990 (p. 1631 – 1641); RIBEIRO et al., 2002 (b) (p. 47-57) e

ANDRADE, 2003, (120p.), podem ser citados como referência em estudos de integração de dados.

O intuito da integração de dados é de ampliar a quantidade e qualidade de informações a respeito da área em estudo. Como os dados tem diferentes fontes, vêm complementar as informações que podem ser extraídas das imagens adquiridas por sensoriamento remoto, visando melhorar a acurácia dos mapas temáticos e auxiliar na extração de informações (interpretação) da cena imageada. A integração de dados de diferentes fontes não é um conceito recente, há muito tempo que esta metodologia vem sendo utilizada analogamente a muitas disciplinas das Ciências da Terra (MOON, 1990, p. 711).

Desde o advento dos Sistemas de Informações Geográficas (SIG), a possibilidade de integração de dados vem crescendo, uma vez que esses sistemas de dados (programa, pessoas e instituições para coletar, armazenar, analisar e disseminar informações sobre a superfície terrestre) têm a “habilidade” de inter-relacionar espacialmente múltiplos e diversos tipos de informação sobre feições georreferenciadas (MOON, 1990, p. 711).

Como as paisagens estão integradas em um contexto físico, no qual atuam na sua formação variáveis climáticas, geológicas, topográficas, etc, a integração de dados torna-se uma ferramenta importante na separação de suas unidades fisionômicas, sendo que essa separação é o primeiro passo para diversos estudos, tais como, geológico e pedológico.

Outra fonte de informações auxiliares para a separação de unidades fisionômicas é a rede de drenagem, que pode ser derivada de fotografias aéreas ou de imagens de satélite. Ela permite agregar objetos da imagem em regiões espacialmente uniformes, podendo caracterizar porções semelhantes no terreno em relação aos solos ou a geologia (ROCHA, 1993, p. 2).

Os dados auxiliares mais empregados na classificação digital são os referentes a informações geológicas e morfoestruturais, de imageamento por radar, de mapas de cobertura do solo, de mapas de floresta e de informações sobre relevo, tais como dados de declividade do terreno e gradiente da encosta (BENEDIKTSSON, et al. 1990, p. 540).

2.4 INTELIGÊNCIA ARTIFICIAL

Segundo HAYKIN (1999, p. 1) a Inteligência Artificial pode ser definida como um conjunto de técnicas de programação que procura resolver problemas em informática, através de programas e algoritmos, que procuram imitar o comportamento humano. Algumas das técnicas da Inteligência Artificial são os Algoritmos Genéticos, a Lógica Fuzzy, os Sistemas Especialistas e as Redes Neurais Artificiais (RNA).

LIPPMAN (1987), HILTON (1989) e SIMPSON (1990) citam que, as RNA constituem uma linha de pesquisa da Inteligência Artificial, dentro do conceito de conexionismo, que visa investigar a possibilidade de simulação de comportamentos inteligentes através de modelos baseados no cérebro humano. São compostas por unidades de processamento simples operando em paralelo. Essas unidades de processamento foram inspiradas nos sistemas biológicos dos neurônios. Existem vários modelos conexionistas, dentre os quais foram selecionados alguns que são apresentados a seguir:

- “Perceptrons” - proposto por ROSEBLATT em 1957;
- “Perceptrons” de Multi-Camadas - proposto por WERBOS, 1974,
- Rede de Kohonen - proposto por KOHONEN em 1980;
- Rede de Hopfield - proposto por HOPFIELD em 1982.

KAO (1996 p. 1033) comenta que as RNA, com sua capacidade própria de aprendizado e organização são uma promissora técnica para estabelecer tarefas que envolvem o conhecimento humano.

As RNA vêm sendo treinadas com sucesso para desempenhar funções complexas em várias áreas de aplicação incluindo reconhecimento de padrões, identificação, classificação, sistemas de controle da fala e da visão, entre outros. Atualmente as redes podem ser treinadas para resolver problemas que são difíceis de serem resolvidos por técnicas estatísticas convencionais. Para FOODY et al.

(1995, p. 392) as redes neurais artificiais têm considerável potencial para a classificação de dados advindos de sensoriamento remoto.

O Quadro 2.1 exemplifica as vantagens e desvantagens encontradas por cientistas da área das Ciências da Terra e Computação, na aplicação das RNA em estudos relacionados com a caracterização, com diversos enfoques do espaço físico territorial.

QUADRO 2.1 – VANTAGENS E DESVANTAGENS DAS REDES NEURAS APLICADAS AO SENSORIAMENTO REMOTO

VANTAGENS
Adaptação não linear dos componentes
Relativa tolerância na perda de dados e ruídos
Acomodação de dados nominais e contínuos
Algoritmo de aprendizado não necessita ser programado “a priori” na rede
A distribuição dos dados de entrada não respeita a suposição estatística
Potencial de processamento em paralelo
Uma vez treinado o classificador é eficiente computacionalmente
Capacidade de utilizar pequeno conjunto de treinamento em relação aos classificadores
Habilidade para executar mudanças nos dados
Incorporação indutiva da textura
Habilidade para incorporar dados contextuais
Os dados de saída exprimem possibilidades “fuzzy”
DESVANTAGENS
Problemas com formas não representativas e não esperadas na classificação
Requer grande capacidade de memória computacional para algumas redes
A rede e algoritmo de treinamento requerem pesquisa atual em função do assunto
Problemas com mínimo local no treinamento
Obscura em explanação de modelos e processos de predição
Disponível em poucos sistemas (programa) de processamento digital de imagens
Usuário deve indicar as entradas relevantes, a rede prioriza feições significantes

FONTE: JARVIS et al., 1996, p. 960.

Para VEAUX et al. (1998, p. 273), as RNA são usualmente designadas como modelos “caixa preta” devido ao fato de seus parâmetros serem ajustados experimentalmente, geralmente, não serem interpretáveis.

Segundo PAOLA et al. (1997, p. 543) a estrutura das RNA faz com que seja viável a incorporação de dados auxiliares ou informações espaciais na classificação digital do uso e cobertura do solo.

HAYKIN (1999, p. 20) compara as características comuns entre as RNA e as redes biológicas:

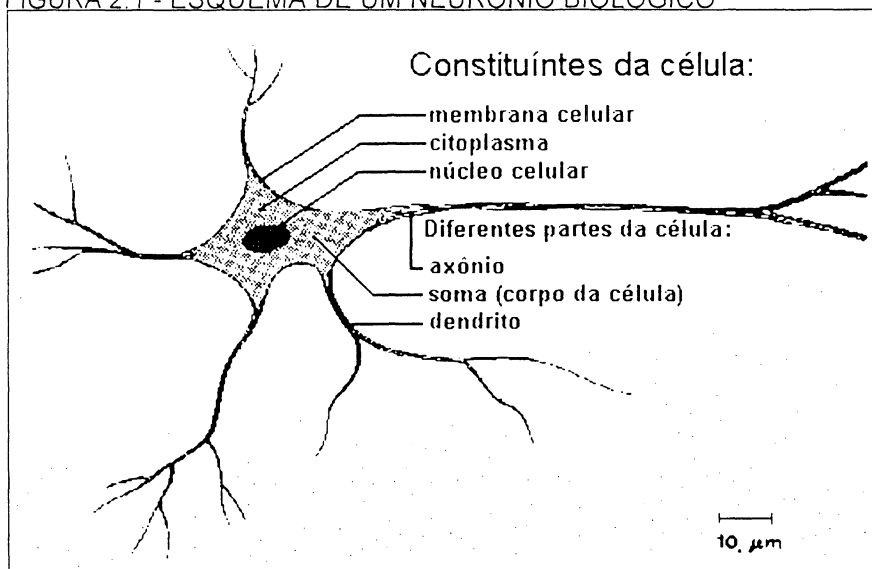
- Os dois sistemas são baseados em unidades de computação, paralela e distribuída, que se comunicam por meio de conexões sinápticas;
- Possuem detectores de características, redundância e modulação de conexões.

Os neurônios biológicos (Figura 2.1) são compostos de:

- Corpo celular ou soma: que combina os sinais recebidos, possui membrana que gera impulsos nervosos (elétricos);
- Dendritos: tem como função receber informações ou impulsos e enviá-los ao corpo celular;
- Axônio: recebe os impulsos e os envia a outros dendritos do neurônio seguinte.

A sinapse é o ponto de contato entre a terminação axônica de um neurônio e o dendrito de outro. São válvulas com capacidade de controlar a transmissão dos impulsos que a ela chegam. A sinapse pode ser inibitória ou excitatória, em função do tipo de neurotransmissor.

FIGURA 2.1 - ESQUEMA DE UM NEURÔNIO BIOLÓGICO



FONTE: KOVÁCS 1996, p. 45.

TAFNER et al. (1995, p. 620), descrevem que o funcionamento de um neurônio biológico pode ser modelado como sendo um circuito binário. Este circuito binário possui entradas binárias (0 e 1) que são combinadas através de uma soma ponderada (corpo celular), gerando a entrada efetiva do neurônio, que determinará a continuação desse estímulo. Se o estímulo for excitatório (1), isto é, ultrapassar um limiar, este é enviado a outro neurônio. Os autores completam que as entradas de um neurônio artificial podem ser comparadas exatamente como estímulos do neurônio biológico. Todos esses estímulos são trazidos até o neurônio simultaneamente, ou seja, se um neurônio possuir cinco entradas, os sinais das cinco entradas deverão chegar até o núcleo de processamento ao mesmo tempo, isto quer dizer paralelamente. Portanto, tanto o neurônio biológico como o artificial possuem muitas entradas e disparos de saída.

Segundo BRAGA et al. (2000, p. 237), para incitar o comportamento das sinapses, os terminais de entrada do neurônio artificial têm pesos cujos valores podem ser maiores que zero ou menores que zero (positivos e negativos), dependendo das sinapses serem inibitórias ou excitatórias. O neurônio dispara quando a soma dos impulsos que ele recebe ultrapassa um limiar de excitação. A ativação do neurônio é feita através da função de ativação que aciona ou não a saída, em função do valor da soma ponderada das entradas.

Uma RNA é composta por vários neurônios distribuídos em camadas. A primeira camada é chamada de camada de entrada e tem a função de armazenar os dados de entrada na rede. As camadas intermediárias denominadas de camadas escondidas são os "pensamentos", onde ocorrem os processamentos da rede. A última camada, definida como de saída, recebe os valores já processados pela rede. A quantidade de neurônios por camadas, o número de camadas por rede e os pesos ajustados após o aprendizado é chamada de arquitetura da rede neural (ITO, et al., 2000, p. 157).

As RNA tem uma camada de entrada e uma de saída e podem ter uma ou mais camadas intermediárias (internas, escondidas ou "pensamentos") em função da complexidade do problema (MURNION, 1996, p. 996).

Como principais características das RNA, segundo BITTENCOURT (1998, p. 302), podem ser citadas:

- A capacidade de aprender (treinar) através de exemplos e de generalizar este aprendizado de maneira a reconhecer instâncias similares que nunca haviam sido apresentadas como exemplo;
- Bom desempenho em tarefas mal definidas, onde falta o conhecimento explícito sobre como encontrar uma solução;
- Não requer conhecimento a respeito de eventuais modelos matemáticos, dos domínios da aplicação.

Segundo LEES (1996, p. 955), o método de aprendizado é uma das partes mais importantes dos sistemas de RNAA e é a diferença fundamental entre as RNA artificiais e os algoritmos convencionais para classificação. RUMMELHART et al. (1986, p. 318 - 362) apontam que o mais popular algoritmo de treinamento supervisionado é o "Backpropagation", que é robusto, flexível e vem sendo utilizado para a classificação de imagens; tendo como primeira dificuldade a complexa definição da taxa de "aprendizado" e do termo "momento" (sendo essas as taxas com que os pesos são alterados em consequência dos erros).

Uma das maiores dificuldades no uso das redes neurais é a escolha da melhor arquitetura. De acordo com KAO (1996, p. 1033), uma configuração ótima para RNA é ainda uma importante área de pesquisa. Na prática o processo experimental vem sendo aplicado com o intuito de testar vários métodos de aprendizado e diferentes configurações.

Outro autor que descreve sua experiência com a arquitetura das RNA é MURNION (1996, p. 996) comenta que, a entrada e a saída na rede são óbvias, a primeira em função do número de variáveis de entrada e a segunda definida pelas classes de saída. Sobre a camada intermediária da rede o mencionado autor cita que não há uma resposta óbvia, pois o número ótimo de camadas escondidas depende da aplicação.

GERMAN et al. (1996, p. 973) descrevem que o número de nós (neurônios) da camada interna é definido levando-se em consideração o funcionamento da rede, isto é, os nós da camada interna executam a separabilidade do espaço das classes.

Para FITZGERALD et al. (1996, p. 984) a complexidade do problema de classificação de dados advindos de SR é a definição do número de nós da camada interna. Os autores citam a regra de HILTON (1989), onde o número de nós da camada interna não deve exceder um terço do conjunto de amostras de treinamento.

Para BENEDIKTSSON et al. (1990, p. 550) o modelo das RNA tem uma vantagem sobre os métodos estatísticos. As redes neurais não são paramétricas, portanto não exigem conhecimento “a priori” da distribuição estatística dos dados. Por isso, uma rede neural é capaz de classificar dados advindos de diversas origens com diferentes escalas. Esta capacidade de classificação não pode ser facilmente conseguida com as técnicas padrão de classificação (GONG et al., 1996, p. 1258).

RIBEIRO et al. (a) (2002, p. 59) utilizaram a técnica das RNA comparando-a com o classificador Máxima Verossimilhança e concluíram que a classificação do uso do solo foi melhor com a técnica das RNA, com uma menor quantidade de amostras de treinamento, e ainda comentam o fato da técnica de RNA não necessitar de hipóteses a respeito da distribuição das classes, podendo assim ser uma ferramenta na integração de dados de diferentes origens na classificação do uso por meio de imagens digitais.

3 MATERIAIS E MÉTODOS

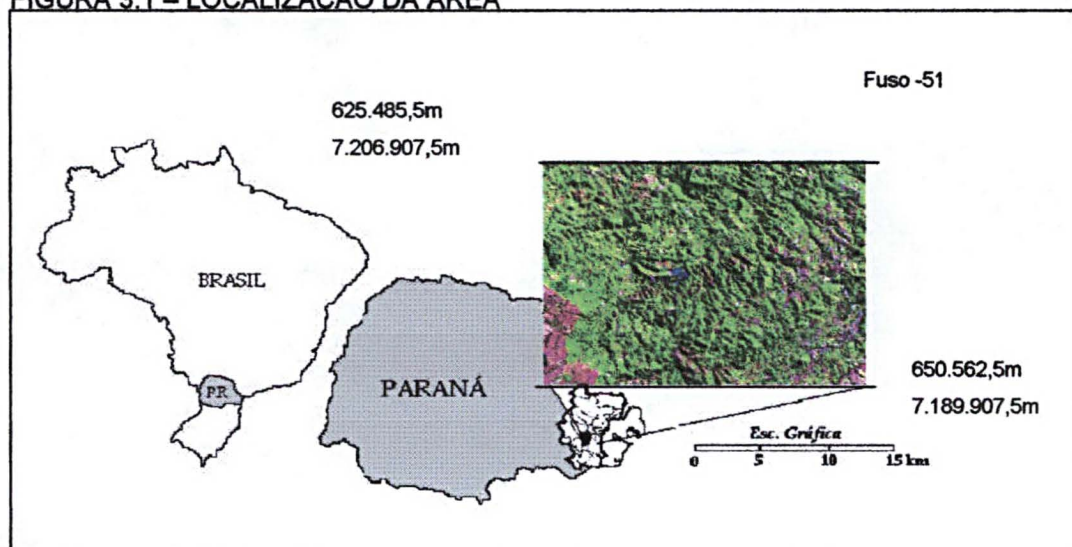
3.1 DESCRIÇÃO DAS CARACTERÍSTICAS FÍSICAS DA ÁREA

As seções 3.1.1 a 3.1.7 descrevem a região quanto à localização, ao relevo, ao clima, à hidrografia, à vegetação, à hidrologia e à geologia.

3.1.1 Localização

A área de estudo está localizada na Folha Campo Largo, na escala 1:50.000, (IBGE, 1983). Esta é apresentada na Figura 3.1 na posição limítrofe entre o primeiro e o segundo planalto, situa-se na escarpa Devoniana, que separa o Planalto de Curitiba do Planalto de Ponta Grossa, abrangendo essas duas unidades geomorfológicas (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 2).

FIGURA 3.1 – LOCALIZAÇÃO DA ÁREA



FONTE: MODIFICADO DE COMEC, 1995

3.1.2 Relevo

O Primeiro Planalto Paranaense está representado por duas porções distintas, uma região de relevo acidentado residual esculpido em rochas metamórficas do Grupo Açunguí e o pediplano dissecado da região de Campo Largo, que ocupa a porção SE da folha homônima. Caracteriza-se por apresentar um relevo acidentado com altitudes que variam entre 800 e 1.100m, em espigões que se alongam segundo as direções estruturais de dobramento (NE). Intrusões básicas com direção geral NW provocam o aparecimento de boqueirões ou esporões com essa direção, dependendo da densidade, da espessura dos diques e da resistência das rochas encaixantes com respeito ao intemperismo (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 4).

O Segundo Planalto Paranaense representado na folha de Campo Largo pela porção elevada que se situa a SW é limitado pela escarpa da Formação Furnas. Compreende os Campos Gerais, com altitudes entre 1.100m e 1.200m. Caracteriza-se por um relevo colinoso, suave com vertentes convexas (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 5).

3.1.3 Clima

De acordo com a classificação de Köppen, a região apresenta um clima do tipo Cfb, quase sempre úmida com características pluviais de clima quente - temperado, no mês mais quente podem ser registradas temperaturas médias inferiores a 22°C e o restante do ano com médias maiores que 10°C. Possui uma precipitação regular ao longo do ano e formação de geadas durante o inverno; raramente neva e pouco se percebe uma estação tipicamente seca (MAACK, 1981, p. 210).

3.1.4 Hidrografia

O padrão de drenagem do Primeiro Planalto é nitidamente retangular seguindo as direções estruturais e os vales profundos, com tendências ao entalhamento. No Segundo Planalto o padrão de drenagem também é retangular e os cursos d'água são adaptados principalmente às linhas tectônicas, caracterizando-se pelo aparecimento de inúmeros canhões retilíneos e profundos (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 4 - 5).

3.1.5 Vegetação

De acordo com BIGARELLA et al. (1994, p. 77-80) existe uma forte relação entre a vegetação e o clima em relação à latitude, à altitude e à natureza do solo, de modo que a ação conjunta desses fatores resultam a ocorrência de determinados tipos de vegetação. Do ponto de vista fisionômico, de um modo geral, a vegetação pode ser assim agrupada:

a. Floresta

A vegetação típica é a mata densa com árvores de grande porte, onde o pinheiro é o elemento predominante. A ação antrópica tem modificado a fitofisionomia da região, no sentido de transformar as matas em campos e zonas de capoeiras, através do desmatamento intensivo (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 4).

b. Campos

Campos subtropicais secundários: constituídos por pastagens artificiais e pela vegetação graminóide que segue a derrubada das matas.

Campos subtropicais das várzeas úmidas: compostos predominantemente por gramíneas e ciperáceas, de pequeno valor nutritivo. Ocupam as depressões ou planícies de inundação, em relevo plano (EMBRAPA, 1974, 20).

3.1.5 Geologia

Na área de estudo encontram-se as Formações Furnas, a Guabirotuba e a Camarinha, Rochas Graníticas (Granitos Três Córregos e do Cerne), o Grupo Açungui e os Aluviões. A seguir essas unidades geológicas são descritas.

Grupo Açungui – Pré-Cambriano, compreende um espesso pacote de rochas epimetamórficas. Contendo as seqüências aluminosa, a arenosa e a calcária. A seqüência predominante é aluminosa, aparecendo não obstante, fácies litológicas típicas de seqüência arenosa, calco-magnesianas carbonatadas e férrica nela intercaladas, que evidenciam sucessivas variações no tipo de material depositado.

Sob o ponto de vista zoneográfico, o metamorfismo regional atuante atingiu a zona dos micaxistos superiores. Na região próxima ao contato com o Granito Três Córregos e Granito do Cerne o metamorfismo atinge grau mais elevado.

A seqüência aluminosa está representada em quase toda a sua totalidade por filitos, fácies petrográfica da Zona Y² dentro desta seqüência. Apresentam via de regra um aspecto lustroso, devido a presença de minerais micáceos de tamanho reduzido. Em alguns afloramentos, uma certa ritmicidade deposicional é evidenciada pela alternância de leitos com diferentes tonalidades e granulometria. Nesses casos, observa-se muitas vezes uma discordância entre os primitivos planos de estratificação e a xistosidade posteriormente imposta intensivo (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 9).

A seqüência arenosa está representada fundamentalmente por quartzitos, excluindo-se os termos intermediários como quartzitos filitoso, filitos, quartzíticos, quartzitos calcários, etc. Ocorrem sob a forma de lentes ou camadas de espessura variável dentro dos filitos e, pela sua maior resistência ao intemperismo resultam em espigões alongados que sublinham as estruturas regionais. Acham-se extremamente perturbados sem, contudo apresentar dobras secundárias, o que é comum no caso dos filitos; a grandes esforços locais, respondem com uma densa rede de fraturamento (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 10).

A seqüência calcária está representada fundamentalmente por calcários e dolomitos, além dos termos intermediários entre eles e das fácies de seqüência

carbonatada impura, com teor relativamente elevado de quartzo. Essas rochas ocorrem sob a forma de lentes de espessura variável, nos flancos, ou nos núcleos de dobras, intercaladas nos filitos. Estão intensamente dobradas, diaclasadas, falhadas, havendo inclusive feições diagnósticas de dobras de arrasto (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 11).

Rochas Graníticas – Pré-Cambriano. Compreende o Granito Três Córregos e o Granito do Cerne.

O Granito Três Córregos, na Folha Campo Largo, cobre uma extensa área no extremo NW, que compreende o bordo S do grande maciço granítico que se estende pelas folhas Três Córregos, Itaiacócoa e Quero-Quero. Apresenta contornos nítidos muito embora, na maioria dos casos as relações de contato encontrem-se cobertas ou mascaradas por efeito de tectônica. Na região de Taquara, filões graníticos recortam filitos e quartzitos do Grupo Açungui, evidenciando caráter intrusivo intensivo (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 13).

O Granito do Cerne ocorre no extremo NE da folha Campo Largo, está praticamente contido nessa folha, restando pequenas porções que se situam nas Três Córregos, Rio Branco do Sul e Curitiba. Ocupa estruturalmente o núcleo de uma anticlinal ectinítica de direção geral NE, constituída por rochas do Grupo Açungui, com forma elíptica, truncada em sua porção meridional por um falhamento de grande envergadura. No que diz respeito às relações de contatos são válidas aqui as mesmas considerações feitas para o Granito Três Córregos intensivo (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 14).

Formação Camarinha – Pré-Devoniano. Essa formação abrange, na Folha Campo Largo, uma área aflorando em duas porções descontínuas, mas de provável continuidade em sub-superfície. No seu conjunto, a formação é constituída por uma seqüência de siltitos, com intercalações de lentes e, mais raramente arcossianas ou argilosas, apresentando, de maneira característica uma coloração castanho escuro, por vezes castanho avermelhada. Toda a seqüência apresenta-se dobrada, com mergulhos de 30° a 80° r formando estruturas do tipo anticlinais e sinclinais mergulhantes de eixo NE. Assenta em discordância angular sobre as rochas do

Grupo Açungui existindo em âmbito regional certo alinhamento de atitudes, provocado por uma provável retomada do eixo de dobramento intensivo (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 16).

Formação Furnas – Devoniano Inferior. Ocorre nas porções W e SW dessa folha sob a forma de um espesso pacote de arenitos que repousam em discordância angular sobre rochas do Grupo Açungui e da Formação Camarinha, aplainadas regionalmente e limitam-se orientalmente por uma escarpa. Apresenta –se numa posição sub-horizontal com suave mergulho de aproximadamente 1° para o quadrante SW. Ocasionalmente, e, sobretudo na região próxima à escarpa encontram-se mergulhos mais acentuados, provocados por basculamentos tectônicos. Sua espessura na área gira em torno de 100-150m, constituída por arenitos grosseiros, friáveis, com típica estratificação cruzada, aparecendo subordinadamente horizontes conglomeráticos e níveis sílticos argilosos intensivo (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 18).

Formação Guabirota – Quaternário (Pleistoceno). Situa-se nessa área de estudo no extremo W, por esse motivo, não obstante sua extensão lateral seja considerável, sua espessura é pequena, em torno de 10-20m. Esses sedimentos repousam discordantemente sobre rochas metamórficas de idade pré-Cambriana, mais ou menos decompostas. No campo, caracterizam-se pela presença de argilitos de coloração avermelhada, mal selecionados, pouco consolidados pobres em estruturas primárias, apresentando raramente indícios de estratificação intensivo (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 22).

Aluviões - Quaternário (Holoceno). Trata-se fundamentalmente de material arenoso totalmente inconsolidado secundado por argilas geralmente portadoras de grande quantidade de matéria orgânica ou mesmo turfas no que difere totalmente dos depósitos pleistocênicos. Além disso, os cascalhos existentes nos leitos dos rios são constituídos predominantemente por material maturo e as areias são fundamentalmente

quartzosas intensivo (UNIVERSIDADE FEDERAL DO PARANÁ - GEOLOGIA, 1966, p. 23).

3.2.MATERIAIS

Imagens Digitais:

- Imagem do satélite Landsat5 TM (221_77, 1998) na composição colorida falsa cor 3, 4, 5. Cedida e georreferenciada pela empresa SENAGRO. Utilizada como base para o georreferenciamento da imagens Landsat7 ETM+;
- Imagem do satélite Landsat7 ETM+ bandas 1, 2, 3, 4, 5, 6 e 7 – (221_77, 2000);
- Fotografias Aéreas (pancromáticas) na escala 1:60.000 ano de 1994, em meio digital, escanerizadas do diapositivo e impressas.

Mapas Impressos:

- Mapa Geológico – Companhia de Pesquisa de Recursos Minerais (CPRM)- SUREG-SP- Comissão da Carta Geológica – Projeto Leste do Paraná- Folha Campo Largo SG-22-X-C-III - escala 1:100.000, 1977.

Mapas em meio Digital:

- Folha Campo Largo – IBGE, 1983, SG-22-X-C-III-D-3 em formato DXF, na escala 1:50.000 com curvas de nível com equidistância de 20 metros, cedido pela empresa SENAGRO;
- Mapa Geológico – formato digital, cedido pela empresa MINEROPAR- escala 1:100.000 –SG-22-X-C-III.

Programas:

- ENVI-RT 3.2. Utilizado Para a correção geométrica das imagens espectrais;
- ArcView 3.2 a, módulo 3D “Spacial Analysis”. Programa usado para o processamento das microbacias, por meio de um “script”, a partir do MDT;
- SURFER 7.0. A partir das curvas de nível, em formato digital, o “software” é utilizado para a interpolação e geração do MDT;

- eCognition 2.0. Processador da segmentação das imagens digitais;
- IDRISI 3.2. Programa utilizado para as verificações quanto ao coeficiente de Cramer's V;
- MatLab 5.3. Laboratório Matemático usado para o processamento das RNA;
- Geosoft. Usado para o recorte e interpolação das imagens do levantamento aerogamaespectrométrico.

Laboratórios:

- Estrutura do Laboratório de Sensoriamento Remoto do Curso de Pós-Graduação em Ciências Geodésicas da Universidade Federal do Paraná, Curitiba – PR;
- Estrutura do Laboratório de Fotogrametria e Sensoriamento Remoto do Institut Photogrammetrie und Geodäsie da Universität Fridericana de Karlsruhe, Karlsruhe (Baden – Württemberg) Alemanha;
- Estrutura do Laboratório de Pesquisas em Geofísica Aplicada do Departamento de Geologia do Setor de Ciências da Terra da Universidade Federal do Paraná, Curitiba -PR.

3.3 MÉTODOS

A separação automática de unidades fisionômicas e geológicas, por meio das RNA, é executada utilizando imagens digitais e dados auxiliares. Duas abordagens são utilizadas como referência, isto é, como verdade de campo, uma é a imagem gerada por meio da fotointerpretação, contendo 7 unidades fisionômicas, a outra é a imagem advinda do mapa geológico, em formato digital, contemplando 6 unidades, seção 3.3.1. A primeira abordagem utiliza, para o processamento, as imagens em nível de abstração do "pixel" e de segmentos e a segunda somente em nível de segmento. As verdades de campo, nas duas abordagens, são utilizadas como parâmetro para a coleta de amostras de treinamento para o processamento da classificação e também para verificar o resultado das unidades separadas utilizando-

se as redes neurais. A princípio, a verdade de campo seria somente a imagem gerada por meio da fotointerpretação, por se acreditar que o material do analista é de boa qualidade. Entretanto, a falta de experiência e a dificuldade encontrada no campo, devido à área de estudo ter um relevo acidentado, optou-se por uma segunda série de testes utilizando um material, o mapa geológico, menos subjetivo e de um órgão respeitado.

Na seção 3.3.2 está descrito como foram pré – processadas as imagens digitais, as informações referentes ao relevo, a rede de drenagem e os dados gamaespectrométricos, com o objetivo de gerar informações de entrada para as redes neurais. Após o pré-processamento de todas os dados, esses são transformados para 8 “bits”, isto é, em 256 níveis de cinza (uma vez que as informações de diferentes fontes, como por exemplo, o MDT varia de 600 a 1200 metros).

Para melhor entendimento da metodologia proposta, a Figura 3.2 apresenta uma síntese de como os dados de entrada foram pré-processados gerando as variáveis de entrada que foram modeladas com a técnica das RNA e posteriormente classificadas.

As imagens digitais, Landsat7 ETM+, foram corrigidas geometricamente, detalhes sobre esse processamento digital no Apêndice I.

A partir das imagens oriundas do SR pode-se gerar imagens artificiais como exemplificado no diagrama de blocos (NDVI, Tcap, etc.), obtendo-se assim as imagens artificiais, derivadas das imagens orbitais.

Por meio da altimetria, aqui representada pelas curvas de nível e pontos cotados no formato digital, são processadas as imagens referentes ao relevo e a rede de drenagem. As imagens representantes do relevo são o MDT, o gradiente da encosta e a direção do gradiente da encosta. A rede de drenagem está representada pelas microbacias e pela direção de escoamento.

Mediante o levantamento aerogeofísico obteve-se as imagens referentes a geologia, isto é, imagens geofísicas dos elementos U, Th e K.

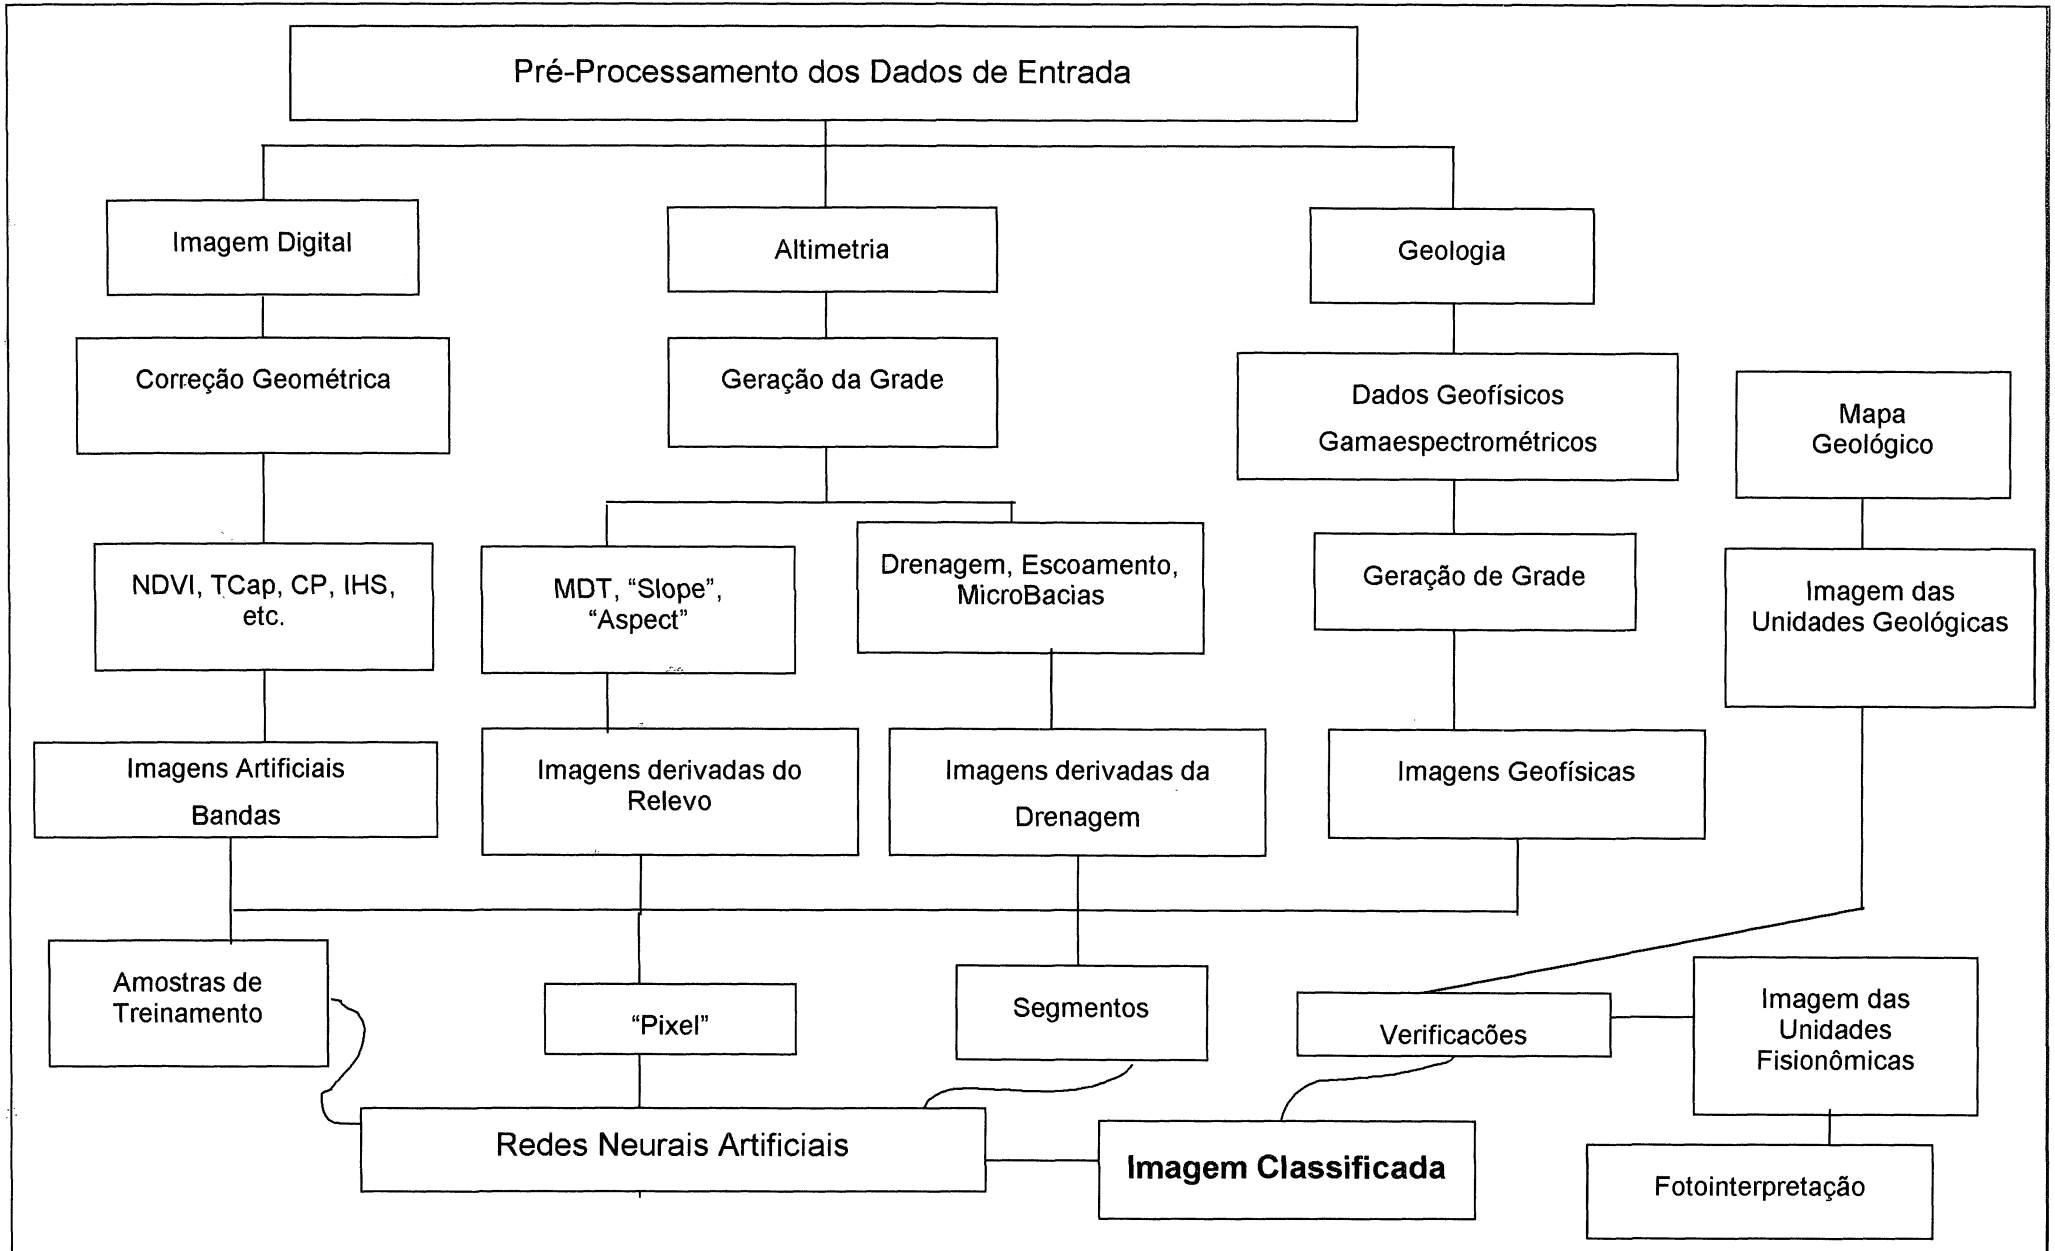
Duas referências são definidas: a realidade a partir da fotointerpretação das fotografias aéreas da região de estudo, gerando a imagem das unidades fisionômicas, sendo esta a primeira abordagem executada, levando-se em

consideração o nível de abstração de "pixel" e de segmentos. A segunda abordagem refere-se a imagem gerada a partir do mapa geológico e trabalha-se somente com o nível de abstração de segmentos.

Tendo-se as variáveis de entrada pré-processadas e utilizando-se como nível de abstração o "pixel" e também os segmentos, coleta-se amostras de treinamento e treina-se a RNA, executando-se teste para verificar quais as variáveis que mais colaboram para a separação das unidades fisionômicas, na primeira abordagem e, as unidades geológicas, numa segunda série de teste. Executa-se a verificação da modelagem da rede mediante a matriz de confusão e finaliza-se com a generalização, obtendo-se a imagem classificada.

Por meio das referências (imagem com unidades geológicas ou imagens das unidades fisionômicas) verifica-se a qualidade da classificação, para tanto se utiliza o coeficiente de correlação Cramer's V.

FIGURA 3.2 – DIAGRAMA DE BLOCO – SEQÜÊNCIA DOS PROCESSAMENTOS



3.3.1 Fotointerpretação de Unidades Fisionômicas e Mapa Geológico

Com a finalidade de se estabelecer uma classificação de referência, isto é, uma verdade de campo, procede-se a análise e delimitação visual das unidades fisionômicas sobre as fotografias aéreas pancromáticas, na escala 1:60.000 impressas, com o auxílio da imagem artificial gerada por meio da transformação IHS (gradiente da encosta / MDT / gradiente da encosta - na seção 3.3.2.3.4 tem-se a descrição desta transformação), do relevo e da hidrografia, como elementos guias no reconhecimento das fisionomias da área.

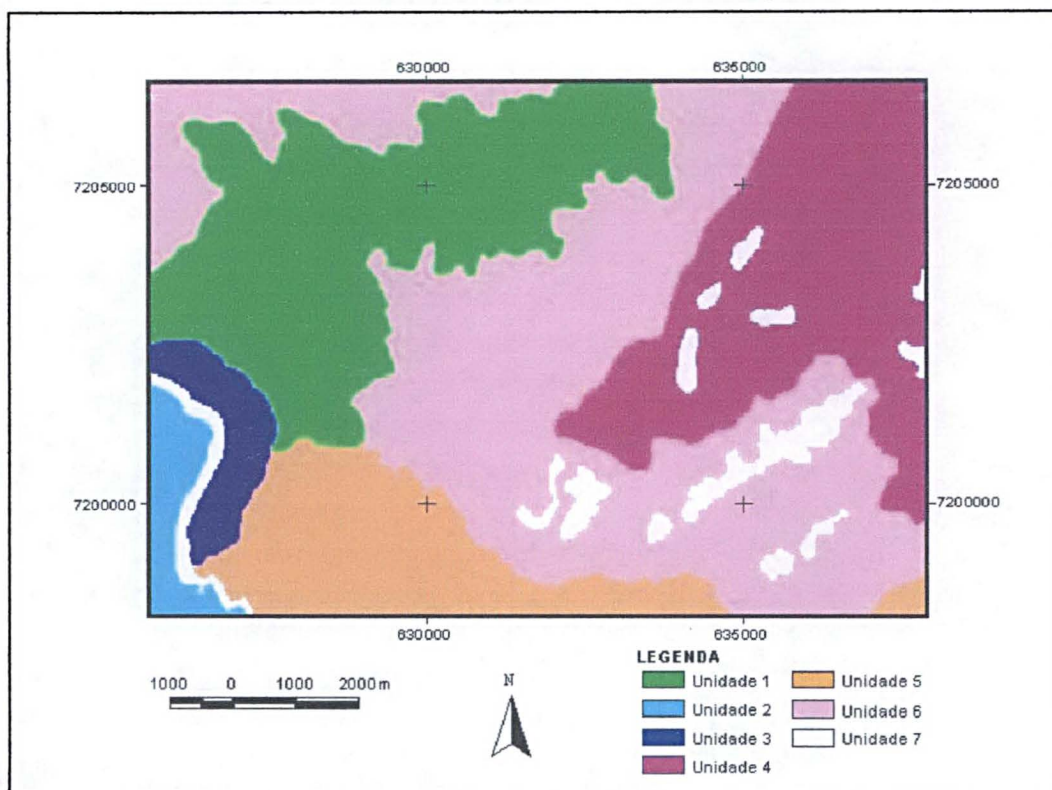
Antes de se iniciar o processo de fotointerpretação, são delimitadas sobre as fotografias aéreas as suas áreas úteis, por meio da formação do estereopar e segundo a metodologia de RABBEN et al. (1960, p. 110). A interpretação das unidades fisionômicas é baseada nos padrões de reconhecimento, como já descrito na seção 2.2.1. Por meio de estereopar, utiliza-se o "overlay" da rede de drenagem como elemento guia para diferenciar o relevo e definir as fisionomias, bem como a imagem da transformação IHS (gradiente da encosta / MDT / gradiente da encosta).

Define-se sete fisionomias, unidades estas consideradas "homogêneas". Portanto, a fotointerpretação das sete (7) unidades fisionômicas define a verdade de campo para a primeira série de testes (uma das abordagens), Figura 3.3 (A).

O sucesso da interpretação por fotografias aéreas depende da qualidade do material fotográfico, da experiência e nível de treinamento do fotointérprete e da natureza dos objetos que estão sendo interpretados (GARCIA, 1972, p. 52).

A Figura 3.3 (A) destaca as unidades fisionômicas separadas por meio da fotointerpretação e esta representa a verdade de campo obtida a partir da interpretação executada sobre as fotografias aéreas.

FIGURA 3.3 (A)– REPRESENTAÇÃO DAS SETE UNIDADES FISIONÔMICAS (DE PAISAGEM) SEPARADAS POR MEIO DA FOTOINTERPRETAÇÃO



As unidades separadas por meio da fotointerpretação estão caracterizadas a seguir:

- Unidade 1 - Delimitada visualmente como Vale. Essa unidade possui as menores variações de altitude, na área de estudo. A drenagem segue o padrão retangular comandado pelas direções estruturais, a vegetação está presente ao longo do vale;
- Unidade 2 - Formação Furnas, possui as maiores altitudes, mas caracteriza-se por um relevo colinoso, suave e com vertentes convexas (Campos Gerais – Segundo Planalto), com pouca vegetação, sendo que as gramíneas predominam nos campos da área de estudo. A unidade 2 é limitada pela escarpa e possui o padrão de drenagem nitidamente retangular e os curso d'água adaptados a linhas tectônicas;

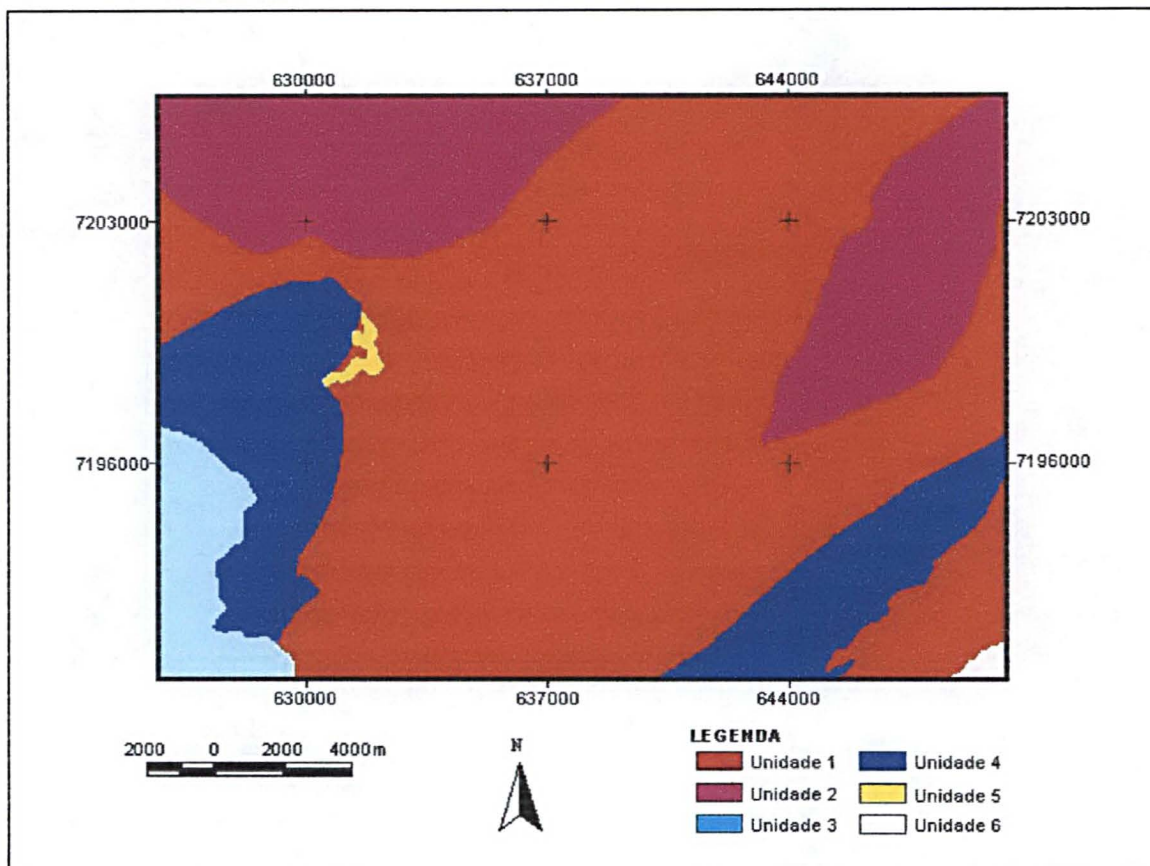
- Unidade 3 - Denominada de Escarpa, na qual verifica-se que o relevo é acidentado e a variação da altitude é grande, de 800 a 1000m, a vegetação é a típica da região mata densa;
- Unidade 4 - Separada devido à direção dos espigões do Primeiro Planalto, evidentes nas fotografias aéreas e na imagem da transformação IHS (gradiente/MDT/gradiente), tendo uma vegetação esparsa e a rede de drenagem é retangular sendo que se encontram nessa unidade as nascentes dos afluentes do Rio Açungui;
- Unidade 5 - Com um relevo mais dissecado, tendo vegetação característica da área (mata) na porção a oeste e pouca vegetação (região de Campo Largo) na porção leste. A rede de drenagem é retangular. Abrange parte do pediplano da região de Campo Largo, a oeste onde o relevo foi dissecado;
- Unidade 6 - Região central da cena, com relevo acidentado residual, vegetação típica (mata) e rede de drenagem;
- Unidade 7 – Unidade de grandes altitudes e variações, portanto, com relevo acidentado, desprovido de vegetação no alto dos topos e com vegetação típica da região (mata) nas partes baixas. A rede de drenagem é retangular.

Com o mesmo objetivo da fotointerpretação das fotografias aéreas, a partir do mapa geológico em meio digital (originalmente na escala 1:100.000), são definidas as unidades geológicas que representam a referência, verdade de campo, para a segunda abordagem, Figura 3.3 (B), a ser comparada com o resultado da classificação quando do processamento das variáveis por meio das redes neurais.

Para essa segunda abordagem, seis unidades são selecionadas, sendo que não são levadas em consideração as distinções entre as Seqüências do Grupo Açungui (aluminosa, arenosa e calcária) e entre Siltitos e Conglomerados na Formação Camarinha.

A Figura 3.3 (B) ilustra as seis unidades do mapa geológico, verdade de campo, para o estudo quando da separação das unidades geológicas por meio das redes neurais.

FIGURA 3.3 (B) – REPRESENTAÇÃO DAS SEIS UNIDADES SELECIONADAS A PARTIR DO MAPA GEOLÓGICO.



As unidades do mapa geológico estão representadas como:

- Unidade 1 - Caracterizada pelo Grupo Açungui, região central da imagem. Constituída por metasedimentos siltico-argilosos, incluindo metassiltitos, filitos, metarritmitos e ardósias, epicalcários calcíticos contendo intercalações de epicalcários dolomíticos e calcários, epicalcários dolomíticos contendo intercalações de epicalcários calcíticos e calcários, metasedimentos silticos-argilosos incluindo epicalcários, calcários e xistos de metamorfismos de contato, metarenitos e quartzitos, cristas de quartzitos, tactitos, rochas anfibolíticas, principalmente metabasitos, corpos de pequena espessura de metabasitos, calco hornfels e metaconglomerados. Pré-cambriano Superior;
- Unidade 2 - Granitos Três Córregos (noroeste) e do Cerne (leste). Rochas graníticas SIN A pós tectônicas. Pré-cambriano Superior a Cambriano;

- Unidade 3 - Formação Furnas. Constituída de arenitos médios a grosseiros com estratificação cruzada, localmente conglomeráticas, incluindo lentes de folhelhos siltico-argiloso ou arenoso, bem como argilitos. Paleozóico, Permo-Carbonífero, Devoniano Inferior, Grupo Campos Gerais;
- Unidade 4 - Formação Camarinha. Constituída de siltitos, siltitos argilosos, localmente argilitos e arenitos arcoseanos, conglomerados e corpos de pequena espessura de conglomerados. Paleozóico, Cambro-Ordoviciano;
- Unidade 5 – Aluviões. Encontra-se na parte mais baixa do vale. Cenozóico, Quaternário, Holceno;
- Unidade 6 - Formação Guabirotuba a sudeste no pediplano de Campo Largo. Constituída por cascalhos, areias, argilitos, arcóseos e margas. Cenozóico, Quaternário Pleistoceno.

3.3.2 Variáveis de Entrada

As imagens digitais, as informações referentes ao relevo, a rede de drenagem e os dados gamaespectrométricos, precisam ser manipulados para que possam ser processados por meio das redes neurais, mas o primeiro passo a ser executado é a correção geométrica para que todas as bandas espectrais e artificiais se encontrem no mesmo sistema, detalhes podem ser verificados no Apêndice I.

3.3.2.1 Variáveis que Representam o Relevo

O relevo, assim como outros elementos que caracterizam as paisagens, são de importância na separação de unidades fisionômicas/geológicas. O relevo é reconhecidamente um dos principais agentes de formação das paisagens (solos). Atua de forma indireta, modificando características climáticas da região, ou direta,

por meio do controle da rede de drenagem. Além disso, suas formas refletem propriedades do material de origem, características geológicas e processos de formação pedogenéticos, sendo por estes motivos apontado como uma das informações mais relevantes para a fotopedologia e fotogeologia (MONIZ In: AMARAL et al 1972, p.432).

3.3.2.1.1 Modelo Digital do Terreno

A variação do relevo pode ser modelada para fins de processamento digital como uma superfície contínua. Uma forma de representar uma superfície variando continuamente é por meio do uso de isolinhas, como é feito geralmente em cartas topográficas. As isolinhas, no entanto, não são particularmente adequadas para análises numéricas ou modelagem. Por motivos práticos, a variação contínua do relevo é representada digitalmente como um Modelo Digital do Terreno (MDT) (BURROUGH, 1986, p. 39).

A representação do terreno pode ser apresentada por meio da geração de um MDT, podendo ser definido por equações analíticas (modelos matemáticos) da distribuição espacial da altitude vinculada a uma superfície real. O MDT pode ser definido como um modelo matemático que reproduz uma superfície real a partir de algoritmos e de um conjunto de pontos, em termos de coordenadas x , y , z e a partir desses é interpolada toda a informação relativa a uma superfície (x, y) , em um referencial qualquer, com atributos denotados de z , que descrevem a variação contínua da superfície (CÂMARA, et al, 1998, p. 419).

Para que se possa estimar valores onde não existem dados são utilizados modelos matemáticos de interpolação. Por meio da interpolação pode-se calcular elevações, gerar grades regulares a partir de dados coletados de forma irregular e densificar grades retangulares (SARAIVA, 2001, p. 4).

O processo de geração do MDT pode ser dividido em três fases: aquisição de dados, geração da grade, retangular ou triangular, e elaboração do produto que representa as informações obtidas. Segundo PORTUGAL et al. (1999, p. 23) a

aquisição de dados é a atividade fundamental para a posterior representação precisa do relevo. Portanto, a qualidade da grade que gera o MDT vai depender em parte do arquivo de entrada de dados. Os dados de entrada para a execução de um MDT podem ser por amostragem primária ou secundária de acordo com seus levantamentos. Os dados primários são aqueles adquiridos por meio de levantamentos de campo ou restituição fotogramétrica, já os oriundos de mapas são os secundários.

Os MDT podem ser elaborados interligando pontos amostrados de maneira a formar polígonos e esses, poliedros. Existem diferentes classes de poliedros, entre elas, a triangulação e a grade regular (MITISHITA, 1997, p. 85).

Os modelos digitais triangulares (Triangulated Irregular Network - TIN), como o próprio nome diz, são compostos por triângulos formados pelos pontos amostrados da superfície que se articulam aos vértices. Estes triângulos obedecem ao método de "Delaunay", com base no princípio de que o círculo circunscrito de cada triângulo não contenha pontos no seu interior e ao critério de ângulo máximo - mínimo, onde a menor medida de ângulos de todos os triângulos é maximizada evitando a construção de triângulos deformados (SARAIVA, 2001, p. 5).

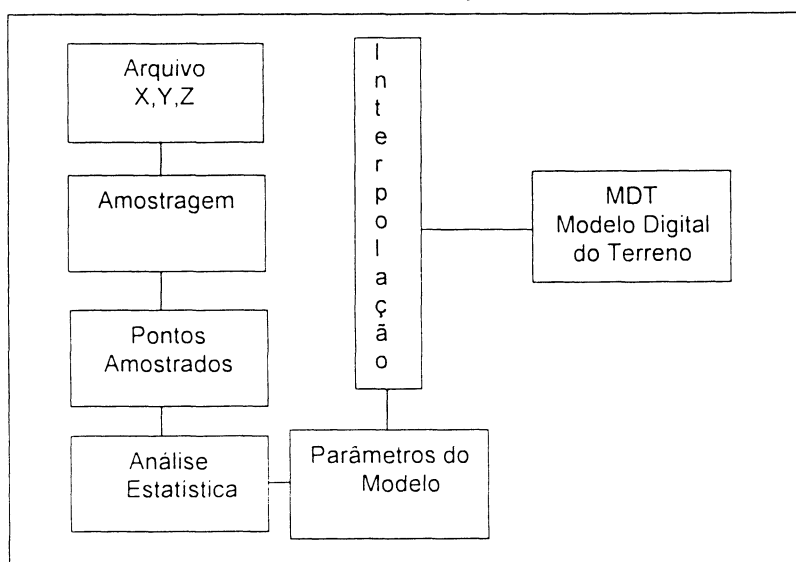
A grade retangular é uma representação matricial onde cada elemento da matriz está associado a um valor numérico. Para a geração da grade torna-se necessário estimar, através de interpoladores matemáticos, os valores para as células que não possuem medidas de elevação, no caso da representação do relevo, considerando-se para tanto as medidas da vizinhança. Os procedimentos de interpolação de grades regulares a partir de amostras variam de acordo com a grandeza medida. No caso de altimetria, é comum o uso de funções de ponderação pelo inverso do quadrado da distância. Já para variáveis geofísicas, ou de natureza pedológica, procedimentos de filtragem ou geoestatística como "krigagem" são utilizados (CÂMARA et al., 1998, p. 420).

Segundo SARAIVA (2000, p. 29), os algoritmos de interpolação baseados no no inverso da distância de uma potência e "kriging" atendem ao padrão "A" de precisão (PEC), quando são utilizados como dados de entrada as curvas de nível, as curvas mestras e os pontos cotados.

As representações do relevo utilizadas no estudo são o modelo digital do terreno (MDT) e suas derivações: gradiente da encosta e exposição da rampa, como exemplificado no diagrama de blocos, Figura 3.2, na seção 3.3.

O MDT é gerado a partir das curvas de nível e pontos cotados, utilizando o algoritmo de interpolação inverso da distância de segunda potência, com resolução da grade retangular de 30 metros. Optou-se por utilizar esse algoritmo de interpolação, pois os dados de entrada, no formato digital, continham as curvas de nível, as curvas mestras e pontos cotados e segundo SARAIVA (2000, p. 29) atendendo assim ao padrão "A" de precisão, como citado nessa mesma seção. Na Figura 3.4 tem-se esquematizado o diagrama de blocos do processo de execução do MDT.

FIGURA 3.4 - PROCESSO DE GERAÇÃO DO MDT



O método do inverso do quadrado de uma distância assume que o valor médio a ser estimado para a variável em um ponto X qualquer é proporcional ao valor medido em "n" estações vizinhas (V_i) e inversamente proporcional ao quadrado da distância entre o ponto X e cada uma destas "n" estações (D_i^2). Portanto quanto mais distante o ponto estiver do ponto X, menor será seu peso ou, em outras palavras, menor sua influência sobre o valor a ser estimado (V_x) (PELLEGRINO et al., 1998, p. 341).

A equação 3.1 mostra o cálculo utilizado pelo método do inverso do quadrado de uma distância.

$$Z = \frac{\sum_{i=1}^n Z_i}{\sum_{i=1}^n \frac{1}{D_i^2}} \quad (3.1)$$

onde:

Z: Altitude

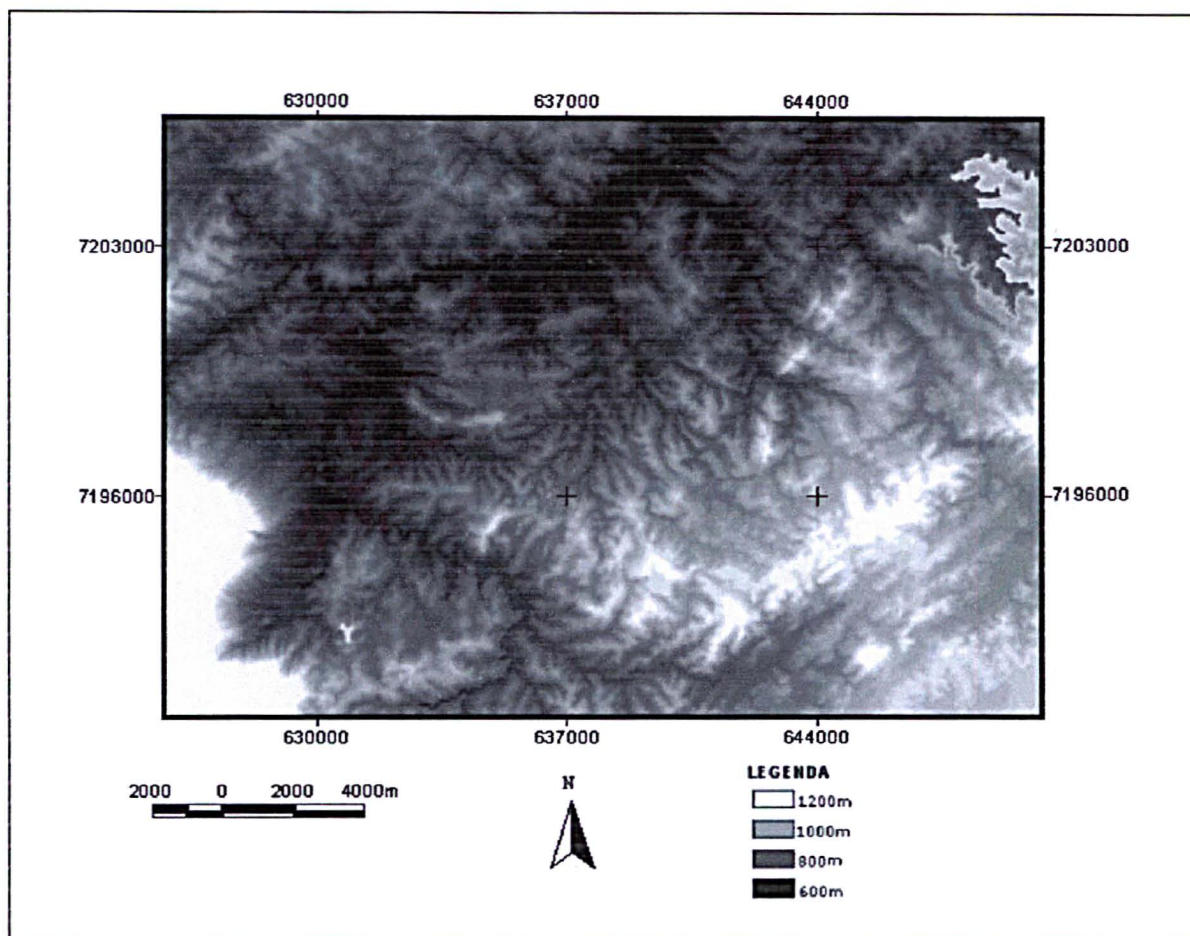
D_i : distância entre o ponto a ser interpolado e o i -ésimo ponto de altitude conhecida

n: número de estações utilizadas

Analisando-se a Figura 3.5, imagem do MDT, as maiores altitudes estão representadas pela cor branca e as menores pela cor preta. As altitudes variam dentro de um intervalo de 600 à 1200m.

Nas porções norte e leste encontram-se um relevo acidentado, isto é predominam as maiores variações da altitude (Granitos Três Córregos e do Cerne e Grupo Açunguí) com elevações em torno de 1000m. Já na posição sudeste da área destaca-se uma região mais dissecada (pediplanos de Campo Largo). A parte sudoeste é dominada pela Formação Furnas (Campos Gerais), bem definida na imagem e contendo “pixels” mais homogêneos, de cor branca, se comparada com o restante da cena, sendo que a altitude média está em torno de 1100m. Observa-se ainda na Figura 3.5 que a região mais escura (preta), da cena do MDT, está representando os vales do Primeiro Planalto (rios Açunguí, Passa Três, da Prata, Santana, Bonito dentre outros)

FIGURA 3.5 - IMAGEM DO MODELO DIGITAL DO TERRENO – MDT.



3.3.2.1.2 Gradiente da Encosta e Exposição da Rampa

Tanto o gradiente da encosta como a exposição da rampa, fornecem informações relevantes sobre o relevo que podem caracterizar as formas de modelados (formas topográficas) de áreas de ocorrência de unidades fisionômicas.

O gradiente da encosta é definido por BURROUGH (1986, p. 50), como sendo um plano tangente a superfície representada pelo MDT, isto é, a máxima razão da variação da altitude. Portanto é expresso como a mudança de elevação sobre uma certa distância e, no caso de MDT no formato digital, esta distância é o tamanho da célula, ou seja, é baseado na resolução da grade (30x30m).

Segundo BURROUGH (1986, p. 50) a direção da máxima razão da variação da altitude caracteriza a exposição da rampa ou imagem de "Aspect". A partir do

MDT pode-se calcular, para cada "pixel" da imagem, a média das altitudes em x e em y das células vizinhas que são adjacentes espacialmente, dividir estas variações das altitudes em x pelas variações em y e calcular o ângulo por meio da tangente. É expresso em graus a partir do norte no sentido horário e varia de 0 a 360 graus.

O gradiente da encosta descreve certamente características topográficas da superfície, tais como direção, comprimento e o movimento do gradiente no sentido descendente da mesma. Segundo TIMOTHY et al. (1991, p. 1180), a imagem representando o gradiente da encosta, gerada a partir do MDT, é o melhor prognóstico do sistema de drenagem.

CHOU (1992, p. 228), salienta que a capacidade de se extrair linhas de rampas de dados topográficos digitais em um SIG é uma ferramenta efetiva para variadas análises do terreno como, por exemplo, a delimitação da rede de drenagem e a extração da estrutura topográfica da área.

Segundo KAMIYA et al. (2001, p. 33) o mapa de gradiente da rampa é uma ferramenta útil na geologia e na geomorfologia para descobrir feições ou problemas desconhecidos e também é uma ferramenta livre da interferência da vegetação sobre a superfície física.

O gradiente da encosta é dado pela equação 3.2 e a equação 3.3, mostra como é determinada a exposição da rampa.

$$\text{TanG} = \left[\left(\frac{\Delta Z}{\Delta X} \right)^2 + \left(\frac{\Delta Z}{\Delta Y} \right)^2 \right]^{1/2} \quad (3.2)$$

$$\text{TanA} = \frac{\Delta Z}{\Delta Y} / \frac{\Delta Z}{\Delta X} \quad (3.3)$$

onde:

Z: altitude

X e Y: coordenadas

Processa-se o gradiente da encosta a partir do MDT e dois resultados são obtidos, em graus e percentual. A partir da imagem do gradiente da rampa gera-se uma nova imagem das classes de declive, descrita na seção 3.3.2.1.3.

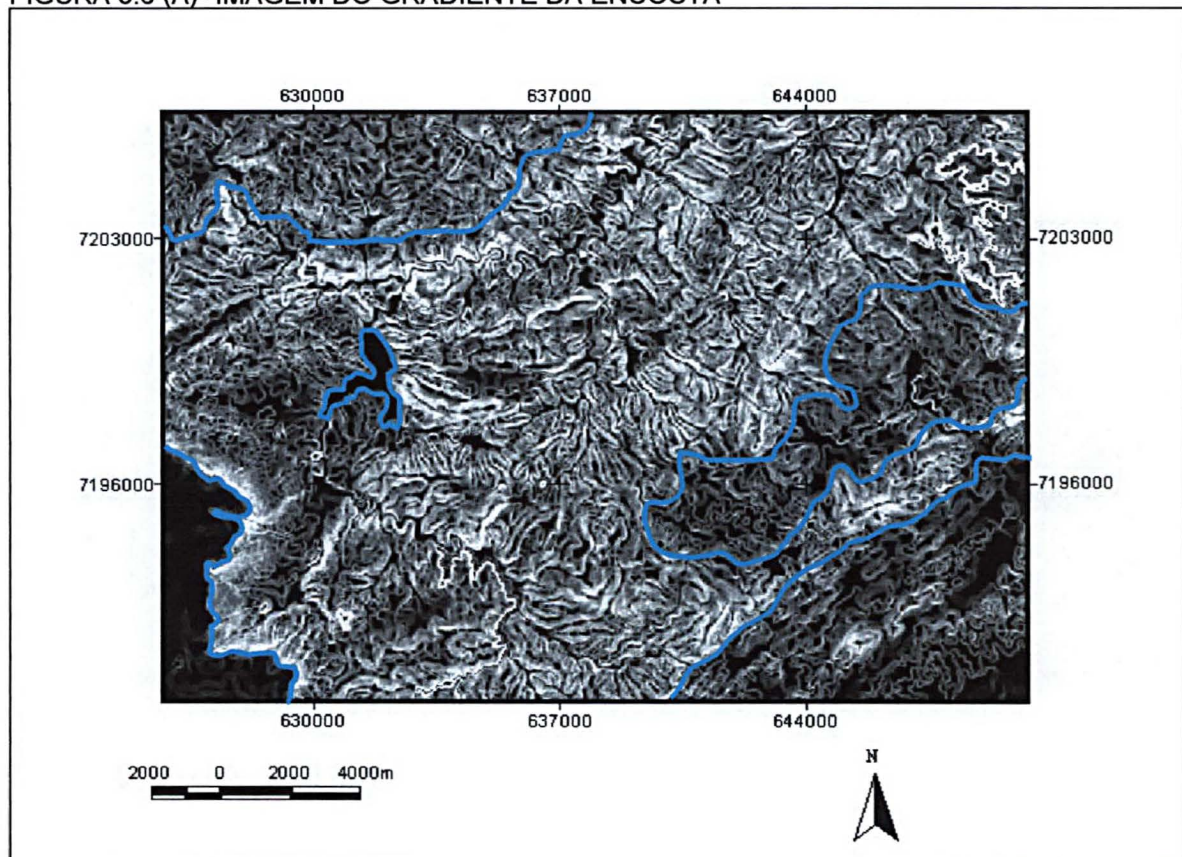
A imagem da direção da máxima inclinação da rampa, também processada utilizando-se o MDT, é obtida em graus decimais, as células (“pixels”) de valor zero indicam uma porção plana do terreno.

A Figura 3.6 (A) mostra a imagem do gradiente da encosta gerada a partir do MDT. Pode-se reconhecer as regiões planas pela cor preta. Portanto, o gradiente é maior quanto mais clara for a cena.

As regiões em destaque são:

- Formação Furnas (SW) - Com o gradiente variando entre 0° e 5° ;
- Região do pediplano de Campo Largo (SE) - Com variações de 0° a 12° ;
- Aluviões (região central da cena à esquerda) - Em preto com um gradiente aproximado de 0° ;
- Granitos: Três Córregos (N) e do Cerne (L) - com valores de 0° a 29° ;
- Grupo Açungui, região central da cena, com valores de 0° a 34° .

FIGURA 3.6 (A)- IMAGEM DO GRADIENTE DA ENCOSTA




A Figura 3.6 (B) mostra a imagem de exposição da rampa, imagem artificial, gerada a partir do MDT. Para o presente estudo, os valores obtidos encontram-se entre -1 e 359, onde o valor -1 representa as regiões planas, definidas como zero na imagem do gradiente da encosta, e 359 o valor máximo da exposição a partir do norte no sentido horário.

Analisando-se a Figura 3.6 (B) nota-se que:

- Na parte superior à direita da cena, as direções são paralelas no sentido nordeste, direções estruturais de dobramento (-SW);
- Aluviões - Na área central à esquerda da cena, encontram-se destacados pela porção plana, valor mínimo da exposição da rampa (-1);
- Formação Furnas - Com pequenas variações, de exposição da rampa, em comparação as demais porções da cena;
- Na porção inferior à direita (sudeste), as formas do relevo também aparecem na cena paralelas no sentido SE.

FIGURA 3.6 (B) - IMAGEM DA EXPOSIÇÃO DA RAMPA



3.3.2.2 Variáveis que Representam a Drenagem

A rede de drenagem superficial, depois do relevo, é o mais confiável e consistente elemento indicador das reais condições da superfície física (AMARAL et al., 1972, p. 434), portanto é evidente a importância da rede de drenagem no estudo e análise das paisagens. A drenagem pode ser analisada em termos da rede de drenagem, dos canais formados na superfície ou em termos das bacias e microbacias que esses canais delimitam.

Por definição, uma microbacia compreende uma área de formação natural, drenada por um curso de água e seus afluentes, a montante de uma seção transversal considerada, para onde converge toda a água da área em questão (BRASIL, 1987, p. 8). A área da microbacia depende do objetivo do trabalho que se pretende realizar, uma vez que não existe consenso quanto ao seu tamanho ideal (FREITAS et al., 1996, p. 45).

Desde a década de 80 que o MDT têm sido processado para derivar informações a respeito da drenagem. Autores, tais como: JENSON et al., 1988 (p. 1593 – 1600); TIMOTHY et al., 1991 (p. 1179 – 1183); LEE et al., 1990 (p. 1461 – 1467) utilizaram o MDT para a identificação do potencial de drenagem em cada “pixel” da imagem.

A primeira etapa a ser executada para delimitar as microbacias, a partir do MDT, é processar a grade de acúmulo de água em cada célula do MDT. Para tanto, existe a necessidade de que, sejam retiradas as depressões da área de estudo (SMITH et al., 1992, p. 579 - 586). Os passos necessários são:

- A partir do MDT são computadas as depressões, que atrapalham o procedimento do escoamento, e estas são preenchidas;
- A seguir são indicadas as direções de escoamento em cada célula; e
- Por último o escoamento acumulado é calculado. Cada célula recebe um valor igual ao número total de células a montante dela. As células que contém o valor zero indicam o local de maior elevação (topos) (JENSON et al., 1988, p. 1594).

No presente estudo o tamanho das microbacias é definido experimentalmente, isto é, fixa-se uma quantidade de “pixels” a ser agrupada

formando uma microbacia e aumenta-se ou diminui-se esta quantidade de (agrupamentos) "pixels" em função da área física e do estudo em questão. Inicia-se com um limiar de 100 "pixels" e visualmente verifica-se se essas áreas com 100 "pixels", para as microbacias são pequenas. Portanto, por tentativa e erro, define-se a quantidade de 1000 "pixels" agrupados para a formação das microbacias com um tamanho relacionado com o estudo.

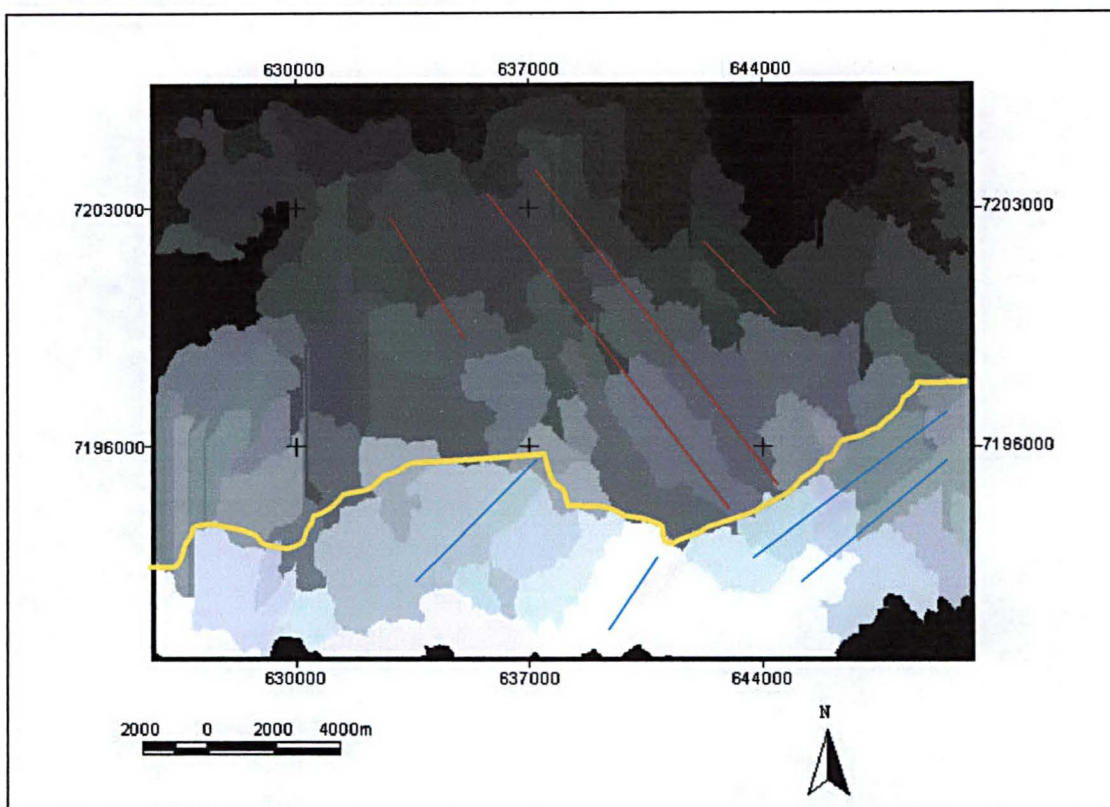
A Figura 3.7 mostra as microbacias da área em estudo, tendo-se como nível de abstração o "pixel". No Apêndice II encontra-se a imagem das microbacias tendo como nível de abstração os segmentos.

Analisando-se visualmente a Figura 3.7 nota-se que as microbacias representam áreas segundo direções paralelas ou subparalelas e pode-se destacar que:

- Nas regiões norte e central da cena, o paralelismo das áreas entre as bacias segue a direção –SW, porção destacada pela cor vermelha na Figura 3.7;
- Na região centro sul o subparalelismo é direcionado para – NE, porção destacada pela cor ciano na Figura 3.7;
- Nas porções pretas, ao norte e ao sul encontram-se os valores zero onde não se obteve agrupamento a respeito das microbacias;
- Na região sul, destacada na Figura 3.7, pela cor amarela, encontra-se os maiores valores numéricos de acúmulo de água.

A utilização da imagem contendo as microbacias tem como vantagem os agrupamentos de "pixels", representando características físicas homogêneas do terreno. No Apêndice II encontra-se a imagem das microbacias e sobre ela a rede de drenagem.

FIGURA 3.7 - IMAGEM DAS MICROBACIAS



3.3.2.3 Imagens Artificiais

As técnicas de realce de imagens digitais, as transformações espectrais ou a geração de novas imagens artificiais, a partir das bandas originais, se destacam como ferramenta para salientar algumas feições em função do contraste entre as leituras dos níveis digitais das bandas espectrais. Dentre as transformações espectrais mais conhecidas encontram-se o índice ou razão entre bandas, como o Índice de Vegetação da Diferença Normalizada (NDVI), a transformação de componentes principais (CP), a transformação “Tasseled Cap” (TCap) e a transformação no espaço de cores (IHS). No presente estudo a transformação no espaço de cores, não utilizou bandas espectrais, mas sim dois atributos, o MDT e o gradiente da encosta. As seções 3.3.2.3.1 a 3.3.2.3.4 descrevem essas transformações.

3.3.2.3.1 Índice de Vegetação da Diferença Normalizada (NDVI)

O NDVI visa discriminar áreas de vegetação na imagem, por meio do comportamento espectral ímpar destas coberturas. Sendo a assinatura espectral da vegetação bem contrastada nas faixas do vermelho (visível - baixa reflexibilidade) e no infravermelho próximo (alta reflexibilidade), do espectro eletromagnético, o princípio do índice de vegetação se apoia na combinação entre estas faixas (0,6 – 0,7µm – luz vermelha e 0,7 – 1,1µm - infravermelho próximo).

Segundo RICHARDS et al. (1999, p. 255) a utilização do NDVI se justifica nas situações:

- Melhorar a discriminação entre solos e vegetação;
- Reduzir o efeito do relevo (pendente e orientação) na caracterização espectral de coberturas distintas.

O índice de vegetação é uma razão entre bandas que gera uma nova imagem artificial, é executado com o intuito de se salientar áreas com vegetação (HUNT et al., 1989, p 45).

A equação 3.4 mostra como é calculado o NDVI:

$$NDVI = \left(\frac{ND_{i,j,IF} - ND_{i,j,V}}{ND_{i,j,IF} + ND_{i,j,V}} \right) \quad (3.4)$$

onde:

NDVI: "Normalized Difference Vegetation Index"- Índice de Vegetação da Diferença Normalizada;


$ND_{i,j,IF}$: valor digital do "pixel" i, j da banda infra-vermelho do espectro eletromagnético;

$ND_{i,j,V}$: nível de digital do "pixel" i, j da banda do vermelho - visível do espectro eletromagnético.

Sendo a assinatura espectral da vegetação bem contrastada nas faixas do vermelho (baixa reflexibilidade) e no infravermelho próximo (alta reflexibilidade) do espectro eletromagnético, o NDVI é processado através da razão entre as bandas 3

(visível) e 4 (infravermelho próximo) da imagem Landsat7 ETM+. A Figura 3.8 mostra a imagem resultante do NDVI onde as áreas com vegetação apresentam a tonalidade esbranquiçada e as áreas desnudas tons escuros, destacadas, a Leste e a Sudoeste.

FIGURA 3.8 - IMAGEM DO ÍNDICE DE VEGETAÇÃO DA DIFERENÇA NORMALIZADA (NDVI)



3.3.2.3.2 Transformação de Componentes Principais (CP)

Segundo JOHNSON et al. (1998, p. 340), a análise de componentes principais procura explicar a estrutura de variância - covariância da matriz de dados através de combinações lineares não correlacionadas de p variáveis originais. Embora p componentes sejam necessárias para reproduzir a variabilidade total do sistema, freqüentemente muito dessa variabilidade pode ser explicada por um número pequeno, k , de componentes principais. Neste caso, existe quase a mesma quantidade de informação nas k componentes, que existe nas p variáveis originais. As k componentes principais podem então substituir as p variáveis iniciais e o

conjunto de dados original que consiste de n medidas das p variáveis, é reduzido para um outro formado pelas medidas das k componentes principais.

De acordo com LILLESAND et al. (2000, p. 518) a Análise de Componentes Principal (CP) vem sendo empregada com o intuito de reduzir a dimensionalidade dos dados e também como técnica de realce (contraste) das imagens digitais. A correlação entre bandas espectrais é um problema freqüente e que pode ser resolvido através da transformação CP.

A transformação CP pode ser utilizada também como operação de realce para a interpretação visual de imagens digitais ou pré-processamento para uma classificação automática de dados. Essa técnica pode melhorar a eficiência computacional na classificação, pois reduz a dimensionalidade do conjunto de dados originais (RICHARDS, 1993, p. 201).

A seguir são mostradas as expressões 3.5 a 3.9 para explicar a redução, das bandas espectrais, conveniente no estudo.

Seja um vetor aleatório $X' = [X_1, X_2, \dots, X_p]$ que tem a matriz de covariância Σ com autovalores $\lambda_1 \geq \lambda_2 \geq \dots \lambda_p \geq 0$. Considere as combinações lineares (C.L.) das Equações 3.5 a 3.8.

$$Y_1 = \underline{c_1}' \underline{X} = c_{11}X_1 + c_{21}X_2 + \dots + c_{p1}X_p \quad (3.5)$$

$$Y_2 = \underline{c_2}' \underline{X} = c_{12}X_1 + c_{22}X_2 + \dots + c_{p2}X_p \quad (3.6)$$

.....

.....

.....

$$Y_p = \underline{c_p}' \underline{X} = c_{1p}X_1 + c_{2p}X_2 + \dots + c_{pp}X_p \quad (3.7)$$

$${}_p C_p = \begin{bmatrix} c_{11} & c_{21} & \dots & c_{p1} \\ c_{21} & c_{22} & \dots & c_{p2} \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots \\ c_{1p} & c_{2p} & \dots & c_{pp} \end{bmatrix}$$

Então tem-se $Y = [Y_1 Y_2 \dots Y_p]' = \begin{bmatrix} c_{11} & c_{21} & \dots & c_{p1} \\ c_{21} & c_{22} & \dots & c_{p2} \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots \\ c_{1p} & c_{2p} & \dots & c_{pp} \end{bmatrix}$ o vetor $X = {}_p C {}_p X$ e (3.8)

- $V(Y_i) = V(c_i' X) = c_i' V(X) c_i = c_i' \Sigma c_i$
- $cov(Y_i, Y_k) = c_i' \Sigma c_k$
- $cov(\underline{Y}_p) = V({}_p C {}_p X) = C \Sigma C'$

As componentes principais são as C.L. não correlacionadas Y_1, Y_2, \dots, Y_p cujas variâncias são:

- A primeira componente é a C.L. com variância máxima, isto é, a CL que maximiza $V(c_1' X)$ sujeito a restrição $c_1' c_1 = 1$ (vetor de comprimento unitário);
- A segunda componente principal é a C.L. que maximiza $V(c_2' X)$ sujeito à restrição $c_2' c_2 = 1$ e assim sucessivamente.

A transformação CP utiliza como entrada 7 bandas espectrais e tem-se como resultado a concentração da maioria das informações nas três componentes principais. Executa-se o processamento no programa ENVI 3.0 e este fornece os dados estatísticos mostrando a média, o desvio padrão e os autovalores. Com os autovalores, calcula-se a porcentagem de informações em cada banda espectral, por meio da equação 3.9. A Tabela 3.2 mostra os dados do processamento e o percentual de informações contidas em cada uma das bandas.

$$\lambda_1 + \lambda_2 + \lambda_3 + \dots + \lambda_n / \Sigma \lambda \quad (3.9)$$

TABELA 3.2 – DADOS ESTATÍSTICOS DA TRANSFORMAÇÃO CP

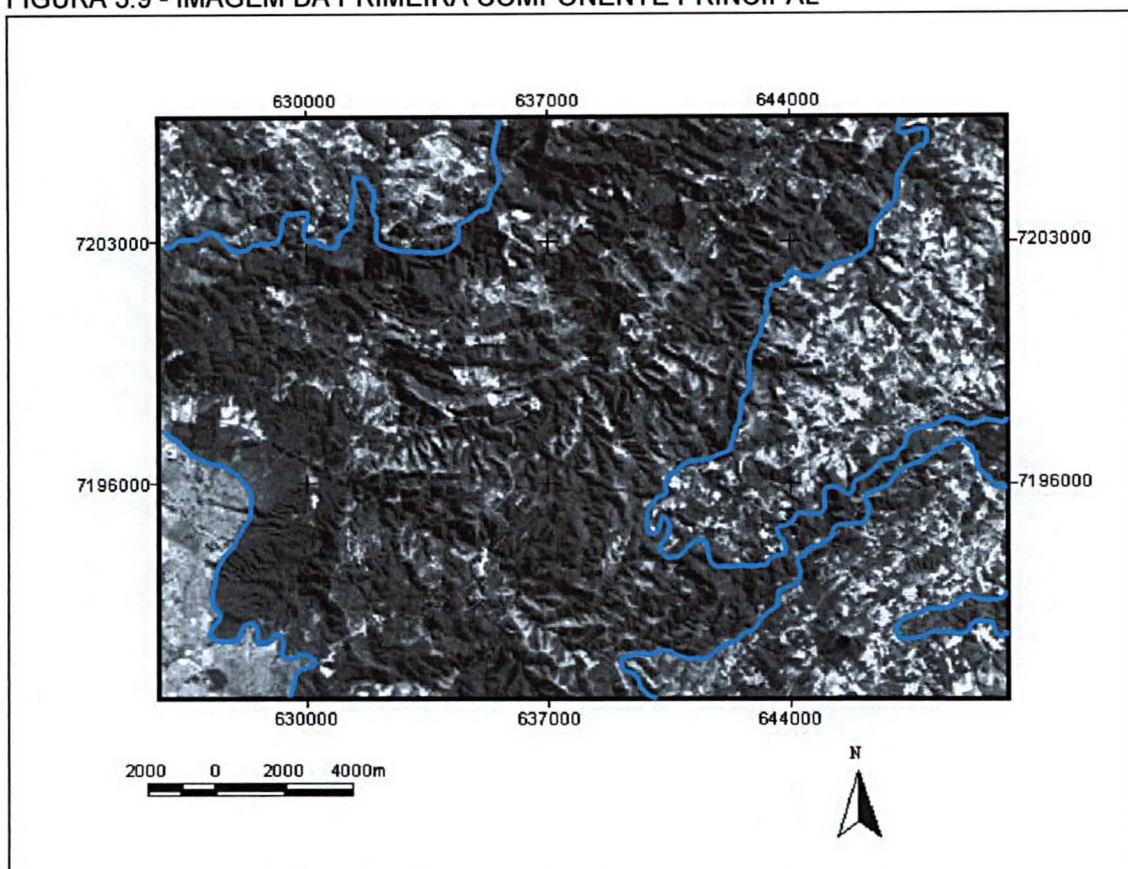
Banda	Média	Desvio padrão	Autovalores	Porcentagem
1	94.571754	55.346937	15088.38198	71,90
2	54.615977	44.986876	3307.997392	15,76
3	86.473829	55.765916	1880.300405	8,96
4	69.298680	54.465105	420.369876	2,00
5	88.710195	57.035040	167.841636	0,79
6	99.867242	37.981339	52.996578	0,30
7	71.202491	40.881994	45.913689	0,25

Como as três primeiras componentes representam 96,62% da informação de todas as bandas espectrais, essas foram as escolhidas para serem usadas como variáveis de entrada, substituindo as sete bandas espectrais da imagem Landsat7 ETM+, no processamento usando a técnica das RNA. As Figuras 3.9, 3.10 e 3.11, exibem as três componentes. No Apêndice II, encontram-se as três componentes segmentadas.

A primeira componente, Figura 3.9, é uma imagem contendo a maioria das informações (71,90%). As porções em destaque dessa imagem são:

- A região sudoeste (SW) - Formação Furnas com tonalidade mais clara em comparação com o restante da cena;
- Nos pediplanos próximo a Campo Largo (SE);
- Ao norte e ao leste, Rochas Graníticas – Granitos Três Córregos (N) e do Cerne (L).


FIGURA 3.9 - IMAGEM DA PRIMEIRA COMPONENTE PRINCIPAL



A segunda componente, Figura 3.10, representa 15,76% das informações espectrais da imagem. Encontra-se em destaque na cena, as seguintes regiões:

- Porção sudoeste (Formação Furnas) com a tonalidade mais clara e apresentando manchas brancas;
- A região sudeste (próximo a Campo Largo) e leste com uma textura mais fina que as das demais áreas.

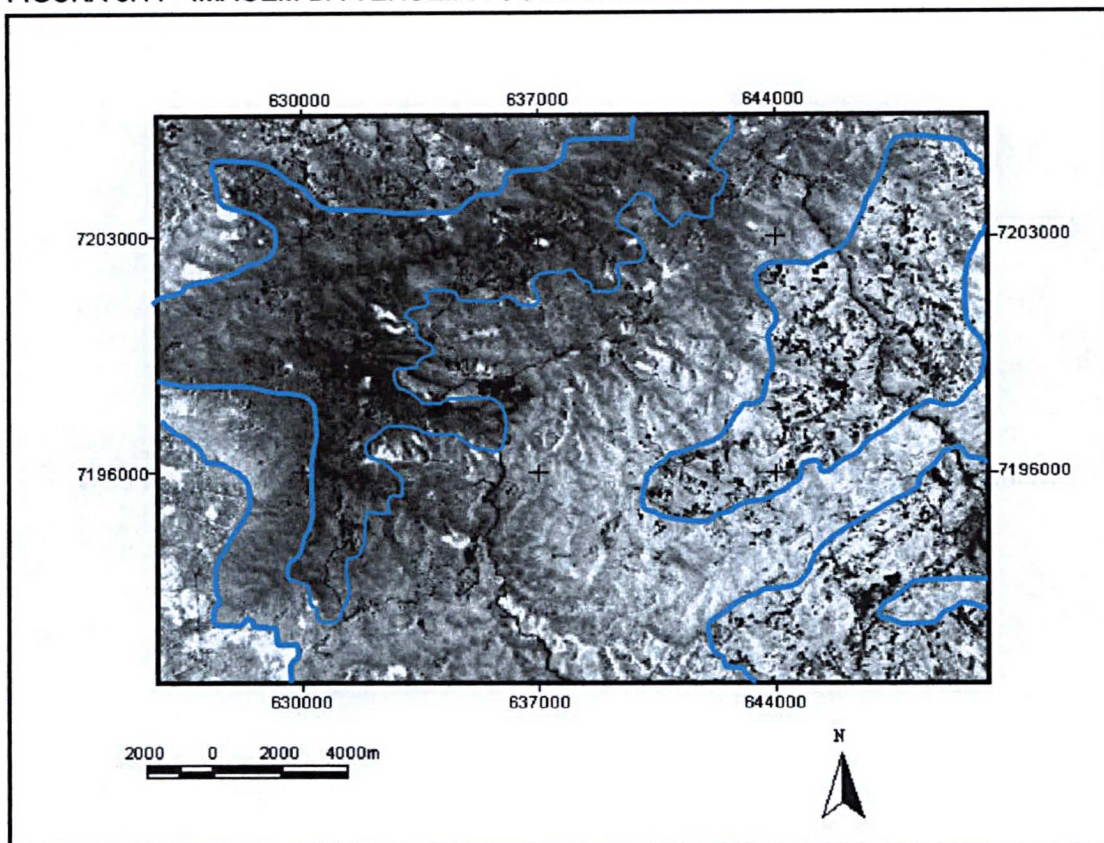
FIGURA 3.10 - IMAGEM DA SEGUNDA COMPONENTE PRINCIPAL



A terceira componente, Figura 3.11, contém 8,96% das informações espectrais e, analisando-a visualmente pode-se destacar:

- Uma diferença de tonalidade entre os vales (região central à esquerda da cena) com tons escuros;
- A região sudoeste (Formação Furnas) com tons claros;
- As porções sudeste e leste pela tonalidade intermediária;
- A região sul também está destacada pelos tons de cinza mais homogêneos, comparando-as com as tonalidades das regiões adjacentes sudoeste e sudeste.

FIGURA 3.11 - IMAGEM DA TERCEIRA COMPONENTE PRINCIPAL



3.3.2.3.3 Transformação “Tasseled Cap” (TCap)

A Transformação TCap foi desenvolvida inicialmente para o sensor “Multispectral Scanner” (MSS) observando-se que, em regiões agrícolas, a correlação entre as bandas do visível e as bandas do infravermelho próximo do MSS leva à informações sobre solos e vegetação direcionadas para um único plano (CRIST et al., 1984, p. 343).

A TCap oferece uma maneira de otimizar os dados para estudos de vegetação. É uma rotação dos dados espectrais, de maneira que a maioria das informações esteja contida em três componentes, (eixos) que são diretamente ligadas às características físicas da cena (CRIST et al., 1984, p. 347; CRIST et al., 1986, p. 85 e KAUTH et al., 1976, p. 43). As três feições (eixos) são:

- Brilho ("brightness")- Primeira característica, é aproximadamente a média ponderada (pesada) de todas as bandas e é definida a direção da principal variação na reflectância do solo;
- Verdor ("greenness")- perpendicular ao brilho e é um contraste entre o infravermelho próximo e as bandas no visível. O verdor, como o nome diz, valoriza a vegetação "verde" (viva) na cena;
- Umidade ("wetness")- transição entre as características solo e vegetação e relata a umidade e cobertura do solo (LILLESAND et al., 2000, p. 513).

Na Transformação TCap além de diminuir a dimensionalidade de dados das bandas originais, visto que, as seis bandas espectrais (exceto a banda 6) após a transformação são representadas por três bandas, também realça características da imagem como a vegetação "viva" e os solos desnudos (ambos relacionados com o teor de umidade).

A equação 3.10 expressa a Transformação TCap, segundo (RICHARDS et al., 1999, p. 150).

$$U_j = R_i X_i + C \quad (3.10)$$

Onde:

U_j : vetor correspondente à imagem dos valores de brilho transformados

X_i : vetor de entrada

R_i : vetor dos coeficientes da transformação

C : constante para evitar valores negativos

No estudo essa transformação é aplicada a imagem digital Landsat7 ETM+ utilizando-se os coeficientes segundo o estudo de CRIST et al. (1984). A Tabela 3.3 mostra os coeficientes da transformação realizada.

TABELA 3.3 – COEFICIENTES DA TRANSFORMAÇÃO TCAP

	Band 1	Band 2	Band 3	Band 4	Band 5	Band 7
TM Bright	0.3037	0.2793	0.4343	0.5585	0.5082	0.1863
TM Green	-0.2848	-0.2435	-0.5436	0.7243	0.0840	-0.1800
TM wetns.	0.1509	0.1793	0.3299	0.3406	0.7112	-0.4572

Fonte : Adaptado de: CRIST et al., 1984, p. 348.

As três imagens artificiais, Figuras 3.12 (A, B e C) geradas por meio da transformação TCap são apresentadas no Apêndice II.

3.3.2.3.4 Transformação IHS Gerada a Partir de Atributos do Relevô

A Transformação IHS foi desenvolvida por HAYDN et al. (1982, p. 599-616) como ferramenta de realce, isto é, para gerar cores mais intensas e reduzir a correlação entre as imagens. Nessa transformação, utiliza-se de um espaço de cores semelhante à percepção do olho humano, o espaço IHS, sendo os atributos desse espaço: Intensidade (I), o matiz ou tonalidade (H) e a saturação (S). (SABINS et al., 1987, p. 149).

Nesta transformação o espaço de cores é definido em um sistema de coordenadas cilíndricas, baseado numa esfera hipotética de cor onde os valores variam de 0 a 255. A relação entre os espaços de cores IHS e RGB são dadas pelas expressões 3.11, 3.12 e 3.13.

$$I = \frac{(R + G + B)}{3} \quad (3.11)$$

$$H = \frac{(G - B)}{(I * 3 * B)} \quad (3.12)$$

$$S = \frac{(I * 3 * B)}{I} \quad (3.13)$$

A partir do espaço de cores RGB, contendo as imagens do gradiente da encosta do MDT e do gradiente da encosta, efetuou-se a transformação para o espaço de

cores IHS. Isto é, do espaço de "R" onde se encontrava a imagem do gradiente passou-se para o I, do de cores espaço "G" que continha o MDT, se transformou para o H e do espaço de cores "B" contendo novamente o gradiente da encosta passou-se para o S.

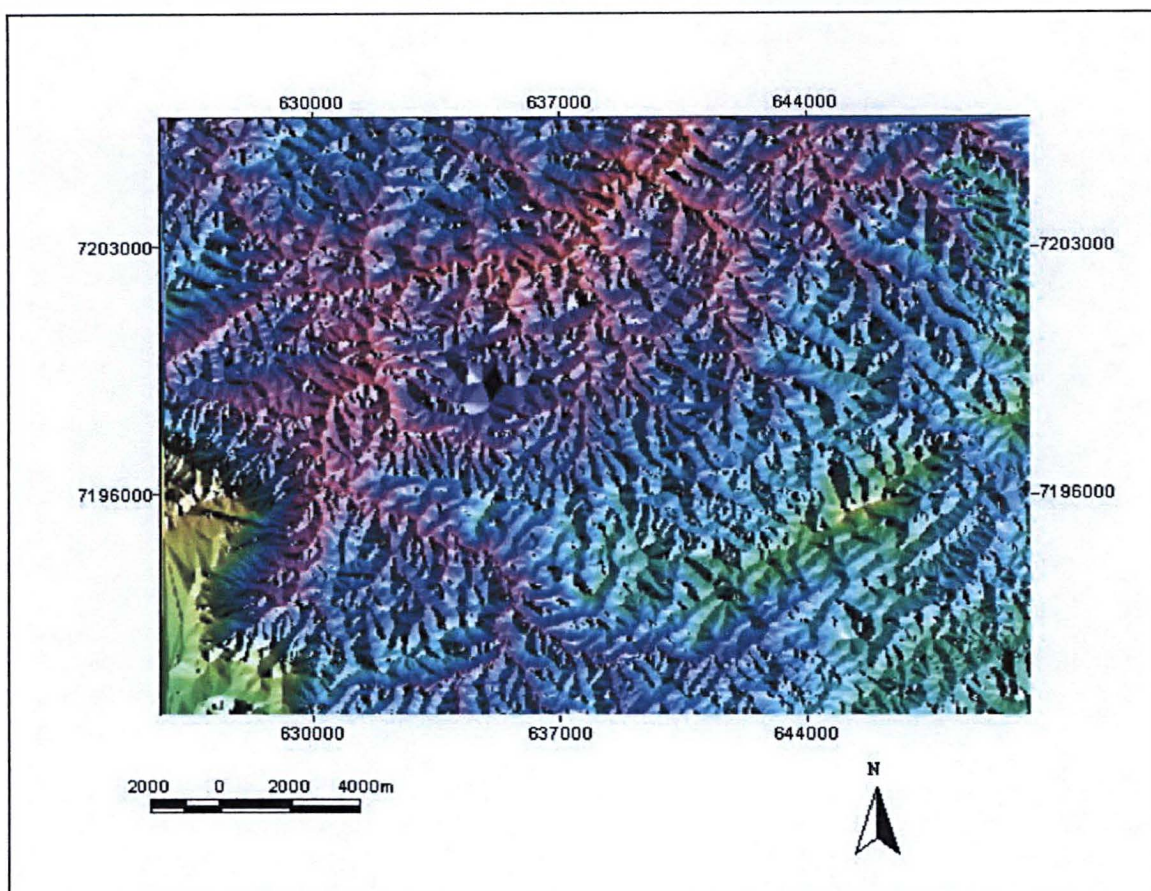
Com a transformação IHS procurou-se salientar o relevo, de forma que essa imagem artificial auxiliasse na delimitação visual de unidades homogêneas, como descrito na seção 3.3.1.

A Figura 3.12 mostra a imagem transformada IHS (Gradiente \MDT\Gradiente), onde as regiões de maior destaque da cena puderam ser visualmente analisadas, como descrito a seguir:

- Os locais de relevo acidentado por meio da cor amarela, passando a verde clara;
- Os tons de ciano as altitudes intermediárias entre os vales e as regiões mais altas;
- Os tons de magenta mostram os locais dos vales.

R: gradiente da encosta	I;
G: MDT	H;
B: gradiente da encosta	S.

FIGURA 3.12 - IMAGEM DA BANDA ARTIFICIAL IHS (Gradiente MDT Gradiente)



3.3.2.4 Tratamento Gamaespectrométrico

Segundo SILVA (1999, p. 20), na natureza a radioatividade é o processo de emissão espontânea de energia (radiação) oriunda de núcleos instáveis de um elemento ou substância. Essa emissão espontânea de energia é denominada de processo de decaimento radioativo que, na natureza, ocorre principalmente através dos decaimentos das radiações alfa, beta e gama.

BIERWIRTH (1996 p. 22) cita que a radiação gama diferencia-se da alfa e da beta por possuir alto poder de penetração. Pode atingir um alcance no ar de centenas de metros e de 30 a 45 cm em rochas e solos, isto devido aos raios gama não possuírem massa e carga elétrica. A pesquisa da emissão de raios gama é uma importante fonte de informações para estudos de solos e geomorfológicos.

De acordo com WILFORD, et al. (1997, p.200), a espectrometria transportada por via aérea de raios gama é uma técnica passiva de Sensoriamento Remoto que mede a emissão de radiação gama por parte da superfície do terreno. Os raios gama são uma forma de alta energia e curto comprimento de onda da radiação eletromagnética. Esses não têm massa ou carga elétrica e são emitidos em diferentes níveis de energia ou picos que correspondem ao decaimento radioativo de partículas de radioisótopos. A relativa abundância ou concentração desses radioelementos nos solos e rochas é estimada por meio das suas intensidades em seus picos de emitância. A espectrometria teletransportada mede a abundância de raios gama de potássio (^{40}K), de tório (^{232}Th) e de urânio (^{238}U e ^{235}U) em rochas e materiais intemperizados, por meio da detecção dos raios gama emitidos do decaimento ativo e natural dos isótopos radioativos desses elementos.

O mesmo autor (WILFORD, et al., 1997, p. 202) ainda afirma que os dados gamaespectrométricos utilizados para o mapeamento de solos e em aplicações geomorfológicas são as concentrações de U e Th em ppm (partes por milhão) e de K em percentual. Isto é, o K é medido diretamente do decaimento do pico do isótopo correspondente (^{40}K). O U e Th são expressos em concentração de decaimento de elementos "irmãos". Os elementos "irmãos" dos decaimentos são os núclídeos irmãos de isótopos de chumbo (Pb), e o decaimento ocorre até a estabilidade.

Para WILFORD et al. (1997, p. 213), a resposta espectral dos raios gama em solos (regolitos) intemperizados "in situ" pode ser agrupada de acordo com o tipo de rocha existente no local intemperizado. Onde a rocha aflora ("bedrock crop out") ou onde os materiais solo/regolito são finos ("thin"), os raios gama refletem diretamente a geoquímica dos minerais primários da rocha.

DICKSON et al. (1997, p.186) comentam que a resposta espectral dos raios gama, em solos transportados pode ser dividida e descrita em termos do material ser aluvial, coluvial e eólico ("aeolian"). Serão introduzidos somente os conceitos da gamaespectrometria referente aos materiais coluvial e aluvial.

O material aluvial é aquele depositado pelo escoamento da água nos canais ("overbank") e sobre as margens dos mesmos (bancos \diques). Se o canal e os sedimentos aluviais são derivados de granitos e rochas metamórficas, eles podem ser distinguidos pelo alto valor de K, de eTh e eU. Sedimentos advindos de rochas metamórficas são diferenciados pelo valor baixo teor de K e valores altos de Th e U,

refletindo a química da rocha original. Já se os sedimentos são derivados de rochas graníticas e são identificados pelo alto valor de K, moderado para alto valor de Th e U. Em (“floodplain”) planícies de inundação os sedimentos podem ser separados através dos raios gama em sedimentos dos rios e nos bancos de areia. Canais de areia são reconhecidos pelo alto valor de K e valores correspondentes pela textura grosseira dos sedimentos ricos em K- feldspato e mica. Em contraste, solos desenvolvidos sobre material aluvial em bancos de areia tem baixo valor de K e relativamente altos valores de eTh e eU na resposta espectral dos raios gamas. Um aumento na abundância de zircão em depósitos de bancos de areia pode indicar um alto valor espectral dos raios de eTh e U. A adsorção de U e Th nas argilas de textura fina em sedimentos de banco ou margens de canais é também devido à contribuição alta das respostas de eU e eTh. Também pode ser distinguida por meio da assinatura radiométrica, a textura e a diferença de idade em sedimentos em planícies de inundação.

Segundo o estudo de WILFORD et al. (1997, p. 218), quando o material coluvial é proveniente de depósitos dos granitos, como na área que estudaram, esse é diferenciado pelos altos valores na resposta radiométrica de K, associado com o K-feldspato. Eles são separados dos antigos depósitos com mínima atividade, pois esses possuem baixa assinatura de K, devido a remoção do mineral solúvel K-feldspato pelo intemperismo. Os colúvios antigos são constituídos de quartzo (areia) e com matriz de argila. A química dos solos e a concentração de radioelementos indicam que, apesar da relativa resolução grosseira dos levantamentos aéreos teletransportados (“pixel” de aproximadamente 100m), há uma correlação entre solos e medidas obtidas por Sensoriamento Remoto teletransportado de K e Th.

O processo de desintegração nuclear é característico de cada radioisótopo, sendo proporcional ao número de radionuclídeos presentes. Assim, o número de núcleos (dN) que decaem em um pequeno intervalo (dt) é proporcional ao número de núcleos, como mostra as equações 3.14 e 3.15 (MINTY, 1997, p. 39).

$$\frac{DN}{dt} = \lambda N \text{ ou} \tag{3.14}$$

$$N(t) = N_0 e^{-\lambda t} \quad (3.15)$$

onde:

λ : constante de decaimento

N_0 : número de núcleos no instante inicial ($t=0$)

N : número de núcleos em um instante de tempo t qualquer

quando:

$$N = \frac{N_0}{2}$$

A meia vida de um determinado radionuclídeo está representada na equação 3.16

$$T_{1/2} = (0,693 / \lambda) \quad (3.16)$$

O Projeto Aerogeofísico Serra do Mar Sul (CPRM, 1978), realizado pela empresa Geofoto no período de 08/75 a 09/77, fruto de um convênio firmado entre o Departamento Nacional da Produção Mineral – DNPM e a Companhia de Recursos Minerais – CPRM, cobriu uma área de 48.600 km² dos estados do Rio Grande do Sul, Santa Catarina, Paraná, Santa Catarina e São Paulo. Realizado a uma altura média de vôo de 150m e espaçamento entre as linhas de vôo em torno de 1000m, mostra uma densidade de uma amostra a cada 56m ao longo das linhas de vôo. As leituras gamaespectrométricas foram realizadas através de um sensor multiespectral modelo DIGRS-3001, da Exploranium, acoplado a um conjunto de cristais de iodeto de sódio ativado a tálio. Já para as medidas do campo magnético foram utilizados dois magnetômetros de precessão nuclear; o primeiro deles, modelo G-803 da Geometrics, a bordo da aeronave e outro fixo, modelo G-316, com o objetivo de monitorar a variação diurna do campo geomagnético. Os dados originais foram micronivelados e convertidos de contagens por segundo (cps) para concentrações (% K e ppm de eU e de eTh) e para microRöntgen por hora (μ R/h), para o canal de contagem total, com base na técnica denominada “back-calibration”. Esta conversão foi realizada por meio do “Brasil Airborne Radiometric Mapping Project” (BARMP,

1997), de acordo com o convênio de cooperação técnica celebrado em 17/10/1996 entre a CPRM e o “Geological Survey of Canadá” (GSC), com a participação da empresa canadense de consultoria em geofísica “Paterson, Grant & Watson Limited” (PGW), com o apoio financeiro da “Canadian International Development Agency” (CIDA) e do “Canadá-Brasil Cooperation Project for Sustainable Development in the Mineral Sector”.

Um recorte correspondente à área de estudo foi obtido desse projeto Aerogeofísico Serra do Mar Sul, extraído por meio das suas coordenadas UTM (E / N), contendo os valores dos dados do levantamento aerogamaespectrométrico dos elementos Tório (Th), Urânio (U) e Potássio (K). Anteriormente ao processamento, executado no Geosoft desses dados foi necessário executar a verificação da existência de valores negativos nas variáveis, caso eles existam adiciona-se a cada variável o menor valor acrescido da unidade, de forma que todas as variáveis contenham o valor mínimo de um (1). Segundo PIRES (1995, p. 65) e CARVALHO (1999, p. 35) esses valores negativos são atribuídos a problemas na correção altimétrica dos dados no pré – processamento.

Estando os dados (variáveis) gamaespectrométricos (K, Th e U) preparados, esses foram transformados em uma malha regular, no programa “Geosoft”, com resolução de 500m, pelo processo de interpolação da curvatura mínima, o qual produz uma superfície suavizada e tendo os dados próximos aos originais, segundo BRIGGS (1974, p. 42).

Nas seções 3.3.2.4.1 a 3.3.2.4.3 e Figuras 3.14, 3.16 e 3.17 são mostrados as imagens geradas dos elementos Potássio, Tório e Urânio e as suas concentrações na área de estudo; a Figura 3.15 mostra a combinação do elemento K com o MDT. A Figura 3.18 é uma composição colorida dos três elementos no espaço de cores RGB.

3.3.2.4.1 Potássio

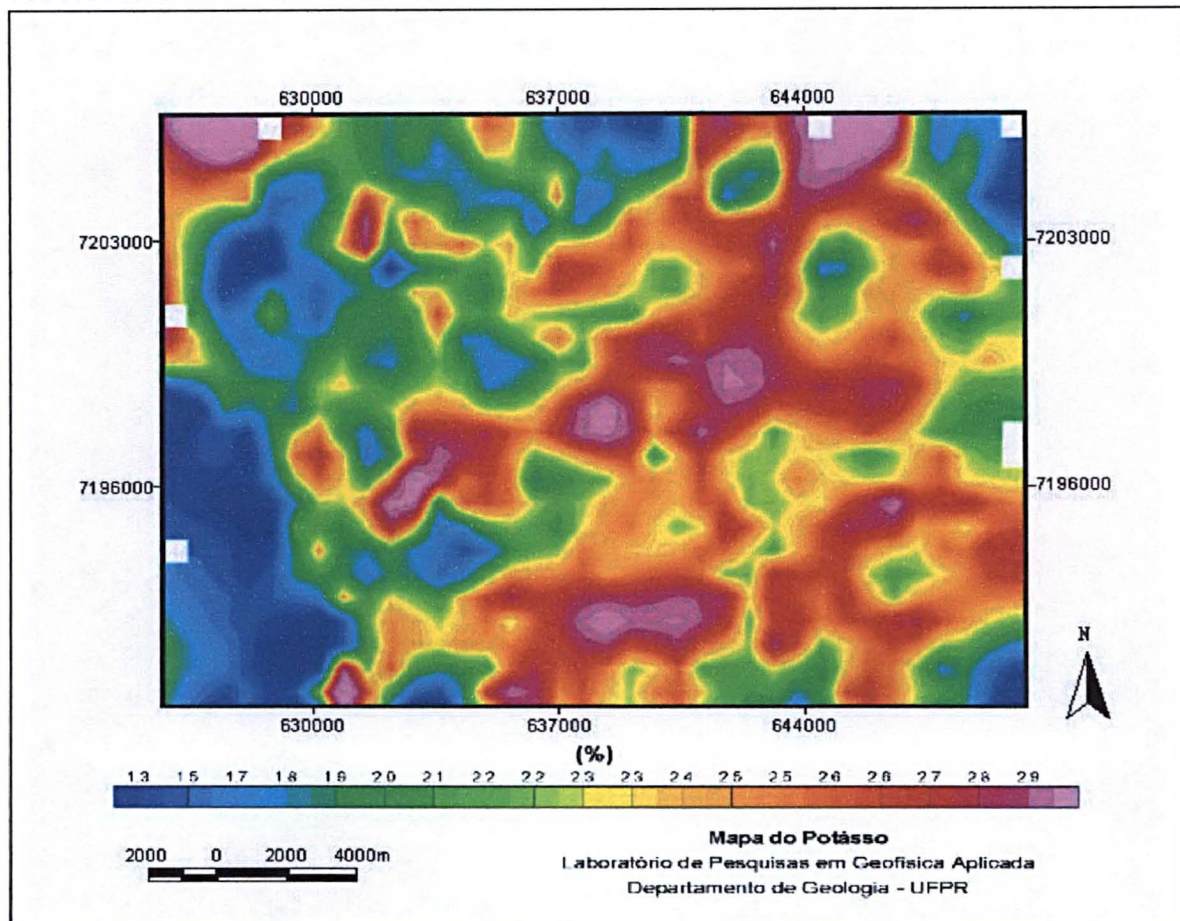
O potássio é um dos elementos mais abundantes na crosta terrestre (2,35%). É um elemento alcalino e tem uma química simples. As ocorrências mais comuns em rochas são observadas nos feldspatos potássicos (aproximadamente 13% de K), nas micas (biotita\muscovita com 8% de K) e em rochas félsicas (granitos). Teores menores são encontrados em basalto, valores baixos em dunitos e perioditos e ausentes em minerais máficos. O comportamento do intemperismo dos minerais que carregam K determina os radioelementos constituintes dos solos e rochas intemperizados. Durante o intemperismo a maior quantidade de K alocada será destruída na ordem biotita-K-feldspato-muscovita. O potássio compreendido durante o intemperismo pode ser acompanhado (“taken up”) na formação de minerais que carregam K tais como a illita ou adsorvidos em menor quantidade em outros argilo minerais, tal como a montmorilonita, em condições especiais (CARVALHO, 1999, p. 52).

O ^{40}K é o único radioisótopo do potássio, ocorrendo em proporções fixas de 0,012% do potássio total natural. Em função disto, a medida da radiação gama pode ser usada para estimar a quantidade total de K. Esse é detectado em levantamentos radiométricos com energia de aproximadamente 1,46 MeV (DICKSON et al., 1997, p. 186).

A Figura 3.13 é referente às concentrações de potássio no solo. No presente estudo esse valor varia de 1,3% a 2,9%. Na área a sudoeste da cena encontra-se a Formação Furnas com a concentração mais baixa, em torno de 1,3% a 1,7%. Com o mesmo valor pode-se destacar a área a sudeste, Formação Guabirotuba. Entretanto, apesar dos baixos valores do elemento, nota-se numa faixa acompanhando o sopé da escarpa que os valores de K estão diminuindo em relação à porção “alta” da Formação Furnas, isto ocorre devido a mobilidade de K. Valores intermediários entre 1,9% a 2,3% aparecem nas regiões dos granitóides, granito a leste (do Cerne) e ao norte (Três Córregos). Os metasedimentos (Grupo Açungui) possuem os maiores percentuais (2,6% a 2,9%), teores estes maiores que os dos granitos. O alto valor de K na direção NNE, nas proximidades do Granito do Cerne, pode ser justificado pela proximidade dos metasedimentos aos compartimentos granitóides, em especial ao

Granito do Cerne, nesta porção a rede de drenagem pode ter lixiviado material do compartimento Granitóide para o Grupo Açungui.

FIGURA 3.13 - IMAGEM DO POTÁSSIO



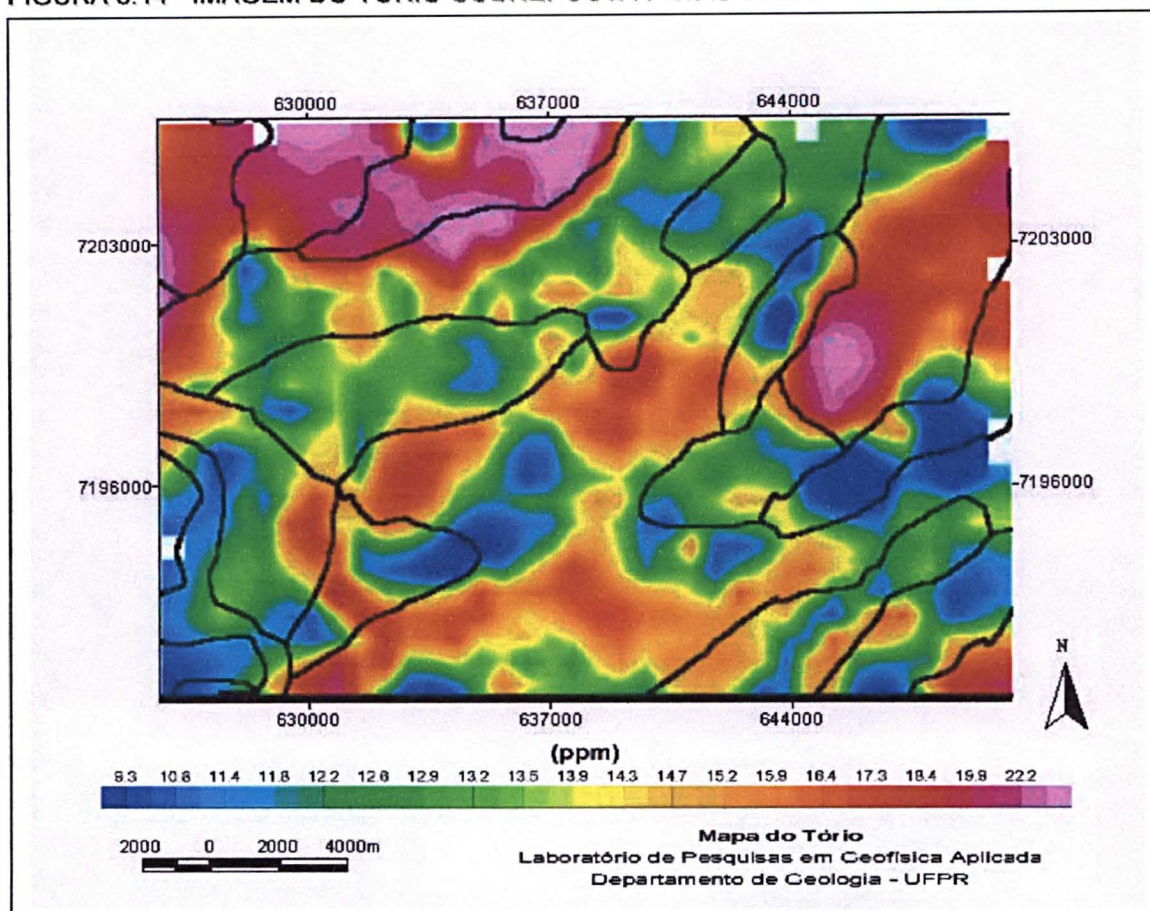
Cabe salientar que na Formação Furnas, região sudoeste da cena, a variação deste elemento diminui no sentido da escarpa. Verifica-se visualmente pela variação de tons, que na parte superior da Formação Furnas o teor desse elemento se modifica do azul claro ao mais escuro e, no sentido descendente da escarpa este varia do azul ao preto. Como já mencionado isto ocorre devido à solubilidade do K e migração (carreamento) deste para a parte baixa da escarpa. No Apêndice II encontra-se a imagem do Potássio sobreposta pelo vetor correspondente as unidades geológicas.

3.3.2.4.2 Tório

O tório é pouco abundante na crosta da Terra (aproximadamente 12ppm), ocorrendo no estado de valência Th^{4+} , tendo como características a baixa solubilidade, excetuando-se as soluções ácidas. Todavia, em condições de pH neutro, compostos orgânicos (ácidos húmicos) podem aumentar a solubilidade desse radionuclídeo. Sendo altamente móvel quando combinado com complexos orgânicos em aquíferos e solos. Pode ocorrer em níveis maiores que 1000 ppm nos seguintes minerais: alanita, monazita, xenotímeo e zircão ou ainda na forma de traço em outros minerais existentes nas rochas (DICKSON et al., 1997, p. 188).

A imagem mostrando as variações do Tório, destacada na Figura 3.14, indica as áreas da cena onde aparecem as concentrações do elemento. A variação desta concentração encontra-se na faixa de 9,3ppm a 22,2ppm. As duas áreas de maior concentração do elemento (15ppm a 22,2ppm) localizam-se nos compartimentos granitóides (Granitos Três Córregos e do Cerne). Os valores entre 9,3ppm a 11,4ppm, os mais baixos, aparecendo como manchas a sudoeste, ao centro e a leste. Os valores intermediários de 12ppm a 15ppm aparecem nas áreas centrais e sul (Grupo Açungui), a sudeste (Formação Guabirotuba). A diferenciação dos compartimentos granitóides justifica-se devido a pouca mobilidade do Th.

FIGURA 3.14 - IMAGEM DO TÓRIO SOBREPOSTA PELAS UNIDADES GEOLÓGICAS DA ÁREA.



3.3.2.4.3 Urânio

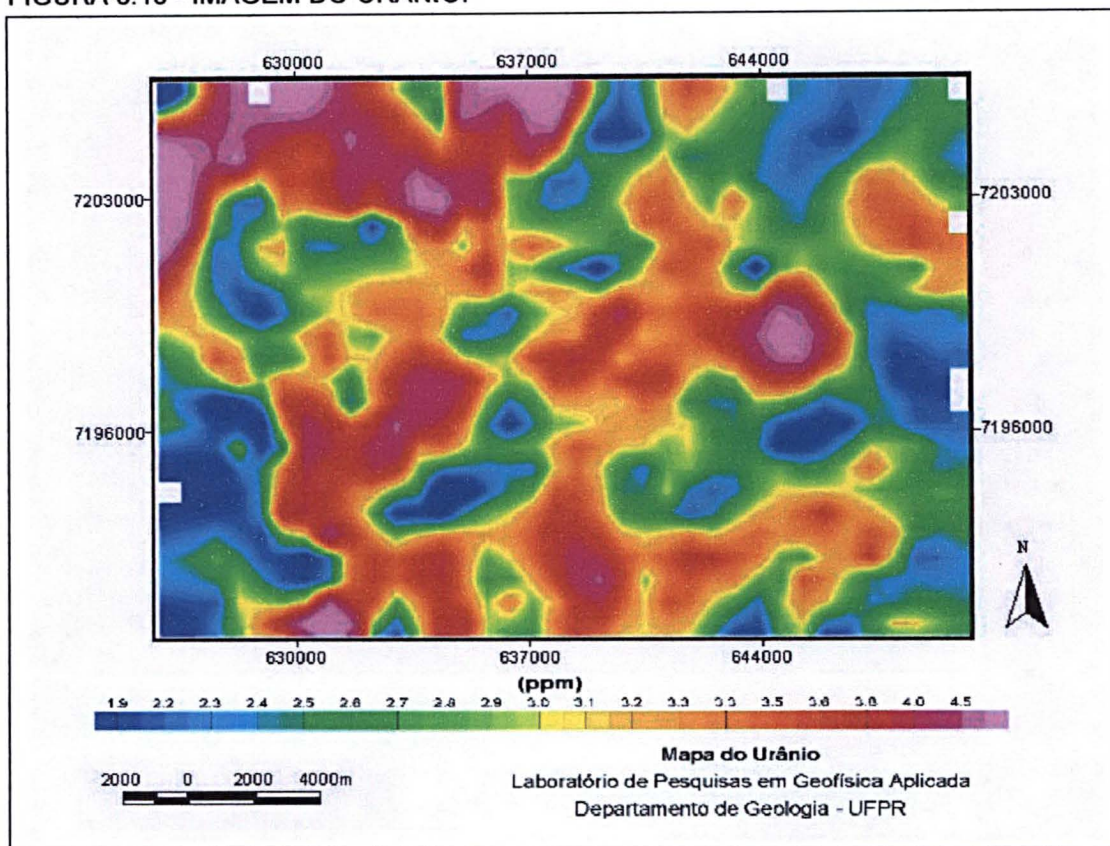
O urânio ocorre em baixa concentração na crosta terrestre (aproximadamente 3 ppm), quimicamente dominado por seus estados de valência U^{4+} e U^{6+} . O primeiro estado está geralmente contido em minerais não solúveis, enquanto o segundo associa-se com ânions como os carbonatos, os sulfatos e os fosfatos para formarem espécies solúveis. A mobilidade deste último estado é modificada pela adsorção a óxidos hidratados de ferro, minerais de argila e colóides, como também pela redução para minerais insolúveis de U^{4+} , em ambientes redutores (zonas de materiais carbonoso ou pirita). O urânio pode estar presente em rochas como óxidos e silicatos, sendo comum em uranita e uranotorita; os principais minerais matrizes são

a monazita, xenotímeo e zircão, dentre os quais, apenas a monazita e o zircão são resistentes ao intemperismo (DICKSON et al., 1997, p. 187).

O urânio liberado pela destruição de minerais durante o intemperismo pode ser retido em óxidos de ferro e minerais de argila e, em circunstâncias favoráveis pode ser precipitado sob condições redutoras formando depósitos de urânio (DICKSON et al., 1997, p. 187). Os minerais de urânio também estão presentes em pegmatitos, sienitos, carboatitos, granitos e alguns folhelhos (WILFORD et al., 1997, p. 212).

Na Figura 3.15 têm-se as concentrações de urânio em ppm (partes por milhão). A variação da concentração deste elemento na área imageada é de 1,9ppm a 4,5ppm. Os valores menores, na faixa de 1,9ppm a 2,4 ppm, encontram-se na parte sudoeste (Formação Furnas), e algumas manchas na parte leste, nordeste e ao centro. Os maiores valores dessa concentração estão localizados ao norte, ao centro e ao sul. Ao norte, no compartimento Três Córregos, encontram-se maiores teores de U. No compartimento geológico Granito do Cerne é possível que este possua diferenciação faciológica. No Apêndice II encontra-se a imagem do Urânio sobreposta pelo vetor correspondente as unidades geológicas.

FIGURA 3.15 - IMAGEM DO URÂNIO.



3.3.2.5 Segmentação

Com o objetivo de tornar as variáveis de entrada mais homogêneas é executada a segmentação, gerando entradas uniformes já que as unidades fisionômicas e geológicas são representadas por porções homogêneas do espaço físico com características semelhantes.

A segmentação é embasada no algoritmo de segmentação multi-resolução, este método de segmentação é aquele disponível no programa eCognition.

Como mencionado, na seção 2.2.3, a segmentação multi-resolução utiliza dois critérios de heterogeneidade para separar os objetos, a cor (espectral) e a forma (espacial). A heterogeneidade no domínio espectral, exemplificada por meio da equação 3.17, é composta pela soma dos desvios padrão dos níveis digitais para uma dada banda " σ_c " ponderada pelos pesos " W_c ". Contudo, em muitos casos, a

heterogeneidade espectral pode resultar em segmentos fragmentados e por isto deve-se considerar a heterogeneidade no domínio espacial.

$$H = \sum W_c \cdot \sigma_c \quad (3.17)$$

onde:

W_c – pesos;

σ_c - desvio padrão médio dos valores de níveis digitais;

H_c – heterogeneidade de cor.

A heterogeneidade no domínio espacial depende da função compacidade, calculada pela razão entre o comprimento da borda de um objeto pelo número total de “pixels” deste objeto, demonstrada pela equação 3.18, como também da suavização que é a razão da borda de um objeto pelo limite da “caixa” do mesmo, ou seja, o comprimento de um quadrado ou retângulo que compreenda o objeto, equação 3.19 (ANTUNES, 2003, p. 47-48).

$$H_f = \frac{L}{\sqrt{N}} \quad (3.18)$$

$$H_f = \frac{L}{B} \quad (3.19)$$

onde:

L – comprimento da borda (perímetro que compõe os objetos);

N – número total de “pixels” que compõe o objeto;

B – razão da borda (perímetro do quadrado que compreende o objeto);

H_f - heterogeneidade de forma

Após a análise da heterogeneidade espacial e espectral, o processo de fusão inicia-se com um “pixel” (como no crescimento de regiões) formando uma região, sendo que a cada etapa, um par de objetos funde-se para formar um objeto maior; o processo de fusão está baseado no critério de homogeneidade, observando-se a

heterogeneidade entre objetos adjacentes (ANTUNES, 2003 p. 49). A fusão dos valores da heterogeneidade de cor e forma é demonstrada pela equação 3.20.

$$f = w.H_c + (1 - w).H_f \quad (3.20)$$

onde:

f – fusão entre a heterogeneidade de H_c e H_f

W – peso para a cor (contra forma)

Segundo ANTUNES (2003, p. 50), o critério de fusão entre duas regiões adjacentes é descrito pela mudança de heterogeneidade após uma fusão virtual. Dado um determinado critério de heterogeneidade para uma região, o crescimento de heterogeneidade na fusão deve ser minimizado. A expressão 3.21 corresponde à diferença de heterogeneidade considerando o tamanho dos objetos.

$$h_{dif} = h_m - (h_1 * n_1 + h_2 * n_2) / n_1 + n_2 \quad (3.21)$$

onde:

h_1 e h_2 - heterogeneidade para dois objetos

h_m - heterogeneidade após a fusão virtual

n - tamanho dos objetos

Os segmentos são discriminados (descritos) por meio de variáveis espectrais e/ou espaciais. As variáveis ou imagens compostas por níveis digitais espectrais podem ser o "brilho", o valor médio de brilho, a razão, etc; e pode-se citar como variáveis espaciais o comprimento, a largura, a direção principal, dentre outros. As equações 3.22 e 3.23 mostram como são calculados dois descritores de segmentos: valor médio de brilho e razão.

$$C_L = \frac{1}{n} \sum_{i=1}^n C_{Li} \quad (3.22)$$

onde:

C_L – valor médio calculado;

N – número de “pixels” que formam o objeto;

C_{Li} - Valor médio de brilho do “pixel” “i” na banda “L”;

$$R_L = \frac{C_L}{\sum_{i=1}^n C_i} \quad (3.23)$$

onde:

R_L – razão de uma banda qualquer “L”;

C_L – valor médio de uma banda qualquer “L”;

C_i – valor médio de cada uma das bandas espectrais;

Na segmentação, todas as imagens digitais, Landsat7 ETM+ (sete bandas espectrais), derivadas do relevo, do levantamento aerogamaespectrométrico e imagens artificiais (Transformações IHS - RGB, TCap, NDVI, etc.), foram empregadas.

Primeiramente, a fim de se definir parâmetros de segmentação, fixa-se o fator de escala da segmentação das imagens com um valor dez (10), a seguir vinte (20) e trinta (30). A escala de segmentação, tamanho dos segmentos, deve ser compatível com a resolução da imagem (30 metros), equação 3.21.

Para os outros parâmetros de segmentação, cor e forma, são mantidos os valores de 0,5, haja vista que, o interesse da segmentação deve ocorrer em relação aos níveis digitais e também em relação a forma, equação 3.20. O fato de se dar importância igual à cor e a forma se deve à área de estudo, onde a forma do relevo e rede de drenagem (relevo acidentado e rede de drenagem definida, paralela e sub-paralela) é marcante e podem ajudar a agrupar segmentos juntamente com os valores digitais.

O fator de forma tem seus valores definidos: compacidade de 0,4 e a suavidade de 0,6, a suavidade é maior que a compacidade devido as fisionomias serem pouco compactas (espigões que se alongam segundo as direções estruturais

de dobramento e intrusões que provocam o aparecimento de boqueirões ou esporões) da área.

São analisados, visualmente, os três (3) resultados da segmentação e define-se como padrão de segmentação o fator vinte (20) de escala, com o valor 0,5 para a cor, 0,5 para a forma e para essa 0,6 de suavidade e 0,4 de compacidade, pois é o resultado que melhor agrupa, experimentalmente, os elementos de interesse das imagens. As variáveis, descritores, utilizados para representar os segmentos são as médias dos valores para cada uma das imagens de entrada, equação 3.22, a serem processadas na RNA.

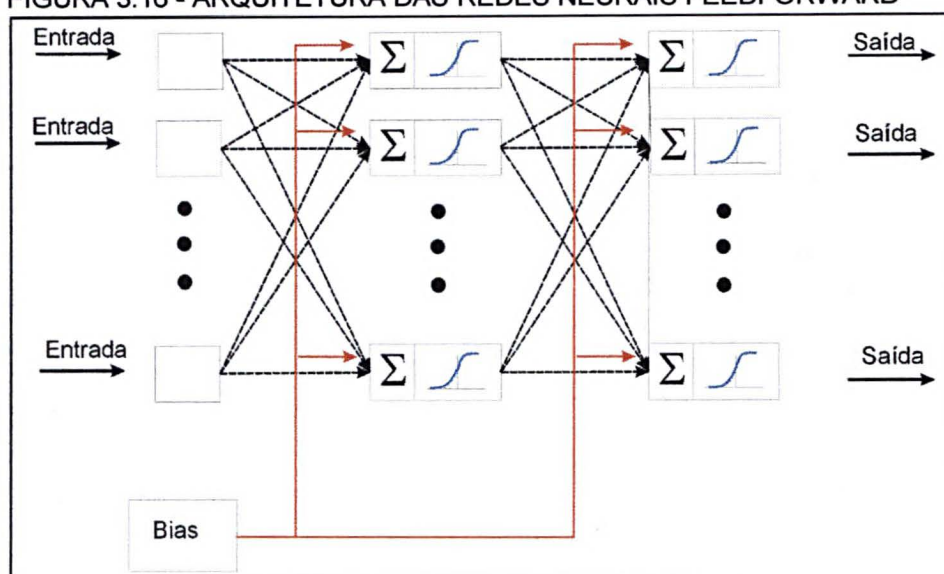
3.3.3 Redes Neurais

As RNA são usualmente organizadas em camadas compostas de unidades de processamento (neurônios), conectadas por canais de comunicação que fazem fluir dados numéricos. Os dados são apresentados à rede por meio de uma camada de entrada, a qual se comunica a uma ou mais camadas ocultas (Figura 3.16) onde ocorre o processamento por meio de um sistema de conexões ponderadas. A camada de saída apresenta o resultado do processamento (GERMAN e GAHEGAN, 1996, p.972).

O fluxo dos sinais da RNA pode ser não recorrente ("feedforward") ou recorrente. Na "feedforward", os neurônios estão organizados em camadas e a informação se desloca em um único sentido (Figura 3.16), desde as camadas de entrada até as de saída.

Na recorrente, a rede é totalmente conectada e cada neurônio está conectado a todos os outros, isto é, possuem realimentação de suas saídas para as suas entradas e por isso são intituladas de "sem memória". As saídas das redes recorrentes são determinadas pelas entradas atuais e pelas saídas anteriores, portanto são dinâmicas, estas redes podem possuir interligações entre neurônios da mesma camada e entre camadas.


FIGURA 3.16 - ARQUITETURA DAS REDES NEURAIS FEEDFORWARD



O funcionamento da rede é determinado pela conexão entre as unidades de processamento. É possível treinar uma rede para reproduzir uma função particular através do ajustamento das conexões entre as unidades. A idéia das RNA é ajustar a conexão entre os neurônios em função do problema a ser desenvolvido.

O funcionamento de um neurônio simples com duas entradas (X_1, X_2) pode ser descrito pelo modelo da Figura 3.17, um neurônio de uma rede neural com uma única saída (Y_1) de dados.

FIGURA 3.17 - EXEMPLO DE UM NEURÔNIO



onde:

X - variável de entrada

W - peso

Y - elemento de saída

Resumidamente, pode-se entender o funcionamento de um neurônio como a geração de um impulso de saída a partir da combinação dos sinais que a ele chegam (equação 3.24).

sendo:

$$Y = f(W \cdot X) \quad (3.24)$$

Na realidade, a saída é gerada em função da soma ponderada das entradas (S_i). O modelo de RNA pode ser descrito segundo a equação 3.25.

$$S_i = \sum_{j=1}^n w_{ij} X_j \quad (3.25)$$

onde:

S_i - nível de ativação ou função de ativação;

w_{ij} - peso ajustado;

X_j - atividade do neurônio (entradas).

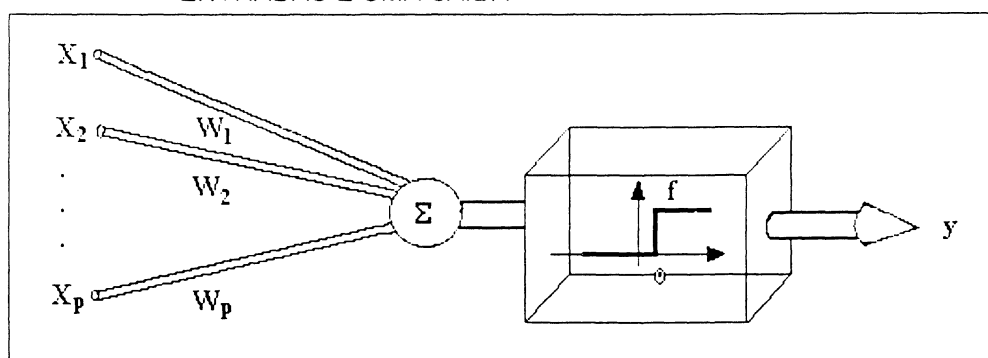
Pela equação 3.25, o valor da função de ativação S_i depende da intensidade combinada dos impulsos que a ela chegam. Uma soma ponderada destes impulsos, através dos pesos w_{ij} , origina um valor de saída $y = f(S_i)$, como esquematizado na Figura 3.19. Se esse valor for muito pequeno, ele é desconsiderado, se não $f(x) > \alpha$ e um impulso unitário é gerado e passado aos neurônios da seguinte camada (seguinte neurônio), por meio da função transferência.

Nesse caso, α desempenha o papel de um limiar que controla a intensidade do sinal de saída.

As funções utilizadas pela RNA para gerar uma saída de sinal $f(x)$, a partir de S_i , podem ser:

- Degrau: $f(x) = 0$, se $x \leq \alpha$ e 1 se $x > \alpha$, sendo α o limiar de disparo;
- Semilinear: $f(x) = 0$, se $x < \alpha_{\min}$; $mx+L$ se $\alpha_{\max} \leq x \leq \alpha_{\min}$ e f_{\max} se $x > \alpha$;
- Sigmoidal: $f(x) = f_{\max} / (1+e^{-x})$, (logsig - MatLab 4.0), a função utilizada no estudo foi a sigmoidal.

FIGURA 3.18 – ESQUEMA DE UMA REDES NEURAIS DE UMA CAMADA COM VÁRIAS ENTRADAS E UMA SAÍDA



FONTE: MODIFICADO DE KOVÁCS 1996, P. 68.

A RNA pode ser treinada para resolver problemas de classificação multiespectral. Treinar uma rede significa ajustar a sua matriz de pesos (W) de forma que o vetor de saída (y) coincida com um certo valor desejado para cada vetor de entrada (x). Também se pode fazer um paralelo com o neurônio biológico e dizer que o aprendizado é um ajuste sináptico. O treinamento pode ser supervisionado ou não supervisionado, sendo que o primeiro exige pares de entrada e de saída para o treinamento e o segundo somente o vetor de entrada.

O treinamento não supervisionado, como já mencionado, não requer pares de entrada-saída e, portanto, não faz comparações para determinar uma resposta ideal. O conjunto de treinamento modifica os pesos de forma a produzir saídas que sejam consistentes, isto é, o processo de treinamento extrai as propriedades estatísticas do conjunto de treinamento e agrupa os vetores similares em classes. A aplicação de um vetor de uma determinada classe à entrada da rede irá produzir um vetor de

saída específico, mas não existe maneira de se determinar, antes do treinamento, qual o padrão que será gerado na saída para um vetor de entrada de uma determinada classe.

Como o treinamento supervisionado necessita de pares de entrada e saída, tais pares são chamados de conjunto de treinamento. Para o treinamento, o vetor de entrada é aplicado, a saída da rede é calculada e comparada com o vetor de saída esperado, e um erro é calculado a partir da diferença. Então, os pesos são atualizados de acordo com o algoritmo a fim de minimizar esse erro. O processo de treinamento é repetido até que o erro, para o conjunto de vetores de treinamento, alcance um valor limite previamente determinado.

O treinamento da RNA foi inspirada na lei de HEBB (1949) que diz:

“A intensidade de uma ligação sináptica entre dois neurônios aumenta se ambos são excitados simultaneamente”.

O treinamento na RNA tem como objetivo (BRAGA et al., 2000, p. 237):

- Auto – associação: reconstruir vetor original;
- Heteroassociação: reconstruir segundo elemento do par;
- Detecção de regularidades: criar padrões.

O treinamento deve ser suficiente para que ocorra a generalização, denominada de memorização e de classificação quando os dados processados na RNA são originários de sensoriamento remoto. A memorização é influenciada por três fatores:

- Tamanho e eficiência do conjunto de treinamento;
- Arquitetura da rede;
- Complexidade física do problema em questão.

Sobre o terceiro fator acima mencionado, não se pode ter controle. Entretanto, para os dois outros fatores pode-se visualizar a memorização sob dois aspectos, no primeiro caso é fixando a arquitetura da rede, em concordância com a complexidade física do problema, e determina-se o “tamanho” do aprendizado (número de iterações) para que este desempenhe uma boa generalização. No segundo caso, o “tamanho” do aprendizado é fixado e a questão é, qual será a melhor arquitetura para que ocorra uma boa generalização (GONZALES e WOODS, 1998, p. 612 - 619).

No que diz respeito aos algoritmos de treinamento utilizados existe uma grande variedade, tanto no treinamento supervisionado, como para o não supervisionado. Os algoritmos mais eficientes e mais utilizados baseiam-se nos trabalhos de ROSENBLAT (1962) e WINDROW et al. (1960).

Segundo GONZALES e WOODS (1998, p. 426), os algoritmos de aprendizado usados no treinamento de "Perceptrons" podem ser para classes linearmente separáveis e classes não linearmente separáveis. A seguir é descrito o algoritmo "Backpropagation" aplicado neste estudo.

O algoritmo para treinamento de RNA multicamadas mais conhecido é o "Backpropagation" ou da retropropagação do erro. É um treinamento supervisionado que utiliza para o ajuste dos pesos em uma rede de multicamadas, o processo de minimização do gradiente descendente e o limiar da função "sigmóide" e que se constitui na Regra Delta generalizada para o treinamento de RNA "feedforward". A Regra Delta Generalizada ou do erro médio quadrático mínimo, utiliza um conjunto de treinamento com o qual se pretende uma aproximação linear, de tal forma que, se obtenha a melhor aproximação possível no sentido do erro quadrático (LEES, 1996, p. 956).

O algoritmo ("Backpropagation") foi criado através da generalização da taxa de aprendizado, sendo essa a taxa com que os "ganhos" (pesos) são alterados em consequência dos erros, de redes de múltiplas camadas com funções de transferência não lineares. Os vetores de entrada e os correspondentes de saída são usados para treinar a rede até que ela possa aproximar a função, isto é, associar os vetores de entrada a um específico vetor de saída, partindo-se de um ponto arbitrário no espaço dos pesos e percorrendo a superfície do erro quadrático em direção a um ponto mínimo. É um método simples de gradiente descendente para minimizar o erro quadrático total de saída computado pela rede (GERMAN e GAHEGAN, 1996, 970).

Na equação 3.26 é demonstrada a variação do peso em função do valor desejado e valor de ativação dos neurônios i e j .

$$\Delta w_{ij} = \eta \cdot (d_i - x_i) x_j \quad (3.26)$$

sendo:

Δw_{ij} - variação dos pesos na correção entre neurônios i e j;

η - taxa de aprendizado;

d_i - valor desejado para a atividade de um neurônio;

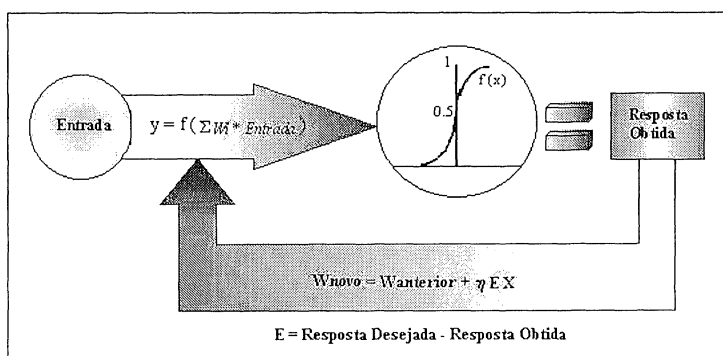
x_i e x_j - atividades dos neurônios i e j.

A RNA é um sistema dinâmico onde o novo estado é função do estado anterior. O cálculo do novo estado é chamado de atualização (equação 3.27).

$$w_i^{\text{novo}} = w_i^{\text{velho}} + \Delta w_{ij} \quad (3.27)$$

A Figura 3.20 mostra como o treinamento e a retropropagação do erro são processados na rede neural.

FIGURA 3.19 – ESQUEMA DE UMA REDE NEURAL MOSTRANDO O TREINAMENTO



FONTE: MODIFICADO DE KOVÁCS 1996, P. 68.

O funcionamento da RNA pode ser descrito da seguinte forma:

- Uma entrada é fornecida à rede e a saída é apresentada;
- O vetor erro é calculado pela rede, que é a diferença entre a saída obtida e a esperada (fornecida como parâmetro de comparação);
- É executada a atualização dos pesos da camada de saída através da Regra Delta Generalizada;
- Propaga-se para as camadas anteriores os valores desejados atualizando assim os pesos nas demais camadas.


O objetivo da Regra Delta é determinar um conjunto de pesos (w) que minimize o erro quadrático sobre determinado número de amostras de treinamento. A obtenção de um ponto de mínimo é alcançada por meio de um processo iterativo local, utilizando um conjunto de amostras.

O aprendizado é o processo no qual a taxa de aprendizado da rede ajusta os pesos através das mudanças do erro fornecido pela saída, isto é, requer que a troca dos pesos seja proporcional a derivada do erro em relação aos pesos. O gradiente descendente ideal necessita que passos infinitesimais sejam executados (HAYKIN, 1999, p. 50).

Segundo JARVIS et al. (1996, p. 964), a taxa de aprendizado é a taxa na qual os pesos são ajustados, a cada iteração, na rede através das mudanças da média do erro, definido pelos valores calculados (saídas).

A Figura 3.21 exemplifica um conjunto de pesos W_1 e W_2 tendo como solução o erro médio quadrático mínimo com infinitos pontos de mínimo e mostra a função erro (calha) com infinitos mínimos. Problemas podem ocorrer quando se atinge mínimos locais na superfície de erro.

FIGURA 3.20– SUPERFÍCIE DO ERRO MÉDIO QUADRÁTICO COM INFINITOS PONTOS DE MÍNIMO



FONTE: MODIFICADO DE KOVÁCS 1996, P. 57.

Considerando-se o conjunto de treinamento:

$$\Psi = \{x_i y_i\}_{i=1}^n \text{ Conjunto de treinamento} \quad (3.28)$$

e a aproximação linear, soma ponderada,

$$y_i = \sum_{i=1}^n w_i x_i \quad (3.29)$$

o parâmetro de correção será:

$$\Delta w_{ij} = n \cdot \delta_j \cdot y_i \quad (3.30)$$

onde:

W_i – pesos;

X_i – entradas;

δ_j - gradiente local;

y_i – saída;

n - taxa de aprendizado.

A verificação do erro cometido em cada uma das camadas e iterações é calculada através da equação 3.31.

$$E(w) = 1/2 [d_i - y_j]^2 \quad (3.31)$$

onde:

$E(W)$ - erro cometido

d_i - valor esperado

y_j - valor de saída da camada j

O erro estipulado como mínimo $E(W)$, equação (3.31), é aquele onde um determinado conjunto de pesos (W^*) satisfaz o valor numérico do erro médio quadrático mínimo. O erro cometido $E(w^*)$, equação 3.32, em cada camada da RNA é comparado com o erro quadrático mínimo $E(w)$ e quando a equação 3.33 é satisfeita, a rede fornece os valores dos conjuntos de pesos (w^*) e a saída .

$$E(w^*) = \sum_{i=1}^n (y(w^*; x_i^n) - y_i^n) \quad (3.32)$$

onde:

$E(w^*)$ - erro médio quadrático calculado (do conjunto de observações Ψ);

W^* - conjunto de pesos, calculados, otimizados (erro quadrático mínimo);

$$E(w^*) \leq E(w). \quad (3.33)$$

onde:

$E(w)$ - erro médio quadrático estipulado

A implementação do algoritmo "Backpropagation" inclui duas etapas; na primeira, o vetor de saída obtido através do processamento dos dados de entrada na rede, determina um conjunto de pesos. No final deste primeiro estágio, a comparação do vetor desejado com o de saída calculado com o primeiro conjunto de pesos, é executado. Na segunda etapa, são efetuados os ajustes nos pesos a partir da comparação do valor desejado e do calculado pela rede a cada iteração, iniciando-se na camada de saída até a primeira camada escondida (retropropagação) (GONZALES e WOODS, 1998, p. 611).

Nesse experimento, as redes multicamadas usam a função de transferência "sigmóide" com suas camadas escondidas, pois o algoritmo de treinamento é o "backpropagation" que utiliza para o ajuste dos pesos o processo de minimização do gradiente descendente e o limiar da função "sigmóide" (Regra Delta Generalizada). Essa função é freqüentemente chamada de "achatada" ("squashing"). Se o gradiente descendente (a derivada do erro em relação aos pesos) tem uma pequena magnitude causa pequenas mudanças nos pesos, mudanças não suficientes para que se atinja um valor ótimo. Devido a esse problema, variações do algoritmo tem sido pesquisado por autores como JARVIS et al. (1996); REIDMILLER et al. (1993) dentre outros. A seguir serão mostradas as variações desse treinamento que foram processadas neste trabalho.

a) Taxa de Aprendizado Variável

Como no gradiente descendente padrão a taxa de aprendizado é constante durante o treinamento, pode ocorrer um processamento muito lento se a taxa de aprendizado é pequena, ou o algoritmo pode se tornar instável se a taxa fixada é muito alta. Com base no exposto, uma solução para se evitar as duas situações é permitir que a taxa de aprendizado seja modificada durante o processo de

treinamento. Primeiro fixa-se uma taxa de aprendizado e a saída inicial da rede e os erros são calculados e, a cada iteração, novos pesos e limiares são calculados utilizando-se a taxa de aprendizado corrente e, novas saídas e pesos são calculados; se o novo erro (calculado) excede o valor do erro “antigo” de um certo valor estipulado, esses pesos e limiares são descartados, caso contrário, os pesos e limiares são conservados. Se o novo erro é menor que o antigo, a taxa é aumentada.

b) Variação do Treinamento “Backpropagation”: “Momentum”

Devido ao mesmo fato exposto no item “a”, pode-se utilizar no processamento do algoritmo “Backpropagation” outra variação chamada de “Momentum”. O “Momentum” é a taxa que prevê os efeitos das mudanças dos pesos no ajustamento em questão, portanto estabelece a direção para a minimização mais rápida do erro (JARVIS et al., 1996, p. 964).

Na equação 3.34 foi introduzido o termo “Momentum” para incrementar os ajustamentos dos pesos a cada iteração, visando obter o erro mínimo estipulado mais rapidamente.

$$\Delta w_i(n + 1) = n \cdot \delta_i \cdot y_i + \mu \cdot \Delta w_i(n) \quad (3.34)$$

onde:

μ - Termo “Momentum”

O termo “Momentum” pode diminuir a oscilação que deixa a convergência lenta, é uma constante positiva que permite a RNA responder não só ao gradiente local, mas também para a direção recente na superfície de erro (GOSE, et al., 1996, p. 207). Atuando como um filtro passa baixa, permite que a rede ignore feições pequenas na superfície de erro. Utilizando-se da variação “Momentum”, a rede pode

permanecer em um mínimo local superficial e também pode deslizar por muitos mínimos (MATLAB, 1998, p. 5-11).

c) Variação do Treinamento "Backpropagation": "Resilient"

Ainda devido ao fato da instabilidade da rede e também ao processamento da mesma poder ocorrer de forma lenta, outra variação do treinamento "Backpropagation" foi desenvolvida por REIDMILLER et al. (1993).

No treinamento, quando da atualização dos pesos por meio da taxa de aprendizado, pode ocorrer um ponto de mínimo local e o gradiente descendente ter pequena magnitude e os pesos não serem ajustados num valor ótimo para o problema. Pode-se então utilizar uma variação do algoritmo "Backpropagation" que minimiza esse problema e a convergência esperada da rede é acelerada, essa variação chama-se "Backpropagation Resilient". O intuito do treinamento "Resilient" (elástico) é eliminar os efeitos de perda de magnitude das derivadas parciais. Somente o sinal da derivada é usado para determinar a direção do ajustamento dos pesos, a magnitude das derivadas não tem efeito sobre o ajustamento dos pesos, isto é, a mudança dos pesos é determinada por ajustamento de valores separados. O ajustamento de cada peso é aumentado por um fator, todas as vezes que o desempenho da derivada da função, com respeito aos pesos, tem o mesmo sinal para duas iterações sucessivas. O valor do ajustamento do peso é diminuído por um fator, todas as vezes que a derivada, com respeito aos pesos, muda de sinal na iteração seguinte. Se a derivada é zero, então o valor do gradiente permanece o mesmo. Toda às vezes que os pesos estão oscilando, a mudança dos mesmos será reduzida. Se os pesos continuam a mudar na mesma direção por várias iterações, então sua magnitude do ajuste deles será aumentada. (REIDMILLER et al., 1993, p. 588). O ajuste dos pesos é calculado com a expressão 3.35.

$$DW = \Delta W * \text{sign}(GW) \quad (3.35)$$

onde:

DW - atualização dos pesos

GW - gradiente

sign - sinal em função da mudança dos pesos nas iterações

ΔW - variação dos pesos

3.3.4 Método para a Coleta das Amostras

Duas séries de experimentos foram realizadas:

- Adotando-se como verdade de campo a imagem gerada por meio da fotointerpretação. Com as unidades fisionômicas denominadas U1, U2, ..., U7, como citado na seção 3.3.1, na Figura 3.3 (A).
- Adotando-se como realidade o mapa geológico generalizado, onde seis unidades geológicas são definidas e intituladas de U1, U2, ..., U6, na seção 3.3.1 é apresentada na Figura 3.3 (B) contendo as unidades.

Para cada unidade são selecionadas 12 matrizes de 10x10 "pixels" (linhas e colunas), definindo elementos amostrais de treinamento, os quais são escolhidos tomando-se a precaução de que as mesmas estejam bem distribuídas na imagem e também sejam representativas, isto é, procura-se cobrir todas as nuances de cada unidade. De cada matriz são destacados cinco "pixels", o central e um de cada extremo, que representam sessenta (12x5) elementos amostras puros, representativos de cada unidade.

Essa quantidade de amostras é definida a partir de testes preliminares, nos quais com uma quantidade menor de amostras de treinamento por classe (40 elementos) não se atingiu um bom aprendizado da rede, tendo sido verificado por meio da matriz de confusão e, para um número maior de amostras de treinamento (100 elementos) o aprendizado da rede se torna lento chegando a 10.000 iterações.

Usando-se como dados de entrada três bandas espectrais e uma entrada auxiliar, portanto quatro variáveis, por exemplo, o vetor de uma amostra tem a

dimensão (1x4) e, no total, o conjunto de amostras é composta por 12 x 5 x número de classes de vetores com dimensão (1x4).

Para o treinamento da rede, há a necessidade de que estas sejam intercaladas por classe, para que o processo de treinamento não se torne tendencioso, isto é, que a modelagem da rede só identifique as características de um conjunto de amostras. Portanto, as 60 amostras de cada classe são alternadas. Para melhor entender o procedimento de alternâncias das amostras de treinamento, pode-se considerar como exemplo, três classes A, B e C e por meio do Quadro 3.1 verificar como as amostras seriam apresentadas a rede sem serem intercaladas e como são, na realidade, intercaladas.

Os elementos amostrais de treinamento para as imagens segmentadas seguem a mesma metodologia, apresentada para o nível de abstração do “pixel”.

QUADRO 3.1 – AMOSTRAS NÃO ALTERNADAS E ALTERNADAS

Amostras sem Alternância	A ₁	A ₂	A ₆₀	B ₁	B ₂	B ₆₀	C ₁	C ₂	C ₆₀
Amostras com Alternância	A ₁	B ₁	C ₁	A ₂	B ₂	C ₂	A ₃	B ₃	A ₆₀	B ₆₀	C ₆₀

3.3.5 Verificações

A seguir serão descritas como foram executadas as verificações a partir da matriz de confusão, em relação à importância das variáveis de entrada quando da generalização (simulação) e também as tabulações cruzadas entre a verdade de campo (unidades fisionômicas e unidades fisionômicas do mapa geológico) e as imagens classificadas.

3.3.5.1 Matriz de Confusão

Segundo LILLESAND et al. (2000, p. 568), uma das maneiras mais comuns de se expressar a acurácia da classificação é através da matriz dos erros (matriz de confusão). A matriz dos erros compara, classe a classe, o relacionamento entre dados conhecidos da realidade, e o correspondente resultado da classificação automática.

A diagonal da matriz de confusão refere-se aos “pixels” de verificação que foram classificados corretamente, isto é, estão corretos em relação às amostras utilizadas para a classificação. Fora da diagonal da matriz, encontram-se os “pixels” denominados de confusão/ambíguos (resíduos). Nas linhas, estão os erros chamados de omissão, “pixels” da classe de interesse que o classificador não reconheceu, e nas colunas os erros de inclusão, que são aqueles que o classificador elegeu como de determinada classe, mas verificou-se que pertence à outra. A matriz de confusão proposta baseia-se na apresentada por GONGALTON et al., (1993, p. 643).

Após a modelagem da rede com as variáveis de entrada, é processada a matriz de confusão com o intuito de verificar os “pixels” que estão alocados correta/incorrectamente. Por meio de análise visual da imagem generalizada nesse estudo estipula-se que o número máximo de “pixels” incorretamente alocados, nas devidas classes, é três. Se este número ultrapassar três, o resultado da rede é descartado e o processamento (treinamento da rede) com a mesma arquitetura, e variáveis de entrada, é novamente executado. Caso contrário, a generalização dessa modelagem é processada gerando uma imagem de saída contendo as classes.

3.3.5.2 Avaliação da Influência das Variáveis de Entrada

Para a verificação da importância das variáveis de entrada na generalização, executa-se generalizações alterando-se uma das variáveis de entrada para a mesma modelagem da rede. Por exemplo, numa modelagem onde as variáveis de entrada são três componentes principais e o MDT, treina-se a rede e armazena-se o resultado da arquitetura dessa modelagem, bem como os pesos e limiares e, executa-se a generalização, a qual gera uma imagem classificada de saída, como normalmente é feito. É executada uma nova generalização (classificação), com a mesma modelagem da rede, a qual foi armazenada, porém com as três variáveis espectrais e a variável auxiliar MDT substituída por uma imagem artificial, isto é, com somente um nível digital, no caso zero. Este processamento gera uma nova imagem temática sem os dados referentes ao MDT, podendo-se assim comparar a imagem generalizada por meio da modelagem da rede com o MDT e sem a inferência do mesmo. Este processamento é assim executado com o intuito de se avaliar o quanto o MDT influencia no resultado final da classificação. Este procedimento é realizado para as outras três variáveis (componentes principais 1, 2 e 3), nesse caso. Assim são processadas as generalizações para todos os testes, sempre substituindo uma das variáveis, por uma imagem artificial com somente um nível digital, para verificar a sua importância na modelagem em questão.

3.3.5.3 Coeficiente de Correlação (Coeficiente de Cramer's V)

A eficiência da classificação é avaliada comparando-se o resultado da classificação com a verdade de campo, proveniente da fotointerpretação e com a realidade originária do mapa geológico, por meio de uma tabulação cruzada, isto é pelo coeficiente de correlação "Cramer's V". No estudo o índice de correlação Cramer's V utilizado é o apresentado pelo "software" Idrisi 3.2.

A tabulação cruzada pode ser descrita como uma sobreposição mostrando todas as combinações da operação lógica “E”. O resultado é uma nova imagem que mostra os locais de todas as combinações das categorias das imagens originais. A tabulação cruzada também fornece o grau de consonância entre a classificação e a verdade de campo. O grau de afinidade ou correlação entre duas imagens é medido pelo coeficiente de correlação “Cramer’s V”, proposto por KENDEL (1980) In: ANTUNES (2003, p, 85). Essa medida é um coeficiente que varia na faixa de 0 até 1, indicando nenhuma ou perfeita correlação, respectivamente, utiliza da estatística de Qui-Quadrado e mede o grau de afinidade entre duas imagens. Segundo o mesmo autor, o coeficiente “Cramer’s V” é demonstrado pela equação 3.36 e 3.37.

$$V = \sqrt{\frac{\chi^2}{N(K-1)}} \quad (3.36)$$

onde:

N - frequência de total das classes, para a imagem da fotointerpretação N=7 e para a imagem gerada a partir do mapa geológico N=6;

K - produto do número de linhas e colunas;

χ^2 - Qui-Quadrado baseado na equação 3.37;

$$\chi^2 = \frac{(o_1 - e_1)^2}{e_1} + \frac{(o_2 - e_2)^2}{e_2} + \dots + \frac{(o_i - e_i)^2}{e_i} \quad (3.37)$$

onde:

o_i – frequências observadas;

e_i - frequências esperadas;

4 EXPERIEMENTOS

4.1 DEFINIÇÃO DA ARQUITETURA DAS REDES E ALGORITMO DE TREINAMENTO

Não existe regra única para a definição da arquitetura das redes neurais. A arquitetura depende do problema e do número de variáveis envolvidas, portanto define-se a melhor arquitetura por meio de experimentos. A fim de definir a arquitetura das RNA iniciam-se testes, definindo as entradas e saídas, as camadas escondidas e o número de neurônios por camada. O número de neurônios de entrada e de saída é definido como citado na seção 2.4 pelos autores GERMAN e GAHEGAN (1996) e MURNION (1996). Para o treinamento utilizando-se a taxa de aprendizado essa foi inicialmente fixada com o valor de 0,001, já para o treinamento com a variação "Momentum" o valor determinado "a priori" foi de 0,9. As camadas escondidas são definidas experimentalmente, começando com uma camada a qual não gera o resultado esperado, erro médio quadrático maior que 0,03 para mais de 1000 iterações, sem convergência da rede. As iterações são limitadas a 500 vezes, de modo que, o processamento contemple um tempo computacional compatível, no máximo 10 minutos. A rede é alterada para treinar com duas camadas escondidas, para gerar hiperplanos, e se obter um erro médio quadrático aceitável.

Para a primeira série de testes, quando o nível de abstração é o "pixel", o erro médio quadrático aceitável é de 0,003 e um número total de 500 iterações. Ainda para a primeira série de testes quando o nível de abstração é o segmento, o erro médio quadrático é de 0,002 e a quantidade de iterações é mantida em 500 vezes. A segunda série de testes, executada somente em nível de abstração de segmentos, conserva os valores definidos da primeira série, isto é, 500 iterações e $E(W)$ de 0,002.

Tendo-se definido a quantidade de camadas escondidas é necessário determinar-se experimentalmente o número de neurônios (nós) por camada. Para tanto, se considera a regra de HILTON (1989) In: FITZGERALD et al. (1996, p. 984),

citado na seção 2.4, isto é, fixa-se à quantidade de neurônios da primeira camada escondida em $1/3$ da quantidade de amostras e, varia-se à quantidade de nós para a segunda camada até se obter uma quantidade de nós nessa camada que forneça o resultado esperado, em termos de iterações e do erro médio quadrático mínimo estipulado. Após os testes define-se que a quantidade de neurônios da segunda camada escondida é $1/4$ dos nós (neurônios) da primeira camada escondida.

Seguindo-se esta regra tem-se em valores numéricos: $1/3$ das amostras na primeira camada escondida, no caso das sete unidades originárias da fotointerpretação. Portanto para 420 amostras ($60 \times 7 / 3$) uma quantidade de 140 neurônios para essa camada, lembrando que o total de 60 amostras representa 12×5 , isto é, 12 amostras selecionadas cinco vezes, como já descrito na seção 3.3.4. Para segunda camada escondida o total de 35 neurônios ($140/4$ - experimental). Experimentalmente processa-se com essa arquitetura e atinge-se a convergência com um número de iterações esperadas, em torno de 500, com um erro médio quadrático mínimo aceitável e com a matriz de confusão com no máximo três "pixels" de resíduo.

O algoritmo de treinamento que se utiliza é o "Backpropagation" e suas variações: "Taxa de Aprendizado Variável" (Traingd), "Momentum (Traingda)" e "Resilient (Trainrp)". Como já mencionado os valores iniciais para a taxa de aprendizado e para o termo "Momentum" são 0,01 e 0,9, respectivamente.

A descrição da variação "Traingd" do algoritmo encontra-se na seção 3.3.5 (a), esta é pertinente quando o gradiente apresentar uma pequena magnitude e, portanto pequenas mudanças nos pesos, mudanças estas não suficientes para que se atinja um valor ótimo, neste estudo em questão 500 iterações. Essa primeira tentativa de variação do treinamento "Backpropagation" é abandonada, pois nem sempre se atinge os objetivos definidos, e passa-se a outra variação o "Traingda", descrito na seção 3.3.5 (b), com o intuito de agilizar a minimização do erro. Alcança-se o objetivo (tempo de processamento inferior a 500 iterações), mas opta-se por testar a variação do algoritmo de treinamento intitulado de "Resilient"- "Trainrp". O treinamento "Backpropagation" com a variação "Resilient", desenvolvido por REIDMILLER et al. (1993), descrito na seção 3.3.5 (c), é executado com o intuito de minimizar as oscilações nos ajustes dos pesos quando o treinamento da rede está

sendo processado, atingindo assim o ponto de mínimo em uma quantidade menor de iterações com um erro médio quadrático menor.

A Tabela 4.1 mostra parte dos experimentos que foram executados, para definir a melhor arquitetura da rede, para gerar a separação das unidades fisionômicas, bem como o ajuste dos parâmetros para a área de estudo.

TABELA 4.1 – TESTES EXECUTADOS PARA O AJUSTE DA RNA, ELEMENTO MÍNIMO DA IMAGEM "PIXEL" E AMOSTRAS BASEADAS NA FOTOINTERPRETAÇÃO

	Iterações Aproximadas	Algoritmo de treinamento	Erro Médio Quadrático
1	500	Traingd	0,003
2	460	Traingda	0,0025
3	360	Trainrp	0,0012 a 0,001

Para as unidades (6) advindas do mapa geológico (segunda série de testes) é utilizado o mesmo método, isto é, 360 (60x6) dividido por três (3), um total de 120 neurônios na primeira camada escondida e 120/4, 30 neurônios na segunda camada escondida.

Ressalta-se que o ajuste da arquitetura da rede é executado com as imagens digitais espectrais e auxiliares processadas, primeiramente, para classificar as unidades fisionômicas advindas da fotointerpretação e, tendo como elemento mínimo o "pixel". Tendo-se a arquitetura da rede ajustada passa-se a trabalhar com as imagens segmentadas para classificar as unidades fisionômicas adquiridas por meio da fotointerpretação e outros testes para classificar unidades fisionômicas geológicas, tendo como unidade mínima os segmentos.

4.2 TESTES: UNIDADES FISIONÔMICAS A PARTIR DA FOTOINTERPRETAÇÃO E DA GEOLOGIA (“PIXEL” E SEGMENTOS)

Duas séries de testes são executadas neste estudo, como descrito na seção 3.3.4. Nos primeiros experimentos como variáveis de entrada utilizam-se somente as variáveis em nível de “pixel” e como verdade de campo a imagem gerada por meio da fotointerpretação, isto é, para o treinamento da rede, utiliza-se as amostras da primeira série descrita na seção supra citada.

Os primeiros testes são executados utilizando-se as sete bandas espectrais (“pixel”) como dados de entrada. Para esse primeiro experimento, o resultado da classificação, em relação à separação das unidades, é de baixa qualidade, isto é, analisando-se visualmente a imagem classificada comparada com a verdade de campo (fotointerpretação), a única unidade separada é a de número 2, apresentada na Figura 3.3 (A) da seção 3.3.1, as demais unidades aparecem misturadas. Devido ao fato de serem necessários testes com todos os dados de diferentes origens e os dados espectrais, escolhe-se por executar o treinamento na rede neural somente com as bandas (R3 G4 B5), menor quantidade de dados de entrada. Neste caso, entrando somente com as três bandas citadas não se obtém o resultado desejado.

Haja vista o ocorrido com o processamento das sete e três bandas espectrais, inicia-se a introdução de outras variáveis (informações) no treinamento da rede neural, para que essas possam melhorar o resultado da classificação, mas decide-se que, devido ao fato do tempo de processamento aumentar em função das variáveis de entrada e como as bandas espectrais têm alta correlação, é pertinente dimensionar as variáveis de entrada. Para tanto, as bandas espectrais são substituídas pelas imagens geradas das transformações de CP e TCap. As primeiras variáveis a serem associadas às imagens digitais CP e TCap são o MDT e as microbacias e sucessivamente as demais variáveis (dados gamaespectrométricos (U, Th e K), NDVI, classes de declive, transformação IHS, etc.). Devido as bandas espectrais, 7 e 4, salientarem a morfologia do terreno essas também foram utilizadas no processamento.


4.2.1 Identificação das Melhores Variáveis de Entrada da Primeira Série - Fotointerpretação ("Pixel" e Segmentos) e Segunda Série - Mapa Geológico e Segmentos

Nesta seção são apresentadas três Tabelas, 4.2 (A), 4.2 (B) e 4.2 (C). Essas se referem aos experimentos realizados com as variáveis de entrada, por meio da técnica das RNA utilizando imagens digitais/espectrais e informações referentes ao relevo, geologia, etc.

Para a Tabela 4.2 (A) tem-se como nível de abstração o "pixel", na primeira coluna encontram-se as variáveis que são testadas e na segunda coluna o resultado do coeficiente de correlação, calculado entre as imagens geradas após o treinamento das redes (classificadas) e a verdade de campo, imagem gerada a partir da fotointerpretação, Figura 3.3 (A) da seção 3.3.1. Nas Tabelas 4.2 (A, B e C), apenas os nove (9) melhores resultados são listados, sendo que na prática foram realizadas aproximadamente 80 combinações.

TABELA 4.2 (A) – EXPERIMENTOS REALIZADOS COM A VARIAÇÃO DAS ENTRADAS E DA REALIDADE DE CAMPO (FOTOINTERPRETAÇÃO) E RESPECTIVO DO ÍNDICE DE CRAMER'S V

Variáveis	Coefficiente de correlação
CP (1, 2 e3) e MDT	0,2897
Cp (1, 2 e3) e microbacias	0,3160
Cp (1, 2 e3), microbacias, MDT e banda 7	0,3451
Cp (1, 2 e 3), microbacias, MDT e Th	0,3717
Tcap (B, G, T), microbacias, MDT	0,3839
Cp (1, 2 e 3), microbacias, MDT e U	0,4016
Cp (1, 2 e 3), microbacias, MDT e banda 4	0,4159
Cp (1, 2 e3), microbacias e MDT	0,4192
Cp (1, 2 e 3), microbacias, MDT e K	0,4347


*  melhor resultado


**  segundo melhor resultado

Na Tabela 4.2 (B) encontram-se os experimentos, da primeira série de testes, tendo-se como nível de abstração segmentos. Na primeira coluna encontram-se as variáveis de entrada e na segunda o resultado coeficiente de correlação executado entre as imagens classificadas e a verdade de campo, imagem gerada a partir da fotointerpretação, Figura 3.3 (A) da seção 3.3.1. Os testes destacados mostram a primeira e segunda melhores classificações, respectivamente.

TABELA 4.2 (B) – EXPERIMENTOS REALIZADOS COM A VARIAÇÃO DAS ENTRADAS E DA REALIDADE DE CAMPO (FOTOINTERPRETAÇÃO) E RESPECTIVO DO ÍNDICE DE CRAMER'S V

VARIÁVIES	Coeficiente de correlação
CP (1, 2 e 3) e MDT	0,3957
Tcap (B, G, T), microbacias, MDT	0,4072
Cp (1, 2 e 3) e microbacias	0,4157
Cp (1, 2 e 3), microbacias, MDT e banda 4	0,4394
Cp (1, 2 e 3), microbacias, MDT e Th	0,4469
Cp (1, 2 e 3), microbacias, MDT e NDVI	0,4523
Cp (1, 2 e 3), microbacias, MDT e K	0,4567
Cp (1, 2 e 3), microbacias, MDT e U	0,4567
Cp (1, 2 e 3), microbacias, MDT e banda 7	0,4669
Cp (1, 2 e 3), microbacias e MDT	0,4767

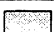
*  melhor resultado

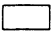
**  segundo melhor resultado

Na Tabela 4.2 (C) encontram-se os experimentos da segunda série de testes, descritos na seção 3.3.4, tendo-se como nível de abstração segmentos. Na primeira coluna encontram-se as variáveis de entrada e na segunda o resultado coeficiente de correlação executado entre as imagens classificadas e a verdade de campo, imagem gerada a partir da generalização do mapa geológico, Figura 3.3 (B) da seção 3.3.1. Os testes destacados mostram a primeira e segunda melhores classificações, respectivamente.

TABELA 4.2 (C) – EXPERIMENTOS REALIZADOS COM A VARIAÇÃO DAS ENTRADAS E DA REALIDADE DE CAMPO (MAPA GEOLÓGICO) E RESPECTIVO DO ÍNDICE DE CRAMER'S V

VARIÁVIES	Coefficiente de correlação
Banda 4, MDT, gradiente da encosta e Th	0,3801
CP (1, 2 e 3), MDT, K e Th	0,4012
Banda 7, MDT, gradiente da encosta e Th	0,4055
CP (1, 2 e 3), MDT, microbacias, banda 4 e Th	0,4073
CP (1, 2 e 3), MDT, microbacias, banda 4 e K	0,4386
MDT, microbacias, banda 4, IHS (DTM-gradiente), CP (3a) e Th	0,4465
MDT, microbacias, banda 4, gradiente da encosta, Th e K	0,5039
MDT, microbacias, gradiente da encosta, IHS (MDT-gradiente), Th, K e U	0,5182
MDT, microbacias, banda 4, gradiente da encosta e Th	0,5493
MDT, microbacias, banda 4, gradiente da encosta, Th, K e U	0,6051

*  melhor resultado

**  segundo melhor resultado

Os coeficientes de correlação apresentados nas Tabelas 4.2 (A, B e C), mostram o grau de afinidade ou consonância entre a imagem referência (Fotointerpretação - Figura 3.3 (A) e Mapa Geológico – Figura 3.3 (B)) e as imagens classificadas. Em se tratando de sensoriamento remoto e separação de unidades geológicas os valores de concordância, dos melhores índices, são aceitáveis.

5 RESULTADOS E DISCUSSÕES

Na seção 5.1 encontram-se os resultados do uso das redes neurais para a identificação de unidades fisionômicas (fotointerpretação/mapa geológico), tendo sido processadas as entradas em nível de “pixel” e de segmentos. Ressalta-se que só aqueles resultados que auxiliaram na discriminação das fisionomias são apresentados. Na seção 5.2 são mostradas as melhores classificações avaliadas por meio do coeficiente de “Cramer's V” e na seção 5.3 são apresentadas generalizações, para verificar qual a importância das variáveis de entrada.

5.1 REDES NEURAI

A seguir são apresentados os resultados relativos ao uso das RNA para a identificação de unidades fisionômicas. Os resultados foram reunidos em dois grupos: experimentos usando como referência a imagem gerada por meio da fotointerpretação e experimentos utilizando como realidade o mapa geológico.

Testes foram realizados, como mostrado na Tabela 4.1 da seção 4.1, para a definição da arquitetura da RNA mais apropriada e que garanta a convergência em um número menor de iterações (“tempo computacional operacional”) e com um resultado coerente com a verdade de campo (fotointerpretação ou mapa geológico). Os melhores resultados da arquitetura da rede foram com o algoritmo “Resilient”, descrito na seção 3.3.5 (c), com a camada de entrada (somente para a “recepção” dos dados) em função das variáveis de entrada e a camada de saída em função do número de classes (6 e 7). Foram adotadas duas (2) camadas escondidas, sendo que o número de neurônios da primeira camada escondida foi definido como 1/3 das amostras de treinamento e a segunda camada escondida com 1/4 do número de neurônios da primeira camada escondida.

Para o treinamento das amostras tendo como base às unidades advindas da fotointerpretação, a arquitetura da rede ficou assim definida:

- Cinco (5) variáveis de entrada: cinco (5) neurônios na primeira camada;
- Cento e quarenta (140), considerando-se 420 amostras, neurônios na primeira camada escondida;
- Trinta e cinco (35) neurônios na segunda camada escondida;
- Sete (7) neurônios na camada de saída.

A arquitetura da rede para o treinamento das amostras tendo como realidade o mapa geológico, ficou definida como:

- Cinco (5) variáveis de entrada: cinco (5) neurônios na primeira camada;
- Cento e vinte (120), considerando-se 360 amostras, neurônios na primeira camada escondida;
- Trinta (30) neurônios na segunda camada escondida;
- Sete (6) neurônios na camada de saída.

5.1.1 Resultado do Treinamento da Rede Neural

Considerando como verdade de campo o resultado da fotointerpretação, foram realizadas duas séries de experimentos visando analisar o desempenho das RNA na fase de treinamento, isto é, avaliar se as amostras de treinamento foram corretamente classificadas pela RNA antes da generalização. Na primeira série, os dados foram analisados em nível de abstração do "pixel". Já na segunda série de testes, as imagens de entrada foram previamente segmentadas.

Em cada caso, o conjunto de variáveis de entrada foi modificado, visando identificar aquelas mais significativas.

Na Tabela 5.1 (A) são mostrados os melhores resultados para a análise usando como referência a imagem oriunda da fotointerpretação em nível de "pixel", e em nível de segmento, Tabela 5.1(B). As colunas dessas tabelas representam as variáveis de entrada de cada experimento, a quantidade de iterações, o erro médio

quadrático mínimo atingido, a taxa de “pixels” corretamente classificados no treinamento da RNA e o número de “pixels” fora da diagonal principal da matriz de confusão, calculada para as amostras (resíduos).

TABELA 5.1 (A) – TREINAMENTO DAS RNA EM NÍVEL DE “PIXEL”, NA FASE DE TREINAMENTO, CONSIDERANDO COMO REFERÊNCIA A IMAGEM GERADA DA FOTOINTERPRETAÇÃO

VARIÁVIES	ITERAÇÕES Tempo/minutos	ERRO MÉDIO QUADRÁTICO	TAXA DE “PIXELS” (%) corretamente classificados	RESÍDUOS Matriz de confusão
CP (3), microbacias, MDT e K	118/1	0,00180	99,76	1
Cp (3), microbacias, MDT e banda 7	330/1,6	0,00188	99,52	2
Cp (3), microbacias e MDT	203/1,5	0,00190	99,52	2
Cp (3) e microbacias	278/1,6	0,00190	99,52	2
Cp (3), microbacias, MDT e Th	141/1,0	0,00192	99,52	2
Cp (3), microbacias, MDT e U	156/1,2	0,00192	99,52	2
Cp (3) e MDT	209/1,5	0,00193	99,52	2
Cp (3), microbacias, MDT e U	156/1,2	0,00192	99,52	2
Tcap (B, G, T), microbacias, MDT	187/1,4	0,00197	99,52	2

Pode-se verificar, por meio da Tabela 5.1 (A), que se tendo como entrada as variáveis em nível de “pixel”, o número de iterações variaram entre 330 e 118 e o erro médio quadrático de 0,00197 a 0,00180.

Considerando-se o nível de segmento, Tabela 5.1 (B), constata-se que a convergência foi verificada em um número menor de iterações. Neste caso, o número de iterações varia entre 171 a 312 e o erro médio quadrático mínimo entre 0,00085 a 0,0016. A taxa de “pixels”, na fase de treinamento, corretamente classificada é similar ao resultado quando o treinamento foi efetuado tendo-se como elemento mínimo “pixels”, Tabela 5.1 (A).


TABELA 5.1 (B) - TREINAMENTO DA RNA EM NÍVEL DE SEGMENTO, NA FASE DE TREINAMENTO, CONSIDERANDO COMO REFERÊNCIA A IMAGEM GERADA DA FOTOINTERPRETAÇÃO

VARIÁVIES	ITERAÇÕES Tempo/minutos	ERRO MÉDIO QUADRÁTICO	TAXA DE "SEGMENTOS" (%) corretamente classificados	RESÍDUOS Matriz de confusão
Cp (3), microbacias, MDT e banda 7	171/1,3	0,00085	99,52	2
Tcap (B, G, T), microbacias, MDT	275/1,5	0,00088	99,52	2
Cp (3), microbacias, MDT e Th	145/1,2	0,00098	99,52	2
Cp (3), microbacias, MDT e U	119/1,2	0,00099	99,52	2
Cp (3), microbacias, MDT e K	119/1,3	0,00099	99,52	2
Cp (3), microbacias, MDT e banda 4	159/1,2	0,00099	99,52	2
Cp (3), microbacias, MDT e NDVI	148/1,2	0,001	99,52	2
Cp (3) e microbacias	312/1,5	0,00118	99,52	2
Cp (3), microbacias e MDT	176/1,5	0,00119	99,52	2
Cp (3) e MDT	170/1,3	0,0016	99,52	2

Para melhor comparação entre as Tabelas 5.1 (A e B) pode-se verificar o Gráfico 5.1. Nesse gráfico, tem-se no eixo Z o erro médio quadrático mínimo, no eixo Y os 9 testes em nível de abstração do "pixel" e os 10 testes em nível de abstração dos segmentos e no eixo X a primeira série de experimentos (A: "pixel" / B: segmentos). Todos os experimentos em nível de abstração dos segmentos obtiveram menor erro quadrático mínimo que os testes em nível de abstração do "pixel", praticamente o erro quadrático mínimo foi diminuído pela metade. No entanto, o erro quadrático mínimo deve ser analisado com cautela, pois é o resultado da diferença entre a classe correta e a classe atribuída a cada "pixel" (segmentos),

onde as classes são representadas por números. Estes valores, no entanto, não obedecem a uma ordem lógica, motivo pelo qual a alteração da ordem das classes, no momento da numeração, pode resultar em valores diferentes. Nos experimentos realizados, a ordem das classes foi mantida constante.

GRÁFICO 5.1 – COMPARAÇÃO ENTRE O ERRO MÉDIO QUADRÁTICO MÍNIMO REFERENTE ÀS TABELAS 5.1 (A E B).



A Tabela 5.1 (C) mostra o resultados dos testes realizados em nível de abstração de segmento e sendo a verdade de campo o mapa geológico, portanto, a segunda série de experimentos. Ainda em relação à tabela 5.1 (C) a variação do erro médio quadrático mínimo é de 0,000097 a 0,000065 e 351 a 84 iterações. Verifica-se também que os resíduos da matriz de confusão foram nulos, com exceção em um dos experimentos, portanto a taxa de segmentos corretamente classificados foi de 100%, como mostra a Tabela 5.1 (C) na quarta coluna.

TABELA 5.1 (C) - TREINAMENTO DA RNA EM NÍVEL DE SEGMENTO, CONSIDERANDO COMO REFERÊNCIA O MAPA GEOLÓGICO.

VARIÁVIES	ITERAÇÕES Tempo minutos	ERRO MÉDIO QUADRÁTICO	TAXA DE SEGMENTOS (%) corretamente classificados	RESÍDUOS Matriz De confusão
MDT, microbacias, banda 4, gradiente, IHS (gradiente- MDT) CP (3ª) e Th, U e K	84/1,0	0,000065	100	0
MDT, microbacias, banda 4, gradiente da encosta e Th, U e K	91/1,0	0,000066	100	0
MDT, microbacias, banda 4, gradiente da encosta, Th e K	130/1,1	0,000067	100	0
CP (3), MDT, microbacias, banda 4 e K	132/1,1	0,000069	100	0
Banda 7, MDT, gradiente da encosta e Th	351/1,5	0,000069	99,75	1
CP (3), MDT, K e Th	147/1,2	0,000073	100	0
Banda 4, MDT, gradiente da encosta e Th	184/1,3	0,000074	100	0
MDT, microbacias, banda 4, gradiente e Th	110/1,0	0,000074	100	0
MDT, microbacias, banda 4, IHS (MDT- gradiente) e Th	112/1,0	0,000076	100	0
CP (3), MDT, microbacias, banda 4 e Th	172/1,3	0,000097	100	0

Apesar dos resíduos da matriz de confusão terem valor zero, ou seja, todas as amostras foram classificadas (treinadas) corretamente, nota-se que o erro quadrático mínimo não atinge zero. Isto pode ser explicado devido a saída da rede não ser binária como é o grau de pertinência dos elementos nas classes.

Porém, somente com o resultado do treinamento da rede, não se pôde avaliar a melhor classificação e nem a variável de maior influência na modelagem da rede neural, portanto na seção 5.2, na Tabela 5.2 (A e B), são apresentados os resultados dos coeficientes de correlação ("Cramer's V).

5.2 VERIFICAÇÃO E CLASSIFICAÇÃO

Nesta seção mostram-se os melhores experimentos, selecionados da Tabela 4.2 (A, B e C), seção 4.2.1, em função do resultado da tabulação cruzada, isto é, do coeficiente de correlação "Cramer's V".

5.2.1 Fotointerpretação

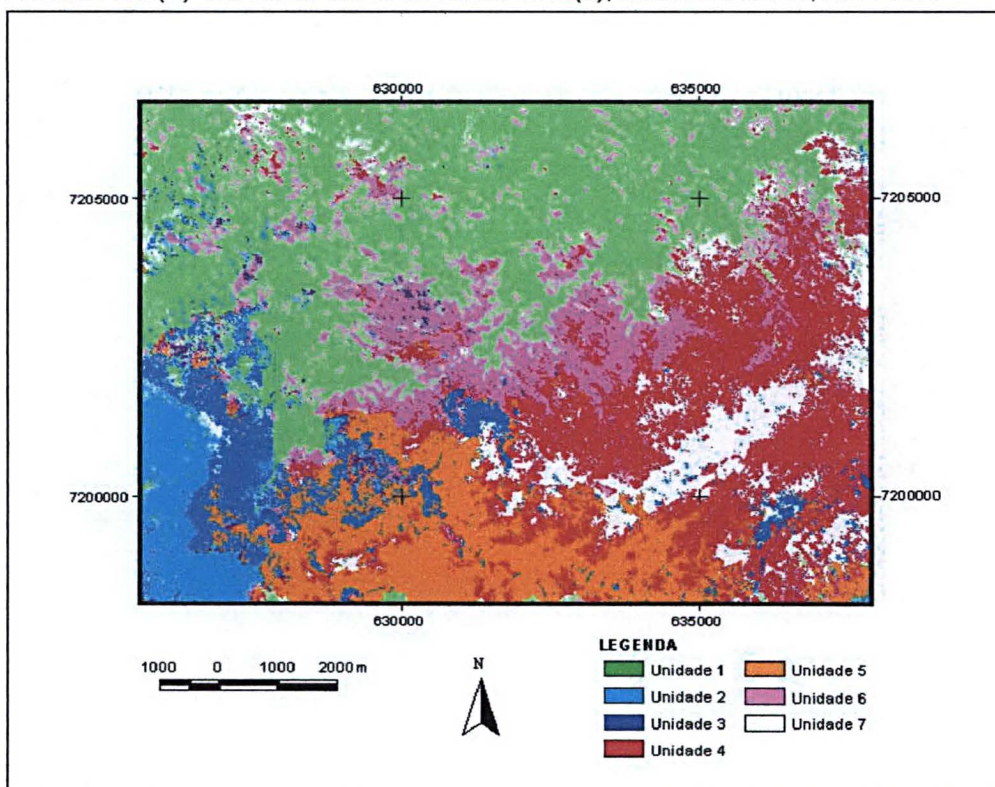
Para a primeira série de experimentos é usada como realidade a imagem originária da fotointerpretação. Na Tabela 5.2 pode-se verificar que os dois melhores testes em nível de abstração de segmentos obtiveram melhor coeficiente de "Cramer's V, se comparados com os dois testes em nível de abstração de "pixel".

TABELA 5.2 - OS MELHORES RESULTADOS ANALISANDO-SE O ÍNDICE DE CRAMER'S V PARA A PRIMEIRA SÉRIE DE EXPERIMENTOS

Nível de Abstração Fotointerpretação	Variáveis	Coeficiente de correlação
"Pixel"	Cp (1, 2 e 3), microbacias e MDT	0,4192
	Cp (1, 2 e 3), microbacias, MDT e K	0,4347
Segmento	Cp (1, 2 e 3), microbacias, MDT e banda 7	0,4669
	Cp (1, 2 e 3), microbacias e MDT	0,4767

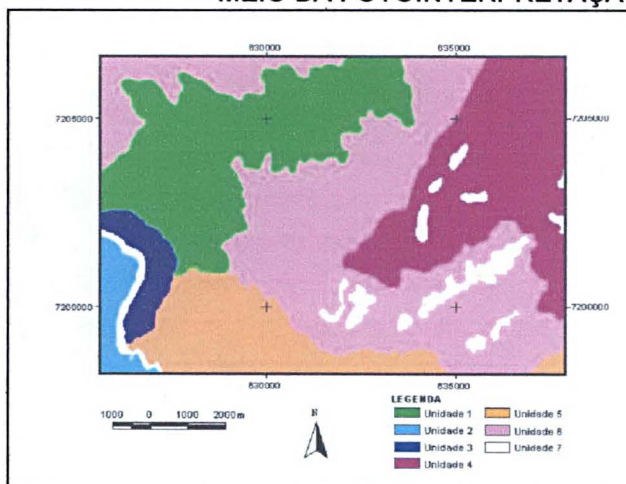
O melhor resultado em nível de "pixel", Tabela 5.2, foi obtido usando como dados de entrada as três componentes principais, o MDT, as microbacias e o elemento K. A Figura 5.1 (A) mostra o resultado dessa classificação. Nota-se que nessa figura, a distribuição das classes está fragmentada, o que pode ser atribuído à adoção do "pixel", como unidade de análise.

FIGURA 5.1 (A)- IMAGEM CLASSIFICADA CP (3), MICROBACIAS, MDT E K



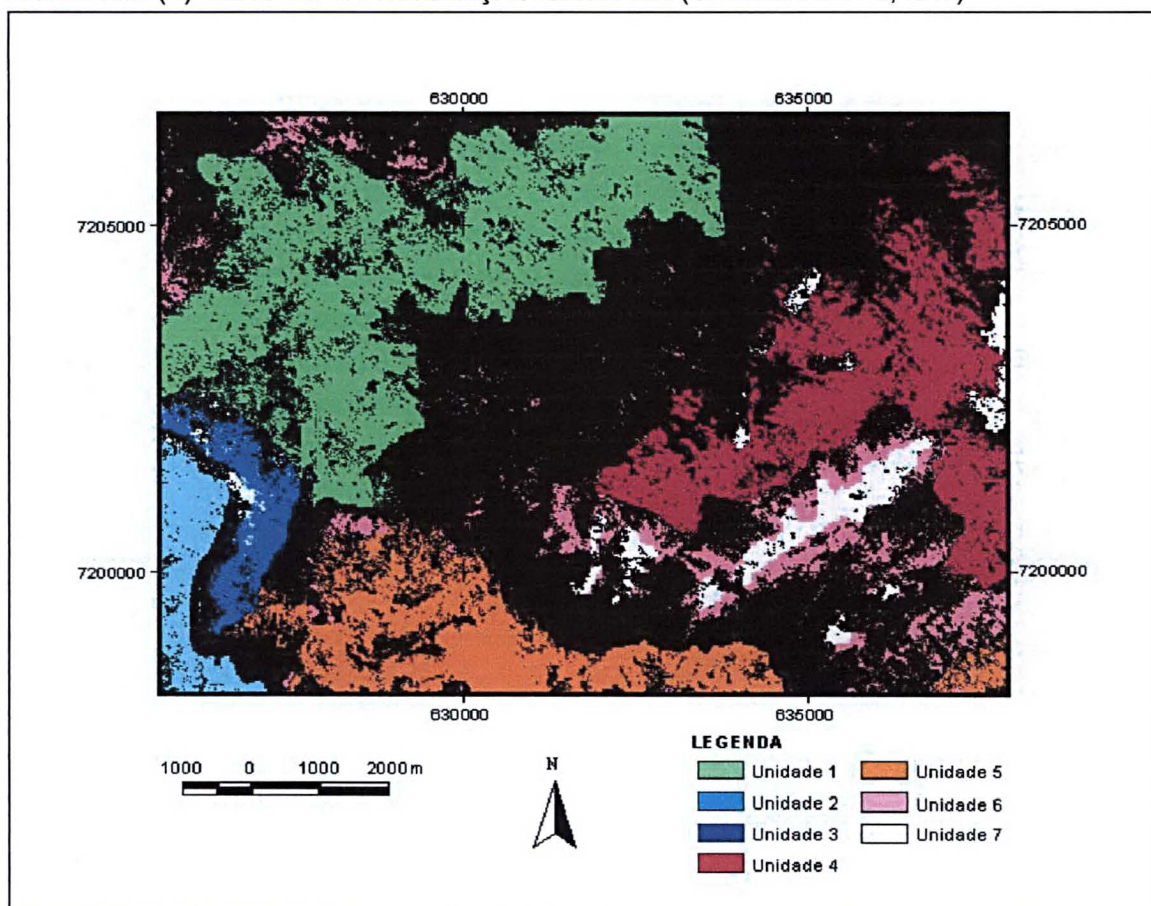
A Figura 3.3 (A) mostrando as sete unidades separadas por meio da fotointerpretação, já apresentada na seção 3.3.1. Encontra-se aqui nessa seção repetida para que se possa comparar a imagem classificada, apresentada na Figura 5.1 (A), com a verdade de campo, Figura 3.3 (A).

FIGURA 3.3 (A)- REPRESENTAÇÃO DAS SETE UNIDADES FISIONÔMICAS SEPARADAS POR MEIO DA FOTOINTERPRETAÇÃO



A Figura 5.1 (B) exibe a imagem proveniente da tabulação cruzada, ou seja, a correlação entre as imagens da Figura 5.1 (A) x Figura 3.3 (A), mapa referência - fotointerpretação. As áreas em preto são as correspondentes aos erros, isto é, sem correlação da imagem classificada e da realidade.

FIGURA 5.1 (B)- IMAGEM DA TABULAÇÃO CRUZADA (CRAMER'S V=0,4347)



A Tabela 5.3 mostra os resultados em percentual da correlação, tabulação cruzada, entre a realidade, fotointerpretação, Figura 3.3 (A) da seção 3.3.1, e as duas imagens classificadas, para a melhor e para a segunda melhor classificação, tendo como índice de Cramer's V" os valores 0,4347 e 0,4192, respectivamente, da Tabela 5.2.

TABELA 5.3 PERCENTUAIS DE ACERTOS

Unidades	Índices	
	"Cramer's V" 0,4347 Entradas CP(1, 2 e 3), Microbacias, MDT e K Total de "pixels" coincidentes com a verdade de campo (%)	"Cramer's V" 0,4192 Entradas CP(1, 2 e 3), Microbacias, MDT Total de "pixels" coincidentes com a verdade de campo(%)
1	71,8	65,1
2	76,3	76,8
3	56,4	44,8
4	43,9	41,9
5	56,0	53,3
6	18,4	23,2
7	95,6	78,4

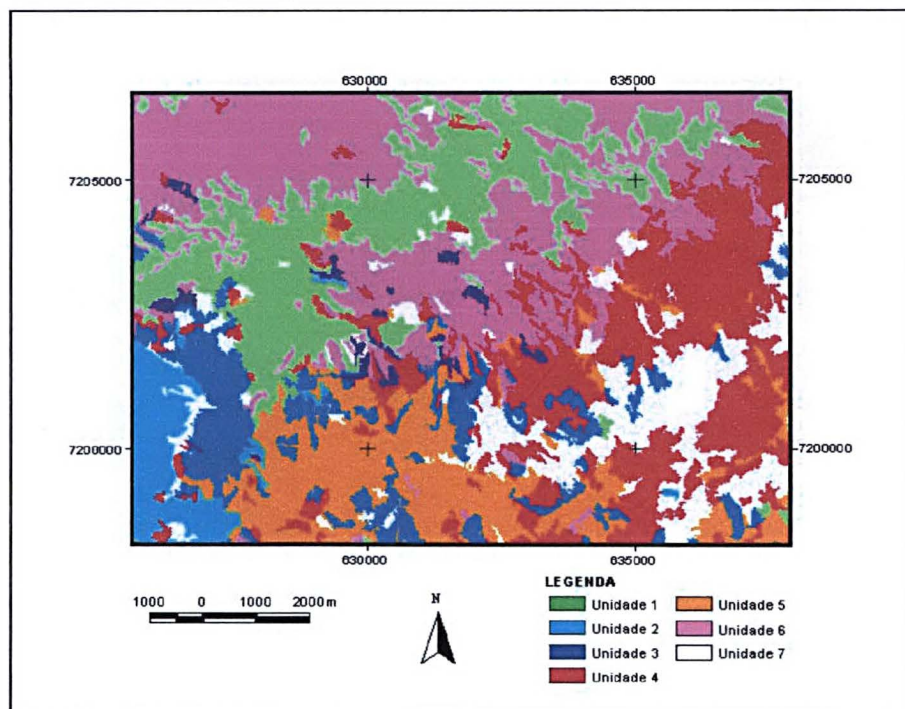
De acordo com a Tabela 5.3 a unidade que obteve o maior índice de acerto em relação à realidade, imagem advinda da fotointerpretação, para a melhor classificação, "Cramer's V" =0,4347, foi a 7, seguida das unidades 2, 1, 3, 5, 4 e 6. Para a segunda melhor classificação, "Cramer's V" = 0,4192, as unidades foram classificadas nesta ordem, decrescente de percentual, de acertos em relação a verdade de campo: unidade 7, 2, 1, 5, 3, 4 e 6.

Comparando-se as duas melhores classificações da Tabela 5.3 pode-se verificar que a associação da variável de entrada K aos demais dados, no processamento, a mesma (K) melhorou o mapeamento das unidades 7 em 17,2%, a 3 em 11,6%, a 1 em 6,9%, a 5 em 2,7% enquanto que as unidades 2 e 4 mantiveram praticamente, o mesmo percentual de acerto. A unidade 6 foi a única que teve o percentual de acerto diminuído em 4,8%. O aumento de acertos de 17,3%, na unidade 7, com a associação da variável K é justificado pelo fato de que nessa unidade o percentual de K é o maior da cena, como descrito na seção 3.3.2.4.1.

Ainda em relação à Tabela 5.2 escolheu-se o melhor experimento em nível de abstração dos segmentos, com "Cramer's V" de 0,4767 e utilizando-se como variáveis de entrada as três componentes principais, o MDT e as microbacias. A

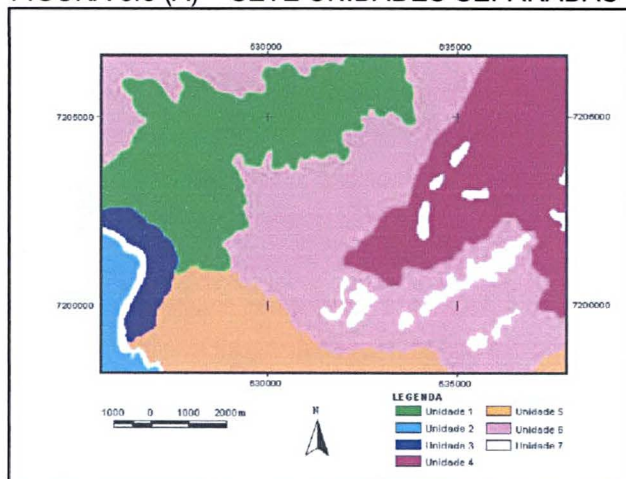
Figura 5.2 (A) mostra o resultado da classificação. Observa-se nessa figura que, as classes foram espacialmente melhor agrupadas devido à segmentação. Em lugar de “pixels” isolados, como ocorre na análise em nível de “pixel”, mostrado na Figura 5.1 (A), são encontradas pequenas regiões isoladas.

FIGURA 5.2 (A) - IMAGEM CLASSIFICADA – TRÊS CP, MICROBACIAS E MDT (CRAMER'S V =0,4767)



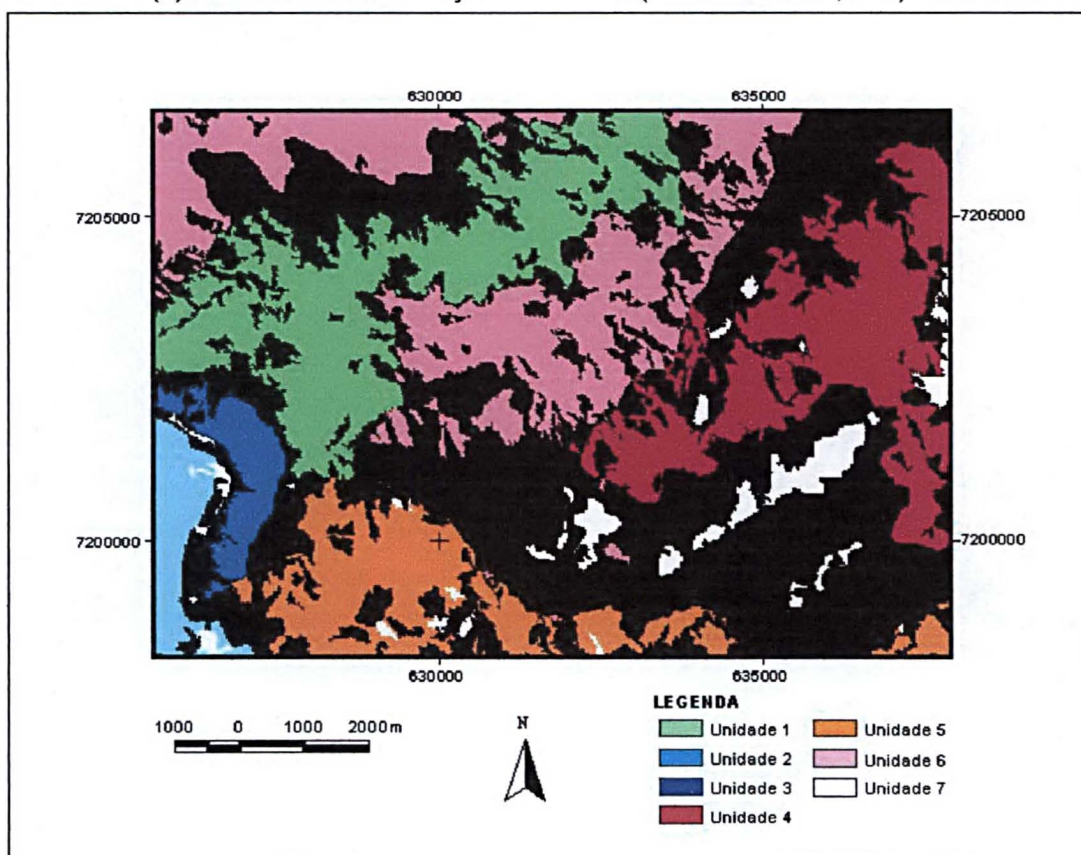
Com o intuito de facilitar a comparação visual da imagem classificada, Figura 5.2 (A), com o mapa referência, gerado por meio da fotointerpretação, apresentado na seção 3.3.1, o mesmo encontra-se abaixo apresentado, Figura 3.3 (A).

FIGURA 3.3 (A) – SETE UNIDADES SEPARADAS POR MEIO DA FOTINTERPRETAÇÃO.



A Figura 5.2 (B) apresenta a imagem resultante da tabulação cruzada do melhor teste, isto é, a correlação existente entre a imagem classificada contendo como dados de entrada as três CP, as microbacias e o MDT, contra a imagem da Figura 3.3 (A) da seção 3.3.1. Como já mencionado, as áreas pretas correspondem à ausência de correlação entre a imagem classificada e a verdade de campo (fotointerpretação). As áreas coloridas representam a concordância entre a classificação e o mapa referência, por classe.

FIGURA 5.2 (B)- IMAGEM DA TABULAÇÃO CRUZADA (CRAMER'S V=0,4767)



Do experimento, em nível de segmento, da Tabela 5.2, o melhor teste foi aquele no qual se obteve, por meio da tabulação cruzada entre a imagem classificada e a verdade de campo definida na seção 3.3.1, Figura 3.3 (A), o índice de "Cramer's V" com valor igual a 0,4767. Nesse teste, as variáveis de entrada foram as três CP, as microbacias e o MDT.

O segundo melhor resultado teve como variáveis de entrada as três CP, as microbacias, o MDT e a banda 7. O resultado da tabulação cruzada, entre a imagem referência, Figura 3.3 (A) da seção 3.3.1, e a imagem classificada, por meio do índice de "Cramer's V" foi de 0,4669. A Tabela 5.4 mostra o resultado, em percentual de acertos de cada uma das unidades desses dois melhores testes, os quais encontram-se detalhados no Apêndice III.

TABELA 5.4 PERCENTUAIS DOS ÍNDICES DE ACERTOS

Unidades	Índices	
	"Cramer's V" 0,4767 Entradas: CP(1, 2, e 3), Microbacias, MDT Total de "pixels" coincidentes com a verdade de campo	"Cramer's V" 0,4669 Entradas: CP(1, 2, e 3), Microbacias, MDT, Banda 7 Total de "pixels" coincidentes com a verdade de campo
1	56,1	59,2
2	80,2	81,1
3	65,2	57,02
4	52,9	49,3
5	55,8	64,2
6	37,2	33,1
7	53,3	54,4

Por meio da Tabela 5.4 pode-se verificar que para os dois casos ("Cramer's V" 0,4767 e 0,4669) a unidade 2 foi a melhor classificada, com 80,2% e 81,1% de acertos, praticamente iguais os percentuais para a primeira e segunda melhores classificações, uma vez que essa unidade aparece discriminada em todas as variáveis de entrada. Comparando-se a primeira melhor classificação com a segunda, para as demais unidades, nota-se que as unidades 3, 4 e 6 tiveram os seus percentuais de acertos aumentados com a exclusão da banda 7; a unidade 3 aumentou em 8,2%, a 4 em 3,6% e a 6 em 4,1%. Para as unidades 1, 5 e 7, o mesmo não ocorreu, haja vista que, tiveram seu percentual de acerto diminuído sem a intervenção da banda 7. Para a unidade 1 a retirada da banda 7 diminuiu os

acertos de 59,2% para 56,1% (3,1%); para as unidades 5 e 7 a diminuição foi de 8,4% e 1,1%, respectivamente.

O fato das unidades de número 7 (Afloramentos) e 5 (Sul) perderem informações com a exclusão da banda 7, é explicado pois estas duas unidades estão bem caracterizadas na banda 7. Essas duas unidades são visíveis na primeira componente, portanto a banda 7 associada à primeira componente pode discriminar melhor as unidades em questão. No Apêndice II encontra-se a variável banda 7 (original e segmentada) e as duas unidades destacadas.

5.2.2 Mapa Geológico

A qualidade das imagens temáticas resultantes da classificação em nível de segmento usando como verdade de campo o mapa geológico, foi também avaliada pelo índice de "Cramer's V". A seguir apenas os dois melhores resultados são apresentados. Na Tabela 5.5 encontram-se os dois melhores testes em nível de abstração do segmento e utilizando-se como referência o mapa geológico.

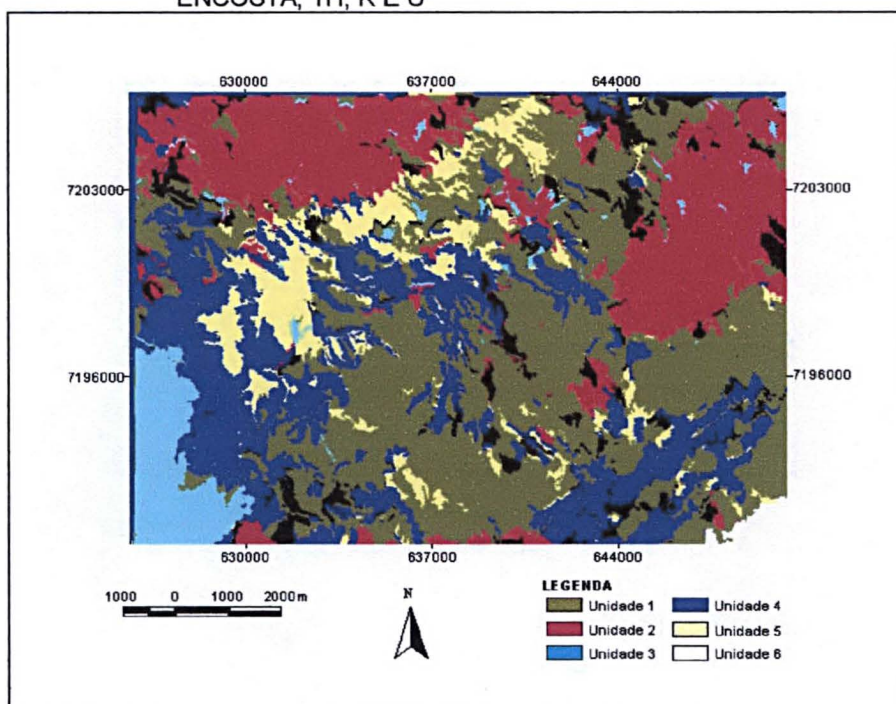
TABELA 5.5 - OS MELHORES RESULTADOS ANALISANDO-SE O ÍNDICE DE CRAMER'S V PARA A SEGUNDA SÉRIE DE EXPERIMENTOS

Nível de Abstração	Variáveis	Coefficiente de correlação
Segmento	MDT, microbacias, banda 4, gradiente da encosta e Th	0,5493
	MDT, microbacias, banda 4, gradiente da encosta, Th, K e U	0,6051

A Tabela 5.5 mostra os valores dos coeficientes de concordância para os dois melhores conjuntos de variáveis. Em ambos os casos, o MDT, as microbacias, a banda 4, o gradiente da encosta e o Th estão presentes. A única diferença é a inclusão das variáveis K e U no conjunto que gerou o melhor resultado.

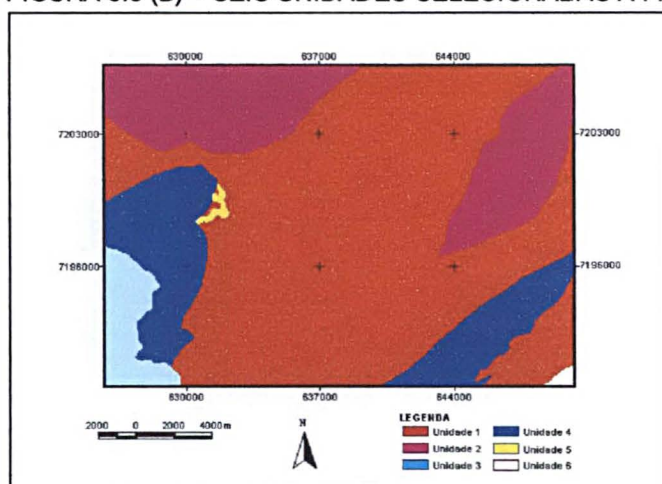
A Figura 5.3 (A) mostra o mapa temático correspondente ao experimento com maior índice de "Cramer's V", ou seja, aquele que inclui as variáveis de entrada K e U.

FIGURA 5.3 (A) - IMAGEM CLASSIFICADA MDT, MICROBACIAS, BANDA 4, GRADIENTE DA ENCOSTA, TH, K E U



Para facilitar a comparação visual da imagem classificada, Figura 5.3 (A), com o mapa referência originário do mapa geológico, apresentado na seção 3.3.1, o mesmo encontra-se abaixo apresentado, Figura 3.3 (B).

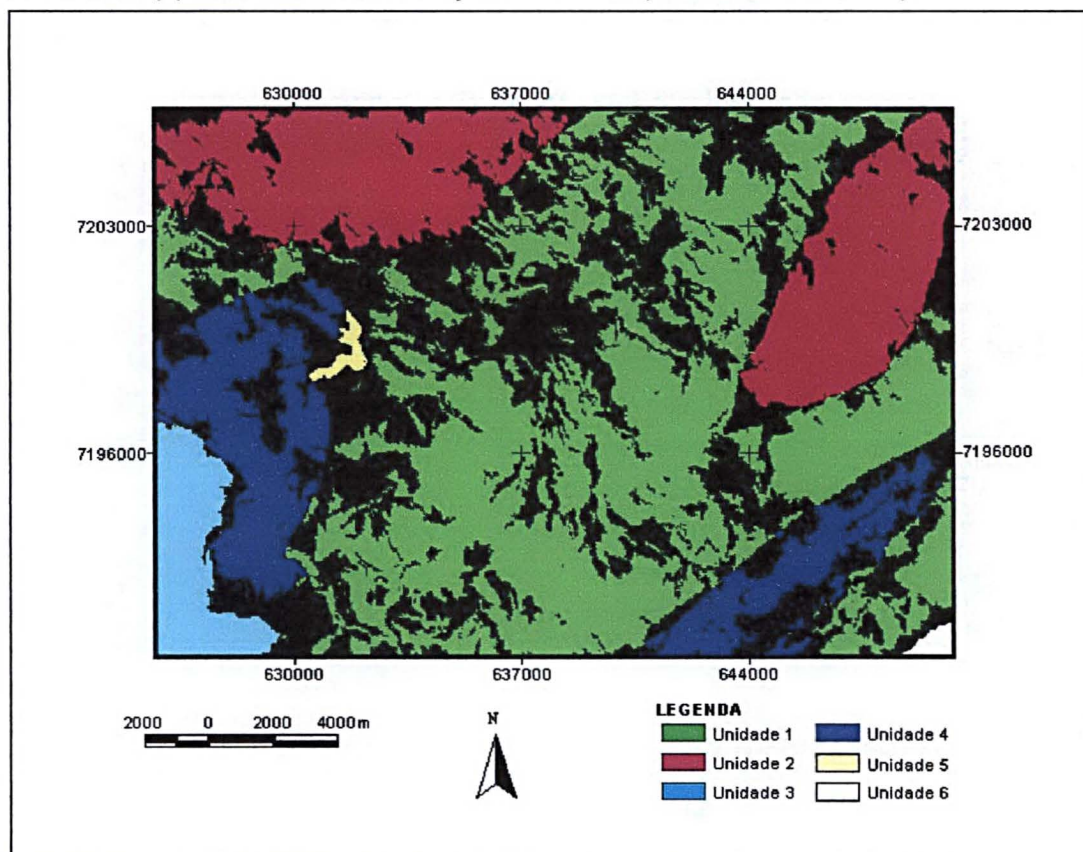
FIGURA 3.3 (B) – SEIS UNIDADES SELECIONADAS A PARTIR DO MAPA GEOLÓGICO.



A Figura 5.3 (B) mostra o resultado na forma de imagem da correlação entre o mapa geológico, Figura 3.3 (B), e a imagem melhor classificada deste teste, a Figura

5.3 (A). As áreas coloridas das unidades 3, 5 e 6, encontram-se bem definidas e uniformes, mostram as áreas de concordância. Nas unidades 1, 2 e 4 aparece a cor preta, mostrando os locais sem correlação entre as imagens cruzadas.

FIGURA 5.3 (B)- IMAGEM DA TABULAÇÃO CRUZADA (CRAMER'S V=0,6051)



Com a finalidade de avaliar o desempenho da classificação por classe, o percentual por unidade foi calculado. Os valores associados às duas melhores classificações estão mostrados na Tabela 5.6, isto é, da primeira e segunda melhores classificações, avaliadas por meio da correlação, e tendo-se como nível de abstração o segmento e referência o mapa geológico. Nesses testes o coeficiente de correlação "Cramer's V", para a tabulação cruzada, do melhor teste foi de 0,6051 e para o segundo melhor teste foi de 0,5493.

TABELA 5.6 PERCENTUAIS DE ACERTOS

Unidades	Índices	
	Cramer's V" 0,6051 Entradas: MDT, Microbacias, Banda 4 Gradiente da Encosta, Th, K e U Total de segmentos coincidentes com a verdade de campo	Cramer's V" 0,5493 Entradas: MDT, Microbacias, Banda 4 Gradiente da Encosta e Th Total de segmentos coincidentes com a verdade de campo
1	55,7	53,3
2	77,4	79,3
3	83,7	73,8
4	58,4	59,0
5	97,0	96,6
6	99,8	98,7

Segundo a Tabela 5.6 pode-se comparar as duas melhores classificações, a primeira melhor classificação tendo como variáveis de entrada MDT, microbacias, banda 4, gradiente da encosta, Th, K e U e a segunda o MDT, microbacias, banda 4, gradiente da encosta, Th.

A unidade com maior índice de acertos foi a 6, seguida das unidades 5, 3, 2, 4 e 1, isto para a primeira melhor classificação. Para a segunda melhor classificação a unidade 6 foi a melhor classificada, seguidas das unidades 5, 2, 3, 4 e 1.

Para o maior índice de Cramer's V (0,6051) as unidades 1, 3, 5 e 6 aumentaram os percentuais de acertos com o acréscimo das variáveis de entrada U e K, 2,4%, 9,9%, 0,4% e 1,1%, respectivamente. O aumento de 9,9% de acerto na unidade 3 é justificado devido ao aumento de informações que as variáveis K e U fornecem no processamento, em especial a variável K, que apesar do baixo percentual de K (1,3 a 1,9%) a unidade está bem definida, na seção 3.3.2.4.1, na Figura 3.14 tem-se a variação do elemento K.

As unidades 2 e 4 perderam percentuais de acertos com entrada das variáveis K e U em 1,9% e 0,6% respectivamente. Pode –se explicar a perda de informação para a unidade 2 em 1,9%, com o acréscimo das variáveis U e K, pois a

associação destas vem confundir a discriminação da unidade 2, haja vista que, a variável Th possui alto percentual nessa unidade de número 2, em relação a U e K.

5.3 SIMULAÇÕES ALTERANDO-SE UMA DAS VARIÁVEIS DE ENTRADA PARA A MESMA MODELAGEM DA REDE

Nesta seção são apresentadas as simulações nas quais uma das variáveis de entrada é substituída por uma imagem com níveis digitais constante, como descrito na seção 3.3.5.2. Apresenta-se somente as simulações dos três melhores resultados apresentados na seção 5.2.

5.3.1 Simulação - Fotointerpretação

Nas seções 5.3.1.1 e 5.3.1.2 encontram-se as simulações em nível de "pixel" e em nível de segmentos, respectivamente, tendo como verdade de campo a fotointerpretação.

5.3.1.1 Simulação em Nível de Abstração do "Pixel"

A Tabela 5.7 compara os resultados das generalizações. Na primeira coluna estão as unidades, na segunda os percentuais de acerto para cada unidade em relação à verdade de campo (fotointerpretação) com todas as variáveis de entrada e nas colunas seguintes os percentuais de acerto com a retirada de uma das variáveis.

TABELA 5.7 PERCENTUAIS DOS ÍNDICES DE ACERTOS COM TODAS AS VARIÁVEIS DE ENTRADA E COM SUBSTITUIÇÃO DAS MESMAS. TOTAL DE "PIXELS" COINCIDENTES COM A VERDADE DE CAMPO

Unidades	Índice de Cramer's V						
	Entradas CP(3), Microbacias, MDT e K	Sem K	Sem Micro Bacia	Sem MDT	Sem CP3	Sem CP2	Sem CP1
Global	0,4347	0,2538	0,2576	0,2648	0,2773	0,3548	0,3890
1	71,8	50,4	85,4	86,2	64,1	70,0	73,7
2	76,3	80,4	11,3	1,3	78,8	65,0	69,4
3	56,4	52,1	4,3	31,2	54,3	70,3	56,9
4	43,9	0,6	17,6	0,1	8,6	28,8	12,9
5	56,0	19,0	4,3	9,1	5,8	45,3	48,7
6	18,4	7,1	11,2	10,4	6,8	7,3	10,6
7	95,6	6,3	28,4	1,2	7,5	28,3	57,3

As Figuras 5.4 (A, B, C, D, E e F) exibem as generalizações das variáveis de entrada com a alteração de uma das entradas. Para todas as 6 generalizações a seguir, a variável de entrada, alterada, nova imagem artificial, recebeu valor de nível de cinza constante igual a zero.

Para a Figura 5.4 (A) a variável proveniente do levantamento aerogamaespectrométrico, K, foi alterada. Pode-se verificar a importância das informações gamaespectrométricas do elemento Potássio (K) a partir das unidades 4, 5, 6 e 7, que tiveram os percentuais de acerto, segundo a Tabela 5.7, diminuídos de 43,9% para 0,6%, de 56,0% para 19,0%, de 18,4 para 7,1, e de 95,6% para 6,3%, respectivamente, isto é, praticamente desapareceram sem a contribuição da mesma.

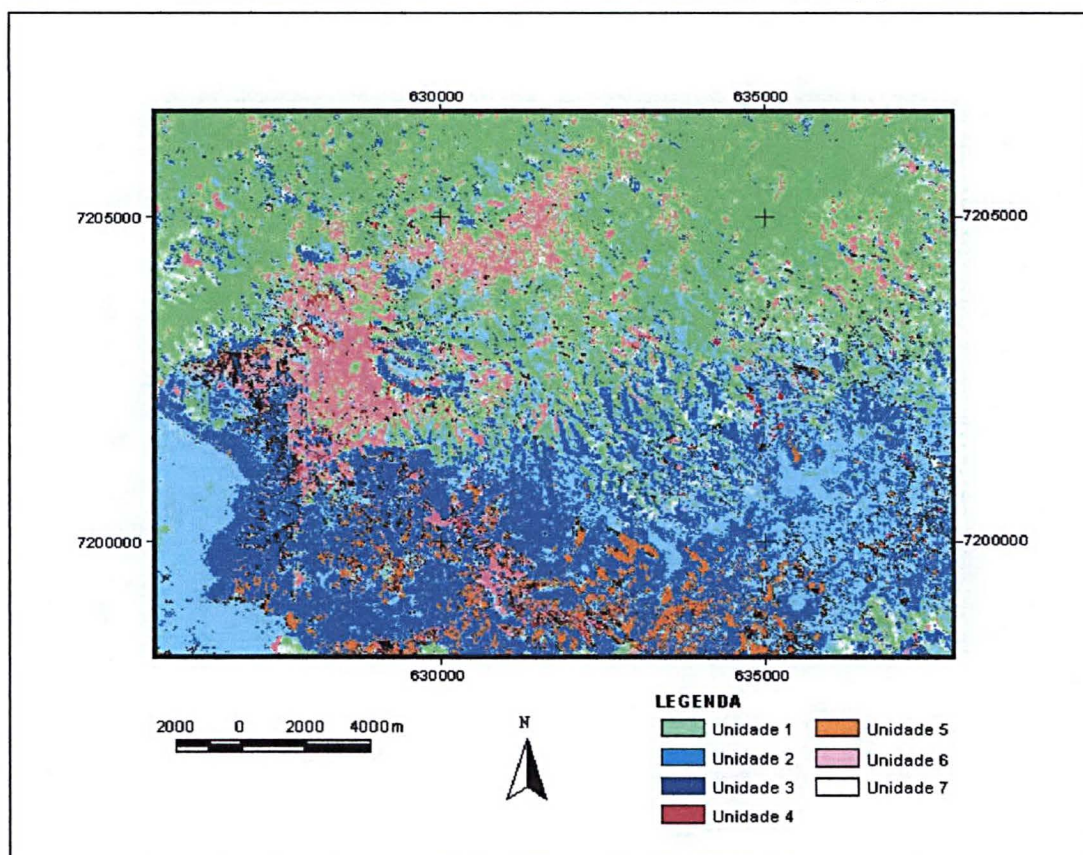
As unidades 3 e 1 obtiveram percentuais de acertos de 52,1% e 50,4%, diminuídos em 4,3% e 21,4%, respectivamente. Pode-se ainda salientar que, a unidade 3 foi classificada erroneamente na área da unidade 5 e a unidade 1 teve sua área extrapolada para a porção norte e nordeste.

A unidade 2 manteve-se alocada corretamente e o percentual de acerto foi aumentado de 76,3% para 80,4%, e ainda pode-se justificar que as variáveis MDT, microbacias e as três componentes fornecem as informações necessárias para que essa, unidade 2, seja reconhecida. Em relação à mesma unidade ainda, pode-se

destacar que a concentração do K, na região dessa unidade, é de 1,3% a 1,7%, o valor mais baixo da cena, seção 3.3.2.4.1, Figura 3.13.

Nas regiões referentes as unidades 4, 5, 6 e 7, que não foram separadas na ausência de informações a respeito do elemento K, o teor em percentual desse elemento varia em torno de 2,3 a 2,9%, isto é, os maiores teores da área, justificando o ocorrido com as unidades, ou seja não foram identificadas.

FIGURA 5.4 (A) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DAS INFORMAÇÕES GAMAESPECTROMÉTRICAS DO ELEMENTO POTÁSSIO (K)



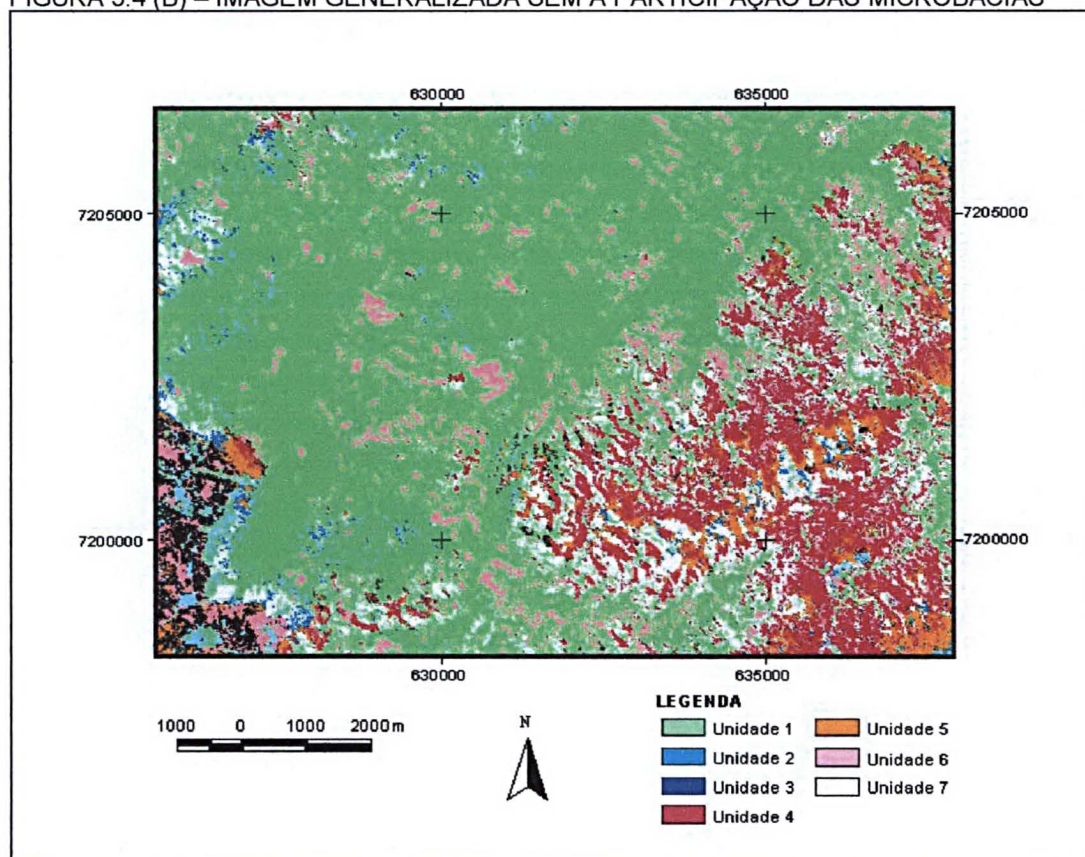
A Figura 5.4 (B) exibe a generalização das variáveis de entrada com a alteração da variável microbacia. Pode-se analisar, por meio da Tabela 5.7 que, sem essa variável as unidades 2, 3, 4, 5, 6 e 7 perderam informação pois todas tiveram seus percentuais de acerto diminuídos, sendo que as unidades 2 e 7 perderam mais percentuais, 65,0% e 67,2%, respectivamente.

A unidade 4 aparece na posição correta em relação à generalização com todas as variáveis de entrada, mas tendo a sua área aumentada na porção sudeste.

A ausência das informações a respeito das microbacias diminuiu a separabilidade ao sul da unidade 5 em 51,7% sendo que, esse local da área de estudo foi generalizado como unidade 1. Na seção 3.3.2.2 foi citado que nesta porção sul, da cena, as microbacias possuem maior valor numérico em termos de acúmulo de água, essa porção está destacada por meio de uma linha amarela na Figura 3.7 da seção mencionada; verificando portanto que esta informação é relevante para a separação da unidade 5.

Nota-se ainda que na falta de informações das microbacias a unidade 1 apresenta influência do MDT quanto a sua forma.

FIGURA 5.4 (B) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DAS MICROBACIAS



Na Figura 5.4 (C) a variável MDT foi substituída para a verificação de sua importância quando da generalização. Pode-se analisar que o MDT é uma importante variável, pois a imagem generalizada sem sua participação perdeu informações a respeito de seis unidades. As unidades 2, 3, 4, 5, 6, e 7 obtiveram os

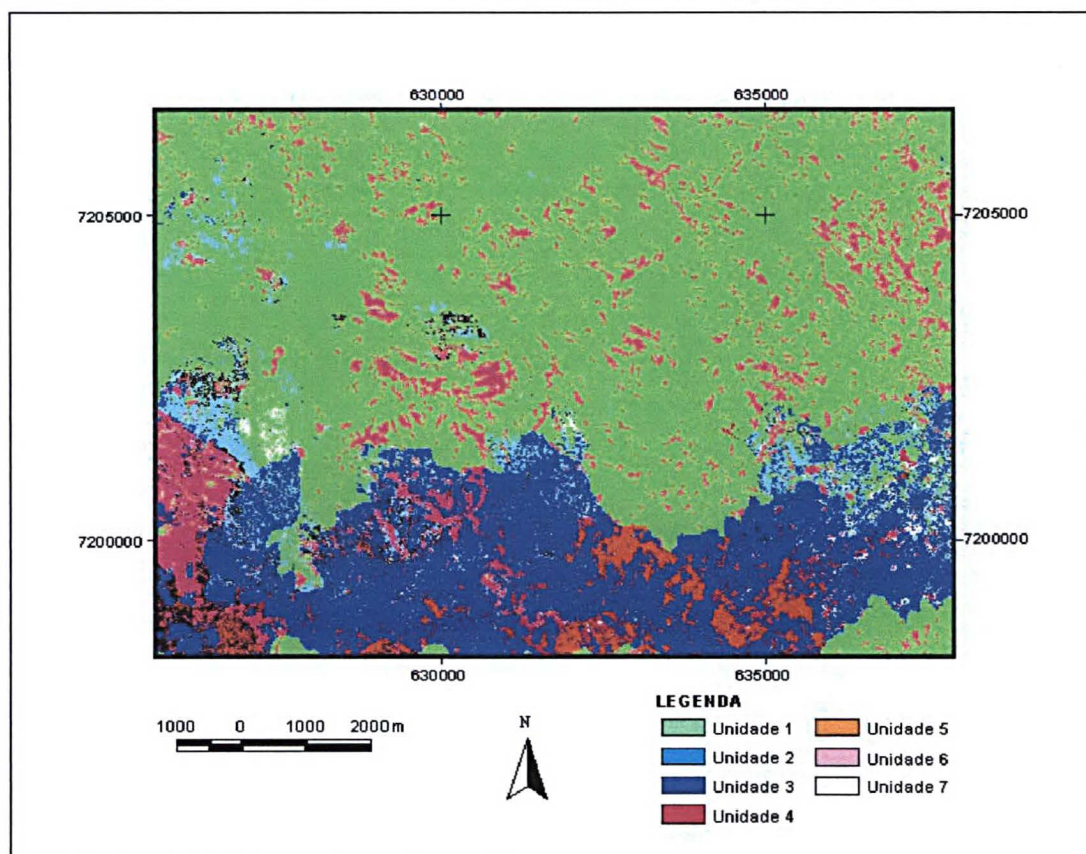
respectivos percentual de acertos de 1,3%, 31,2%, 0,1%, 9,1%, 10,4% e 1,2%. As duas maiores diferenças de percentuais para este processamento estão nas unidades 2 e 7, com 75% e 94,4% de decréscimo no percentual quando a variável MDT foi alterada. A unidade de número 1 foi a única, neste processamento, que obteve ganho de percentual de 71,8% para 86,2%, isto é, um acréscimo de 14,4%.

O fato ocorreu, pois o MDT discrimina as unidades, ou seja, a área de estudo possui um relevo com três regiões distintas, isto é, na região sudeste o pediplano dissecado, na região central e noroeste esse é acidentado e na porção sudoeste o relevo é colinoso e com vertentes convexas e nas porções, na seção 3.3.2.1.1 encontra-se a descrição das unidades salientadas na imagem do MDT e na seção 3.1.2 as características do relevo local.

A unidade 1 (Vale) aparece alocada com uma área de abrangência maior que a da classificação com todas as entradas. Analisando-se o MDT, visualmente, nota-se que este delimita a região de vale, menores altitudes, portanto sem esta informação a unidade 1 (Vale) perde seus limites.

Pode-se notar que na ausência das informações referentes ao MDT a região sul aparece, visualmente, classificada erroneamente como unidade 3 e com influência das microbacias, onde essas possuem a maior concentração de água.

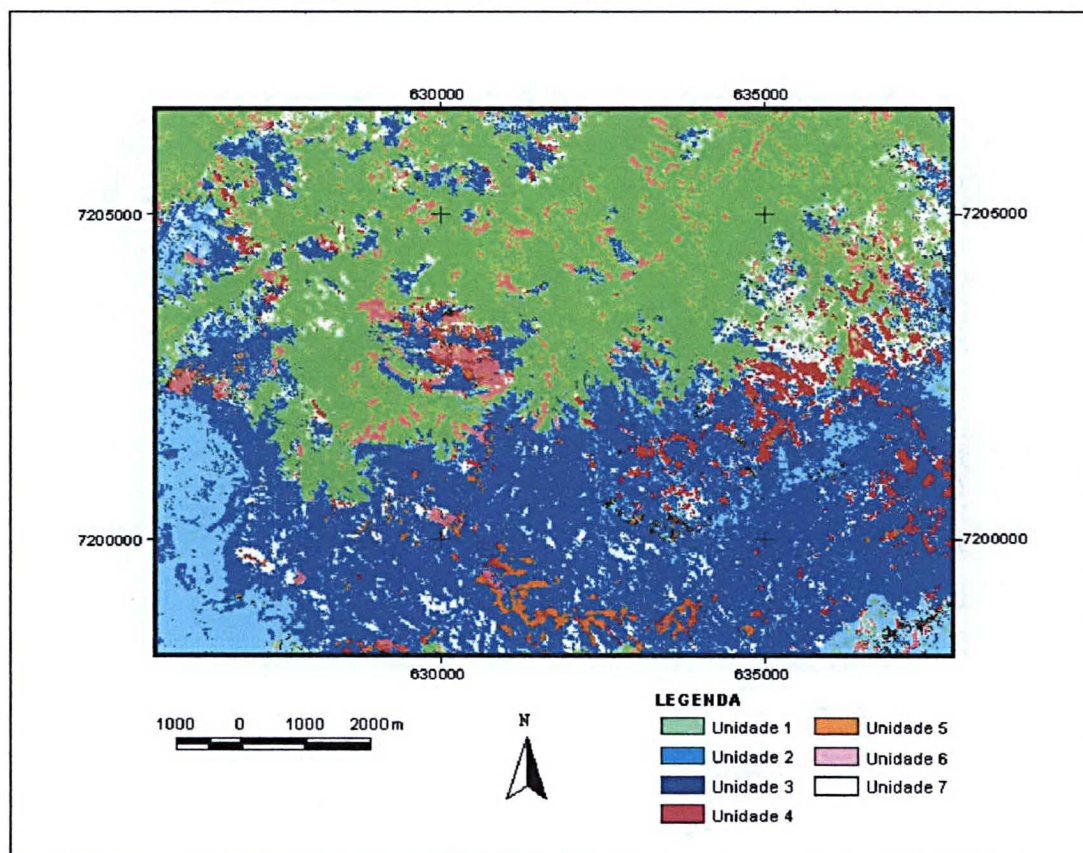
FIGURA 5.4 (C) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DO MDT



A generalização de mais uma variável de entrada é apresentada na Figura 5.4 (D), com a alteração da terceira componente. Somente a unidade 2 teve o percentual aumentado de 76,3% para 78,8%, devido as variáveis MDT, microbacias e a primeira e segunda componentes fornecerem informações para a separação dela.

Os maiores decréscimos nos percentuais foram para as unidades 7, 5 e 4, isto é, 88,1% 50,2 e 35,3% respectivamente, justamente nas regiões sul e leste onde essas porções encontram-se em evidência para a componente retirada, como citado na seção 3.3.2.3.2.

FIGURA 5.4 (D) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA TERCEIRA COMPONENTE DA TRANSFORMAÇÃO CP.

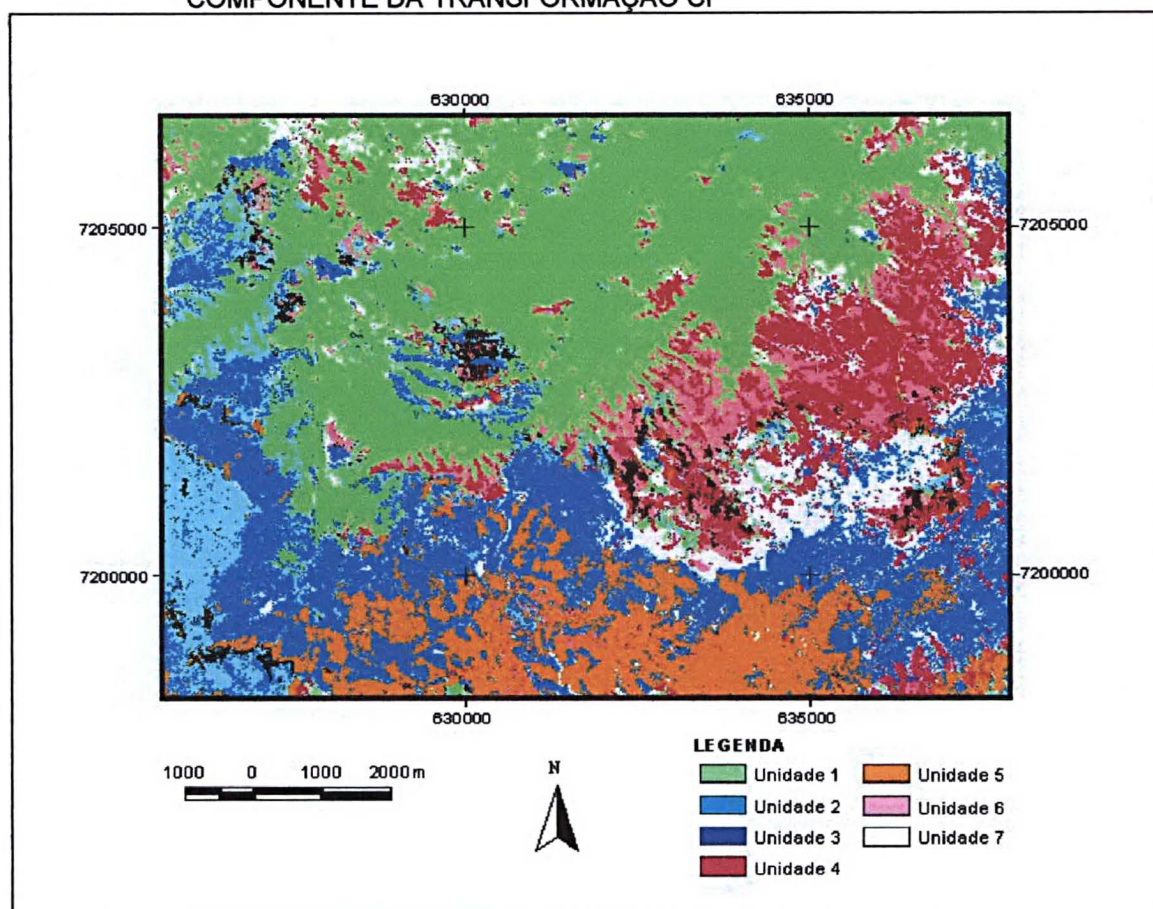


A Figura 5.4 (E) exibe a generalização após a remoção das informações a respeito da segunda componente. A unidade 3, nesse processamento, teve o percentual aumentado em 13,9%.

As unidades 1, 2, 4, 5, 6 e 7 tiveram os percentuais diminuídos em 1,8%, 11,3%, 15,1%, 10,7%, 11,1% e 67,3%.

A unidade que obteve o percentual com maior decréscimo, se comparado com a generalização com todas as variáveis de entrada, foi a unidade 7, isto pode ser justificado pelo fato da segunda componente salienta a região sudeste da cena, como descrito na seção 3.3.2.3.2 e (Figura 3.10).

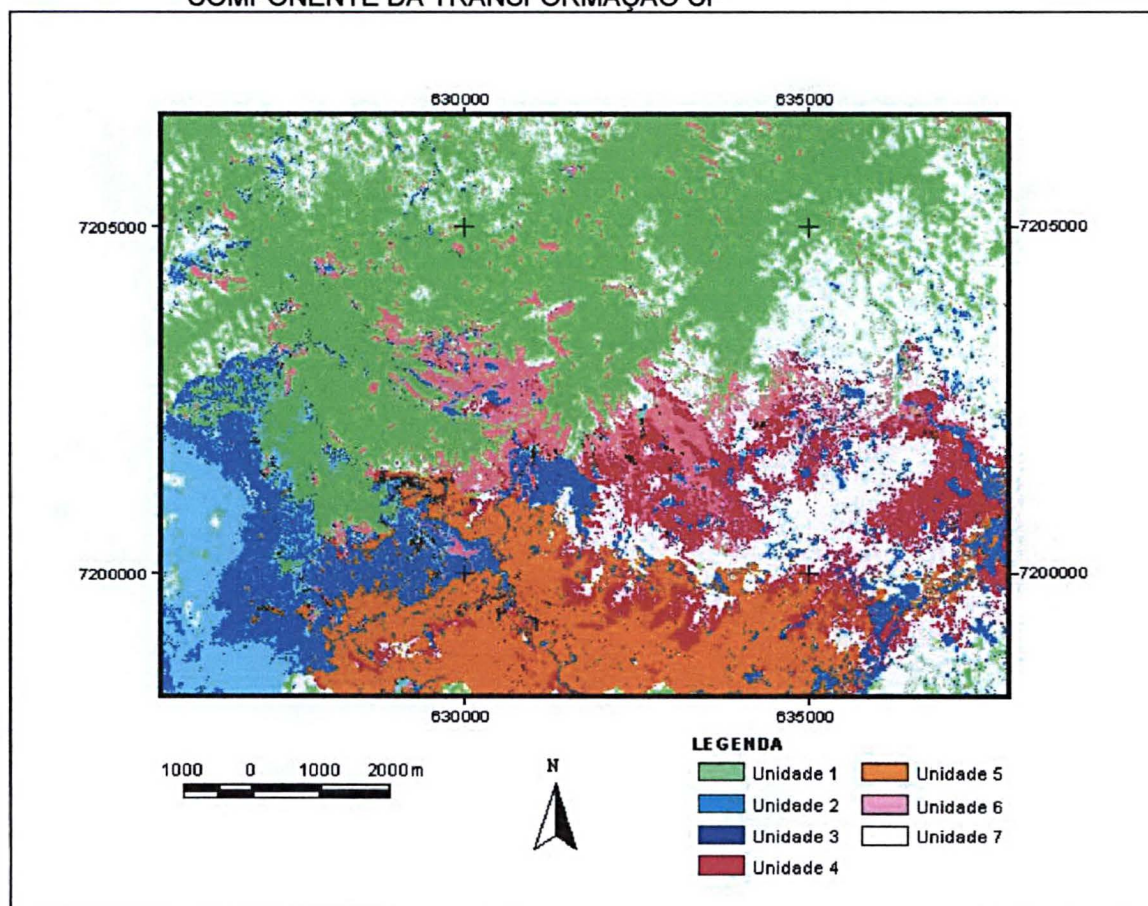
FIGURA 5.4 (E) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA SEGUNDA COMPONENTE DA TRANSFORMAÇÃO CP



A Figura 5.4 (F) exibe a generalização sem a primeira componente da transformação CP que foi substituída por uma banda artificial de níveis digitais constante (zero). Pode-se verificar que as unidades 1, 2, 3 e 5 aparecem melhor delineadas nesse processamento, comparando-se com as mesmas unidades das Figuras 5.4 (A, B e C) e por meio da Tabela 5.7, na qual se verifica que os percentuais de acerto dessas unidades, apesar de serem menores que no processamento com todas as variáveis, são maiores que nas generalizações sem as variáveis K, MDT e microbacias, demonstrando a menor importância da primeira componente, da transformada em CP, para essa modelagem.

A unidade 7 (Afloramento) e a 4 (leste) foram aquelas que obtiveram maior decréscimo nos percentuais de acertos, isto é, para a unidade 4 o decréscimo foi de 31,0% e para a unidade 7 foi de 38,3%. Como nessa componente a região leste (unidade 4) encontra-se bem marcada, tonalidade mais clara da cena, para essa modelagem ela praticamente desapareceu, na Figura 3.

FIGURA 5.4 (F) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA PRIMEIRA COMPONENTE DA TRANSFORMAÇÃO CP



Para os testes realizados com as três componentes principais, o MDT, as microbacias e o Potássio, a variável mais importante levando-se em consideração a correlação entre a verdade de campo, fotointerpretação, versus as generalizações, conforme a Tabela 5.7, foi o Potássio (“Cramer’s V” =0,2538), seguida das microbacias (“Cramer’s V” =0,2576), do MDT (“Cramer’s V” =0,2648), da terceira (“Cramer’s V” =0,2773), da segunda (“Cramer’s V” =0,3548) e da primeira componentes (“Cramer’s V” =0,3890).

Apesar do índice de “Cramer’s V” possuir o valor numérico maior para a generalização das Figuras 5.4 (A e B), sem a inferência das variáveis K e microbacias, em relação a Figura 5.4 (C), sem a participação do MDT, pode-se averiguar que, somente o percentual de acerto para a unidade 1 da Figura 5.4 (C) aumentou em 14,4% e visualmente nota-se que essa imagem é a que mais se distancia da realidade.

5.3.1.2 Simulação em Nível de Abstração de Segmentos

Na Tabela 5.8 encontra-se o resultado do índice de “Cramer’s V”, para a generalização com todas as variáveis de entrada e também para o processamento com a alternância das variáveis, além dos percentuais de “pixels” corretamente associados a cada uma das classes.

TABELA 5.8. PERCENTUAIS DOS ÍNDICES DE ACERTOS COM TODAS AS VARIÁVEIS DE ENTRADA E COM SUBSTITUIÇÃO DAS MESMAS. TOTAL DE “PIXELS” COINCIDENTES COM A VERDADE DE CAMPO

Unidades	Índice de Cramer's V					
	Entradas: CP(3), Microbacias, MDT	Sem CP2	Sem CP1	Sem CP3	Sem MDT	Sem Micro Bacia
Global	0,4767	0,1932	0,2325	0,2444	0,2903	0,2979
1	56,1	33,8	41,1	70,6	71,9	0,93
2	80,2	5,8	0	0	0	72,4
3	65,2	19,9	7,8	2,2	20,7	43,9
4	52,9	20,6	54,7	10,8	32,4	35,7
5	55,8	19,4	30,9	29,8	24,9	41,4
6	37,2	18,7	4,0	13,3	17,5	1,6
7	53,3	20,5	27,5	12,3	13,6	39,8

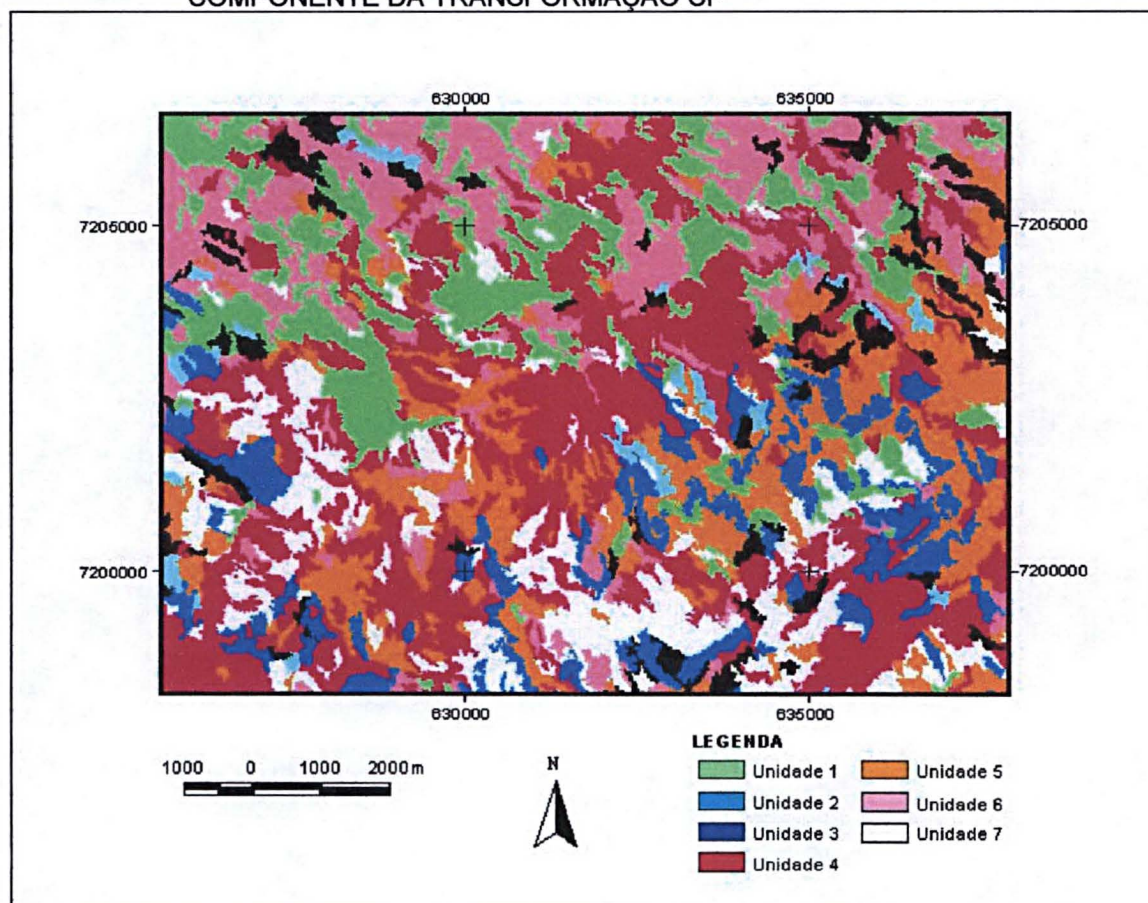
As Figuras 5.5 (A, B, C, D e E) exibem as generalizações das variáveis de entrada com a omissão de informações de uma das variáveis. Para todas as 5 generalizações a seguir, a variável de entrada alterada recebeu valor de nível de cinza constante igual a zero.

A Figura 5.5 (A) exhibe a generalização onde a segunda componente da transformação CP foi substituída pela imagem artificial com valores numéricos constantes. Com a ausência dessa componente, todas as unidades foram espacialmente e numericamente alteradas.

A unidade que sofreu maior decréscimo foi a 2, com uma diminuição de percentual de acertos de 74,4%, seguida das unidades 3, com 45,3%, da 5 com

36,4%, da 7 com 32,8%, da 4 com 27,6%, da 1 com 22,3% e finalmente da unidade 6 com 18,8%. Nota-se visualmente que a imagem generalizada, Figura 5.5 (A), sem a inferência da segunda componente, não representa espacialmente nenhuma unidade se comparada com a verdade de campo, Figura 3.3 (A) da seção 3.3.

FIGURA 5.5 (A) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA SEGUNDA COMPONENTE DA TRANSFORMAÇÃO CP



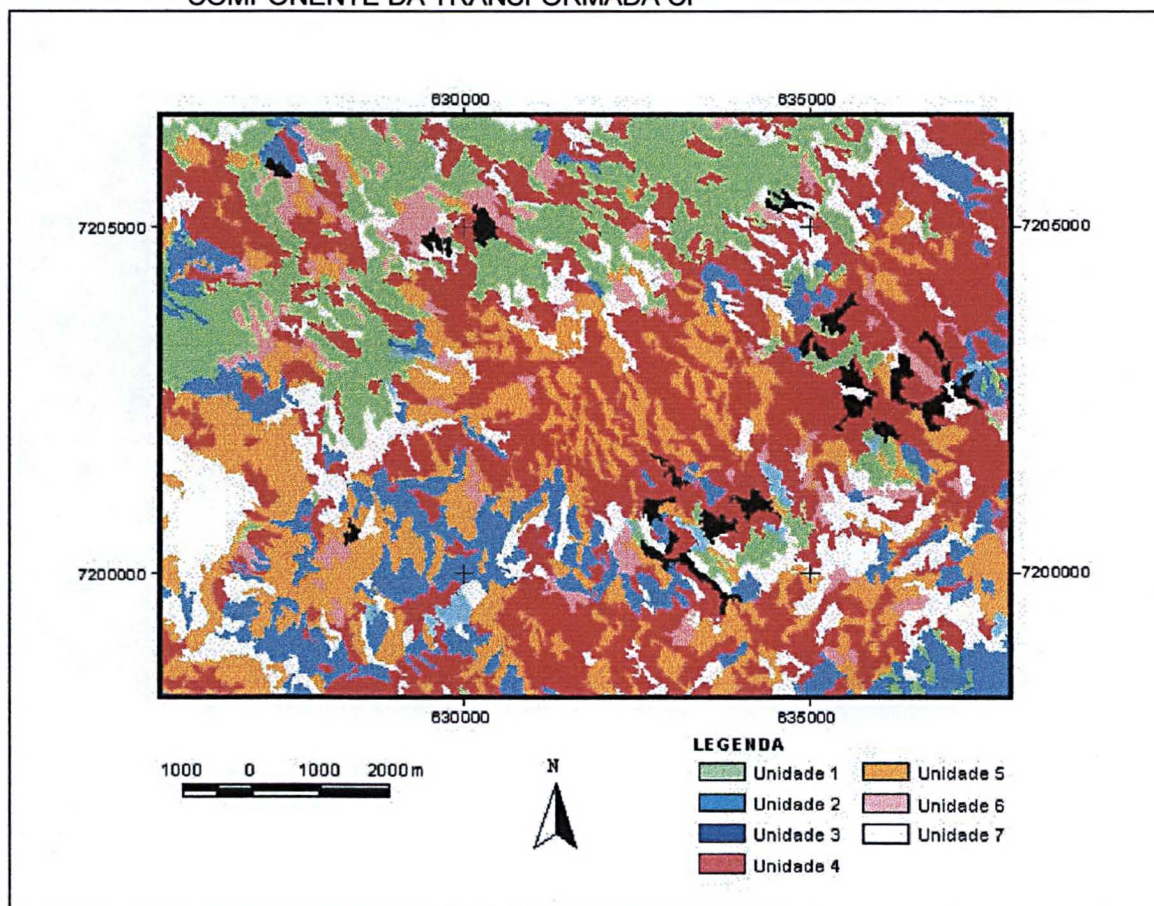
A Figura 5.5 (B) mostra a generalização das variáveis de entrada com a substituição da primeira componente. Pode-se analisar que, sem a informação dessa variável todas as unidades foram misturadas e generalizadas erroneamente.

A unidade mais alterada com a ausência da variável em questão foi a 2, com 0% de acertos, seguida das unidades 6 com 4%, da 3 com 7,8%, da 7 com 27,5%, da 5 com 30,9%, da 1 com 41% e da 4 com 54,7%, sendo que essa última unidade foi a única que foi classificada corretamente e com um aumento no percentual em relação a realidade de 1,8%.

Na seção 3.3.2.3.2 encontram-se descritas as unidades destacadas pela primeira componente. A unidade 2 encontra-se bem discriminada na cena da primeira componente e, ainda devido à segmentação esta unidade aparece agrupada mais uniformemente que as demais porções da cena, portanto nessa generalização a ausência de informação dessa variável (primeira componente) causou uma diminuição no índice de acertos de 80,2% para a unidade 2, isto é, praticamente nenhum segmento foi alocado para essa unidade, como pode ser confirmado na Tabela 5.8.

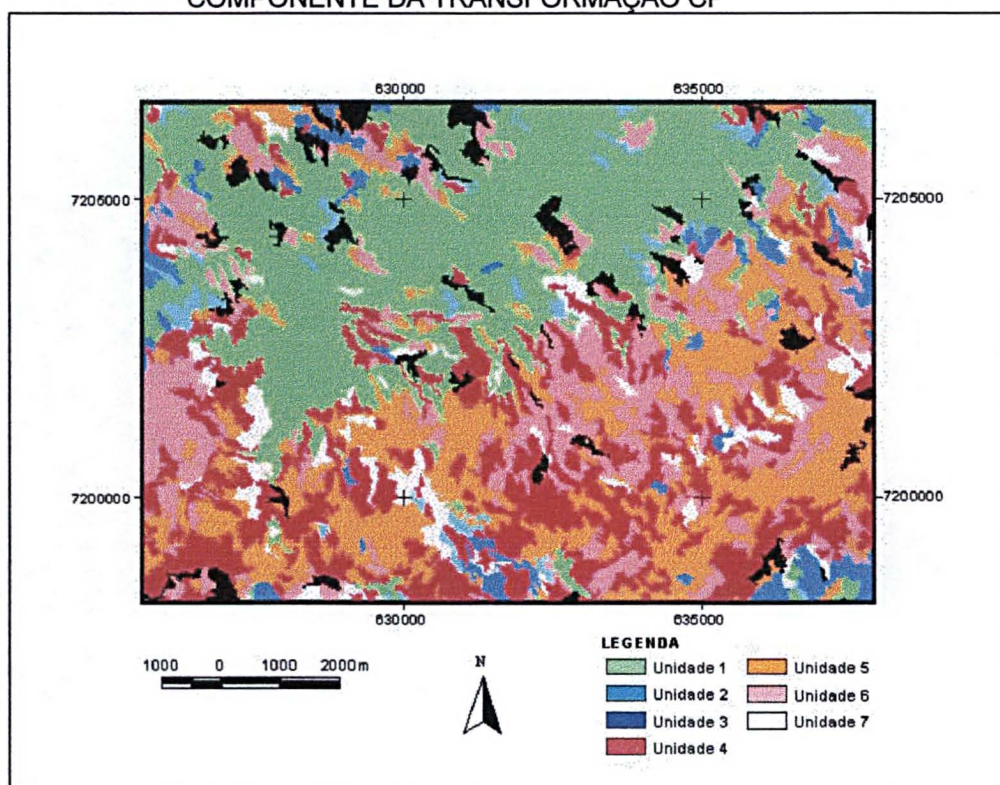
A unidade 3 teve seu percentual de acertos diminuído de 65,2% para 7,8%, sendo justificado pelo fato da componente, quando segmentada formar regiões que seguem uma direção, nesse caso os segmentos estão direcionados segundo SE, o Apêndice III mostra a primeira componente segmentada.

FIGURA 5.5 (B) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA PRIMEIRA COMPONENTE DA TRANSFORMADA CP



A generalização das variáveis de entrada, sem a terceira componente da transformação CP, é exibida na Figura 5.5. (C). Para essa generalização, a retirada da componente interferiu em todas as unidades, com exceção da unidade 1. Para a unidade 1 o percentual de acertos em relação a verdade de campo, foi aumentado de 56,1% para 70,6% e ainda teve sua área aumentada se comparada com a generalização processada com todas as cinco variáveis de entrada. Na seção 3.3.2.3.3, encontra-se descrição da banda artificial terceira componente, somente com 8,86% das informações em relação às demais componentes, com uma tonalidade escura delimitando a região do vale, este fato vem esclarecer que sem a associação das informações desta componente o vale, unidade 1, tenha a sua área extrapolada, mas ainda representada pelas demais variáveis utilizadas no processamento. A unidade 2, igualmente ao processamento sem a primeira componente, não obteve nenhum segmento classificado corretamente, 0% de acertos na Tabela 5.8. As unidades 3, 4, 7, 6 e 5 alcançaram os percentuais de 2,2%, 10,8%, 12,3%, 13,3% e 29,8%, respectivamente.

FIGURA 5.5 (C) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA TERCEIRA COMPONENTE DA TRANSFORMAÇÃO CP

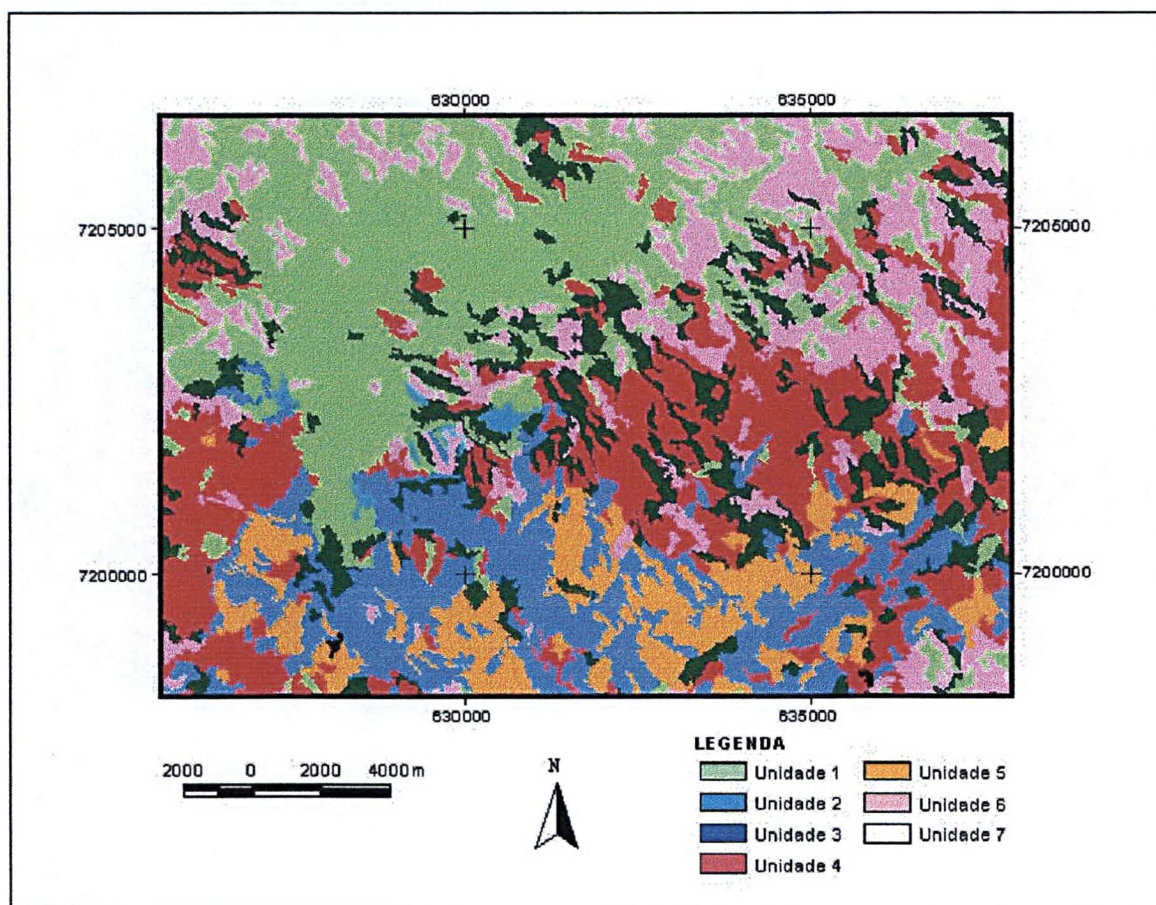


Na classificação mostrada na Figura 5.5 (D) a variável MDT foi substituída por uma banda constituída de valores numéricos nulos. Pode-se analisar visualmente que, a variável de entrada MDT interfere na generalização.

As unidades afetadas foram a 2, 7, 6, 3, 5 e 4, com acertos de 0%, 13,6%, 17,5%, 20,7%, 24,9% e 32,4%, respectivamente. A unidade 1 (Vale) teve sua forma mantida, atingindo 71,9% um aumento de 15,8%, mas com uma área de abrangência maior que a da imagem generalizada com a mesma modelagem e tendo como entrada todas as variáveis, como se pode verificar visualmente na Figura 5.5 (D).

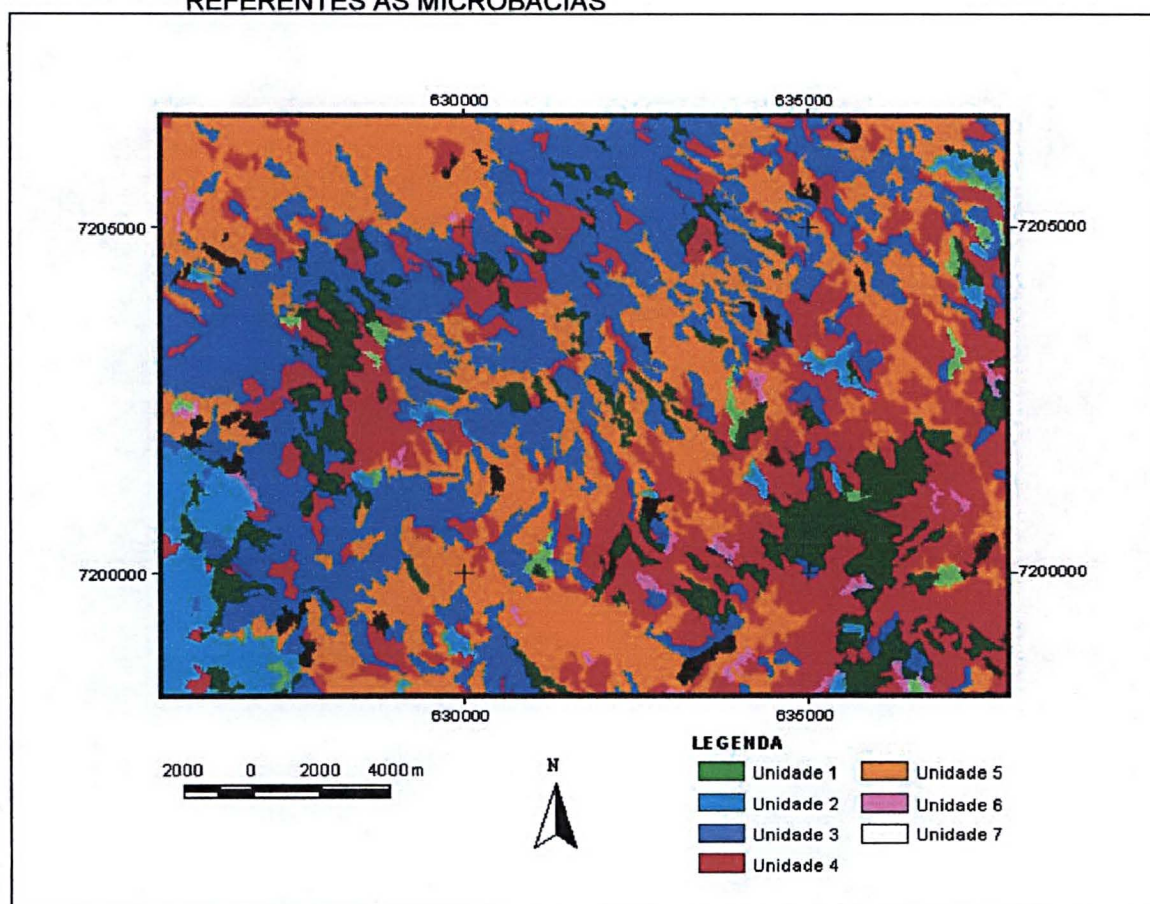
Na seção anterior 5.3.1.1, quando da generalização sem a participação do MDT, Figura 5.4 (C) a unidade 1 foi discriminada como nessa generalização, mas com uma área de abrangência muito maior. Pode-se portanto notar que a participação do MDT nesses dois processamentos restringe a unidade na sua porção correta que é o Vale da imagem, onde se encontram as menores altitudes.

FIGURA 5.5 (D) – IMAGEM GENERALIZADA SEM A INFERÊNCIA DAS INFORMAÇÕES DE ENTRADA DO MDT



A classificação mostrada na Figura 5.5 (E) foi processada sem informações das microbacias. A relevância da variável de entrada retirada, está presente nas unidades 1, 6, 7, 4, 5, 3 e 2. A unidade 2 foi a menos alterada com a retirada desta entrada, o índice de acertos foi de 72,4%, pois as outras variáveis, três componentes e o MDT forneceram informações suficientes para a separação da mesma. Como descrito na seção 3.3.2.2, as microbacias representam direções paralelas e sub-paralelas principalmente na região central, unidade 6, e norte, unidade 1, explicando que, com a retirada da variável a diminuição do percentual de acertos nessas unidades foi de 35,6% e 55,6%.

FIGURA 5.5 (E) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DAS INFORMAÇÕES REFERENTES AS MICROBACIAS



Para os testes realizados com as três componentes principais, o MDT e as microbacias, as variáveis mais importantes foram: a segunda e a primeira componentes, seguidas do MDT e da terceira componente e por último das microbacias. Nota-se, nessa classificação, que a variável microbacias influenciou menos na modelagem da rede que nas simulações apresentadas na seção 5.3.1.1

(nível de abstração do “pixel”) e pode-se explicar o ocorrido, pois a variável microbacias em nível de segmento “perde” importância, pois as imagens digitais segmentadas já incluem a informação do agrupamento espacial que as bacias oferecem em nível de “pixel”. Quando da exclusão de uma das variáveis de entrada, a abordagem por segmento produz uma classificação mais fragmentada na classificação por “pixel”, verificando-se a influência das regiões deixando de caracterizar espacialmente unidades.

5.3.2 Simulação – Mapa Geológico

A seção 5.3.1 mostra a simulação com a alternância das variáveis de entrada para o melhor resultado da classificação, tendo como referência o mapa geológico e em nível de segmentos.

5.3.2.1 Simulação em Nível de Abstração de Segmentos

A Tabela 5.9 compara os resultados das generalizações realizadas com todas as variáveis de entrada e com a substituição de uma das variáveis por uma banda artificial com nível digital constante. Na primeira coluna estão as unidades, na segunda os percentuais de acertos para cada unidade em relação à verdade de campo, mapa geológico, com todas as variáveis de entrada e nas colunas seguintes os percentuais de acertos com a substituição de uma das variáveis. A tabela apresenta também o índice de “Cramer’s V” global, ou seja, o índice de concordância para todas as variáveis de cada processamento.

TABELA 5.9. PERCENTUAIS DOS ÍNDICES DE ACERTOS COM TODAS AS VARIÁVEIS DE ENTRADA E COM ALTERNAÂNCIA DAS MESMAS. TOTAL DE "PIXELS" COINCIDENTES COM A VERDADE DE CAMPO

Unidades	Índices Cramer's V"							
	Entradas MDT, Microbacias, Banda 4 Gradiente da Encosta, Th, K e U	Sem MDT	Sem Grad Encos	Sem Micro Bacia	Sem Th	Sem U	Sem K	Sem Banda4
Global	0,6051	0,3126	0,3551	0,4224	0,4671	0,4929	0,4975	0,5321
1	55,7	12,0	24,2	39,9	83,3	26,2	26,8	56,5
2	77,4	28,6	19,2	0	0	45,3	59,9	70,7
3	83,7	26,9	90,4	90,3	89,9	83,9	83,9	84,3
4	58,4	12,2	46,6	53,0	4,3	70,8	68,9	11,5
5	97,0	99,8	100	96,7	95,5	93,0	88,6	97,9
6	99,8	0	99,9	0	41,9	99,9	99,9	59,0

As Figuras 5.6 (A, B, C, D, E, F e G) mostram as classificações com a exclusão de uma das entradas. Para todas as 7 generalizações a seguir, a variável de entrada excluída (sem informações) recebeu valor de nível de cinza constante igual a zero.

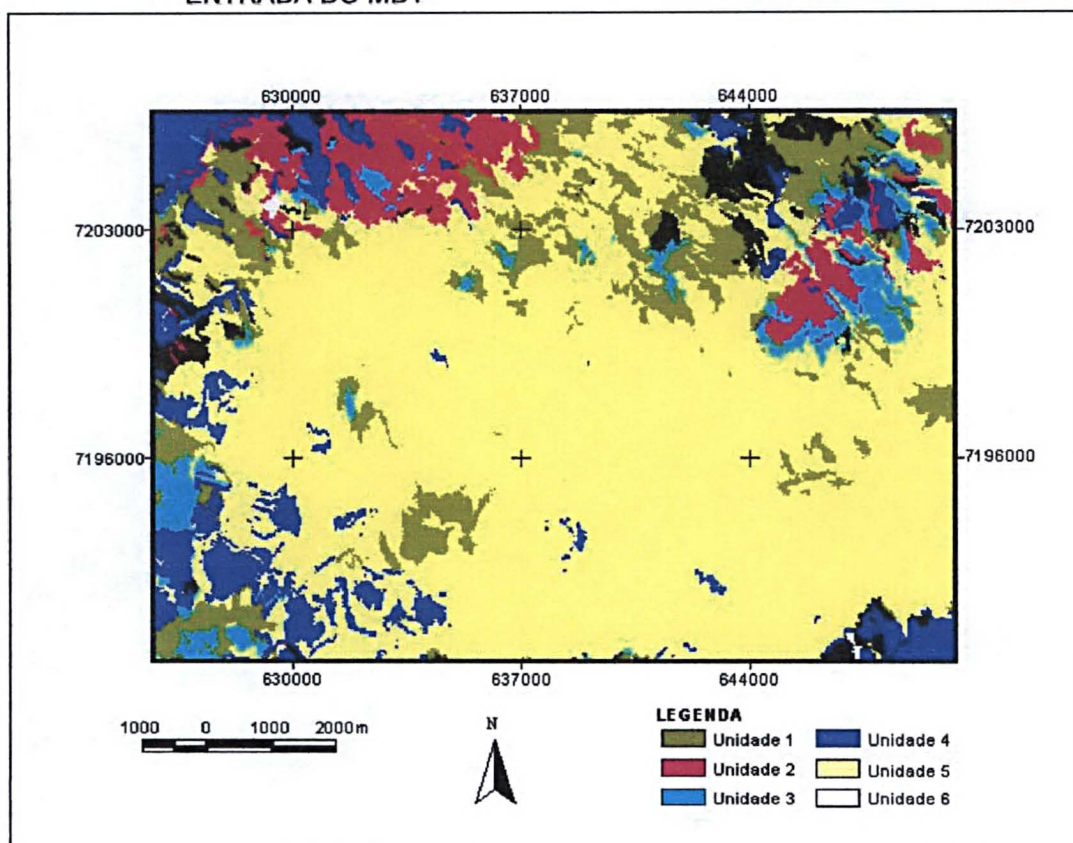
A Figura 5.6 (A) exibe a imagem gerada com a substituição da variável MDT por uma imagem com níveis digitais nulos. Pode-se analisar, visualmente, que a variável de entrada MDT intervêm na generalização de todas as unidades.

As unidades foram classificadas com os seguintes percentuais: unidade 6, com 0%; unidade 1 com 12,0%; unidade 4 com 12,3%, unidade 3 com 26,9%, unidade 2 com 28,6% e unidade 5 com 99,8%.

A única unidade que obteve percentual com acréscimo foi a 5 (Aluviões) com 1,8% de aumento, mas foi espalhada por toda a cena. Somente parte da unidade 2 ao noroeste (Granito Três Córregos), foi mantida no local correto, mas com sua área diminuída se comparada com a generalização com todas as variáveis de entrada.

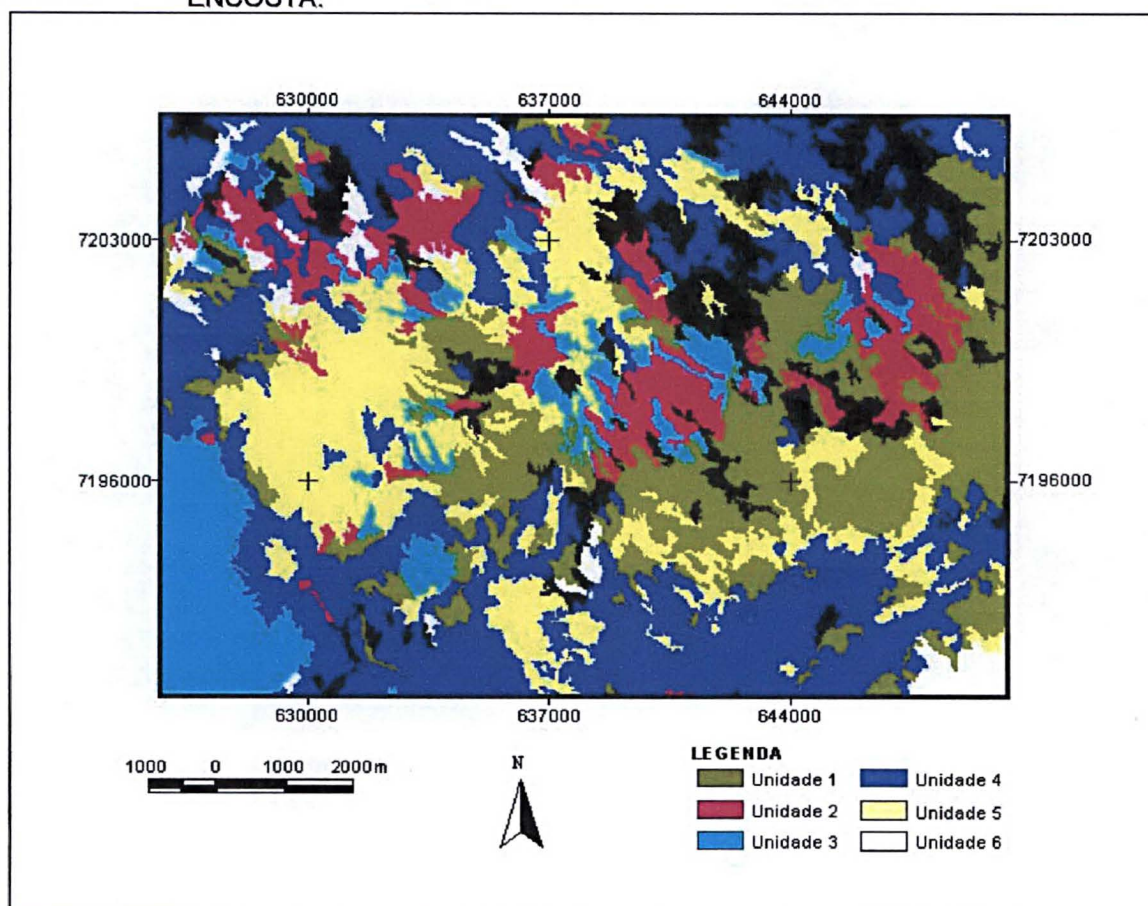
Mais uma vez pode-se constatar que o MDT delimita a área dos vales da região, uma vez que a unidade 5, os Aluviões, abrangeu quase toda a cena.

FIGURA 5.6 (A) – IMAGEM GENERALIZADA SEM A INFERÊNCIA DAS INFORMAÇÕES DE ENTRADA DO MDT



Para a classificação, da Figura 5.6 (B), a alteração foi a exclusão da imagem derivada do MDT, o gradiente da encosta. As unidades 3 (Formação Furnas) 5 (Aluviões) e 6 (Formação Guabirotuba) aparecem classificadas corretamente, com os percentuais de acertos aumentados de 6,7%, 3,0% e 0,1%, pois as outras variáveis processadas nesta generalização discriminam essas unidades. Os granitos tiveram seus percentuais de acerto diminuídos de 77,4% para 19,2%, haja vista que o Granito do Cerne aparece, na imagem do gradiente da encosta segmentada, discriminado pela tonalidade cinza escura, uniforme ao longo do compartimento e o granito Três Córregos também delimitado, mas por uma tonalidade mais clara. A unidade 4 (Camarinha) substituiu uma porção do Granito Três Córregos e parte da Formação Açunguí.

FIGURA 5.6 (B) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DO GRADIENTE DA ENCOSTA.

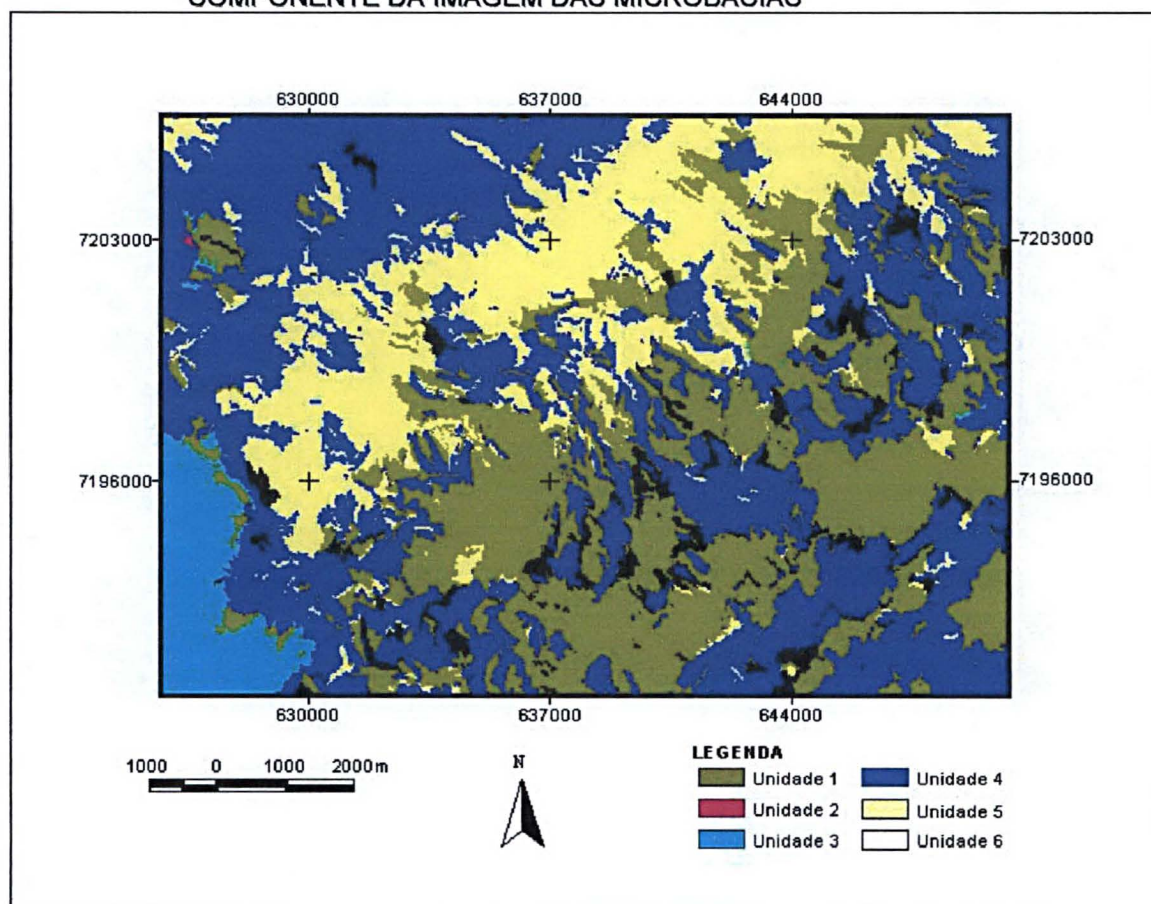


A Figura 5.6 (C) mostra a classificação com a alteração da variável microbacias. Pode-se analisar que sem a informação dessa variável, a unidade 3 (Furnas) permanece classificada corretamente e com um aumento de percentual de 83,7% para 90,3%, o que acusa a baixa importância da variável para essa unidade. A unidade 5 (Aluviões) apesar de estar generalizada na posição correta teve sua área aumentada, com um decréscimo de acertos no valor de 0,3%. A unidade 4 (Camarinha), teve uma redução nos acerto de 5,4% e foi alocada na posição dos granitos (Três Córregos e do Cerne).

A unidade 2 (granitos) nenhum segmento foi classificado, confirmado pelo percentual de acertos de 0%, na Tabela 5.9. No apêndice II encontra-se a imagem das microbacias segmentadas e, pode-se visualizar os granitos e a unidade 6 (Formação Guabirotuba) com valores de níveis de cinza próximos de zero, apesar de um valor numérico baixo, mostrando a ausência de drenagem nas duas porções, gerando informações para a separação das unidades. A unidade 1 (Grupo Açungui)

foi simulada corretamente com exceção da região onde a unidade 4 (Camarinha) assumiu seu local. A unidade 5 (Aluviões) teve o maior percentual de acerto nesse processamento, 96,7% e foi extrapolada ao longo de todo o vale.

FIGURA 5.6 (C) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DA PRIMEIRA COMPONENTE DA IMAGEM DAS MICROBACIAS

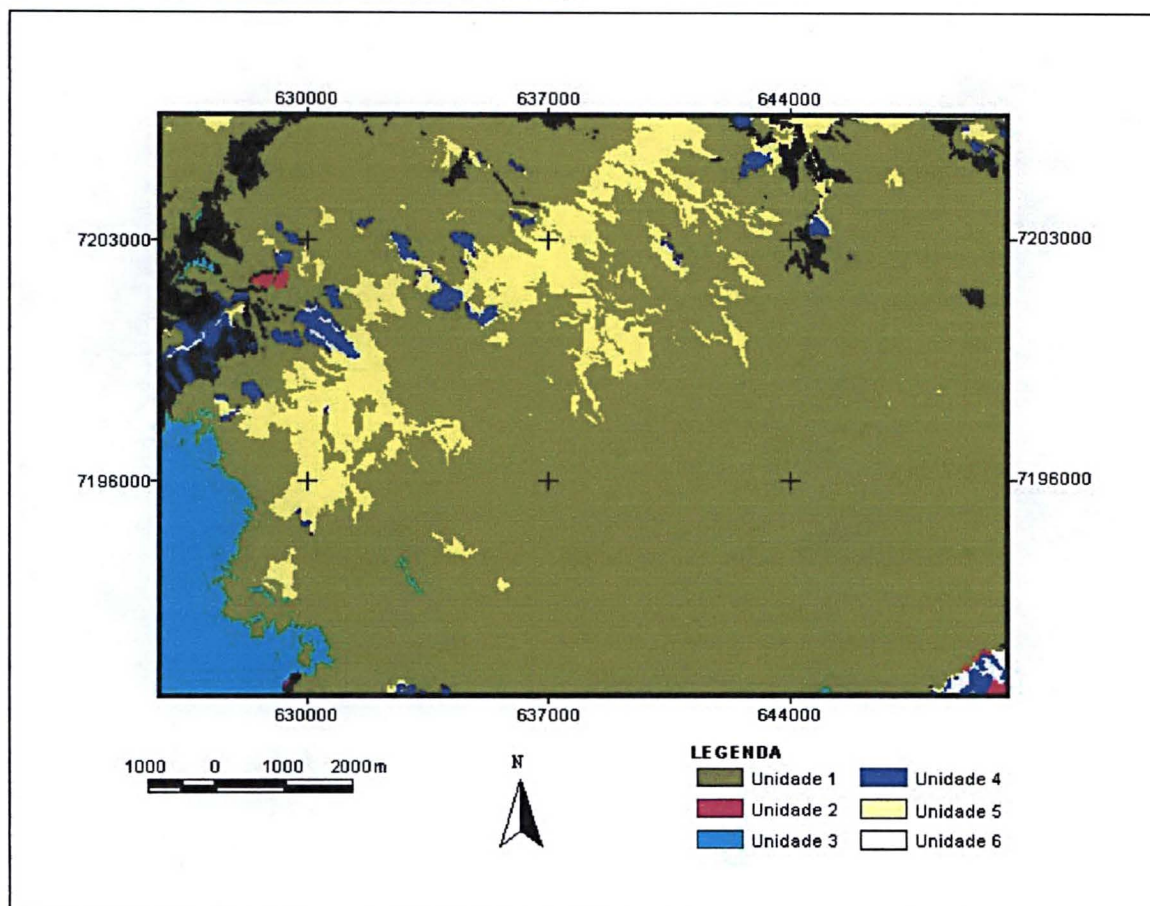


A classificação sem a participação da variável originária do levantamento aerogamaespectrométrico Th é mostrada na Figura 5.6 (D). A ausência desta variável, na generalização, interferiu com mais ênfase nas unidades 2 e 4. Como comentado, na seção 2.3.3.4.2, os maiores valores de do elemento Th encontram-se nos granitos (15ppm a 22,2ppm), unidade 2, não classificada. A imagem do Th segmentada deixa mais evidente a separação da unidade 2. No Apêndice III pode-se observar esta variável segmentada onde os granitos são praticamente um único segmento de cor branca.

A menor concentração do Th é a sudoeste (Furnas, unidade 3) sem interferência desta variável no presente processamento esta foi simulada

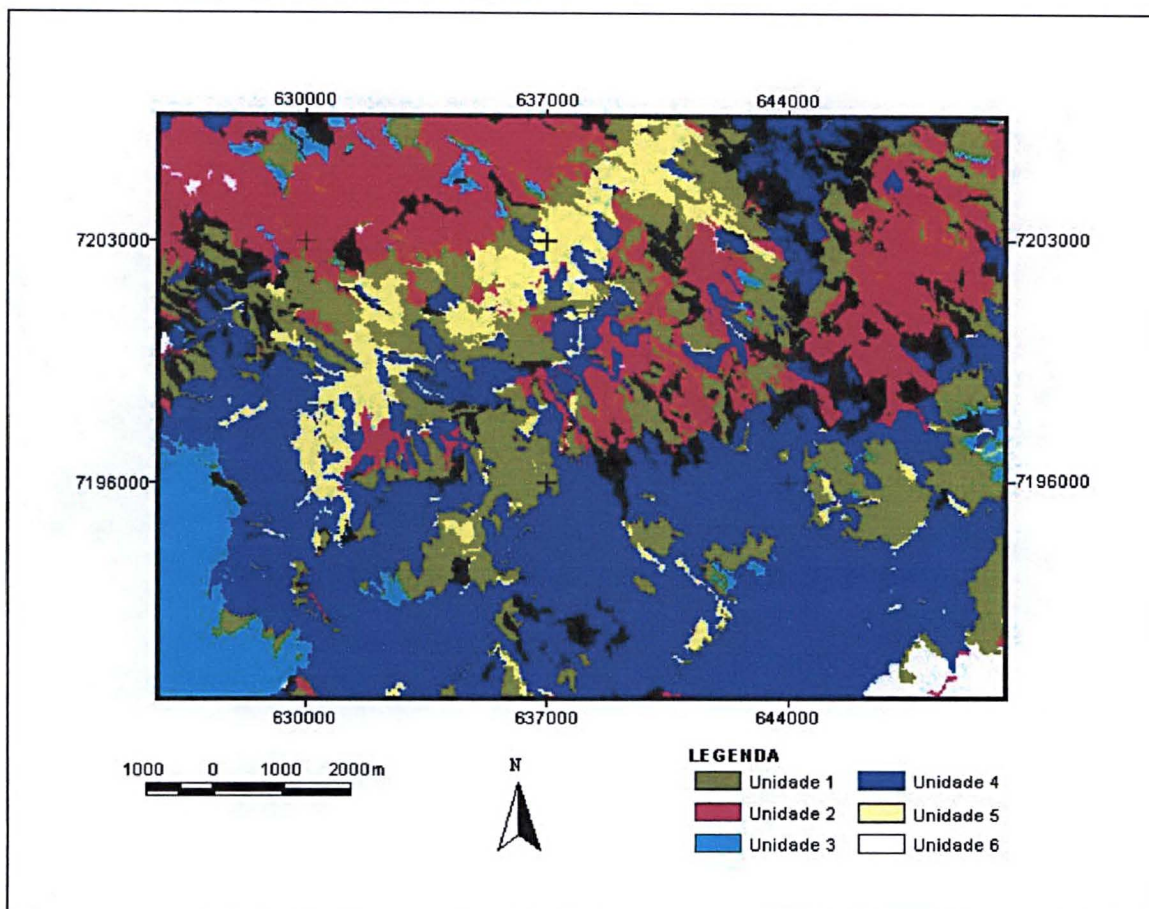
corretamente e com um aumento de percentual no valor de 6,2%. A unidade 5 foi alocada corretamente e teve sua área aumentada.

FIGURA 5.6 (D) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DO DADO GAMAESPECTROMÉTRICO TH



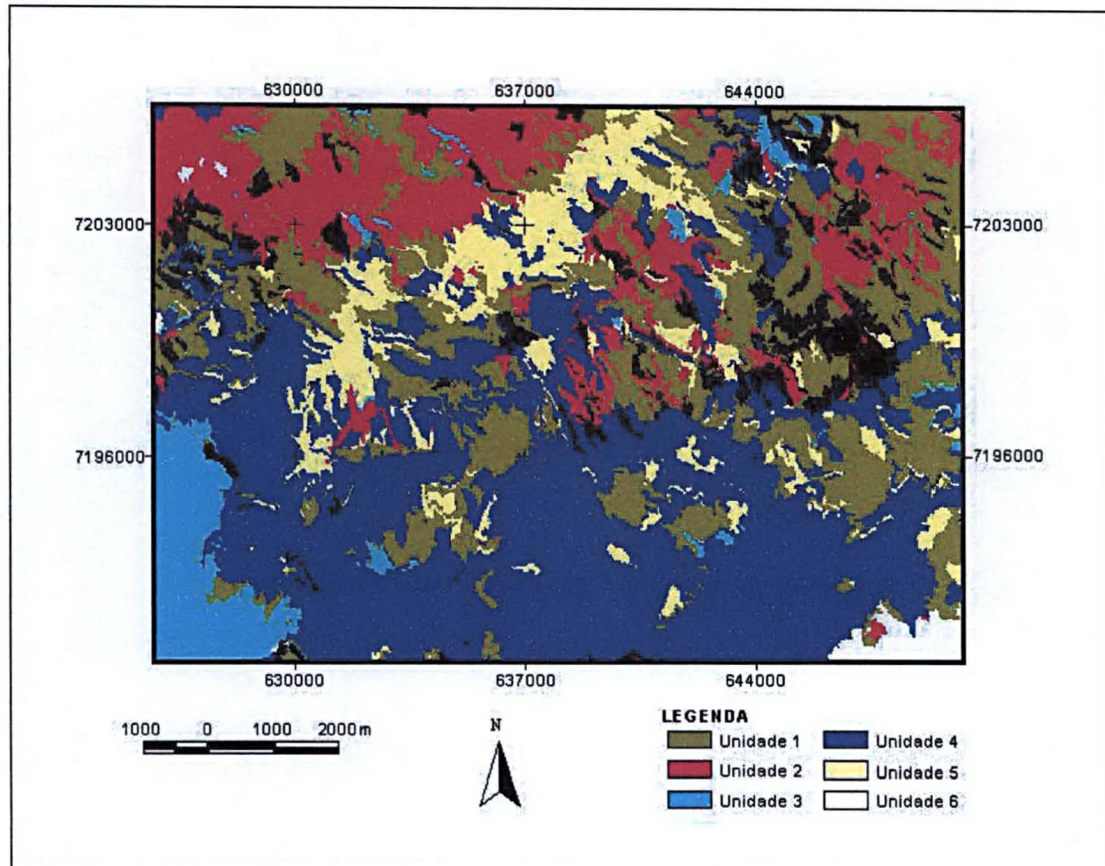
A Figura 5.6 (E) apresenta a imagem classificada com a alteração da variável U. Como citado, na seção 3.3.2.4.3, a menor concentração do U aparece na unidade 3, Formação Furnas, classificada corretamente e o mesmo ocorreu para a unidade 6, 83,9% e 99,9% de acertos respectivamente. Na região sul onde a variável tem valores maiores, a unidade 4 (Formação Camarinha) assumiu a posição da unidade 1 (Formação Açungui) e devido a este fato a unidade 1 teve seu percentual de acertos diminuído do valor 55,7% para 26,2%. A unidade 5, os Aluviões, foi classificada corretamente, sugerindo que outras variáveis contribuíram para que esta fosse corretamente separada.

FIGURA 5.6 (E) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DO DADO GAMAESPECTROMÉTRICO U



Com a omissão das informações do elemento K obteve-se a imagem classificada mostrada na A Figura 5.6 (F). Devido à baixa concentração do elemento na unidade 3 (Furnas) essa unidade foi classificada corretamente, com praticamente o mesmo percentual que no processamento com todas as variáveis, como mostra a Tabela 5.9, na seção 3.3.2.4.1 está a distribuição do percentual deste elemento na cena de estudo. A ausência desta variável na generalização interferiu nas unidades 2 (granitos) com um decréscimo no percentual de acerto de 17,6%, pois o K aparece com percentuais maiores que 2,3% nessa região. A unidade 5, Aluviões, teve sua área pouco expandida se comparada com as demais generalizações, sugerindo que, variáveis como o MDT associada a microbacias delimitam o vale onde estão depositados os aluviões.

FIGURA 5.6 (F) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DO DADO GAMAESPECTROMÉTRICO K

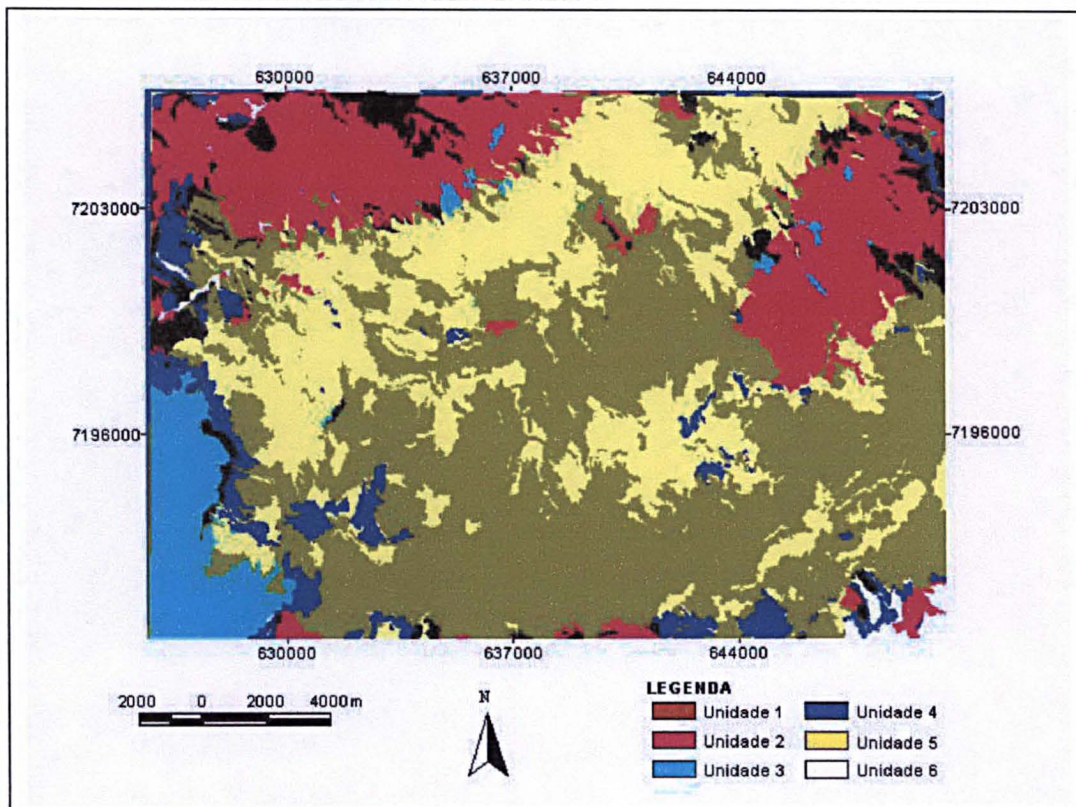


Na Figura 5.6 (G) pode-se observar o resultado da classificação sem a participação das informações da banda 4. A importância da variável, está presente nas unidades 4 e 6. A unidade 4 (Formação Camarinha) foi reduzida e teve o percentual de acerto reduzido de 58,4% para 11,5%.

A unidade 3 (Furnas) não sofreu influência, percentual praticamente mantido, 84,3%. Os granitos tiveram regiões não classificadas (cor preta) mostradas pela redução do percentual de acertos em 6,7% e a unidade 5 (os aluviões) teve a área classificada expandida.

A cena da banda 4 representada em nível de abstração de segmentos, tem um destaque nos compartimentos graníticos, do Cerne e Três Córregos (unidades 2) aparecem na cena desta componente em evidência, portanto é possível que as porções não classificadas dos granitos seja devido a isto.

FIGURA 5.6 (G) – IMAGEM GENERALIZADA SEM A PARTICIPAÇÃO DAS INFORMAÇÕES REFERENTES A IMAGEM BANDA 4



Para a simulação realizada demonstrada na Tabela 5.9, as variáveis mais importantes foram MDT, gradiente da encosta, microbacias, dados gamaespectrométricos Th, K, U e banda 4.

6 CONCLUSÕES

Baseado no que foi apresentado neste trabalho pôde-se chegar às conclusões a respeito do uso das RNA na integração de dados e na identificação de unidades fisionômicas e geológicas. Devido a abrangência do estudo, as conclusões foram agrupadas segundo o tema.

6.1 REDES NEURAIIS

- Com a técnica das RNA é possível separar unidades fisionômicas e geológicas. A RNA possibilita a integração de diferentes variáveis. Essas variáveis são de importância, pois representam a cobertura do solo, podendo-se citar as imagens espectrais, o relevo por meio do MDT, a rede de drenagem através das microbacias. A subjetividade da fotointerpretação, gerada devido ao fato de cada analista interpretar a área de estudo visualmente, utilizando seu conhecimento e intuitivamente as variáveis que representam a cobertura, o relevo dentre outros elementos, pode ser substituída pela técnica das RNA por meio da análise quantitativa das variáveis, separando unidades automaticamente e sistematicamente;
- Por meio das técnicas de redes neurais é possível a integração de dados de diferentes origens e escalas, o que não é possível com classificadores estatísticos convencionais;
- A utilização da segmentação por meio do algoritmo FNEA, na modelagem das redes neurais, mostrou-se superior a análise "pixel" a "pixel" em termos do aprendizado da rede e em relação ao número de iterações;
- A definição da arquitetura da RNA requer disponibilidade de tempo, ou seja, é trabalhosa, devido ao fato desta ser empírica, mas uma vez a rede

treinada, para a área de estudo, pode-se alterar as variáveis de entrada. Assim como o intérprete necessita de treinamento, conhecimento e de elementos que auxiliem a interpretação da cena, a RNA também, com uma vantagem, pois o analista tem limitações para avaliar grande quantidade de variáveis e para a RNA, estando esta treinada, isso não é problema.

6.2 INTEGRAÇÃO DE DADOS

- A integração de dados de diferentes origens e escalas é pertinente para o estudo das unidades fisionômicas e geológicas, já que a automação na separação das unidades pretende simular o “comportamento humano”, isto é, utilizar os elementos da fotointerpretação que o intérprete utiliza quando da interpretação de imagens para diferentes fins;
- No presente estudo pôde-se verificar a importância da integração dos dados de diferentes origens, pois sem a associação destas informações às imagens provenientes do sensoriamento remoto, o resultado da classificação (separação das unidades fisionômicas e geológicas) não atingiu o objetivo, quanto à convergência e ao erro quadrático mínimo das RNA e à verificação dos “pixels” alocados corretamente, na análise da matriz de confusão.

6.3 SEGMENTOS VERSUS “PIXELS”

- Os melhores resultados ocorreram quando as variáveis de entrada foram segmentadas. Pode-se fazer um paralelo entre a análise visual e a análise em nível de abstração de segmentos, pois o analista quando interpreta uma cena, procura identificar regiões similares, visando uma análise e agrupamento entre as mesmas fazendo com que toda a imagem seja generalizada, de forma a atingir os objetivos da interpretação. Tendo sido a imagem segmentada, ela que possuía um nível de abstração do “pixel” passa em nível de abstração de regiões, isto é, elementos da cena com características similares de cor e forma são fundidos gerando uma imagem menos heterogênea;
- Quando a avaliação por meio da correlação foi executada ao nível do “pixel”, os valores de acertos foram menores se comparados aos percentuais de acerto em nível de abstração dos segmentos, uma vez que nas imagens classificadas a distribuição espacial das classes encontra-se fragmentada. Nas imagens classificadas em nível de segmentos encontram-se também classes fragmentadas, porém essas não aparecem como “ruídos” mas sim como pequenas regiões (segmentos) isoladas, aumentando, portanto os acertos.

6.4 VARIÁVEIS DE ENTRADA

- As três componentes principais puderam substituir as sete bandas espectrais. Somente com três bandas (CP), ao invés das sete originais, houve um ganho de processamento das variáveis de entrada no processamento das redes neurais. Esta substituição possibilitou ainda, devido ao tamanho de arquivo de entradas advindo de sensoriamento remoto ter sido reduzido, a associação dessas variáveis a outras complementares;

- O MDT foi uma variável que atingiu importância em todos os testes apresentados na seção 5.3, apesar de nos resultados finais, da seção 5.3.1.2, a segunda e a primeira CP terem sido as variáveis de maior influência na generalização. Como a fotointerpretação utiliza a estereoscopia para que, por meio do relevo o interprete possa definir outros parâmetros de reconhecimento como rede de drenagem, vales etc, o MDT na separação automática, de unidades fisionômicas e geológicas, é uma variável crucial para a determinação das mesmas, pois ele delimita as regiões dos vales, nos testes executados no estudo;
- A influência das microbacias também está presente em todos os testes e, essa quando associada ao MDT, fornece mais informações a respeito da área de estudo. As microbacias fornecem um agrupamento espacial de "pixels" representando a drenagem, esse agrupamento auxilia na separação das unidades haja vista que, as unidades não são pontuais e sim porções com características físicas similares;
- Apesar da imagem gerada da transformação IHS (Gradiente/DTM/Gradiente), visualmente, ter um resultado satisfatório e ter auxiliado na fotointerpretação ela não se mostrou no treinamento da RNA, uma variável de entrada viável, pois não se obteve resultado de treinamento satisfatório para uma possível classificação, sendo que o mesmo ocorreu para a imagem artificial NDVI. No entanto, a mesma informação, encontrada no NDVI, está presente na segunda CP e ainda cabe salientar que, a CP inclui informações das outras bandas espectrais;
- O elemento originário do levantamento aerogamaespectrométrico Th foi o que mais se destacou na generalização da classificação, utilizando-se a análise em nível de abstração de segmentos e como verdade de campo, o mapa geológico. Justifica-se que esse elemento tenha se sobressaído no processamento, se comparado com o K e U, pois nos compartimentos granitóides encontram-se as maiores concentrações do Th e ainda pode-se citar a baixa mobilidade do elemento evitando assim a presença desse em outras unidades;

- Apesar da Banda 4 discriminar visualmente a morfologia da área, nesse estudo ela não foi o melhor resultado na classificação e nem a variável de maior influência na generalização;
- As variáveis de entrada, quando processadas baseando-se na análise em nível de abstração de segmentos, possibilitaram uma precisão maior, verificada por meio do coeficiente de correlação Cramer's V. Isso se deve, ao tipo de classificação processada, visto que, as unidades fisionômicas e geológicas são homogêneas e, regiões representam melhor estas unidades que a análise em nível de abstração do "pixel".

7 RECOMENDAÇÕES

- Esse trabalho pretende apontar a viabilidade do uso das RNA na integração de dados espaciais. A metodologia proposta, no entanto, se baseia na análise de um único conjunto de dados, motivo pelo qual indica-se a necessidade de executar testes em outras áreas físicas;
- O mapa temático produzido neste estudo contou com um restrito trabalho de campo, sendo necessária fazer verificação no local, isto devido ao fato da unidade 5, Aluviões, no mapa geológico, aparecer restrita a uma área pequena, enquanto nas classificações verificou-se uma área classificada sempre maior, sugerindo uma verificação “in loco” na região dos vales onde se encontram os depósitos da encosta;
- Os resultados da pesquisa apontam também novos temas para serem estudados, dentre os quais pode-se citar:
 - a) Verificação dessa metodologia em outras regiões, áreas com diferentes características físicas;
 - b) Inclusão de outras variáveis de entrada, como mapas de solos ou de uso do solo;
 - c) Análise da viabilidade do uso de MDT gerados por outros métodos, mesmo com resolução espacial inferior, mas economicamente mais baratos;
 - d) Análise da viabilidade do uso de imagens de outros sensores, com resolução espacial e espectral diferentes como o ASTER ou NOAA – AVHRR.

REFERÊNCIAS BIBLIOGRÁFICAS

- AMARAL, A. Z.; AUDI, R. 1972. **Fotopedologia**. In: MONIZ, A. C. Elementos de pedologia. São Paulo. Ed. Universidade de São Paulo. V.41, p.169 – 263.
- ANDRADE, A. F. 2003. **Integração de variáveis espectrais e forma na classificação de imagens de alta resolução utilizando redes neurais artificiais**. Dissertação de mestrado. Universidade federal do Paraná. 153p.
- ANTUNES, A. F. B. 2003, **Classificação de Ambiente Ciliar Baseada em Orientação a Objeto em Imagens de Alta Resolução Espacial**. Tese de doutoramento Universidade Federal do Paraná. 147 p.
- ARAKI, H. 1998. **Classificação de imagens multispectral com redes neurais: revisão bibliográfica e alguns experimentos**. Seminário PÓS- Graduação, UFPR, Curitiba.
- BAATZ, M.; SCHÄPE, A. 2001. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. München. Disponível em www.definiens.com Acesso em março.
- BÄHR, H. P., 2002. **Models in philosophy and in image analysis**. Universität Karlsruhe, Institut für Photogrammetrie und FernAerkundung. ISPRS, extended abstract, comm. II 10p.
- BALTSAVIAS, E.; HAHN, M. 1999. **Integration of Image Analysis and GIS**. International Archives of Photogrammetric and Remote Sensing, v. 32, n.4, 8p.
- BARMP. 1997. **Brazil AirboRNAe Radiometric Mapping Project and Survey Atlas**. A collaboration between Peterson, Grant & Watson Limited (PWG), Companhia de Pesquisa de Recursos Minerais (CPRM) and Geological Survey of Canada (GSC). Rio de Janeiro.
- BENEDIKTSSON, J. A .; SWAIN, P. H.; ERSOY, O . K. 1990. **Neural network approaches versus statistical methods in classification of multisource remote sensing data**. IEEE Transactions on Geoscience and Remote Sensing. v.28 n.4, p. 540- 552.

- BIERWIRTH, P. N. 1996. **Investigation of airborne gamma-ray image as a rapid mapping tool for soil and land degradation** – Wagga Wagga, NSW. Australian Geological Survey Organization, Record, 22p.
- BIGARELLA J. J.; BECKER R. D. ; SANTOS G. F. 1994. **Estruturas e origem das paisagens tropicais e subtropicais**. Editora UFSC, Florianópolis - SC, v. I e II
- BITTENCOURT, G. 1998. **Inteligência artificial**. Editora UFSC, Florianópolis - S. C. 400p.
- BLASCHE, T.; HAY G. 2002. Object-oriented image analysis and scale: theory and methods for modeling and evaluating multiscale landscape structure. Disponível em www.defeniens.com/publication.pdf Acesso em janeiro.
- BRAGA, A .P. ; LUDEMIR, T. B. ; CARVALHO, A . C. P. F. 2000. **Redes neurais artificiais – teoria e aplicações**. Rio de Janeiro. LTC Livros Técnicos e Científicos Editora S. A , p. 237.
- BRASIL, 1987. MINISTÉRIO DA AGRICULTURA. **Programa Nacional de Microbacias Hidrográficas**; Manual Operativo. Coordenação Nacional do PNMH, Ministério da Agricultura. Brasília. DF. 60 p.
- BRIGGS, I. C. 1974. **Machine contouring using minimum curvature**. Geophysics, v.39, p. 39-48.
- BURROUGH, P. A. 1986. **Principles of geographical information systems of land resources assessment**. Francis & Taylor.185p.
- CÂMARA, G.; MEDEIROS, J. S. 1998. **Tendências de evolução do geoprocessamento**. In: Sistemas de Informação Geográfica – Aplicação na Agricultura. EMBRAPA, 2ª ed, p. 411-424.
- CARVALHO M. T. N., 1999. Integração de dados geológicos, geofísicos e geoquímicos aplicados à prospecção de ouro nos "greenstone belts" de Pilar de Goiás e Guarinos, GO. Dissertação de mestrado, IG, UNB, Brasília, p. 150.
- CENTENO, J. A. 2000. Integrierte verarbeitung von satellitenbild – und gescannter karteninformation. Tese de doutorado. Universidade de Karlsruhe.
- CENTENO, J. A.; TEDESCO, A.; FARIA, A.; MAFFRA, C.; AUGUSTO, E.G.G; SILVA, F. R. R.. 2001. **Análise da forma em imagens temáticas**. Anais do II Colóquio Brasileiro em Ciências Geodésicas, UFPR, Curitiba. CD-ROM.
- CHOU Y. H. 1992. **Slope Gradation - line detection in a vector- based GIS**. Photogrammetric Engineering & Remote Sensing, V.63, n.2, p. 227- 233.

- CHUVIECO, E. 1990. **Fundamentos de teledetección espacial**. Ediciones Rialp S. A., Madrid, p. 449.
- COMEC – Coordenação da Região Metropolitana de Curitiba, 1997. **Relatório da região metropolitana de Curitiba**. GovernA do Estado do Paraná/ Secretaria do Planejamento e Coordenação Geral - SEPLA/ Coordenação da Região Metropolitana de Curitiba - COMEC . Curitiba – PR.
- CPRM. 1978. Projeto Aerogeofísico Serra do Mar Sul. CPRM/GEOFOTO (Arquivo Digital). Rio de Janeiro.
- CRIST, E. P. e CICONI, R. C. 1984. **Application of the tasseled cap concept to simulated thematic mapper data**. Photogrammetric Engineering & Remote Sensing, v.50, n.3, p.343–352.
- CRIST, E. P. e KAUTH, R. J. 1986. **The tasseled cap de-mystified**. Photogrammetric Engineering & Remote Sensing, v.52, n.1, p.81–87.
- DICKSON, B. L.; SCOTT, K. M. 1997. **Interpretation of aerial gamma-ray surveys-adding the geochemical factors**. In: AirboRNAe Magnetic and Radiometric Surveys, AGSO JouRNAal of Australian Geology and Geophysics, v.17, n.2, p. 187-200.
- ECOGNITION, 2001. **User Guide**. Definiens Imaging. München, Germany
- EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária 1974. **Boletim Técnico N° 40**. Centro de Pesquisas Pedológicas. EMBRAPA/SUDESUL/UFPR/CERENA. Curitiba – PR 120p.
- FAN, G; XIA, X. 2001. A joint multicontext and multiscale approach to Bayesian image segmentation. IEEE Transaction on Geosciences and Remote Sensing. Vol 39, nº 2, p. 2680-2688.
- FOODY, C.M. ; McCULLOCH, M. B. ; YATES, W.B. 1995. **Classification of remote sensed data by an artificial neural network: issues related to training data characteristics**. Photogrammetric Engineering & Remote Sensing, v.61, n.4, p.391– 401.
- FREITAS, P. L.; KER, J. C. 1996. **As pesquisas em microbacias hidrográficas: situação atual, entraves e perspectivas no Brasil**. Manejo Integrado de Solos em Microbacias Hidrográficas. IAPAR (Instituto Agrônômico do Paraná). Sociedade Brasileira de Ciência dos Solos. 150p.Londrina – PR.

- FITZGERALD, R. W.; LEES, B. G. 1996. **Temporal context in floristic classification**. Computers Geosciences, v. 22, n.9, p. 981 – 994.
- GARCIA, G. J. 1972. Sensoriamento Remoto: Princípios e Aplicações de Imagens. Ed Blücher. São Paulo. 357p.
- GERMAN, G. W. H.; GAHEGAN, M. N. 1996. **Neural network architectures for the classification of temporal image sequences**. Computers Geosciences, v. 22, n.9, p. 969 – 979.
- GONG, P.; PU R. ; CHEN, J. 1996. **Mapping ecological land systems and classification uncertainties from digital elevation and forest- cover data using neural network**. Photogrammetric Engineering & Remote Sensing, v.62, n.11, p.1249–1260.
- GONGALTON, R. e GREEN, K., 1993. **A practical look at sources of confusion in error matrix generation**. Photogrammetric Engineering & Remote Sensing, v.59, n.5, p. 641–644.
- GONZALEZ, R. C.; WOODS, R. E. 1998. **Digital image processing**. Addison-Wesley Publishing Company, 630p.
- GOSE E.; JOHNSONBAUGH, R.; JOST, S.1996. **Pattern recognition and image analysis**. Prentice Hall, Inc. New Jersey. USA. 484p.
- GUPTA, R. P. 1991. Remote Sensing. Springer. Verlag. Berlin – Heidelberg. Germany, 356p.
- HARRIS, R. J.; MURRAY, R. 1990. **IHS transform for the integration of RADAR imagery with other remotely sensing data**. Photogrammetric Engineering & Remote Sensing. V. 61, n. 12, p. 1631- 1641.
- HAYDN, R. DALKA, G. W.; HENKEL, J. BARE, J.E. 1982. **Applications of the IHS color transformation to the processing of multisensor data and image enhancement**. Proceeding: International Symposium on Remote Sensing on arid and semi- arid lands. Cairo, Egito. In: Remote Sensing and Image Interpretation. 3 Ed. Wiley, p. 599-616. USA.
- HAYKIN, S.1999. **Neural networks. A comprehensive foundation**. 2 Ed. Prentice Hall. New Jersey. p. 842.
- HEBB, D. O. 1949.**The organization of behavior: A neuropsychological theory**. New York: Wiley. p. 1860-1863.

HILTON G. E.. 1989. **Connections learning procedures**. Artificial Intel, v. 40, n.1-3, p. 185-234.

HOPFIELD, J. J. 1982. **Neural networks and physical Systems with emergent collective computational abilities**. Proc. Nat. Acad. Science, USA, v.79, p. 2554-2558.

HUNT, R. E. JR; ROCK, B. 1989. **Detection of changes in leaf water content using near and middle infrared reflectances: remote sensing of environment**. v.30, p.43-45.

IBGE, 1983, Folha Campo Largo SG-22-X-C-III-D

ITO, Y. ; HOSOKAMA, M.; LEE, H. ; LIU, J. G. 2000. **Extraction of damaged regions using SAR data and neural networks**. Amsterdam. International Archives of Photogrammetric Engineering and Remote Sensing. v.33, part B1, p. 156-163

JARVIS, H. C.; STUART, N. 1996. **The sensitivity of neural network for classifying remotely sensed imagery**. Computers Geosciences, v. 22, n.9, p. 959 – 967.

JENSON, S. K.; DOMINIQUE, J. O. 1988. **Extracting topographic structure from digital elevation data for geographic information system analysis**. Photogrammetric Engineering & Remote Sensing, v. 54, n.11, p.1593–1600.

JOHNSON, J. A.; WICHERNA, W. W. 1998. **Applied multivariate statistical analysis**. Prentice Hall Series Statistics. 3 ed. 607p.

KAMIYA, I.; SATO, H. 2001. **Slope gradation as a useful tool for detecting landform features**. Bulletin of the Geographical Survey Institute, Geographical Survey Institute, Ministry of Land, Infrastructure and Transport, Japan, v. 47, p. 29- 34.

KAO, J. J. 1996. **A xerion – based perl program to train a neural network for grid pattern recognition**. Computers Geosciences, v. 22, n.9, p. 1033 – 1049.

KARTIEKEYAN, K.; MAJUNDER, K.L.; DASGUPTA, A .R. 1996. **An expert systems for land cover classification**. Photogrammetric Engineering & Remote Sensing, v. 62, n.5, p .1033-1049.

KAUTH, R. J. e THOMAS, G. S. 1976. **The tasseled cap – a graphic description of spectral-temporal development of agricultural crops as seen by Landsat**.

- Proceedings of Symposium on Machine Processing of Remotely Sensed Data, Purdue University, West Lafayette, Indiana, USA, p.4B41 –4B51.
- KENDEL, M., 1980 **Multivariate analysis**. Charles Griffin & Company. London. Second edition. In: ANTUNES, A. F. B. 2003, Classificação de Ambiente Ciliar Baseada em Orientação a Objeto em Imagens de Alta Resolução Espacial. Tese de doutoramento Universidade Federal do Paraná. 147 p.
- KOHONEN, K. 1980. **Self - organization and associative memory**. Berlin. Springer. Verlang.
- KOK, R., SCHNEIDER, T., AMMER, U., 1999. Object-based classification and application in alpine Forest environment. *International Archives of Photogrammetry and Remote Sensing*. Valladolid. Espanha. v. 32, p. 110-155.
- KOVÁCS, Z. L. 1996. **Redes Neurais Artificiais – Fundamentos e Aplicações**. 2ª ed. São Paulo, editora Collegium Cognitione e editora Acadêmica, 163p.
- LEE, J. ; SNYDER P. K. ; FISHER, P. F. 1990. **Modeling the effect of data errors on feature extraction from digital elevation model**. *Photogrammetric Engineering & Remote Sensing*. v. 63, n. 10, p.1461- 1467.
- LEES, B. G. 1996. **Neural network application in the geoscience: an introduction**. *Computers Geosciences*, v. 22, n.9, p. 955 – 957.
- LILLESAND, T. M.; KIEFER, R. W. 2000. **Remote sensing and image interpretation**. 3ª ed. John Wiley & Sons. 724p. USA.
- LIPPMANN, R. 1987. **An introduction to computing with neural nets**. *IEEE ASSP Magazine*, v.2, p. 4-22.
- MAACK, R. 1981. **Geografia física do Paraná**. 2ª edição José Olympio. Rio de Janeiro, p. 450.
- MATLAB, 1998. **User`s Guide – Neural Network Toolbox**, version 3.0. Mth Works.
- MINTY, B. R. S. 1997. **The fundamentals of airborne gamma-ray spectrometry**. *AGSO Journal of Australian and Geophysics*. V.17, n. 2, p. 39-50.
- MITISHITA, E. A.1997. **Monorestituição digital de fotos associada com sistema de computação gráfica CAD, para fins de mapeamento na área florestal**. Tese de doutorado, Curso de Pós – Graduação em engenharia Florestal, Universidade federal do Paraná, Curitiba.p.251
- MONIZ, A. C. 1972. **Elementos de fotopedologia**. USP. São Paulo. 135p.

- MOON, W. M., 1990. **Integration of geophysical and geological data using evidential belief functional**. IEEE Transaction on Geosciences and Remote Sensing, v. 28 n. 4, p. 711-719.
- MULDERS, M. A. 1982. **Introduction airphoto – interpretation for landscape analysis soil survey**. Bodemkunde em geologie. Departament of Soil Science and Geology . Tropical Soils Section. Wagenigen Agricultural University. The Netherlands. 37p.
- MURNION, S. 1996. **Comparison of back propagation and binary diamond neural networks in the classification of LandSat TM image**. Computers Geosciences, v. 22, n.9, p. 995 – 1001.
- OLIVEIRA J.B.; JACOMINE, P.K.T.; CAMARGO, M.N. 1992. **Classes gerais de solos do Brasil : guia auxiliar de reconhecimento**. Jaboticabal, FUNEP. 201p.
- PAOLA, J. D. ; SCHOWENGERDT, R. A . 1997. **The effect of neural–network structure on a multispectral land–use/land–cover classification**. Photogrammetric Engineering & Remote Sensing, v.63, n.5, p.535–544.
- PELLEGRINO, G. Q.; PINTO, H. S.; ZULLO, J.J.; BRUNINI, O., 1998. **O uso de um sistema de informações geográficas no mapeamento de informações agrometeorológicas**. In: Sistema de Informações Geográficas – Aplicações na Agricultura. EMBRAPA. 2ª ed. p. 329-348.
- PIRES, A. C. B. 1995. **Identificação geofísica de áreas de alteração hidrotermal**. Crixás – Guarinos, Goiás. Revista brasileira de Geociências. São Paulo: SBG, v.25, n.1, p. 61-68.
- PORTUGAL, J. L.; S. Á ., L. A .C.M.; ROMÃO, V.M.C.; CARNAEIRO, A .F.T. 1999. **Modelo Digital de Terreno - Cartografia e Cadastro**. nº10 1999. p.23- 31.
- RABBEN, E. L.; CHALMERS JUNIOR, E.L.; MANLEY, E.; PICKNP, J. 1960. **Fundamentals of photointerpretation**. In: Manual of Photographic Interpretation. American Society of Photogrammetry – USA. p.99 -168.
- REIDMILLER, M.; BRAUN, H. 1993. **A direct adaptive meted for faster backpropagation learning: the RPROP algorithm**. Proc. IEEE Int. Conf. On NN (ICNN). P. 586 – 591. San Francisco.CA. USA.
- RIBEIRO, S.R. A . CENTENO, J.A . S. 2002. (a) **Clasificación del uso del suelo utilizando redes neurales y el algoritmo MAXVER**. Innovación, año 14, n.1, p. 55-60. Antofagasta- Chile.

- RIBEIRO, S.R. A. CENTENO, J.A. S. 2002. (b) **Integração de imagens de satélite e dados complementares para a delimitação de unidades de paisagem usando uma abordagem baseada em regiões.** Boletim de Ciências Geodésicas- Curso de Pós-Graduação em Ciências Geodésicas –UFPR. P. 47-57.
- RICHARDS, J. A. 1993. **Remote sensing digital image analysis.** 2 Ed. Springer Verlag, 339 p.
- RICHARDS, J. A.; JIA, X. 1999, **Remote sensing digital image analysis – an introduction.** 3ª ed. Springer Austrália., p. 363.
- ROCHA, H. O. 1993. **Integração de dados através da análise multivariada e interpretação de imagens orbitais para o levantamento de solos.** Tese para a obtenção do título de professor titular – Área de conhecimento Fotointerpretação e Levantamentos de Solos. Universidade Federal do Paraná, Curitiba - PR, p. 95.
- ROSEMBLATT, F. 1957. **The perceptrons: a perceiving and reconizing automaton (project PARA).** Technical Report. 85-460-1. Cornell Aeronautical Laboratory.
- ROSEMBLATT, F. 1962. **Principles of neurodynamics.** Spartan Books. New York.
- RUMMELHART, D.; HILTON, G.E.; WILLIAMS, R.J. 1986. Learning internal representation by error propagation in parallel data processing. Edited by RUMMELHART, D. E.; MC-CLELLAND, J. I. MIT Press, Cambridge, Massachussets, 318-362pp.
- SABINS, J. R.; FLOYD, F. 1987. **Remote sensing principles and interpretation.** 2ª ed. W.H. Freeman Co. New York, USA, p. 363.
- SARAIVA, C. C. S., 2000. **Geração de grade regular de pontos altimétricos: um estudo de caso da folha Igarapé na escala de 1:25.000.** Seminário II-PPGCG- Curso de Pós Graduação em Ciências Geodésicas. Universidade Federal do Paraná. 31 p.
- SARAIVA, C. C. S., 2001. **Avaliação das grades regulares geradas pelos métodos de Kriging e inverso da distância de uma potência para fins de monorestituição.** II COLOQUIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS. Curitiba- PR.

- SILVA, F.V., 1999. **Integração gamaespectrométrica - geológica da folha Curitiba**. Dissertação de Mestrado- Universidade Federal do Paraná, Curitiba - PR, p165.
- SIMPSON, P. K. 1990. **Artificial neural systems foundations, paradigms, applications and implementations**. San Diego: Pergamon Press.
- SMITH, M. B. ; BRILLY, M. 1992. **Automated grid element ordering for GIS – based overland flow modeling**. Photogrammetric Engineering & Remote Sensing. v. 63, n.5, p. 579- 586.
- SOLBERG, A. H. S.; TAXT, T. ; JAIN, A. K. 1996. **A Markov random field model for classification of multisource satellite imagery**. IEEE Transactions on Geosciences and Remote Sensing. v. 34, n. 1, p. 100-112
- SONKA M. ; HLAVAC, V.; BOYJE R. 1998. **Image processing. Analysis, and machine vision**. 2 ed. Brooks / Cole Publishing Company. USA. 770p.
- TAFNER, M. A. ; XEREZ, M. ; RODRIGUES I. W. F. 1995. **Redes neurais artificiais: introdução e princípios de neurocomputação**. Blumenau. Editora da FURB, p. 190.
- TIMOTHY, A ; CAMPAGNA, D. ; EVANS C. ; LEVANDOWSKI, W. D. ; CETIN, H. 1991. **Analysis remote sensing geobotanical trends in Quetico Provincial Park, Ontario, Canada, using digital elevation data**. Photogrammetric Engineering & Remote Sensing. V. 63, n. 9 p. 1179- 1183.
- UNIVERSIDADE FEDERAL DO PARANÁ. 1966 – **BOLETIM DE GEOLOGIA – Curitiba**. PR, 29p.
- VEAUX; R. D.; SCHUMI, J.; SCHWEINSBERG, J. ;UNGAR, L. H. 1998. **Prediction interval for neural network via nonlinear regression**. Theometrics, v.40, p. 273-282.
- VENTURIERI A.; SANTOS, J. R. 1998. **Técnicas de classificação de imagens para análise de cobertura vegetal**. Sistema de Informações Geográficas- Aplicações na Agricultura. EMBRAPA. 2ª ed. Brasília. 351-371p.
- WARNAER, T. A.; SHANK, M. 1997. **An evaluation of the potential fuzzy classification of multispectral data using artificial neural networks**. Photogrammetric Engineering & Remote Sensing. v.63, n.11, p.1285-1294.
- WERBOS, P. J. 1974. **Beyond regression: new tools for prediction and analysis in the behavioral science**. Harvard University. Tese de Phd.

- WILFORD, J. R. A.; BIERWIRTH, P.N.; CRAIG, M. A. 1997. **Application of airborne gamma-ray spectrometry in soil / regolith mapping and applied geomorphology**. AGSO JOURNAL of Australian Geology & Geophysics, Airborne Magnetic and Radiometric Surveys, v. 12, n. 2. Blackwell Science for the Geological Society of Australia. Australian. p. 200-232.
- WILLHAUCK, G. BENZ, U. SIERGERT, F. 2000 **Semiautomatic classification procedures for FIRE monitoring using multitemporal SAR images and NOAA-AVHRR hotspot data**. Defines digital paper. Munich.
- WINDROW, B.; HOFF, M. E..1960. **Adaptive switching circuits**. IN: IRE WESCON, p.96-104. New York. Convention Record.
- WOLF, P. R. 1983. **Elements of Photogrammetry with photo interpretation and remote sensing**, 2 Ed. McGraw – Hill Book Company. USA, 683 p.

APÊNDICE I

• CORREÇÃO GEOMÉTRICA

Segundo CHUVIECO (1990, p. 205) a correção geométrica se realiza em três fases:

- Primeira é a localização de pontos comuns na imagem, a ser corrigida, e no mapa ou em outra imagem já georreferenciada;
- Segunda é o cálculo das funções de transferência entre as coordenadas da imagem e da referência (mapa ou imagem georreferenciada previamente);
- Terceira a transferência dos níveis de cinza originais para a nova posição (reamostragem), definida pela transformação prévia.

O mesmo autor ainda cita que é utilizado o erro médio quadrático para que se tenha confiança na correção geométrica da imagem, e esse erro deve estar dentro de "margens" toleráveis, de acordo com a escala e a precisão com que se pretende obter os resultados.

A correção geométrica pode ser chamada de absoluta, quando é executada tendo como referência um mapa com projeção cartográfica padronizada e dita relativa se a correção é feita imagem x imagem. Os pontos de controle devem ser de fácil localização na imagem e no mapa (correção absoluta) ou na imagem referência e imagem a ser corrigida (correção relativa); devem ser bem distribuídos, estáveis e destacados tanto na imagem como na referência. Algumas feições são as mais usadas como pontos de controle, tais como interseções de estradas, curvas de rios, construções, etc (GUPTA, 1991, p.191).

Segundo GONZALES e WOODS (1998, p. 213), a interpolação pelo vizinho mais próximo tem a desvantagem de produzir efeitos indesejáveis, como a distorção de bordas retas em imagens de resolução fina. Resultados mais suaves podem ser obtidos usando-se técnicas mais sofisticadas, tal como a convolução cúbica, entretanto, do ponto de vista computacional essa técnica é custosa e uma saída razoável é utilizar uma abordagem de interpolação bilinear que, por meio dos níveis de cinza de quatro "pixels" vizinhos, executa a reamostragem de todos os "pixels" da imagem.

A imagem do satélite Landsat TM5 na composição colorida falsa cor 3, 4, 5, serviu de base para a correção geométrica da imagem Landsat7 ETM+ (sete bandas espectrais). A escolha dessa composição deve-se às características intrínsecas a cada uma destas faixas do espectro eletromagnético, ou seja, a banda 3 apresenta bom contraste entre diferentes tipos de cobertura vegetal, a banda 4 permite a identificação de corpos de água e geomorfologia e a banda 5 apresenta sensibilidade às variações de uso do solo.

A imagem do satélite Landsat7 ETM+ (bandas 1, 2, 3, 4, 5, 6, e 7) foi processada no programa ENVI 3.0 para a execução da correção geométrica, as sete (7) bandas foram georreferenciadas à partir da imagem digital composição colorida falsa cor 3, 4 e 5 Landsat TM5 (imagem x imagem).

A reamostragem das sete (7) bandas da imagem digital Landsat TM7 foi executada por meio da interpolação bilinear e um polinômio do segundo grau foi utilizado para a correção geométrica da imagem. A utilização do polinômio do segundo grau é justificada devido ao fato da área física em questão ter um relevo acidentado (espigões que se alongam segundo as direções estruturais de dobramento e intrusões que provocam o aparecimento de boqueirões ou esporões), como citado na seção 3.1.2 neste trabalho. Segundo RICHARDS (1993, p.51) a utilização do polinômio de primeiro, segundo ou terceiro grau está vinculada à complexidade da área a ser corrigida. Como citado, a reamostragem foi executada utilizando o interpolador bilinear de acordo com GONZALES e WOODS (1998, p. 213).

A seguir encontram-se as Equações 3.1 e 3.2 referentes ao Interpolador Bilinear (reamostragem) e ao Erro Médio Quadrático (RMS - verificação do erro de correção), respectivamente.

$$V'_i = \left[\frac{V_3 - V_1}{D} \right] * d_y + V_1 \quad (3.1)$$

Onde;

Y_i : coordenada Y do "pixel" i ;

V_i : valor numérico do "pixel" i ;

D : distância em Y_1 e Y_m do sistema de coordenadas original;

D_y : distância em Y_1 e Y_3 do sistema de coordenadas original.

$$RMS = \sqrt{(x_r - x_i)^2 + (y_r - y_i)^2} \quad (3.2)$$

Onde:

x_r e x_i : coordenadas re transformadas;


y_r e y_i : dados originais de entrada.

No processamento da imagem foi constatado um erro médio quadrático de 0,36 "pixel", isto é, 10,8 metros, menor que um "pixel" da imagem Landsat7 ETM+, portanto aceitável, conforme RICHARDS e JIA (1999, p. 63).

APÊNDICE II


1. IMAGENS SATÉLITE

Banda 7




2. IMAGENS ARTIFICIAIS


“Tasseled Cap” – Primeira característica: Brilho



“Tasseled Cap” – Segunda característica: Verdor




“Tasseled Cap” – Terceira característica: Umidade




3. IMAGENS SATÉLITE E DERIVADAS, SEGMENTADAS


BANDA 7




BANDA 4




CP1



CP2




CP3

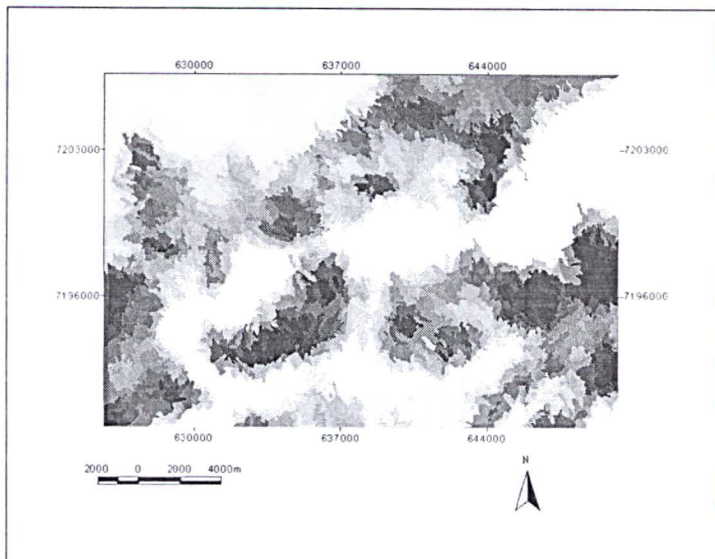


3. IMAGENS DOS ELEMENTOS GAMAESPECTROMÉTRICOS (U, Th e K) SEGMENTADAS


U



Th




K




4 IMAGENS DERIVADAS DA CURVAS DE NÍVEL SEGMENTADAS


MDT




GRADIENTE DA ENCOSTA




EXPOSIÇÃO DA RAMPA



5 IMAGEM DAS MICROBACIAS SEGMENTADAS

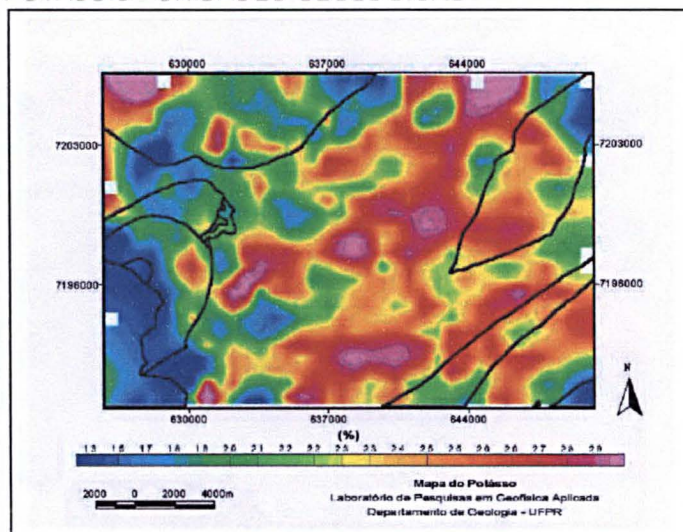


6 IMAGEM DAS MICROBACIAS SOBREPOSTA PELA REDE DE DRENAGEM

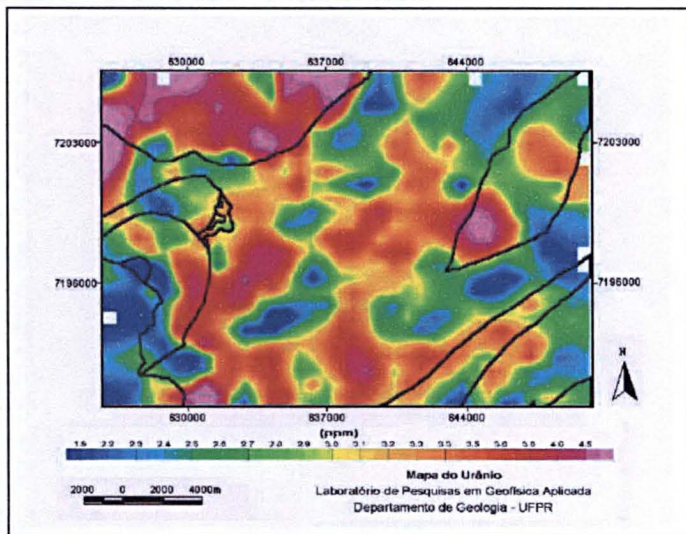


6. IMAGENS GAMAESPECTROMÉTRICAS SOBREPOSTAS PELO VETOR DAS UNIDADES GEOLÓGICAS.

POTÁSSIO - UNIDADES GEOLÓGICAS



URÂNIO - UNIDADES GEOLÓGICAS



APÊNDICE III

1. TABULAÇÃO CRUZADA TENDO COMO VERDADE CAMPO A FOTOINTERPRETAÇÃO E ELEMENTO MÍNIMO O "PIXEL"

A Tabela 5.3 (A) mostra o resultado da tabulação cruzada entre "verdade de campo" (Fotointepretação) com os dados de entrada (CP13, CP23, CP33, MDT e Microbacias)

Tabela 5.3 (A)– Resultado da Tabulação Cruzada entre a "verdade campo" e a imagem classificada (CP13, CP23, CP33, MDT e Microbacias)

Unidades	Total pixel I. Class.	Total de Pixel "V. campo"	Pixel por classe	Índice	
				I. Class	"V. Campo
1	130592	106789	69426	53,1	65,1
2	18786	14571	11193	59,6	76,8
3	41728	13724	6141	14,7	44,8
4	79112	87912	36825	46,5	41,9
5	64695	59129	31494	48,7	53,3
6	88859	176019	40775	46,0	23,2
7	55829	21457	8853	15,9	78,4

CRAMER=0,4192

A Tabela 5.3 (B) mostra o resultado da tabulação cruzada entre "verdade de campo" (Fotointepretação) com os dados de entrada (CP13, CP23, CP33, MDT, Microbacias e Dados gamaespectrométricos (K))

Tabela 5.3 (B) – Resultado da Tabulação Cruzada entre a “verdade campo” e a imagem classificada (CP13, CP23, CP33, MDT, Microbacias e Dados gamaespectrométricos (K))

Unidades	Total pixel I. Class.	Total de Pixel “V. campo”	Pixel por classe	Índice	
				I.Class	“V. Campo
1	161540	106789	76634	47,4	71,8
2	22820	14571	11121	48,7	76,3
3	31494	13724	7739	24,6	56,4
4	85266	87912	38557	45,2	43,9
5	60230	59129	33106	54,9	56,0
6	68873	176019	32440	47,1	18,4
7	49378	21457	10748	21,7	95,6

CRAMER=0,4347

2. TABULAÇÃO CRUZADA TENDO COMO VERDADE CAMPO A FOTOINTERPRETAÇÃO E ELEMENTO MÍNIMO SEGMENTO

A Tabela 5.4 (A) mostra o resultado da tabulação cruzada entre “verdade de campo” (Fotointepretação) com os dados de entrada (CP13, CP23, CP33, MDT e Microbacias)

Tabela 5.4 (A) – Resultado da Tabulação Cruzada entre a “verdade campo” e a imagem classificada (CP13, CP23, CP33, MDT e Microbacias)

Unidades	Total pixel I. Class.	Total de Pixel “V. campo”	Pixel por classe	Índice	
				I.Class	“V. Campo
1	91258	106789	59912	65,7	56,1
2	20372	14571	11684	57,4	80,2
3	39382	13724	8950	22,7	65,2
4	92922	87912	46520	48,0	52,9
5	60403	59129	32981	54,6	55,8
6	125120	176019	65500	52,4	37,2
7	50144	21457	11426	22,8	53,3

CRAMER=0,4767

A Tabela 5.4 (B) mostra o resultado da tabulação cruzada entre "verdade de campo" (Fotointerpretação) com os dados de entrada (CP13, CP23, CP33, MDT, Microbacias e Banda 7)

Tabela 5.4 (B) – Resultado da Tabulação Cruzada entre a "verdade campo" e a imagem classificada (CP13, CP23, CP33, MDT, Microbacias e Banda 7)

Unidades	Total pixel I. Class.	Total de Pixel "V. campo"	Pixel por classe	Índice	
				I.Class	"V. Campo
1	105387	106789	63231	60,0	59,2
2	24730	14571	11810	47,8	81,1
3	28937	13724	7826	27,0	57,02
4	97789	87912	43299	44,3	49,3
5	63381	59129	37935	59,9	64,2
6	113787	176019	58258	51,2	33,1
7	45590	21457	11661	25,6	54,4

CRAMER=0,4669

3. TABULAÇÃO CRUZADA TENDO COMO VERDADE CAMPO O MAPA GEOLÓGICO E ELEMENTO MÍNIMO SEGMENTO

A Tabela 5.5 (A) mostra o resultado da tabulação cruzada entre "verdade de campo" (mapa geológico) com os dados de entrada (MDT, Microbacias, Banda 4, Gradiente da Encosta, Dados gamaespectrométricos Th).

Tabela 5.5 (A) – Resultado da Tabulação Cruzada entre a “verdade de campo” e a imagem classificada (MDT, Microbacias, Banda 4, Gradiente da Encosta, Dados gamaespectrométricos Th)

Unidades	Total pixel I. Class.	Total de Pixel “V. campo”	Pixel por classe	Índice	
				I.Class	“V. Campo
1	188276	293489	157275	83,5	53,3
2	92191	93829	74438	80,7	79,3
3	28776	21736	16049	55,8	73,8
4	106268	67015	39569	37,2	59,0
5	26310	1411	1363	5,2	96,6
6	5154	2121	2093	40,6	98,7

CRAMER=0,5493

A Tabela 5.5 (B) mostra o resultado da tabulação cruzada entre “verdade de campo” (mapa geológico) com os dados de entrada (MDT, Microbacias, Gradiente da Encosta, Banda 4, Dados gamaespectrométricos Th, U e K)

Tabela 5.5 (B) – Resultado da Tabulação Cruzada entre a “verdade campo” e a imagem classificada (MDT, Microbacias, Gradiente da Encosta, Banda 4, Dados gamaespectrométricos Th, U e K)

Unidades	Total pixel I. Class.	Total de Pixel “V. campo”	Pixel por classe	Índice	
				I.Class	“V. Campo
1	185019	293489	163331	88,3	55,7
2	94420	93829	72629	76,9	77,4
3	24953	21736	18186	72,9	83,7
4	97945	67015	39156	40,0	58,4
5	42347	1411	1368	3,2	97,0
6	3779	2121	2117	56,0	99,8

CRAMER=0,6051