

# USO INTEGRADO DE IMAGEM DE ALTA RESOLUÇÃO ESPACIAL E ALTURA DERIVADA DO *LASER SCANNER* NA ESCOLHA DO CLASSIFICADOR ORIENTADO A REGIÃO

*Integrated Use Of Spatial High Resolution Image And Laser Scanner Derived  
Hight Classifier Oriented To Region To Choose*

MOSAR FARIA BOTELHO  
JORGE ANTONIO SILVA CENTENO

Programa de pós graduação em Ciências Geodésicas  
Universidade Federal do Paraná – Brasil  
(mosar, centeno)@ufpr.br

## RESUMO

Neste artigo são apresentados os resultados de um estudo que aborda o tema da integração das alturas derivadas de um levantamento *laser scanner* com imagens de satélite de alta resolução espacial, Quickbird II, para o mapeamento temático de áreas urbanas. Justifica-se este trabalho, devido o uso de imagens orbitais não ser suficiente para distinguir os objetos associados ao mapeamento em áreas urbanas, de forma semi-automática, tornando-se necessária a inclusão de outras informações auxiliares. Para isto, uma metodologia orientada à análise de regiões na imagem é proposta. O ganho obtido com a inclusão da altura derivada do *laser scanner* é comparado com o ganho resultante do uso de parâmetros espaciais derivados das imagens, mediante a utilização do algoritmo de classificação da rede neural artificial (RNA) e classificadores convencionais (máxima verossimilhança, distância mínima). Os resultados mostram que, a contribuição da informação altimétrica é muito útil na classificação de edificações, vias e vegetação. Dentre os algoritmos testados, o uso de RNA incluindo informações de elevações derivadas do *laser scanner* foi o que forneceu os melhores resultados.

## ABSTRACT

In this article, the results of a research about the integration of height derived from a *laser scanner* measurement with high resolution spatial satellite image are presented, QUICKBIRD II, for the thematic mapping of urban areas. This research is justified, for so as not to suffice the use of orbital images, to distinguish the

associated objects to the urban area mapping, in a semi-automatic way, one needs the inclusion of other auxiliary information. Therefore, it is proposed a methodology oriented to a regional analysis in the image. The gain obtained with the *laser scanner* derived height inclusion is compared to the resulting gain obtained from the use of spatial parameters derived from the images, through the use an artificial neural network classification algorithm (ANN) and usual classifiers (maximum likelihood and minimum distance). The results show that the altimetry information contribution is very useful in building, road and vegetation classification. From the tested algorithms, the use of an ANN including information of height derived from a *laser scanner* was the one which got the best results.

## 1. INTRODUÇÃO

Com o avanço da tecnologia dos sensores e o surgimento dos sistemas de Sensoriamento Remoto de alta resolução espacial, como o sistema QUICKBIRD II com 61 cm de resolução espacial, é possível a análise mais detalhada da cena, isto é, objetos menores como casas, ruas e árvores estão mais evidenciados, fato que vêm provocando uma evolução nos processos de geração e manutenção de bases cartográficas, como também nos processos de classificação digital de imagens. Porém, em uma abordagem de classificação semi-automática, o uso de imagens orbitais, não é suficiente para distinguir as feições do ambiente urbano e a inclusão de outras informações auxiliares, torna-se necessária.

O *laser scanner* fornece as coordenadas plano-altimétricas e a intensidade do objeto da cena. A altimetria adquirida dos pontos na superfície da terra pode também ser incluída no processo de classificação, diferenciando os objetos de mesmo comportamento espectral localizados em diferentes elevações, tornando-se assim, uma informação auxiliar interessante nesse processo.

O processo de classificação de imagens pode ser realizado por dois métodos distintos: “pixel” a “pixel” ou por regiões. O processo “pixel” a “pixel” consiste na atribuição de cada “pixel” a uma determinada classe analisando, na maioria dos casos, apenas as propriedades espectrais dos mesmos. O processo por regiões consiste em agrupar os “pixels” próximos e com atributos similares, em regiões, e em atribuir cada região a uma das classes. Esse processo tem como vantagem a utilização de uma maior quantidade de descritores para as regiões, como por exemplo de forma, de tamanho e de textura, o que tem como consequência o aumento de variáveis de entrada no processo de classificação.

Para classificar dados de diferentes origens, a utilização da RNA emerge como uma alternativa vantajosa aos classificadores de imagens baseados em conceitos estatísticos (Ex.: Máxima Verossimilhança, Distância Mínima), uma vez que nenhuma hipótese prévia sobre a distribuição dos dados a serem classificados é exigida e os dados de entrada podem ter escalas diferentes. O uso de RNA, aliado ao aumento de variáveis derivadas da imagem e da altimetria do *laser scanner*, em

uma abordagem de classificação baseado em regiões, é uma alternativa viável e interessante no sensoriamento remoto, especialmente na classificação de imagens de alta resolução espacial.

Neste artigo, é descrita uma metodologia que utiliza algoritmos de classificação de padrões, utilizando a integração de variáveis espectrais e espaciais, ou seja, forma e altura dos objetos, fornecida pelos dados do *laser scanner*, a fim de se obter uma qualidade e acurácia maior na geração de mapas temáticos oriundos da classificação.

## 2. OBJETIVO

O objetivo destes experimentos é classificar uma imagem de alta resolução espacial, utilizando a altura fornecida pelo *laser scanner* e descritores de forma como variáveis auxiliares no processamento de aprendizado da rede neural, orientados a região. Também se objetiva analisar o comportamento destas variáveis em classificadores convencionais como máxima verossimilhança e distância mínima.

## 3. MATERIAL UTILIZADO

### 3.1 Área de Estudo

Uma região, da cidade de Curitiba, próxima do Centro Politécnico, foi escolhida como alvo do estudo. Esta região é uma área urbana, com edificações, vias e outros objetos presentes no cotidiano das cidades. A área foi escolhida devido à disponibilidade de imagens QUICKBIRD II (a imagem foi cedida pela empresa TESE – Tecnologia em Sistemas Espaciais.) e sendo próxima à UFPR possibilita visitas para o levantamento da área de verificação e reconhecimento das classes presente na imagem. A região está situada dentro das coordenadas: 677889.58E, 7184178.02N e 678448.18E, 7183549.42N.

Foram realizados 3 recortes das quatro bandas pertencentes à imagem QUICKBIRD II correspondentes à área de estudo. O primeiro, com dimensão 400x400 pixels está apresentado na Figura 3.1. Este recorte apresenta vias asfaltadas, casas bem definidas e espaçadas, edificações grandes, como um “Shopping”, árvores e vegetação de baixo porte (gramíneas, pequenos arbustos, pastagens etc), e é caracterizado pela vegetação entre as edificações. Um segundo recorte de 500x500 pixels, posicionado à esquerda do primeiro, possui as mesmas classes do primeiro recorte, porém destaca-se pela grande aglomeração entre edificações. E finalmente um terceiro recorte, também de 500x500, posicionado acima do segundo recorte, que possui as mesmas classes do primeiro, porém caracterizado pela vegetação arbórea.

Figura 3.1 - Primeiro recorte da imagem QUICKBIRD II, da região em estudo.



### 3.2 Dados do *Laser Scanner*

O levantamento *laser scanner* da região foi realizado com o sistema OPTECH / INS GPS APPLANIX, pertencente ao Instituto de Tecnologia para o Desenvolvimento (LACTEC - UFPR). O sistema de referência de coordenadas utilizado para o rastreamento foi o WGS84 (*World Geodetic System*, 1984).

## 4. METODOLOGIA

### 4.1 Conceitos Fundamentais

A partir de uma segmentação, variáveis espectrais (bandas do sensor) e espaciais (descritores de forma e altimetria fornecida pelo *laser scanner*) serão utilizadas para o aprendizado dos algoritmos classificadores. Portanto, para um melhor esclarecimento, nas próximas seções estes temas serão abordados.

#### 4.1.1 Segmentação

O processo de segmentação de imagens tem por objetivo fragmentar uma imagem em regiões homogêneas, considerando algumas de suas características intrínsecas como, por exemplo, o nível digital dos “pixels”, a forma ou a textura de uma região.

Os algoritmos de segmentação são geralmente baseados na análise da descontinuidade ou da similaridade entre “pixels”. Na primeira categoria a abordagem é particionar a imagem baseando-se em mudanças bruscas nos valores digitais. Os principais algoritmos nessa categoria são a detecção de pontos isolados e detecção de linhas e bordas na imagem. A abordagem da segunda categoria é particionar a imagem baseando-se na homogeneidade dos níveis de cinza, ou seja, detecção de regiões uniformes. As principais técnicas nessa categoria são: a limiarização, crescimento de regiões e divisão e fusão de regiões (GONZALES e WOODS, 2000 p. 295).

Uma das grandes desvantagens das técnicas convencionais de agrupamento é não considerar a característica espacial dos segmentos. Com o objetivo de superar as limitações dos segmentadores convencionais, estudos se voltam a analisar os objetos de estrutura topológica vetorial. Desta forma, o aspecto espacial possui um importante papel e pode ser descrito por relações entre os segmentos vizinhos (CHENG, 2002 p.41). Um segmentador que considera o aspecto espectral junto com o espacial é aquele proposto por BAATZ E SCHAPE (1999), denominado *Fractal Net Evolution Approach* (FNEA).

O conceito de FNEA considera a imagem como sendo de natureza fractal. Ao segmentar a imagem de forma fina e de forma grosseira, dá-se origem a diferentes escalas de segmentação. O procedimento de segmentação é basicamente de crescimento de regiões que agrupa sub-regiões em regiões maiores. Inicialmente, a imagem é segmentada em segmentos menores que, baseados em parâmetros espectrais (cor) e espaciais (forma, descrita pela compacidade e suavidade dos objetos), podem ainda ser reagrupados em objetos maiores denominados superobjetos ou regiões. Estas regiões possuem relações com os segmentos que as constituem num nível mais baixo (ANTUNES, 2003, p.32). Um programa comercial que possui este algoritmo de segmentação é o “eCognition”.

A descrição de heterogeneidade espectral ( $H_e$ ), como apresentado e disponível no aplicativo ECOGNITION (2001, p.3-20), é composta pela soma dos desvios padrão dos valores do contador digital ( $\sigma_c$ ) para uma dada banda ( $c$ ) ponderados pelos pesos  $W_c$ , sendo:

$$H_e = \sum w_c \sigma_c \quad (1)$$

Contudo, em muitos casos, a minimização exclusiva da heterogeneidade espectral resulta em segmentos fragmentados, principalmente em imagem muito texturizada. Por esta razão, deve-se considerar além da heterogeneidade espectral o critério de heterogeneidade espacial.

A heterogeneidade espacial é considerada como um desvio de uma forma compacta, descrita pela razão do comprimento da borda do objeto e o número de “pixels” que o compõe (equação 2).

$$hf_{cp} = \frac{P}{\sqrt{n}} \quad (2)$$

onde

P = perímetro do objeto e

n = número de “pixels” que compõe o objeto.

É ainda possível descrever a forma utilizando ao invés de números de “pixels”, o comprimento de um quadrado ou retângulo que compreenda o objeto (equação 3) (ECOGNITION, 2001, p.3-20), ou seja:

$$hf_{sv} = P/b_A \quad (3)$$

onde

$b_A$  = perímetro do quadrado que compreende o objeto.

O processo de segmentação inicia-se agregando “pixels” formando um objeto ou 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 espectral e espacial entre os objetos adjacentes.

A fusão local de objetos é um processo iterativo que objetiva alcançar uma heterogeneidade mínima no processo de agregação. A base é o grau de diferença de heterogeneidade entre duas regiões. Uma vez que a diferença decresce, torna-se maior o critério de fusão. Esta diferença otimiza o processo, comparando os atributos das duas regiões. Num dado espaço de atributos, os objetos são considerados similares se estiverem espectralmente próximos. De acordo com ECOGNITION (2001, p.3-22), o valor geral do critério de fusão “f” é determinado pela equação 4, tendo em vista a forma (heterogeneidade espacial) e cor (homogeneidade espectral).

$$f = wh_e + (1-w)h_{forma} \quad (4)$$

onde

f = critério de fusão;

w = é o peso dado a variável (cor);

$h_e$  = heterogeneidade espectral;

$h_{forma}$  = heterogeneidade espacial.

A equação 5 determina  $h_{forma}$ :

$$h_{forma} = w_{cp}h_{cp} + (1-w_{cp})h_{sv} \quad (5)$$

onde

$w_{cp}$  = peso da compacidade;

$h_{cp}$  = coeficiente de compacidade do objeto; e

$h_{sv}$  = coeficiente de suavidade do objeto.

Os pesos são determinados de acordo com os critérios de semelhança definidos pelo usuário. O peso maior é dado para a variável espectral, por ser a imagem multiespectral. Toda a imagem segmentada e os objetos são gerados

baseados em critérios ajustáveis de homogeneidade ou heterogeneidade espacial ou espectral.

#### 4.1.2. Descritores de Forma

Em termos visuais, a forma é um dos elementos mais importantes para a interpretação de imagens digitais, sendo uma variável que permite a percepção associativa dos objetos da imagem. Na verdade, a forma é um dos “Elementos de Classificação”, utilizados nos métodos clássicos de fotointerpretação, como pode-se ver ANDERSON (1982). No entanto, de acordo com ANDRADE (2003, p.35), embora seja uma ferramenta interessante para a discriminação de objetos, o conceito de forma não é fácil de ser implementado na análise de imagens “raster” por computadores. Ainda a esta autora comenta que parâmetros de forma como o coeficiente de compacidade, a relação entre o eixo menor e maior da elipse envolvente dos objetos, a Área e o Perímetro estão entre os coeficientes que mais contribuem para a descrição de um objeto na classificação de imagem digital gerada por uma RNA.

O coeficiente de compacidade ( $cc$ ) mede o grau de semelhança entre a região e a circunferência de um objeto. O objeto é menos compacto à medida que seu contorno se torna mais irregular. O coeficiente de compacidade ( $cc$ ), é obtido através da equação 6:

$$cc = \frac{P^2}{4\pi A} \quad (6)$$

onde

P = perímetro do objeto; e

A = área do objeto.

A razão entre eixos principais descreve o alongamento de uma região e é obtido calculando a razão dos eixos menor e maior da elipse que mais se ajusta ao contorno do objeto ou elemento analisado (ANDRADE, 2003).

#### 4.1.3. Laser Scanner

O *laser scanner* é um sistema ativo usado para determinar a altitude da superfície da terra e os objetos presentes a partir de medições de distância entre o sensor e a superfície dos objetos. Esse sensor utiliza um feixe de laser que é disparado em direção aos objetos. O feixe é refletido e novamente captados pelo sistema. A distancia entre o objeto e o sensor é calculada utilizando-se do tempo decorrido entre a emissão e o registro do retorno do sinal (LOHR E EIBERT, 1995).

Segundo SHERSTHA ET AL (1997), uma unidade típica possui um espelho montado em frente ao ponto de emissão do feixe laser. Este espelho roda com a finalidade de varrer uma linha transversal ao deslocamento do avião. Os pulsos possuem uma duração de nanossegundos e são direcionados pelo espelho através de uma abertura ou janela em direção ao chão. Quando o *laser scanner* é montado no avião, com a linha do scanner perpendicular a direção do voo, a superfície do terreno é varrida, formando uma faixa coberta. A largura desta faixa e o espaço entre os pontos do objeto dependem da altura e velocidade do voo e do domínio limite dos ângulos do scanner. Estes fatores variam devido ao tipo de scanner usado e o plano de voo.

De acordo com MASAHARU E HASEGAWA (2000, p.557), um método eficiente para extrair dados de prédios de alta elevação, obtidos por um *laser scanner*, é feito pela aplicação do método de segmentação de regiões, considerando que cada prédio tem uma altura diferente do vizinho. Entretanto pode-se distinguir cada prédio segmentando o Modelo Digital de Elevação (DEM), com a condição de que um “pixel”, com diferença de altura, comparado com seu vizinho, pertença a mesma região se estiverem dentro de uma área pré-determinada. O estudo de Masaharu e Hasegawa constatou alguns problemas como: os objetos extraídos não são apenas prédios, árvores são também incluídos.

#### 4.1.4. Classificação Digital de Imagem

Tomando como hipótese que os elementos da imagem que cobrem um mesmo alvo têm características similares, algoritmos computacionais podem ser usados para dividi-los em grupos. Este processo é denominado classificação de imagem e pode ser “pixel” a “pixel” ou por regiões, dependendo do nível de abstração considerado.


##### a) Classificação usando RNA

Uma RNA pode ser definida, de modo simplificado, como um arranjo de unidades, neurônios interconectados, que trabalham em paralelo para classificar e generalizar dados de entrada em classes de saída (HAYKIN, 2001).

As redes neurais são organizadas em camadas conectadas, podendo ser a “camada de entrada”, a(s) camada(s) escondida(s) ou oculta(s) e a camada de saída (Figura 4.1). Na camada de entrada, onde não ocorre processamento, os dados são apresentados à rede. A camada de entrada se comunica a uma ou mais camadas ocultas (intermediárias) onde ocorre o processamento por meio de um sistema de conexões ponderadas. A camada de saída apresenta o resultado do processamento. O funcionamento da rede é determinado pela conexão entre as unidades de processamento, definida pelos pesos de cada ligação (GERMAN e GAHEGAN, 1996, p.972-973).



Figura 4.1 – Arquitetura do Modelo de Multicamada



Fonte: Adaptado de HAYKIN (2001)

#### b) Classificação utilizando Algoritmos convencionais

Para este estudo serão utilizados dois algoritmos convencionais para o aprendizado e classificação de imagens digitais: distância mínima e máxima verossimilhança.

O método da distância mínima atribui cada elemento desconhecido à classe cuja média é mais próxima, ou seja, a atribuição de uma classe ao elemento depende da distância em relação à classe a qual este foi atribuído (isso implica que todas as distâncias devem ser verificadas, até que se ache a menor delas) (HODGSON, 1988).

O método, ou critério de máxima verossimilhança pressupõe que os elementos de cada classe seguem uma distribuição normal multivariada. O método avalia as probabilidades que um determinado elemento tem de pertencer às classes identificadas e o designa àquela cuja probabilidade é maior (SWAIN E DAVIS, 1978; BLAISDELL, 1993).

## 5. RESULTADOS

Para a execução deste trabalho, foi realizada a geração do modelo digital de superfície, a delimitação dos parâmetros para o funcionamento do algoritmo da RNA (a escolha da forma de aprendizado da RNA) e o estabelecimento de um modelo estatístico para a avaliação do produto obtido, como discutido na seqüência.


### 5.1. Modelo Digital de Superfície Normalizado

Com os dados disponíveis pelo laser é gerada, por meio do programa SURFER, utilizando o método de interpolação “inverso do quadrado de uma distância”, uma grade altimétrica regular de 0,7m com as mesmas dimensões da

resolução espacial da imagem QUICKBIRD II. No intuito de se obter apenas as alturas dos objetos em relação ao solo, para cada recorte, foram realizados os seguintes passos:

1. Inicialmente, são coletados pontos, aproximadamente 70 pontos para cada recorte, a partir da grade regular original. Estes pontos foram escolhidos de modo que fossem representativos da superfície do solo, desprezando assim as elevações das edificações, árvores, etc.
2. De posse deste conjunto de pontos, que descrevem a superfície do solo, é gerada uma segunda grade.
3. Finalmente, é realizada a subtração das grades. Esta operação resulta em uma terceira grade com apenas a altura dos objetos em relação ao solo. Este produto final pode ser observado na Figura 5.1 e é chamado de Modelo Digital de Superfície normalizado - MDSN (WEIDNER E FÖRSTNER, 1995).

Figura 5.1 - Imagem Altimétrica da altura dos objetos em relação ao solo.



## 5.2. Redes Neurais Artificiais

Utilizando a linguagem C++, foi implementado um algoritmo de RNA, com arquitetura multicamadas com alimentação adiante (“feed-forward”), possuindo duas camadas ocultas, com o processo de aprendizagem de retro-propagação (“back-propagation”). Este algoritmo possui “bias” que tem influência externa ao neurônio, e a função de transferência adotada é a sigmóide. Foram utilizadas cinco classes para seu treinamento (edificação de telhado claro, edificação de telhado escuro, gramínea, árvore, vias), sendo coletadas 46 amostras para cada classe.

## 5.3. Análise Estatística

Para a verificação do comportamento dos classificadores testados neste trabalho foi utilizado o índice “kappa”, proposto por COHEN(1960), que retrata o quanto o algoritmo acertou em uma determinada área de verificação. Esta área foi

obtida através de uma restituição fotogramétrica, realizada na escala de 1:2000, a partir de uma foto aérea na escala de 1:8000.

No intuito de verificar a qualidade da classificação, será comparado o produto obtido pela rede neural com o produto obtido pelos algoritmos convencionais.

## 6. ANÁLISE DOS RESULTADOS

### 6.1. Segmentação

O resultado da segmentação obtido pelo programa “eCognition”, que utiliza o método FNEA, é uma imagem temática, ou classificada. A cada uma das regiões desta classificação é atribuído um valor digital, que pode ser associado a uma tabela contendo os descritores de cada região. Com estes segmentos foi realizada a amostragem.

Os três recortes mencionados na seção 3 foram segmentados utilizando os mesmos parâmetros de escala, cor, forma, compacidade e suavidade disponíveis no programa. Para realizar a segmentação foram introduzidas as 4 bandas espectrais disponíveis e a imagem altimétrica, todas com o mesmo peso, originando uma nova imagem segmentada. Os valores utilizados para esta segmentação podem ser observados no Quadro 6.1.


**Quadro 6.1** - Parâmetros utilizados em cada nível de segmentação no *ecognition*.

Nível	Escala	Escala		Forma	
		Cor	Forma	Suavidade	Compacidade
1	7	0,7	0,3	0,7	0,3
2	5	0,3	0,7	0,7	0,3


Por meio do Quadro 6.1, nota-se que foram utilizados 2 níveis de segmentação. No primeiro nível foram utilizadas as 4 bandas espectrais aplicando uma escala de valor igual a 7, parâmetro de cor igual a 0,7 e forma igual a 0,3 isto devido ao fato dos objetos da cena estarem caracterizados mais pela cor (informação espectral). A suavidade e compacidade, após vários testes, são fixados em 0,7 e 0,3 respectivamente. No segundo nível foi acrescida a imagem altimétrica gerada a partir da grade regular (Figura 5.1). O programa gera os segmentos do segundo nível a partir dos segmentos criados pelo primeiro nível. Como a escala é o fator linearizador do crescimento de região, assim foi utilizada uma escala menor no segundo nível, com valor igual a 5, na tentativa de aglomerar os pequenos segmentos, que junto podem formar um objeto maior. No segundo nível foi incluído a imagem altimétrica produzida a partir dos dados do *laser scanner*. Nesta imagem, a forma dos objetos é mais predominante que a cor, portanto foi atribuído mais peso a forma que a cor, sendo dados os valores a cor de 0,3 e 0,7 a forma. Foi mantida a

mesma configuração do nível 1 para os parâmetros de suavidade e compacidade. Na Figura 6.1 observa-se um exemplo de segmentos que são produtos por esta metodologia. Nota-se que os segmentos da Figura 6.1b estão representando coerentemente os objetos apresentados na Figura 6.1a. Observa-se também que as edificações apresentadas na Figura 6.1a são representadas por mais de um segmento (Figura 6.1b).

Figura 6.1 – Parte da imagem do primeiro recorte (a) e após segmentação e codificação (b)



(a) Imagem Original




(b) Imagem Segmentada

## 6.2. Escolha das Melhores Variáveis

Com o intuito de encontrar uma melhor separabilidade entre classes, foram realizados experimentos entre as bandas espectrais e sua relação com as informações espaciais. Para tal, foram coletadas 46 amostras para cada classe (“edificações de telhado escuro”, “edificações de telhado claro”, “gramínea”, “árvores”) e utilizadas para a análise através de gráficos que comparam estas informações espectrais e espaciais. Todas as variáveis foram normalizadas entre 0 e 255 níveis digitais. Um exemplo destes gráficos pode ser observado na Figura 6.2, que evidencia a relação espectral entre classes nas bandas 4 e 3. Nota-se a presença de grupos que podem ser separados com retas, estes são representados pelas classes: “edificações de telhado claro”, “gramínea” e “árvores”. Um quarto grupo, encontra-se separado dos demais, composto por duas classes espectrais: “Edificação de telhado escuro” e “vias”.

Figura 6.2 - Relação entre banda 4 (infravermelho) e banda 3 (visível).



Análises similares foram realizadas para diferentes combinações entre bandas e a altura dos objetos (Z). Conclui-se, após a análise de todos os gráficos, que as bandas espectrais que se mostraram mais eficientes na separabilidade entre as classes, foram as bandas 4, 3 e 2, respectivamente. Já na relação entre bandas espectrais e na altura dos objetos (Z), a combinação que mostrou maior eficiência na separabilidade foi a composição entre a banda 4 e a altura dos objetos.

### 6.3. Classificação Orientada a Regiões

As quatro variáveis (Bandas 2 a 4 e Z) que apresentaram uma melhor separabilidade foram utilizadas para o treinamento dos classificadores (RNA, Máxima Verossimilhança e Distância Mínima). O Quadro 6.2 mostra o resultado do teste supra citado. Observa-se que os descritores de forma não contribuíram para a separabilidade entre classes, confirmando assim a análise estatística realizada. Esta situação pode ser observada no Quadro 6.2, como exemplo, onde I é a Informação Espectral fornecida pelas 3 melhores bandas espectrais

Quadro 6.2 – Resultados da RNA para o segundo recorte realizado na imagem.

Composição considerada	Kappa
I	41,1
I+Z	<b>65,2</b>
I+Z+A	33,7
I+Z+P	37,7

I = Imagem QUICK BIRD II com as bandas 4,3 e 2;

Z = Altura dos objetos, dados oriundos do *laser scanner*;

A = Descritor de forma – Área;

P – Descritor de forma – Perímetro

#### 6.4. Comparação de Classificadores


Para comparar os classificadores, inicialmente foram selecionados os melhores valores de “kappa” encontrados para as combinações realizadas. Foram desconsiderados os valores encontrados para as combinações que envolvem os descritores de forma, devido estes não contribuírem para este estudo. Estes valores e combinações podem ser observados pelo Quadro 6.3.

Quadro 6.3 - Melhores resultados do índice kappa para os métodos de classificação.

Variável	Método		
	RNA	Distância Mínima	Máxima Verossimilhança gaussiana
I	<b>41,6</b>	35,1	32,0
I + Z	<b>65,2</b>	53,0	45,0

Observando o Quadro 6.3, nota-se que a RNA exhibe os melhores valores do “kappa” para todos os recortes, tanto na utilização de informações espectrais oriundas da imagem QUICKBIRDII representadas pelas bandas 2, 3 e 4 (I), quanto na composição de informação espectral (I) e altura dos objetos (Z), com 41,6 e 65,2 respectivamente. Devido às estatísticas demonstradas, a RNA, nesta pesquisa e para esta aplicação, se mostrou como o melhor método para a classificação de regiões utilizando dados oriundos do *laser scanner*. Na Figura 6.3 observa-se a imagem classificada de um dos recortes, sendo o melhor resultado, ou seja, por meio da RNA.

Figura 6.3 - Imagem do primeiro recorte classificada por RNA utilizando a composição I+Z (informação espectral e altimetria do laser)



## 7. CONSIDERAÇÕES FINAIS

Os três algoritmos de classificação empregados integraram dados de diferentes fontes e desempenharam o objetivo de classificar uma imagem de alta resolução, sendo o melhor resultado obtido com RNA. Em seu treinamento, o algoritmo considera implicitamente a escala e dispersão das classes e exige poucas amostras de treinamento, apesar de ser ainda um problema a definição da arquitetura da RNA, que é experimental.

Os dados do *laser scanner* melhoraram a qualidade da classificação quando comparada ao resultado da classificação puramente espectral. Por meio da análise dos resultados obtidos através dos três métodos de classificação empregados, pode-se concluir que a altimetria fornecida pelo *laser scanner* possibilita a obtenção de uma imagem temática de melhor qualidade do que os descritores de forma, geralmente utilizados como variável auxiliar.

Como a classificação orientada a regiões depende de uma prévia segmentação, a mesma deve ser a mais rigorosa possível, ou seja, delimitar bem os objetos, tendo assim o menor número de segmentos em sua representação. Percebe-se que, os resultados das classificações ficaram limitados ao resultado obtido pela segmentação, não sendo possível corrigi-los no processamento da classificação.

Sugerem-se estudos que aprimorem a segmentação de imagem de alta resolução, que possibilitem uma melhor determinação dos objetos, o que irá aumentar a qualidade do mapa temático resultante, ou mesmo a construção de uma nova metodologia específica para imagem de alta resolução espacial, onde se

considere o tamanho, a forma e textura, ou seja, que extraia diferentes objetos em diferentes escalas, simultaneamente.

## 8. REFERÊNCIA BIBLIOGRÁFICA

- ANDERSON, P. S. Fundamentos para fotointerpretação. Sociedade Brasileira de Cartografia: Rio de Janeiro, 1982.
- ANDRADE, F. A. **Integração de variáveis espectrais e forma na classificação de imagens de alta resolução utilizando redes neurais artificiais.** Dissertação de mestrado pela Universidade Federal do Paraná, Curitiba - PR, 112 p., 2003.
- ANTUNES, A. F. B. **Classificação de Ambiente Ciliar Baseada em Orientação a Objeto em Imagens de Alta Resolução Espacial.** Tese de Doutorado pela Universidade Federal do Paraná, Curitiba – PR, 145 p., 2003.
- BAATZ, M.; SCHAPE, A. **Object-Oriented and Multi-Scale Image Analysis in Semantic Networks.** In: Proceedings of the 2nd Int. Symposium on Operationalization of Remote Sensing, Enschede, Netherlands, 1999.
- BLAISDELL, E. A. **Statistic in practice.** New York: Harcourt Brace Javanovich, 653p. 1993.
- CHENG, T. **Fuzzy objects: Their changes and uncertainties.** Photogrammetric Engineering & Remote Sensing, v.68, n.1, p. 41-49, 2002.
- COHEN, J. **A coefficient of agreement for nominal scales.** Educational and Psychological Measurement, v.20, n.1, p.37-46. 1960.
- ECOGNITION. **User guide.** Definiens Imaging. München, Germany, 2001.
- GERMAN, G. W. H. e GAHEGAN, M. N. **Neural Network Architectures for the Classification of Temporal Image Sequences.** Computers & Geosciences, v.22, n.09, p.969-979, 1996.
- GONZALES, R. C.; WOODS, R. E. **Processamento de imagens digitais.** Edgard Blücher Ltda. São Paulo, 527 p., 2000.
- HAYKIN, S. **Redes neurais. Princípios e prática.** Porto Alegre: Bookman, 900 p., 2001.
- HODGSON, M. E. **Reducing the computacional requirements of the minimum-distance classifier.** Remote sensing of environment, vol. 25, p. 117-128, 1988.
- LOHR, U.; EIBERT, M. **The TopoSys laser scanner – system,** In: Photogrammetric Week' 95, D. Fritsch, D. Hobbie (eds.), Wichmann Verlag, Heidelberg, 1995.
- MASAHARU, H; HASEGAWA, H. **Three-dimensional city modeling from laser scanner data by extracting building polygons using region segmentation**



- method.** International Archives fo Photogrammetry and Remote Sensing. Vol. XXXIII, Part B3. P.556-562, Amsterdam 2000.
- SHERSTHA, W. E.; THOMPSON, P. Y.; DEAN, R. G.; HARRELL, H. **Coastal & highway mapping by airborne laser swath mapping tecnology.** Third International Airborne Remote Sensing Conference and Exhibition, Copenhagen, Denmark, 7-10 July 1997
- SWAIN, P. H.; DAVIS, S. M. **Remote sensing: The quantitative approach.** New York: McGraw-Hill, p. 166-174, 1978.
- WEIDNER, U.; FÖRSTNER, W. **Towards automatic building reconstruction from hilgh-resolution digital elevation models.** ISPRS Journal of Photogrammetry and Remote Sensing 50(4), p.38-49. 1995.

(Recebido em setembro/04. Aceito em fevereiro/05.)