

Integração de imagens digitais, dados gamaespectrométricos e complementares a fim de separar unidades geológicas utilizando redes neurais artificiais e uma abordagem baseada na análise de regiões

Selma Regina Aranha Ribeiro¹
Jorge Antonio Silva Centeno¹

Universidade Federal do Paraná - Departamento de Geomática
Caixa Postal 19001- 81531-990 - Curitiba PR - Brasil
(selmar, centeno)@ufpr.br

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 geological units. 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. For the digital classification of the geological units, the relevant information was the digital terrain model, represented the relief, the micro basins, represented the drainage, and to represent the geology, the element Thorium, Uranium and Potassium.

Palavras-chave: remote sensing, geology, data base integration, artificial neural networks, sensoriamento remoto, geologia, integração de dados, redes neurais artificiais.

1. INTRODUÇÃO

Várias técnicas vêm sendo empregadas para automatizar a análise e classificação de imagens digitais. Pesquisas mais recentes tem utilizado as técnicas da inteligência artificial para reconhecimento de padrões e classificação de imagens digitais integrando dados de diferentes origens. A técnica das redes neurais artificiais (RNA) é usada para a classificação do uso do solo com sucesso, podendo-se citar os trabalhos de Ricchetti (2000) e Ji (2000). A vantagem das RNA sobre outros classificadores é a facilidade na integração de dados de diferentes origens, resoluções, datas e escalas e de não necessitar de conhecimento da distribuição estatística das classes.

Uma das vantagens do uso de RNA é a facilidade para efetuar a integração de dados de diferentes origens na classificação digital, pois isto incrementa a análise de maneira similar a análise visual. A integração de dados de diferentes origens e escalas, tais como informações a respeito do relevo e rede de drenagem e imagens de satélite é um tema atual e têm sido enfoque de estudo de autores tal como Ribeiro e Centeno (2002), dentre outros.

Uma fonte alternativa de dados, compatível com as imagens multiespectrais, é um levantamento gamaespectrométrico aerotransportado. A espectrometria aerotransportada é uma técnica passiva de sensoriamento remoto. Ela se baseia na emissão terrestre de raios gama, uma forma de alta energia e curto comprimento de onda da radiação eletromagnética. 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 (K), de Tório (Th) e de Urânio (U) em rochas e materiais intemperizados, por meio da detecção dos raios gama emitidos do decaimento ativo e natural dos isótopos radioativos desses elementos (Wilford, et al. 1997).

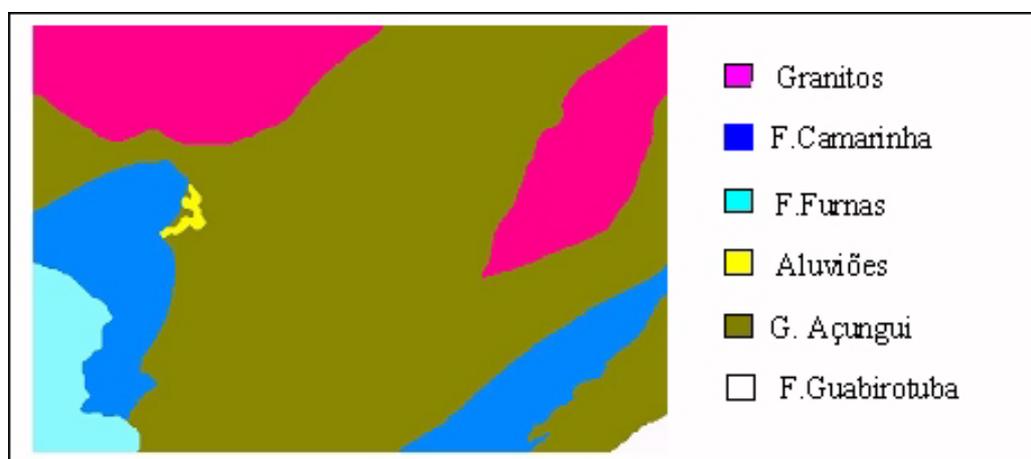
O presente estudo utilizando a técnica das RNA, executou a separação automática de unidades geológicas e comparou o produto gerado com o mapa geológico, no formato digital.

Para a geração da imagem contendo as unidades geológicas separadas mediante o processamento da RNA, foram utilizados dados advindos do sensoriamento remoto, isto é, imagens orbitais e gamaespectrométricas, integrados a informações complementares que descrevem as características hidrológicas e de relevo baseando-se na análise orientada a regiões.

2. ÁREA DE ESTUDO

A área de estudo está localizada na Folha Campo Largo (IBGE, 1983). 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. Na **Figura 1** encontra-se a imagem contendo as seis (6) unidades a serem separadas, isto é, a “verdade de campo”, originária do mapa geológico.

Figura 1 - Mapa geológico da área de estudo – Modificado MINEROPAR, 1977.



3. MATERIAIS

Os seguintes materiais foram utilizados: Imagens digitais - Landsat7 ETM+ (221_77, 2000) e dos radioelementos: Urânio, Tório e Potássio; Curvas de nível-formato digital, equidistância de 20 m (empresa SENAGRO) Folha Campo Largo (SG-22-C-X-III-3 - IBGE, 1983); Mapa Geológico-Folha Campo Largo (SG-22-C-X-III), formato digital - MINEROPAR/CPRM/SUREG-SP/Comissão da Carta Geológica do Paraná;

Estes dados foram processados usando diversos programas, como: ENVI 3.6- Correção geométrica e transformações espectrais; SURFER 7.0- Geração do MDT; ArcView 3.2a, módulo 3D “Spatial Analysis”-Delineamento de microbacias a partir do MDT; eCognition 2.0- Segmentação; IDRISI 3.0 – Fase de Verificação; MatLab 5.3- Processamento das RNA; Geosoft - Recorte - interpolação das imagens do levantamento aerogamaespectrométrico.

4. MÉTODOS

Variáveis que representam o relevo e drenagem

As curvas de nível foram interpoladas para definir um modelo matemático que representasse a superfície que descreve a variação contínua do terreno, portanto, o modelo digital do terreno (MDT). A partir do MDT foram derivadas novas grades, como gerado o gradiente da encosta. Aplicando a abordagem de Jenson e Dominique (1988), foram delineadas as microbacias a partir do MDT, e com isto, uma imagem do acúmulo de água que simula a quantidade de água em cada célula foi gerada.

Variável que representa as sete bandas espectrais

A transformação de componentes principais (CP) procura explicar a estrutura de variância - covariância da matriz de dados através de combinações lineares não correlacionadas das variáveis originais. Frequentemente a variabilidade de todas as variáveis originais pode ser explicada por um número menor de componentes principais. Uma menor quantidade de componentes principais podem então substituir as variáveis iniciais e o conjunto de dados é reduzido. Seguindo este princípio, as sete bandas espectrais Landsat7 ETM+, foram processadas, no programa ENVI, onde as três primeiras componentes passaram a representar 96,62% das informações das sete bandas originais.

Variáveis geradas a partir da gamaespectrometria teletransportada

Dados gamaespectrométricos correspondentes à região de estudo (Folha Campo Largo) foram extraídos do Projeto Aerofísico Serra do Mar Sul. O arquivo contendo os dados gamaespectrométricos dos radioelementos Urânio, Tório e Potássio foi importado para o programa “Geosoft”, o qual gera uma grade regular por meio de interpolação dos dados tabelados. Os dados gamaespectrométricos (K, Th e U) foram transformados em uma malha regular, com resolução de 30m, pelo processo de interpolação da curvatura mínima, o qual produz uma superfície cujos valores são muito próximos dos dados originais, segundo Briggs (1974).

Seleção de variáveis

Analisando a variação dos dados na região, foram identificadas as variáveis consideradas mais relevantes em relação ao relevo, a drenagem, a aerogamaespectrometria e variação espectral. Elas são: Banda 4 Landsat7 ETM+, as CP a partir das 7 bandas espectrais da imagem Landsat7 ETM+, MDT, gradiente da encosta, microbacias e as imagens geradas a partir do levantamento gamaespectrométrico teletransportado (U, Th e K).

Processamento digital de imagens - segmentação

A segmentação é o primeiro passo para a análise de imagens digitais baseada em regiões. O processo de segmentação representa um passo no sentido de preparar as imagens digitais para uma futura classificação temática, onde os elementos analisados e utilizados são regiões resultantes da aplicação do segmentador utilizado para a definição do espaço de atributos da classificação.

Neste trabalho, optou-se por utilizar o método conhecido como FNEA (Baatz and Schäpe, 1999). Esta técnica funciona como um processo de otimização heurística que minimiza a heterogeneidade média das regiões da imagem para alcançar uma resolução ótima para toda a cena em função de parâmetros previamente fixados. Ou seja, “pixels” adjacentes e similares são agregados por regiões (segmentos) onde a heterogeneidade no domínio espectral e espacial é minimizada. Segmentos vizinhos são “fundidos”, formando um novo segmento (região). Portanto, dois critérios de semelhança são usados para descrever a separação de objetos da imagem, os critérios de cor e de forma, ambos controlam a homogeneidade dos segmentos.

A heterogeneidade do domínio espectral, exemplificada por meio da **Equação 1**, é composta pela soma dos desvios padrão dos níveis de cinza 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 isso deve-se considerar a heterogeneidade espacial.

A heterogeneidade no domínio espacial depende de como é a forma da função compacidade, calculada pela razão entre o comprimento da borda de um objeto pelo número total de “pixels” deste objeto, demonstrada pela **Equação 2** e também pela suavidade 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** (Antunes, 2003).

$$H_c = \sum W_c \cdot \sigma_c \quad (1)$$

$$H_{fc} = \frac{L}{\sqrt{N}} \quad (2)$$

$$H_{fs} = \frac{L}{B} \quad (3)$$

onde:

W_c – pesos

σ_c - desvio padrão médio dos valores espectrais

H_c - heterogeneidade de cor

H_{fc} – compacidade do objeto

H_{fs} – suavidade do objeto

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)

A participação de cada fator na segmentação é dada por **Equação 4**:

$$H = (a) H_c + (1-a) H_f \quad (4)$$

Onde “a” representa um fator ponderador escolhido pelo usuário e H_f heterogeneidade da forma.

Os segmentos podem então ser descritos em termos espectrais e/ou espaciais para fins de classificação. Os descritores espectrais podem ser o “brilho”, o valor médio, a razão entre bandas, etc; e pode-se citar como descritores espaciais o fator de forma, o comprimento, a largura, a direção principal, dentre outros. No estudo foi utilizado o descritor valor médio de brilho.

As variáveis de entrada foram segmentadas no programa eCognition, adotando-se 0,7 como peso para a cor e 0,3 para a forma, considerando em relação a forma o valor de 0,7 para a suavidade e 0,3 para a compacidade, valores esses definidos experimentalmente de acordo com o estudo.

Redes neurais artificiais (RNA)

As RNA representam uma linha de pesquisa da inteligência artificial, que visa investigar a possibilidade de simulação de comportamentos inteligentes por meio de modelos baseados no comportamento do cérebro humano. São compostas por unidades de processamento simples operando em paralelo. Inspiradas nos sistemas biológicos dos neurônios. Em cada neurônio, os impulsos de entrada (x) são ponderados e somados, gerando uma saída (y). Para isto, pesos (w) são atribuídos a cada entrada (Haykin, 1999). Esta função pode ser simulada matematicamente, por meio das **Equações 5 e 6**.

$$Y = f (S_i) \quad (5)$$

$$S_i = \sum w_{ij} x_i \quad (6)$$

onde:

Y – saída

w_{ij} – peso atribuído da entrada j ao neurônio i

S_i - função ativação

x_i – entrada do neurônio i

As unidades de processamento (neurônios) das RNA são usualmente organizadas em camadas, 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 onde ocorre o processamento por meio de um sistema de conexões ponderadas. A camada de saída apresenta o resultado do processamento (Foody et al., 1995).

A RNA pode ser treinada para resolver problemas de classificação multiespectral. Treinar uma rede significa ajustar a sua matriz de pesos de forma que o vetor de saída coincida com um certo valor desejado para cada vetor de entrada.

O algoritmo para treinamento da RNA mais conhecido é o da retropropagação do erro. É um treinamento supervisionado que utiliza para o treinamento dos pesos em uma rede de multicamadas o processo de minimização do gradiente descendente e o limiar da função sigmoideal, considerado uma generalização da regra delta para rede neural (“feedforward”). A regra delta ou do erro médio quadrático 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.

A arquitetura da RNA foi então definida com 5 a 8 variáveis de entrada, ou seja os neurônios da primeira camada; 120 neurônios na primeira camada oculta, considerando-se 360 amostras; 30 neurônios na segunda camada oculta e 6 neurônios na camada de saída.

Coleta das amostras

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 sejam representativas. 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.

5. EXPERIMENTOS

Nos primeiros testes, usando somente as variáveis espectrais, o processamento da rede não “convergiu”. Portanto acrescentou-se as variáveis representantes do relevo, da rede de drenagem e as informações referentes a aerogamaespectrometria.

A seguir foram verificadas diferentes combinações de variáveis espectrais derivadas das imagens Landsat, com os dados das outras fontes. Por exemplo, a inclusão da variável gamaespectrométrica Potássio, juntamente com as três componentes principais, o MDT, as microbacias e a banda 4 foi mais eficiente. O processamento foi de apenas 140 iterações e o erro médio quadrático passou a ser apenas 0,000008.

Com base nestes testes, a variáveis de entrada definidas foram os segmentos obtidos após a segmentação do seguinte conjunto de variáveis: as imagens do MDT, as microbacias, o gradiente da encosta, a banda 4, a CP e dos dados gamaespectrométrico (U, Th e K). Como saída as unidades geológicas: Grupo Açungui, Formação Furnas, Aluviões, Formação Guabirotuba, Formação Camarinha e os Granitos do Cerne e Três Córregos, como ilustrado na **Figura 1**. Na **Tabela 1** encontram-se os três testes os quais foram utilizados como dados de entrada as variáveis enumeradas.

Tabela 1 – Variáveis de entradas utilizadas nos três testes executados.

Variáveis	MDT	Microbacias	Banda 4	Gradiente	Th	U	K	1ª CP
Teste 1								
Teste2								
Teste 3								

6. RESULTADOS E DISCUSSÕES

A eficiência da classificação foi avaliada comparando os resultados da classificação com o mapa temático das unidades geológicas, “verdade de campo”, por meio de uma tabulação cruzada. A tabulação cruzada pode ser descrita como um “overlay” múltiplo mostrando todas as combinações da operação lógica AND. Esta tabulação também fornece o grau de consonância entre a classificação e a “verdade de campo”, isto é, o grau de afinidade ou correlação entre duas imagens é medido pelo coeficiente de correlação “Cramer’s V”. Essa medida é um coeficiente que varia na faixa de 0 até 1, indicando nenhuma e perfeita correlação respectivamente, utiliza da estatística de Qui-Quadrado e mede o grau de afinidade entre duas imagens. O resultado é uma nova imagem que mostra os locais de todas as combinações das categorias (classes) das imagens originais.

Para a classificação das unidades geológicas obteve-se um coeficiente de Cramer’s V de 0,6051, teste 1; 0,5493, teste 2 e 0,3633 para o teste 3 onde não foram adicionadas as variáveis gamaespectrométricas.

A **Tabela 2** exibe o resultado da tabulação cruzada entre as classificações (testes 1, 2 e 3) e a “verdade de campo”, mapa geológico, apresentado na Figura 1. Os teste executados foram os abaixo discriminados:

Tabela 2 – Resultado da tabulação cruzada (Índice de Cramer’s V) entre a “verdade de campo” e as imagens dos testes 1, 2 e 3.

Teste 1	Índice =0,6051	MDT, microbacias, , banda 4, gradiente da encosta, Th, K e U.
Teste 2	Índice =0,5493	MDT, microbacias, banda 4, gradiente da encosta, Th e U.
Teste 3	Índice =0,3633	MDT, microbacias, banda 4, gradiente da encosta, e 3ª CP.

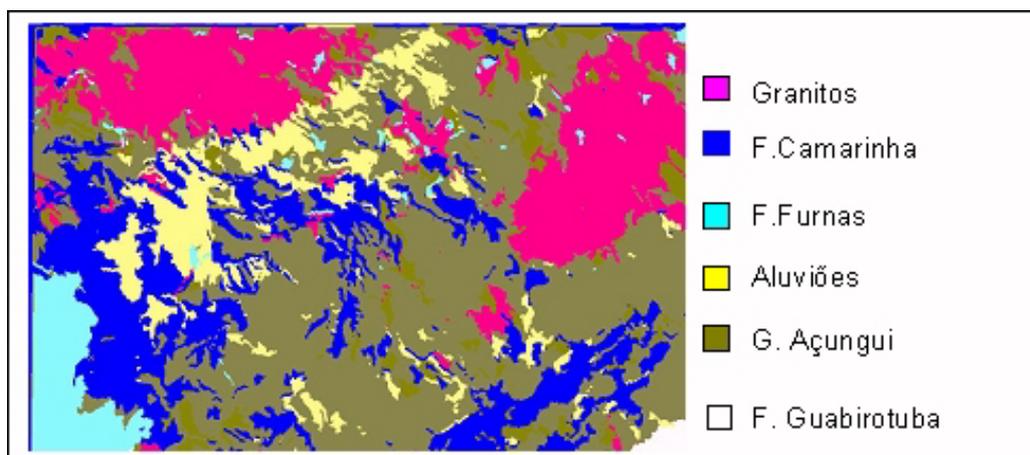
O melhor resultado avaliado por meio do coeficiente de correlação (Índice de Cramer’s V) foi para o primeiro teste, com as variáveis de entrada MDT, as microbacias, a banda 4, o gradiente da encosta e os elementos U, Th e K. A **Tabela 3** exibe o resultado da tabulação cruzada em percentual para os três testes.

Tabela 3 – Resultado da tabulação cruzada em percentual (acertos)

Testes	Unidades					
	F.Guabirota	G.Açungui	F. Furnas	F. Camarinha	Aluviões	Granitos
1	99,8%	97,0%	83,7%	77,4%	58,4%	55,7%.
2	98,7%	96,6%	73,8%	79,3%	59,0%	53,3%
3	0%	4,5%	65,7%	57,6%	43,4%	36,6%

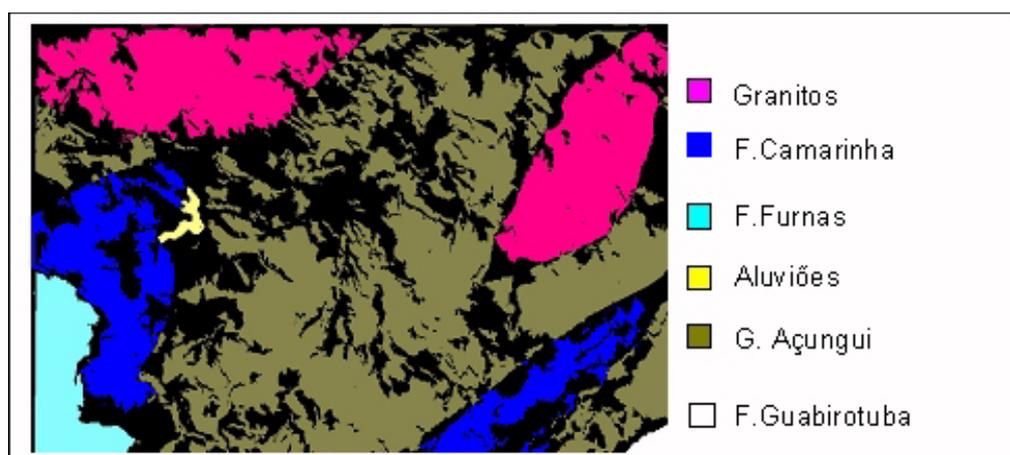
Ainda em relação a “verdade de campo”, para os testes de números 1 e 2 que contém informações dos elementos oriundos do levantamento gamaespectrométrico, as unidades Formação Guabirota e Grupo Açungui foram as duas melhores discriminadas. A maior concentração dos elementos K, Th e U encontram-se na unidade Grupo Açungui e para a unidade Formação Guabirota o elemento Th; sugerindo que a presença desses elementos no processamento auxiliam na discriminação das unidades citadas. A **Figura 2** mostra o resultado do primeiro teste, o melhor resultado.

Figura 2 - Imagem do resultado do teste 1, com as seis unidades separadas.



Na **Figura 3** pode-se verificar o resultado da tabulação cruzada entre a imagem classificada (**Figura 2**) e a “verdade de campo” (**Figura 1**). As áreas de cor preta foram classificadas erroneamente.

Figura 3 - Imagem do resultado da tabulação cruzada entre as Figuras 2 e 1.



7. CONCLUSÕES

O estudo comprovou que a utilização de RNA para a separação de unidades geológicas, automaticamente, é viável. Esta metodologia é satisfatória e facilita a integração de dados de diferentes origens, fato este importante para a descrição das unidades, pois somente dados advindos das bandas espectrais não são suficientes para a caracterização de classes (unidades), como verificado anteriormente.

A associação de dados complementares deve ser analisada de acordo com as variáveis que representem a área física em questão. Neste estudo a inferência de informações referente ao relevo e rede de drenagem integradas a imagem digital banda 4 e a primeira componente, gerou uma classificação com o mais baixo coeficiente de correlação (**Tabela 2** - teste 3) na separação das unidades, portanto pode-se acrescentar que a integração de dados de diferentes origens, que sejam relevantes para o estudo, é pertinente pois se pode notar que essa associação interfere na classificação melhorando a discriminação de determinadas unidades com a introdução de variáveis que realcem as suas feições, como nos testes 1 e 2 com a complementação de informações, obtidas por aerogamaespectrometria, dos elementos Tório, Urânio e Potássio para o primeiro teste e somente do Tório para o teste 2 aumentando o coeficiente de correlação para 0,6051 e 0,5493, respectivamente.

Importante salientar que a entrada das variáveis foi com as imagens segmentadas, isto é, foi utilizada a análise baseada em regiões e não em “pixel”. A utilização da abordagem por regiões foi adotada devido ao fato de, anteriormente a esses resultados testes terem sido processados analisando-se o “pixel” e esses apresentaram resultados inferiores.

8. REFERÊNCIAS BIBLIOGRÁFICAS

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.

BAATZ, M. e SCHÄPE, A., 1999: *Object-Oriented and Multi-Scale Image Analysis in Semantic Networks*. In: *Proc. Of the 2nd International Symposium on Operationalization of Remote Sensing*. August 16.th-20th, 1999. Enschede. ITC

BRIGGS, I. C. 1974. *Machine contouring using minimum curvature*. Geophysics, v.39, p. 39-48.

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.

HAYKIN, S.1999. *Neural networks. A comprehensive foundation*. 2 Ed. Prentice Hall. New Jersey. p. 842.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 1983, Rio de Janeiro (RJ) *Folha Campo Largo SG-22-X-C-III-1*, Mapa Topográfico, escala 1:50.000.

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.

JI C. Y. 2000. *Land-use classification of remotely sensed data using kohonen self-organizing feature map neural networks*. Photogrammetric Engineering & Remote Sensing. v.66, n.12, p.1451-1460.

MINEROPAR, Convênio DNPM – BADEP – UFPR 1977. *Folha Campo Largo - Mapa Geológico*. Folha SG – 22 – X – C – III. Escala 1:100.000.

RIBEIRO S. R. A.e CENTENO, J. A. S. 2002. *Integração de dados de diferentes origens na delimitação de unidades de paisagens utilizando uma abordagem baseada na análise de regiões*. Boletim de Geociências – UFPR, p. 47 – 57

RICCHETTI E. 2000. *Multispectral satellite image and ancillary data integration for geological classification*. Photogrammetric Engineering & Remote Sensing. v.66, n.4, p.429-435.

WILFORD, J.R.; 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 Australian. Australian. p. 200-232.