

INTEGRAÇÃO DE INFORMAÇÕES ESPECTRAIS E DE FORMA NA CLASSIFICAÇÃO DE IMAGENS COM REDES NEURAIS

Neural Networks Based Image Classification Using Spectral and Spatial Information

ANDRÉA FARIA ANDRADE
JORGE ANTONIO SILVA CENTENO

Curso de Pós-Graduação em Ciências Geodésicas
Universidade Federal do Paraná
Caixa Postal 515 – Centro Politécnico – Jardim das Américas
CEP 12201-970 - Curitiba – PR - Brasil
andrefar@ig.com.br; centeno@geoc.ufpr.br

RESUMO

Neste artigo são apresentados os resultados de um estudo que tem como objetivo a inserção da forma no processo de classificação, por considerar que a mesma é relevante na identificação de objetos presentes nas imagens de alta resolução espacial. A metodologia utilizada baseia-se na análise de regiões. Para isto, a imagem é segmentada e posteriormente os segmentos obtidos, que correspondem a objetos, são classificados usando informações espectrais e espaciais. O algoritmo de classificação utilizado se baseia no princípio das Redes Neurais Artificiais. A análise de forma comprovou ser uma poderosa ferramenta na separação de objetos com características espectrais similares nas imagens de alta resolução espacial, como a malha viária e construções.

ABSTRACT

In this paper, the results of a study that aims at inserting of shape parameters in the classification process is presented. The proposed methodology is based on the analysis of regions. Therefore, the image is segmented and later the resulting segments, that correspond to objects in the image, are classified using spectral and spatial information. The classification schema is based upon Artificial Neural Networks. Shape parameters proved to be a powerful tool that helps to discriminate objects with similar spectral characteristics in high spatial resolution satellite imagery, such as the road network and constructions.

1 INTRODUÇÃO

O recente aumento da resolução espacial dos sensores comercialmente disponíveis tornou interessante o uso de imagens orbitais para fins de mapeamento do espaço urbano, provocando uma revolução nos processos de geração e manutenção de bases cartográficas, como também nos processos clássicos de classificação de imagens (NISHIDA, 1998). Para garantir seu pleno aproveitamento, estes avanços devem ser acompanhados por aprimoramentos nas ferramentas de análise e processamento de imagens.

De acordo com MEYER e WERTH (1990), cerca de 95% dos processos de classificação de imagens atualmente empregados faz uso apenas dos atributos espectrais. Portanto não é surpreendente que existam erros em mapas temáticos provenientes da classificação de imagens multiespectrais. Sabendo desta limitação, esforços vêm sendo dedicados para aumentar a acurácia e a qualidade da classificação de imagens em sensoriamento remoto através da incorporação de dados auxiliares no processo de classificação (HUTCHINSON, 1982; FRANKLIN e WILSON, 1992).

Os algoritmos de classificação de imagens multiespectrais mais comuns estão baseados na análise de um restrito número de leituras associadas a cada pixel. Os recentes avanços na captura e processamento de imagens geraram alternativas para aprimorar os resultados da classificação, como o uso de imagens hiperespectrais e a inclusão de outros atributos, espaciais e de contexto, no processo decisório. Uma alternativa à abordagem *pixel a pixel* tradicional é o uso de técnicas de classificação *orientadas a regiões*. Nelas, a classificação não é feita analisando os valores de um único *pixel*, mas sim analisando regiões ou segmentos obtidos nas imagens através de um processo de segmentação (RIBEIRO *et al.*, 2002). A representação de uma imagem em termos de regiões permite a inclusão de atributos espaciais, como forma e textura, durante a fase de classificação.

O presente artigo aborda a questão da inclusão de parâmetros de forma no processo de classificação de imagens de alta resolução espacial pelo método orientado a regiões. A imagem utilizada para este estudo foi um recorte da imagem híbrida do sensor *IKONOS II* de uma região no Município de Matinhos, no Litoral Paranaense, resultante da fusão da banda pancromática com as bandas 2, 3 e 4 (verde, vermelho e infravermelho próximo).

2 ANÁLISE DA FORMA

A forma pode ser considerada como uma expressão de contorno dos objetos. Objetos formados por culturas agrícolas ou formados pelas construções observadas na paisagem urbana, normalmente tendem a apresentar formas regulares, enquanto que feições naturais tendem a apresentar formas irregulares (AVERY e BERLIN, 1992). Assim como a análise espectral baseia-se nos valores dos contadores digitais na bandas espectrais, é necessário dispor de um parâmetro de forma e tamanho para

descrever a forma dos objetos. A seguir, são apresentados os parâmetros de forma mais conhecidos e utilizados nesta pesquisa.

2.1 ÁREA E PERÍMETRO

A área (A) e o perímetro (P) são os mais simples descritores utilizados. A área é obtida contando todos os *pixels* que formam a região, e o perímetro é calculado considerando o número de *pixels* conexos (em função do predicado de conectividade escolhido) que constituem o contorno da região.

2.2 COEFICIENTE DE COMPACIDADE

De acordo com BÄSSMAN e KREYSS (1998), o coeficiente de compacidade descreve o quanto a forma se aproxima de uma circunferência com a mesma área. Por isto o valor do coeficiente de compacidade de uma circunferência é 1. O valor cresce na medida em que o contorno do objeto se torna irregular, ou seja, menos compacto (SONKA *et al.*, 1998). O coeficiente de compacidade (cc), é obtido através da equação 1, a partir dos valores do perímetro (P) e a área (A) da região.

$$cc = \frac{P^2}{4\pi A} \quad (1)$$

De acordo com FACON (1993), o coeficiente de compacidade (cc) é um descritor invariante à mudança de escala. O coeficiente de compacidade é também invariante à translação e à mudança de orientação.

2.3 MOMENTOS

Assumindo que as regiões são compostas por *pixels* com valores diferentes de zero, o momento de ordem ($p + q$) da região pode ser calculado segundo a equação 2 (FACON 1993):

$$m_{pq} = \sum_i \sum_j x_i^p y_j^q f(i, j) \quad (2)$$

onde p e q indicam a ordem do momento, $f(i,j)$ representa o valor do contador digital da imagem na posição (i,j) e x_i e y_j representam a distância em linhas e colunas, respectivamente, entre o pixel e a origem do sistema na imagem.

Uma região pode ser tratada como uma imagem binária onde os pixels podem assumir dois estados: pertencem à região ou não. No caso de uma imagem binária, apenas dois valores do contador digital são permitidos ($f(i,j)=0$ para o “fundo” e $f(i,j)=1$ para o “objeto”). Logo, os momentos permitem definir algumas propriedades de base de uma região, como sua área e o centro de gravidade:

- área: corresponde ao momento m_{00} (Equação 3) e representa o número de *pixels* constituindo a região:

$$m_{00} = \sum_i \sum_j f(i, j) \quad (3)$$

- centro de gravidade:

$$x_g = m_{10} / m_{00} \quad (4)$$

$$y_g = m_{01} / m_{00} \quad (5)$$

Outros momentos de ordem superior também podem ser úteis para descrever a região, principalmente quando se considera a origem localizada no centro de gravidade da região (x_g, y_g) . Com isto, os momentos calculados passam a ser chamados de momentos centrados (μ_{pq}) e podem ser calculados pela fórmula apresentada na equação 6:

$$\mu_{pq} = \sum_i \sum_j (x_i - x_g)^p (y_i - y_g)^q f(i, j) \quad (6)$$

De acordo com SONKA (1998), este tipo de descrição é invariável em relação à translação e mudança de escala. Para eliminar o efeito de rotação, aplicam-se os 7 momentos normalizados, que são obtidos a partir dos momentos μ_{pq} e estes são invariantes à translação, rotação e mudança de escala:

$$\Phi_1 = v_{20} + v_{02} \quad (7)$$

$$\Phi_2 = (v_{20} + v_{02})^2 + 4(v_{11})^2 \quad (8)$$

$$\Phi_3 = (v_{30} - 3v_{12})^2 + (3v_{21} - v_{03})^2 \quad (9)$$

$$\Phi_4 = (v_{30} - v_{12})^2 + (v_{21} + v_{03})^2 \quad (10)$$

$$\Phi_5 = (v_{30} - 3v_{12})(v_{30} + v_{12}) \{ (v_{30} + v_{12})^2 - 3(v_{21} - v_{03})^2 \} \\ + (3v_{21} - v_{03})(v_{21} + v_{03}) \{ 3(v_{30} + v_{12})^2 - (v_{21} + v_{03})^2 \} \quad (11)$$

$$\Phi_6 = (v_{20} - v_{02}) \{ (v_{30} + v_{12})^2 - (v_{21} + v_{03})^2 \} \\ + 4v_{11}(v_{30} + v_{12})(v_{21} + v_{03}) \quad (12)$$

$$\Phi_7 = 3(v_{21} - v_{03})(v_{30} + v_{12}) \{ (v_{30} + v_{12})^2 - 3(v_{21} + v_{03})^2 \} \\ - (v_{30} - 3v_{12})(v_{21} + v_{03}) \{ 3(v_{30} + v_{12})^2 - (v_{21} + v_{03})^2 \} \quad (13)$$

onde:

$$v_{pq} = \mu_{pq} / (\mu_{00})^\gamma \quad (14)$$

$$\gamma = (p + q) / 2 + 1 \quad (15)$$

2.4 RELAÇÃO EIXO MENOR E MAIOR DA ELIPSE (RE)

Descreve o grau de alongamento de uma região. Ele é calculado através da razão dos eixos menor e maior da elipse que mais se ajusta ao objeto ou elemento analisado (MASCARENHAS e VELASCO, 1998). Estes eixos podem ser obtidos

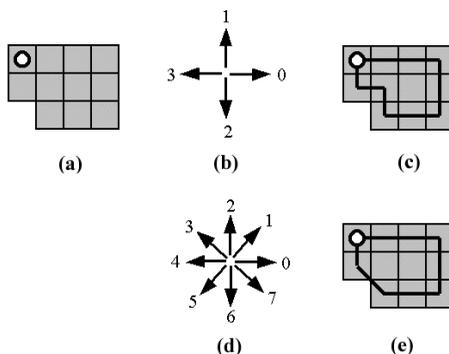
através da análise por componentes principais. No cálculo da transformação por componentes principais, cada *pixel* da imagem, ou de uma região, é tratado como um vetor bidimensional, cujas componentes correspondem às coordenadas linha/coluna do *pixel* na imagem. Estes vetores são usados para computar o vetor médio e a matriz variância covariância do conjunto (região). A partir da matriz variância-covariância (de dimensão igual a dois), podem ser estimados os dois autovalores e os respectivos autovetores. Os autovetores estimam a direção dos dois eixos da elipse gaussiana que descreve a distribuição dos dados e os autovalores o comprimento destes eixos (variância nestas direções).

2.5 CÓDIGO DA CADEIA (CA)

Uma região pode ser descrita em termos da variação dos valores do contador digital dentro dela ou em termos da variação espacial da posição relativa dos pixels localizados nas bordas da mesma, os pixels de fronteira. Uma maneira de descrever a região em termos da posição relativa de seus pixels de fronteira é através do código da cadeia.

O código da cadeia é usado na representação da fronteira de uma região por uma seqüência conectada de segmentos de linha reta de determinado tamanho e direção. Essa representação baseia-se tipicamente na conectividade-de-4 ou na de-8 dos segmentos. A direção de cada segmento é codificada por um esquema de numeração como o mostrado nas Figuras 1b e c.

Figura 1. Código da Cadeia: (a) região; (b) código direcional-4; (c) perímetro para vizinhança-4; (d) código direcional-8; (e) perímetro para vizinhança-8.

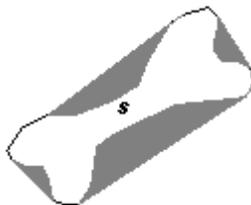


Um exemplo simples para a representação deste descritor pode ser observado através das Figuras 1c e e. Considerando o início da descrição do código no canto superior esquerdo da forma: No primeiro caso (código direcional-4), o código da cadeia resultante é $CA=(0,0,0,2,2,3,3,1,3,1)$. Já considerando o código direcional-8, a cadeia resultante é menor $CA=(0,0,0,6,6,4,4,3,2)$.

2.6 DEFICIÊNCIA CONVEXA (DC)

A deficiência convexa é a diferença entre os contornos da região e o fecho convexo da mesma. O *fecho convexo* H de um conjunto arbitrário S é o menor conjunto convexo que contiver S . A diferença entre os conjuntos $H - S$ é chamada *deficiência convexa (DC)* do conjunto S . Este descritor é atrativo quando a fronteira contem uma ou mais concavidades significativas que carregam informação sobre a forma. Na Figura 2 é mostrada uma região (conjunto S) e sua deficiência convexa, que corresponde às áreas sombreadas (GONZALES e WOODS, 2000).

Figura 2 - Exemplo de deficiência convexa de uma região (S)



3 PROCESSO DE CLASSIFICAÇÃO

O processo de classificação adotado neste trabalho segue os princípios dos algoritmos orientados a regiões, que de uma maneira geral consistem em inicialmente segmentar a imagem, ou seja dividir a imagem em regiões uniformes, para depois classificar estes segmentos de acordo a suas características espectrais e espaciais. Este tipo de abordagem ganha significado quando a imagem apresenta um grande número de objetos maiores que a resolução espacial, como ocorre nas imagens da nova geração de sensores de alta resolução espacial, que apresentam um alto nível de detalhes.

3.1 EXTRAÇÃO DE REGIÕES

De acordo com MASCARENHAS e VELASCO (1989), uma região é um conjunto de pontos "*conectados*", ou seja, de qualquer ponto da região pode-se chegar a qualquer outro ponto por um caminho inteiramente contido na região. As regiões que se deseja detectar, geralmente são regiões "*homogêneas*", ou seja, apresentam alguma propriedade local aproximadamente constante em toda sua extensão. Exemplos de propriedades locais comumente utilizadas são o valor do contador digital e a textura. As regiões, em uma imagem digital, são identificadas por técnicas de segmentação.

A segmentação é um processo em que uma imagem é subdividida em partes ou objetos constituintes. Os algoritmos de segmentação são geralmente baseados em uma das seguintes propriedades básicas de valores do contador digital: descontinuidade e similaridade. Na primeira categoria a abordagem é segmentar a imagem procurando mudanças bruscas nos níveis de cinza. As principais áreas de

interesse nessa categoria são a detecção de pontos isolados e detecção de linhas e bordas na imagem. As principais abordagens da segunda categoria baseiam-se em limiarização, crescimento de regiões e divisão e fusão de regiões: GONZALES e WOODS (2000).

3.2 DESCRIÇÃO DAS REGIÕES

As regiões, inicialmente caracterizadas pela distribuição espacial de seus pixels, podem ser classificadas de acordo a seus atributos espaciais e espectrais. Como atributos espectrais os valores médios da região são adotados. Outro descritor que pode ser incluído é o desvio padrão ou a variância dos valores digitais dentro da região mas, como a segmentação utilizada nesta pesquisa se baseia na uniformidade espectral das regiões, estes parâmetros não foram considerados.

Entre os parâmetros utilizados neste trabalho como descritores da variação espacial dos objetos encontram-se: área (A), perímetro (P), coeficiente de compacidade (cc), distância polar ao centro de gravidade do objeto (momentos invariantes), razão entre os eixos menor e maior da elipse que mais se aproxima do objeto (excentricidade), código da cadeia e deficiência convexa.

3.3 CLASSIFICAÇÃO USANDO REDES NEURAIS

Tarefas, como o reconhecimento de padrões, são executadas pelo cérebro humano de forma rotineira, porém os sistemas computacionais tradicionais ainda estão longe de alcançar um desempenho similar. Na atualidade, busca-se emular o raciocínio humano através de algoritmos de computador com a finalidade de extrair informações das imagens automaticamente, tentando simular o processo executado pelo cérebro humano. Para isto, técnicas de Inteligência Artificial vêm sendo implementadas no processo de análise de imagens. Neste contexto, as Redes Neurais Artificiais são uma das linhas na área de Inteligência Artificial que mais interesse levantam no processamento de imagens.

NELSON e ILLINGWORTH (1990), definem as RNA's como sendo técnicas inovadoras de processamento de informações, que têm como objetivo básico, simular, em computadores, o funcionamento do sistema nervoso biológico.

Conforme DYMINSKI (2000), uma rede neural é constituída por diversos neurônios artificiais dispostos em camadas. Estes neurônios tentam simular as funções sinápticas dos neurônios naturais através da combinação e ponderação de funções matemáticas simples. Para simular o alto grau de interligação dos neurônios naturais, os neurônios artificiais são armazenados em camadas, que são classificadas em três grupos: camada de entrada: onde os padrões são apresentados à rede; camadas escondidas: onde é feita a maior parte do processamento; camada de saída: onde o resultado final é concluído e apresentado. O número de neurônios de entrada é função do número de dados considerados na classificação, no caso do presente trabalho o número de entradas é a soma das entradas espectrais (IVP-R-G) e dos dados espaciais (descritores de forma utilizados). A configuração da rede é um

processo difícil e importante, e a acurácia e tempo de processamento é dependente da alteração destes parâmetros (JARVIS e STUART, 1996).

4 EXPERIMENTOS

Um recorte de uma cena obtida pelo sensor *IKONOS-II* na região de Matinhos, no Litoral Paranaense, foi utilizado neste trabalho. Esta imagem possui uma resolução espacial de 1m, resultado da fusão das imagens multiespectrais (resolução espacial de 4 m) e pancromática (resolução espacial de 1m). Um recorte desta imagem é visto na figura 3. Este recorte será usado para ilustrar o artigo.

Figura 4 – Recorte da imagem original



Nesta imagem podem ser identificados objetos como:

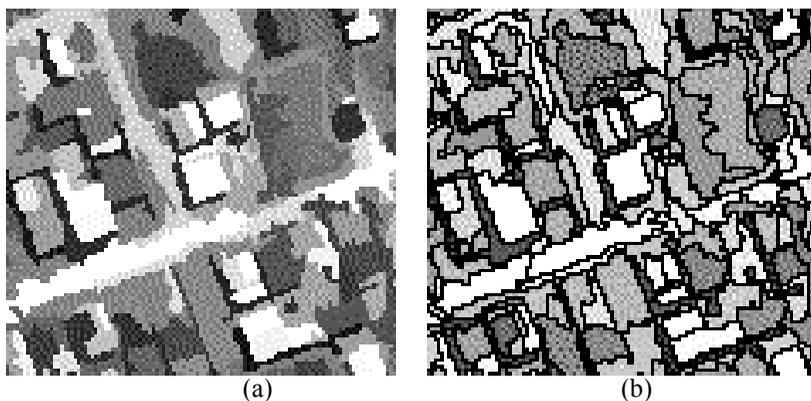
- área de asfalto, sendo estas localizadas junto à nova Rodoviária;
- ruas e solo exposto compostos de areia;
- vegetação, sob forma de pasto e árvores;
- telhados com uma grande variação de tipos de material (o que causa uma certa dificuldade em se distinguir áreas cobertas por areia e construções, pois alguns telhados possuem comportamento espectral similar ao da areia. Também se verifica a confusão entre ruas, asfalto e telhados) e;
- sombra, resultante das construções e árvores.

Como primeiro passo, foi realizada a segmentação da imagem utilizando o *software* comercial *E-COGNITION*. Um exemplo do resultado da segmentação pode ser visto na Figura 4. A figura esquerda (4a) mostra a imagem original, enquanto que a segunda (4b) mostra os limites das regiões identificadas neste pequeno recorte. Neste exemplo, é visível a separação de regiões espectralmente uniformes.

Após a segmentação, onde as regiões espectralmente uniformes foram identificadas, foram calculados os parâmetros de forma para estes grupos. Todos

estes cálculos forma realizados através de um programa no ambiente *MATLAB*, sendo que o resultado obtido foi armazenado sob forma de uma tabela de entrada de dados da rede neural. Nas colunas desta tabela constam os valores do contador digital de cada banda e os parâmetros de forma de cada segmento ou objeto da imagem. Um exemplo desta tabela é mostrado na Tabela 1, considerando apenas as variáveis espectrais, as bandas do infravermelho próximo, vermelho e verde (IVP-R-G) do sistema sensor *IKONOS-II*, e dois parâmetros espaciais, forma e perímetro. O número de colunas da tabela é função do número de parâmetros considerados.

Figura 4 - Resultado da segmentação (a) original; (b) imagem segmentada.



Os dados a respeito da forma, junto com os valores digitais médios dos segmentos, serviram de entrada numa rede neural, para discriminar os objetos presentes na imagem. As classes de objetos considerados foram: “rua pavimentada”, “areia”, “vegetação rasteira”, “árvores”, “sombras” e três tipos de “telhados” (com resposta espectral diferente em função do tipo de material). Como o objetivo do trabalho é a classificação de objetos presentes na imagem *IKONOS-II*, o tipo de rede utilizada foi a *Feedforward*, com o algoritmo *Backpropagation*, já que a mesma é a recomendada para a classificação supervisionada de imagens de sensoriamento remoto (LEES, 1996; JARVIS e STUART, 1996; LOESCH e SARI, 1996).

A rede foi treinada utilizando 21 amostras (segmentos) de treinamento para cada classe. Na rede, foram utilizadas duas camadas escondidas, com 138 e 46 neurônios, respectivamente. O número de neurônios das camadas escondidas, foi estimado através de experimentos realizados com imagens sintéticas e posteriormente com imagens *IKONOS-II* (porém de menos complexidade para a classificação).

Tabela 1 – Exemplo de entradas para a classificação com Redes Neurais

Segmento	IVP	R	G	Área	Perímetro	Compacidade
1	28	159	159	452	332	19.40
2	215	251	259	92	58	2.91
3	191	195	214	8	6	0.36
4	218	155	156	186	55	1.29
5	196	229	234	18	9	0.36
6	28	51	69	9	6	0.32
...						
717	255	210	123	188	9	0.03

Iniciou-se pela classificação puramente espectral dos segmentos, utilizando o método das redes neurais, com a finalidade de se estabelecer uma referência para estimar o ganho que é possível obter a com a inserção dos índices de forma. Nos seguintes experimentos, o número de variáveis de entrada foi variado, adicionando progressivamente as variáveis de forma. Os resultados dos experimentos foram agrupados em função do número de variáveis de entrada utilizados, resultando nos 10 grupos mostrados na tabela 2.

Tabela 2 – Variáveis de entrada consideradas na série de experimentos

Experimento	Total de variáveis de entrada	Variáveis espectrais	Quantidade de índices de forma
I	3	IVP-R-G	0
II	4	IVP-R-G	1
III	5	IVP-R-G	2
IV	6	IVP-R-G	3
V	7	IVP-R-G	4
VI	8	IVP-R-G	5
VII	9	IVP-R-G	6
VIII	10	IVP-R-G	7
IX	11	IVP-R-G	8
X	12	IVP-R-G	9

No último experimento, considerando 12 variáveis de entrada, por exemplo, foram utilizados as variáveis espectrais (*valores dos contadores digitais nas bandas IVP, R, G*) e as variáveis espaciais consideradas mais relevantes (*coeficiente de compacidade, relação eixo menor e maior da elipse e os 7 momentos invariantes*).

A arquitetura da rede foi mantida constante, variando apenas o número de entradas. Foram utilizadas duas camadas escondidas, com 138 e 46 neurônios. A

camada de saída foi composta por três neurônios, usados para representar, de maneira binária, as oito classes.

O desempenho das redes neurais em cada experimento foi medido utilizando o índice de acurácia global, ou seja, calculando a taxa de regiões corretamente classificadas no mapa temático. Para isto, segmentos de verificação foram analisados visualmente.

5 RESULTADOS E DISCUSSÕES

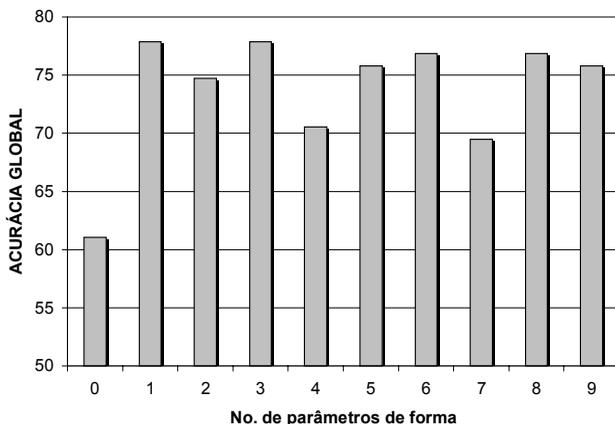
Em uma primeira fase, cada índice de forma foi incluído junto com os valores médios de cada banda espectral para compor o conjunto de variáveis de entrada na rede. Com estas variáveis, as redes neurais foram treinadas e a imagem classificada. Um resumo da acurácia global de cada classificação pode ser visto na tabela 3. O melhor resultado corresponde ao experimento que inclui o *coeficiente de compacidade*, seguido dos que incluem a *área* e o *5º momento*.

Tabela 3. Resultado das classificações com a inclusão de um único índice de forma.

Variáveis de entrada	Acurácia Global	Variáveis de entrada	Acurácia Global
Apenas IVP-R-G	0.6105	IVP-R-G + Φ_1	0.6526
IVP-R-G + CC	0.7789	IVP-R-G + RE	0.6526
IVP-R-G + A	0.7368	IVP-R-G + Φ_7	0.6526
IVP-R-G + Φ_5	0.7263	IVP-R-G + Φ_3	0.6316
IVP-R-G + P	0.6842	IVP-R-G + DC	0.6316
IVP-R-G + Φ_2	0.6842	IVP-R-G + CA	0.6316
IVP-R-G + Φ_4	0.6737	IVP-R-G + Φ_6	0.6000

Nos seguintes experimentos, a quantidade de índices de forma incluídos foi aumentada progressivamente. Em cada caso, as diferentes combinações de índices foram avaliadas. A tabela 4 apresenta um resumo das variáveis que produziram os melhores resultados em cada série. Em todas elas, os valores dos contadores digitais das três bandas (IVP-R-G) foram considerados. Na tabela 4, os dados espectrais são identificados como *I*. O melhor resultado, segundo o coeficiente de acurácia global, foi obtido incluindo os dados espectrais e 3 variáveis de forma (série de experimentos IV). As variáveis que participaram do melhor resultado foram: *IVP-R-G + compacidade + razão eixos + 1º momento*, que proporcionaram um ganho no valor da acurácia de 17% em relação à classificação puramente espectral.

O sucesso obtido na série de testes foi medido pela acurácia global da classificação, estimada a partir da diagonal principal da matriz de confusão de segmentos de verificação. A acurácia global em função do número de variáveis pode ser vista na figura 5. A primeira barra (0) indica o experimento com apenas os valores do contador digital médio da região.

Figura 5 - Acurácia global em função do número de parâmetros de forma

Observa-se que um ganho significativo é verificado com a inclusão de pelo menos uma variável de forma. Neste caso, trata-se do índice de compacidade. Na medida em que mais variáveis são incluídas, a acurácia global tende a diminuir, provavelmente porque a arquitetura da rede neural tem problemas para selecionar a variável mais significativa e com isto gera resultados piores. No entanto, qualquer combinação testada gerou resultados melhores que uma classificação puramente espectral. É de se esperar que a queda na qualidade da imagem temática com a inclusão de novas variáveis seja contornada com a utilização de outra arquitetura de rede, que melhor se adapte ao conjunto de dados de entrada, o que não foi feito nestes experimentos.

Tabela 4 – Conjuntos de variáveis de entrada mais significativos para cada série

	I	P	CC	RE	DC	CA	Φ_1	Φ_2	Φ_3	Φ_4	Φ_5	Φ_6	Φ_7
I			X										
II	X		X										
III	X		X	X									
IV	X		X	X			X						
V	X	X	X	X			X						
VI	X		X	X			X	X	X				
VII	X	X	X	X	X	X	X						
VIII	X		X	X			X	X	X	X	X		
IX	X		X				X	X	X	X	X	X	X
X	X		X	X			X	X	X	X	X	X	X

Os testes realizados comprovam que a adição de informação espacial à informação espectral no processo de classificação pode contribuir significativamente para a melhora dos resultados. No entanto, torna-se difícil escolher o melhor parâmetro de forma para a solução do problema, visto que existe uma grande variedade de parâmetros reportados na literatura.

O resultado da classificação puramente espectral (*IVP-R-G*) e com a melhor combinação dos índices de forma (*IVP-R-G + compacidade + razão eixos + 1º momento*) podem ser observadas através das Figuras 6 e 7, respectivamente. Na segunda imagem temática, nota-se algumas melhoras, como a redução de “árvores” nas regiões cobertas por “vegetação rasteira” ou a confusão entre “construções” e “areia”, bem como a melhor caracterização das construções. As circunferências identificam regiões onde a melhora na classificação é mais visível.

6 CONSIDERAÇÕES FINAIS

A inclusão de informações auxiliares, a respeito da forma, constitui um fator muito relevante para o aprimoramento da classificação dos objetos presentes na superfície da Terra, principalmente para imagens onde há muitos padrões distintos com resposta espectral semelhante.

Como a classificação *orientada a objeto* é dependente de uma prévia segmentação da imagem, a mesma deve ser a mais rigorosa possível. Porém ainda há uma certa dificuldade em se obter uma segmentação ideal para todos os padrões da imagem, talvez em função de uma carência por parte dos algoritmos de segmentação. O que se pôde perceber foi que o resultado da classificação ficou limitado ao resultado encontrado pela segmentação, ou seja, a acurácia da classificação é totalmente dependente do resultado da segmentação. Erros já vindos da segmentação, não poderão ser corrigidos na classificação.

Os melhores resultados obtidos para a classificação utilizando a forma foram obtidos utilizando uma variável espacial (*IVP-R-G + compacidade*) e três variáveis espaciais (*IVP-R-G + compacidade + razão eixos + 1º momento*). Se pode então concluir que para a área estudada, a compacidade foi muito relevante seguida da razão entre os eixos principais e o 1º momento, isto porque as formas dos segmentos que geraram maior confusão foram as mais próximas de um quadrado (relativas às construções) com as mais alongadas (relativas às ruas). O ganho obtido com a inclusão de novas variáveis não é significativo e utilizando apenas a compacidade, o resultado foi muito satisfatório. O efeito da inclusão das variáveis *razão eixos e 1º momento* é reduzir a confusão no mapa temático.

Os outros índices de forma utilizados não se mostraram tão relevantes nos experimentos realizados, já que os mesmos nem sempre apresentavam a invariância quanto à rotação, translação e mudança de escala dos objetos. Isto dificulta a separabilidade entre segmentos de mesma classe por exemplo, mas com tamanhos ou em posições distintas.

Figura 6 - Classificação puramente espectral

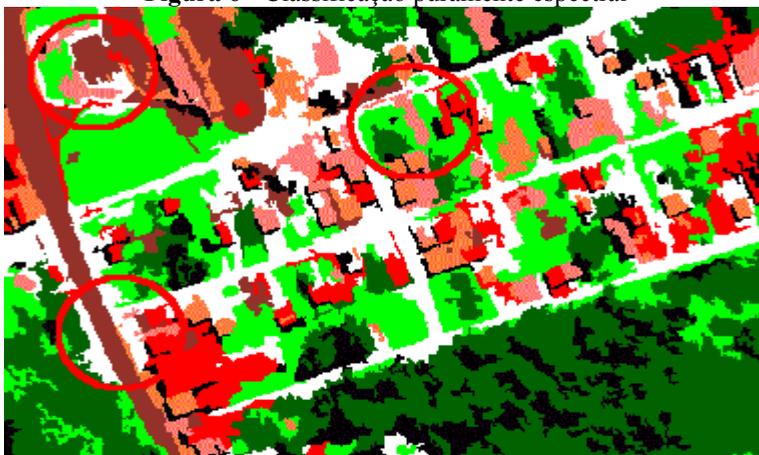
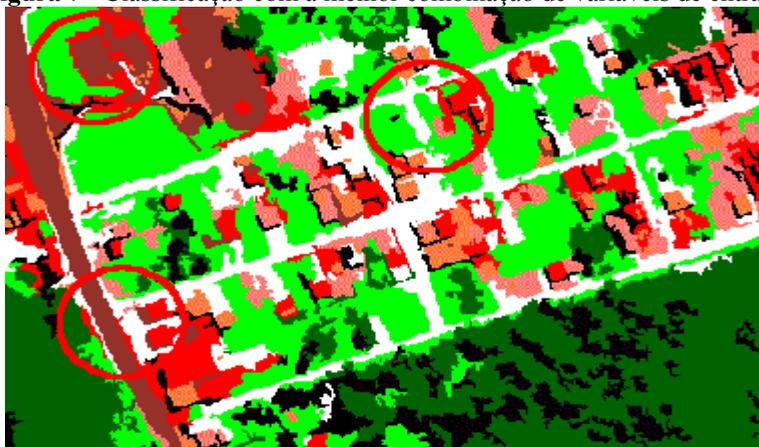


Figura 7 - Classificação com a melhor combinação de variáveis de entrada



Legenda	
■ Telhado A (amianto)	 Areia
■ Telhado B	■ Veg. densa
■ Telhado C	■ Veg. rasteira
■ Asfalto	■ Sombra

7 REFERÊNCIAS BIBLIOGRÁFICAS

- AVERY, T. E.; BERLIN, G. L. **Fundamentals of Remote Sensing and Airphoto Interpretation**. Prentice-Hall. New Jersey, USA., 1992.
- BÄSSMAN, H.; KREYSS, J. **Bildverarbeitung Ad Oculum**. Heidelberg Springer, 1998.

- DYMINSKI, A S. **Análise de Problemas Geotécnicos Através de Redes Neurais**. Rio de Janeiro, 2000. Tese (Doutorado em Geotecnia) - Curso de Pós-Graduação em Engenharia Civil, PUC - Rio de Janeiro.
- FACON, J. **Processamento e Análise de Imagens**. Universidad Nacional de Córdoba, Argentina, 1993, 196p.
- FRANKLIN, S.E.; WILSON, B.A A Three Stage Classifier for Remote Sensing of Mountain Environment. **Photogrammetric Engineering and Remote Sensing**. v. 58, n. 4, p. 449-454, 1992.
- GONZALES, R.C.; WOODS, R.E. **Processamento de Imagens Digitais**. Edgard Blücher Ltda. São Paulo, 2000, 509p.
- HUTCHINSON, F.C. Techniques for Combining Landsat and Ancillary Data for Digital Classification Improvement. **Photogrammetric Engineering and Remote Sensing**. v. 48, n. 1, p. 123-130, 1982.
- JARVIS, C.H.; STUART, N. The Sensitivity of a Neural Network for Classifying Remotely Sensed Imagery. **Computers & Geosciences**. v.22, n.9, p.959-967, 1996.
- LEES, B. G. Neural Network Applications in the Geosciences: an application. **Computers & Geosciences**. v.22, n.9, p.955-957, 1996.
- LOESCH, C.; SARI, S.T. **Redes Neurais Artificiais. Fundamentos e Modelos**. Editora da FURB. Blumenau, 1996, 166p.
- MASCARENHAS, N.D.A; VELASCO, F.R.D. **Processamento Digital de Imagens**. Editora Kapelusz. Buenos Aires, 1989.
- MEYER, M.; WERTH. Satellite Data: Management Panacea or Potencial Problem? **Journal of Forestry**. v. 88, n. 09, p. 10-13, 1990.
- NELSON, M.M.; ILLINGWORTH, W.T. **A Pratical Guide to Neural Networks**. Addison-Wesley Publishing Company, Inc. USA, 1991.
- NISHIDA, W. **Uma Rede Neural Artificial para Classificação de Imagens Multiespectrais de Sensoriamento Remoto**. Florianópolis, 1998. Dissertação (Mestrado em Engenharia de Produção) - Curso de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina.
- RIBEIRO, S. A.; SANTOS, D. R.; CENTENO, J. S.; **Aplicação da Metodologia de Dados Orientado a Objeto na Classificação de uma Área Urbanizada, Utilizando uma Imagem Digital obtida por meio da Tecnologia do Laser Scanner**. In: Simpósio Brasileiro de Geomática. Presidente Prudente, S.P., 2002. **Anais**. CD.
- SONKA, M; HLAVAC, V.; BOYLE, R. **Image Processing, analysis, and Machine Vision**. Brooks/Cole Publishing Company. USA, 1998.

(Recebido em junho/03. Aceito em agosto/03)