

Integração de dados do laser scanner com a banda pan-cromática do sensor QuickBird II para a identificação de edificações através das redes neurais numa abordagem orientada a regiões

Mosar Faria Botelho^{1*} e Jorge Antonio Silva Centeno²

¹Programa de Pós-Graduação em Ciências Geodésicas, Universidade Federal do Paraná (UFPR). ²Departamento de Geomática, Universidade Federal do Paraná (UFPR). *Autor para correspondência. e-mail: mfbotelho@yahoo.com.br

RESUMO. As imagens produzidas pelo sensor QuickBird II e pelos dados laser scanner são produtos caros para comercialização, porém têm mostrado seu valor técnico-científico no processamento digital de imagens. O objetivo deste estudo está em mostrar uma alternativa viável para a identificação de edificações através da classificação de imagem de alta resolução utilizando dados do sistema laser scanner e imagens do QuickBird II. No intuito de diminuir os custos na aquisição dos dados para o processamento digital, foram utilizados dados de intensidade e altimetria do laser, integrando-os com a banda pan-cromática do sensor QuickBird II, por meio do algoritmo de redes neurais e uma abordagem orientada a regiões. O trabalho justifica-se por utilizar tecnologias recentes (laser scanner e imagem QuickBird II) e um algoritmo integrador de variáveis de diferentes origens (as redes neurais artificiais), na elaboração de mapas temáticos com custos menores. O método mostrou-se viável para a elaboração de mapa temático.

Palavras-chave: sensoriamento remoto, redes neurais artificiais, laser scanner.

ABSTRACT. Integration of the laser scanner with image panchromatic of QuickBird II in identification of building using neural network and region orientation. The images produced by QuickBird II sensor and laser scanner data are expensive products to commercialize. Therefore, it has shown its value in the processing of digital images. The goal of this work is to show a viable option for building identification through high resolution image classification using laser scanner system data and images of QuickBird II. For doing so, it used intensity and altimetry laser data integrated with the panchromatic band of the QuickBird II sensor; by means of neural network algorithms and a region oriented approach. The work is justified because it uses recent technologies (laser scanner and QuickBird II images), and it can reduce the production costs of a thematic map. The method showed viable the elaboration of a thematic map.

Key words: remote sensing, neural network, laser scanner.

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 70 cm de resolução espacial, é possível a análise mais detalhada da cena, isto é, objetos menores como casas, ruas e árvores ficam 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 surge como uma tecnologia interessante para a extração de informações dos objetos da superfície do solo. Resumidamente, o método envolve a emissão de um pulso eletromagnético em direção a superfície tendo como produto as coordenadas plano-altimétricas e a intensidade do feixe refletido pelo objeto atingido. Esta informação, a altura dos pontos na superfície da terra, pode também ser incluída no processo de classificação, auxiliando-se assim a distinção de ambientes urbanos, como edificações.

A classificação de imagens digitais tem por objetivo extrair feições espaciais de forma

automática visando à compreensão humana. O processo de classificação de imagens pode ser realizado por dois processos 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 primeiro agrupar “pixels” similares e próximos em regiões e em atribuir cada região a uma das classes. Esse processo tem como vantagem a utilização de descritores podendo ser forma, tamanho e textura da região. Sendo que a definição de regiões é dada por um grupo de “pixels” que são similares e adjacentes. Observa-se também que o aumento de variáveis de entrada no processo de classificação gera problemas como o aumento do tempo de processamento e dificuldade da proposta do modelo mais adequado.

Para classificar dados de diferentes origens as Redes Neurais Artificiais (RNA's) são atualmente uma opção emergente. A utilização RNA's 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's, aliado ao aumento de variáveis derivadas da imagem, que oferece a abordagem de classificação baseado em regiões, é uma alternativa viável e interessante no sensoriamento remoto, especialmente na classificação de imagens de alta resolução espacial. No intuito de amenizar os custos de aquisição da imagem, o objetivo deste estudo está em avaliar a classificação de imagem digital utilizando apenas a banda pan-cromática do satélite QuickBird II, a altimetria e a intensidade fornecida pelo laser scanner aplicando a estas uma abordagem orientada a objetos.

Material

Área de estudo

Foi realizado um recorte de banda pan-cromática pertencentes a imagem QuickBird II correspondentes à área de estudo. Este recorte apresenta vias asfaltadas, casas, árvores e vegetação branda (gramíneas, pequenos arbustos, pastagens etc), destaca-se pela grande aglomeração entre edificações, representando um ambiente urbano realista. Este recorte pode ser observado na Figura 1.



Figura 1. Imagem pan-cromática do QuickBird II, da região em estudo.

Dados do laser scanner

Foi utilizado um conjunto de pontos do laser scanner, resultante de um levantamento realizado próximo ao campus Centro Politécnico na Universidade Federal do Paraná. O sistema utilizado para o levantamento foi o OPTECH / INS GPS APPLANIX, pertencente ao Instituto de Tecnologia para o Desenvolvimento (LACTEC - UFPR). O sistema de referência de coordenadas para o rastreamento foi o WGS84 (World Geodetic System, 1984). O levantamento foi realizado com um voo a uma altura de 1000 metros. A densidade de pontos é de 1 ponto a cada 66 cm em média tanto em x como em y. A largura da faixa foi de 350 metros com 6 faixas disponíveis.

A imagem intensidade foi fornecida pelo LACTEC (Figura 2b). Nesta foi realizada uma reamostragem, utilizando o método bilinear, com o objetivo de obter a mesma resolução espacial (0,7 m) da imagem pan-cromática do sensor QuickBird II.


No intuito de compatibilizar os dados altimétricos do laser scanner com a resolução espacial da imagem pan-cromática, foi gerada, através do programa SURFER, utilizando o método de interpolação “inverso do quadrado de uma distância”, uma grade altimétrica regular de 0,7 m. Objetivando obter apenas as alturas dos objetos em relação ao solo, presentes na cena, foram realizados os seguintes passos:

Inicialmente, foi coletada uma amostragem aleatória de pontos (aproximadamente 70 pontos geometricamente espaçados e distribuídos sobre a superfície), a partir da grade regular original. Pontos representativos que modelem a superfície do solo,

desprezando assim as elevações das edificações, árvores, etc.

De posse deste conjunto de pontos irregulares, que descrevem a superfície do solo, é gerada uma segunda grade regular de 0,7 m, compatível em sua dimensão com a original.

Finalmente, em um terceiro momento, é realizada a subtração das grades. Esta operação resulta em uma terceira grade com apenas a altura dos objetos em relação ao solo, contidos na cena. Este produto final pode ser observado na Figura 2a e é chamada de MDSN (modelo digital de superfície normalizado (Weidner e Förstner, 1995)).



(a)



(b)

Figura 2. Imagens oriundas dos dados do laser scanner; (a) Altimetria e (b) Intensidade.

Metodologia

Conceitos fundamentais

Para um melhor esclarecimento deste estudo serão abordados, nas próximas seções, os conceitos fundamentais de laser scanner, redes neurais, classificação digital de imagem e segmentação.

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 captado pelo sistema. A distância 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).

Redes neurais artificiais

Uma RNA pode ser definida, de modo simplificado, como um arranjo de unidades, neurônios interconectados, que trabalham em paralelo para classificar 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. Na camada de entrada, ou simplesmente nomeada “entrada” devido a não ocorrer processamento, os dados são apresentados à rede. A camada de entrada se comunica a uma ou mais camadas ocultas onde ocorre o processamento por meio de um sistema de conexões. A camada de saída apresenta o resultado do processamento. O funcionamento da rede é determinado pela conexão entre as unidades de processamento (German e Gahegan, 1996), definida pelos pesos de cada ligação.

De acordo com Jarvis e Stuart (1996), 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 variáveis consideradas pelas entradas espectrais (banda do sensor QuickBird II e intensidade do laser scanner) e espaciais (altitude fornecida pelo laser scanner). A saída da rede, para este trabalho, é a quantidade das classes que se deseja identificar.

Classificação digital

Um modo de tornar a interpretação de imagens mais simples consiste em separar grupos de elementos da imagem (“pixels” ou regiões) com características similares em classes, geralmente

associadas a tipos de uso ou cobertura do solo. 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.

Os métodos de classificação podem ser “pixel” a “pixel” ou por regiões, dependendo do nível de abstração. O método “pixel” a “pixel” admite como o menor elemento a ser classificado o “pixel” e o método por regiões admite como menor elemento o segmento, ou seja, a região que pode representar um objeto na cena ou parte deste, permitindo a descrição de sua forma.

De acordo Masaharu e Hasegawa (2000), um método eficiente para extrair dados de prédios com grande altura, obtidos por um laser scanner, é aplicando o método de segmentação de regiões. A idéia básica é que cada prédio tem uma altura diferente do vizinho. Entretanto pode-se distinguir cada prédio segmentando o MDSN, 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 constatou alguns problemas como: os objetos extraídos não são apenas prédios mas outros objetos diferentes, como, por exemplo, árvores são incluídas na classe. O estudo, apesar do problema mencionado aponta que a segmentação dos dados do laser scanner é um bom método para gerar modelo de imagem em 3D, no sentido de que o método pode gerá-la através de um processo automático.

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).

O algoritmo de segmentação mais utilizado atualmente é o que emprega o conceito de evolução de rede fractal (FNEA: fractal net evolution approach). Este método considera a imagem de sensoriamento remoto como de natureza fractal. Ao segmentar-se a imagem simultaneamente de forma fina e de forma grosseira, dá-se origem a diferentes escalas de segmentação. O procedimento de segmentação é similar ao crescimento de regiões que agrupa “pixels” ou sub-regiões em regiões maiores. A segmentação da imagem resulta em segmentos ou objetos, que baseados em parâmetros espectrais e espaciais, podem ainda ser reagrupados em objetos maiores denominados superobjetos ou regiões. Estas regiões possuem relações com os segmentos que as constituem num nível hierárquico mais baixo (Antunes, 2003). Um programa comercial que possui este algoritmo de segmentação é o “eCognition”.

Método

O método empregado neste trabalho consiste em segmentar uma imagem de alta resolução espacial (pan-cromática) utilizando uma técnica que considera a forma e textura dos objetos da cena e após realizar a classificação destes segmentos. Para esta segmentação foram consideradas, em seu processo, as variáveis auxiliares provenientes do laser scanner (intensidade e altimetria). A seguir é feita a classificação de cada segmento utilizando as redes neurais artificiais para integrar dados de diferentes fontes (laser scanner e sensor QuickBird II). Para verificar a validade do experimento, o produto gerado com a RNA foi comparado ao produto gerado por meio do algoritmo de classificação distância mínima.

Segmentação

A segmentação foi realizada utilizando o programa “eCognition” que possui o algoritmo de segmentação FNEA, o qual considera em seu processo parâmetros espaciais e espectrais. Neste processo foram consideradas as variáveis de intensidade e altimetria provenientes dos dados laser scanner. Estas auxiliaram a fornecer segmentos com formatos mais similares aos do objeto da cena. Os segmentos gerados por este processo foram utilizados no processo de classificação.

Redes neurais

Para este trabalho é adotada a arquitetura multicamadas com alimentação adiante (“feed-forward”) com o aprendizado de retro-propagação (“back-propagation”); possui “bias” que tem

influência externa ao neurônio, e a função de transferência adotada é a sigmóide. Esta arquitetura multicamadas, com duas camadas intermediárias, foi implementada na linguagem C++.

As variáveis de entrada na rede neural foram: o valor digital da intensidade fornecida pela imagem pan-cromática, o valor digital da intensidade fornecida pelo laser scanner e o valor da altura das edificações fornecidas pelo levantamento laser scanner e representado pela imagem altimétrica.

Análise estatística

Para a verificação do melhor classificador, 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, de uma foto aérea na escala de 1:8000.

No intuito de verificar a qualidade da classificação, foi comparado o produto obtido pela rede neural com o produto obtido pelo algoritmo mínima distância. O método da mínima distância 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.

Resultados

Os experimentos foram executados na seguinte ordem: segmentação da imagem, amostragem e treinamento da rede neural e finalmente a classificação da imagem e sua verificação.

Segmentação

O resultado da segmentação no “eCognition”, que utiliza o método FNEA, é uma imagem temática, onde a cada região é atribuído um valor digital, e uma tabela com os descritores de cada região, disponíveis neste sistema. Com estes segmentos foi realizada a amostragem.

O recorte mencionado foi segmentado utilizando os mesmos parâmetros de escala, cor, forma, compacidade e suavidade disponíveis no “eCognition”. Quanto maior o valor da escala, maior será as regiões que descrevem o objeto na cena, ou seja, menos detalhes são observados na imagem.

Para realizar a segmentação no “eCognition”, foram introduzidas a banda pan-cromática, a imagem altimétrica e a imagem intensidade, todas com o mesmo peso. Após o fornecimento de parâmetros espaciais e espectrais (Tabela 1), para cada nível que possibilitará a fusão entre “pixels” e segmentos, gerou-se uma nova imagem segmentada.

Cada região desta imagem foi codificada, ou seja, a cada região é dado um valor digital. Os valores utilizados para esta segmentação podem ser observados na Tabela 1.

Tabela 1. Fornece os parâmetros utilizados em cada nível de segmentação no ecognition.

Nível	Escala	Escala		Forma	
		Cor	Forma	Suavidade	Compacidade
1	5	0,7	0,3	0,7	0,3
2	5	0,3	0,7	0,7	0,3
3	10	0,3	0,7	0,7	0,3

Como pode ser observado na Tabela 1, foram utilizados 3 níveis de segmentação. No primeiro nível foi utilizada uma escala de valor igual a 5, 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). À suavidade e compacidade, após vários testes, foram dados os mesmos pesos de 0,7 e 0,3. No segundo nível foi acrescida a imagem altimétrica gerada a partir da grade regular (Figura 2). O “eCognition” gera os segmentos do segundo nível a partir dos segmentos criados pelo primeiro nível. Portanto, com base no primeiro nível, a configuração do segundo nível utilizou uma escala com valor igual a 5, na tentativa de aglomerar mais os segmentos de um objeto, para representá-lo melhor, parâmetro de cor igual a 0,3 e forma 0,7 isto devido, neste nível, ter sido incluído a imagem altimétrica produzida a partir dos dados laser scanner. Foi mantida a mesma configuração do nível 1 para os parâmetros de suavidade e compacidade. E finalmente, um terceiro nível, com o valor de escala maior, sendo este baseado no segundo, na tentativa de aglomerar mais “pixels” e aumentar o tamanho e representatividade da região. A imagem final deste processo pode ser observada na Figura 3.



Figura 3. Imagem segmentada no ecognition.

Um algoritmo de segmentação eficiente tem o objetivo de gerar regiões com o menor número de

iterações possíveis, neste caso, o menor número de sub-níveis. Portanto, as figuras dos níveis 1 e 2 não foram apresentadas devido as modificações ocorridas em suas regiões serem mínimas, e assim a diferença ocorrida em uma região é de difícil visualização nesta escala.

Amostragem e treinamento dos algoritmos de classificação utilizados

Foram encontradas quatro classes diferentes para esta área em estudo: vias asfaltadas, casas, árvores e vegetação branda.

Segundo German e Gahegan (1996), a escolha da arquitetura da rede neural é totalmente experimental. Porém para iniciar o processo, em uma arquitetura de multicamadas, pode-se adotar o critério da segunda camada intermediária ser 1/3 da primeira camada intermediária. Portanto foram executados testes que ajudaram na escolha da arquitetura para a melhor classificação desta imagem. Foram coletadas 15 amostras de cada classe para o treinamento deste algoritmo.

Para o treinamento do algoritmo de mínima distância foram utilizadas as mesmas classes, porém aumentando o número de amostras por classe, sendo 25 amostras por classe. Isso ocorre devido a este algoritmo exigir um número de amostras maior para seu aprendizado.

Classificação orientada a região

Três variáveis foram utilizadas para o treinamento dos classificadores (Redes Neurais e Distância Mínima), sendo a banda pan-cromática, a altimetria e a intensidade. Na Tabela 2 podem ser observados os resultados obtidos pelos classificadores utilizando a composição entre altimetria, intensidade do laser e a banda pan-cromática.

Tabela 2. resultado da rede neural e mínima distância para o recorte em estudo.

Variável	Método	
	Redes Neurais Artificiais	Distancia Mínima
P+I+A	58.1	56.1
I+A	52.2	50.3

P: pan-cromática; I: Intensidade do laser scanner; A: Altimetria fornecida pelo laser scanner.

Observando a Tabela 2, nota-se que os índices encontrados para o índice “kappa” são baixos. Isto ocorre devido à avaliação da classificação ser realizada comparando o resultado obtido com a digitalização dos contornos dos objetos, produzidos por restituição fotogramétrica. Uma parte dos erros apontados pelo índice “kappa” corresponde a “pixels” localizados nas fronteiras dos objetos. Tais

fronteiras dependem do sucesso da segmentação. A avaliação da imagem temática, portanto, inclui erros da segmentação, os quais não podem ser diferenciados na avaliação da classificação.

Ainda, observando-se a Tabela 2, nota-se que a rede neural apresenta um melhor resultado comparado com o método de Distância Mínima. Observando-se a influência da banda pan-cromática, nota-se um ganho de 5,9% quando adicionado esta banda na composição. O mesmo ocorre com o algoritmo distância mínima. Na Figura 4 pode-se observar a imagem temática produzida pelo melhor algoritmo de classificação, para esta área de estudo, a rede neural artificial.




Figura 4. Imagem temática produzida pela rede neural.

Considerações finais

Conclui-se que o uso da altimetria e intensidade derivada do laser como variável auxiliar na classificação de imagem de alta resolução espacial contribui na produção da imagem temática final. Através da análise dos resultados obtidos por meio dos dois métodos de classificação empregados, pode-se concluir que a composição da banda pan-cromática fornecida pelo sensor QuickBird II com a

altimetria e a intensidade fornecidas pelo laser scanner possibilitam a obtenção de uma imagem temática ligeiramente melhor.

Como a classificação orientada a regiões depende de uma prévia segmentação, a mesma deve ser a mais rigorosa possível. Percebe-se que os resultados das classificações ficaram limitados ao resultado obtido pela segmentação.

Referências

- ANTUNES, A.F.B. *Classificação de Ambiente Ciliar Baseada em Orientação a Objeto em Imagens de Alta Resolução Espacial*. 2003. Tese (Doutorado)-Universidade Federal do Paraná, Curitiba, 2003.
- COHEN, J. A coefficient of agreement for nominal scales. *Educ. Psychol. Meas.*, Durhaur, v. 20, n. 1, p. 37-46. 1960.
- GERMAN, G.W.H.; GAHEGAN, M.N. Neural Network Architectures for the Classification of Temporal Image Sequences. *Comp. Geosci.*, v. 22, n. 9, p. 969-979, 1996.
- GONZALES, R.C.; WOODS, R.E. *Processamento de imagens digitais*. São Paulo: Edgard Blücher Ltda, 2000.
- HAYKIN, S. *Redes neurais*. Princípios e prática. Porto Alegre: Bookman, 2001.
- JARVIS, C.H.; STUART, N. The Sensitivity of a Neural Network for Classifying Remotely Sensed Imagery. *Comp. Geosci.*, v. 22, n. 9, p. 959-967, 1996.
- LOHR, U.; EIBERT, M. The TopoSys laser scanner – system, *In: FRITSCH, D.; HOBBIE, D. (Ed.). Photogrammetric Week' 95*. Heidelberg: Wichmann Verlag, 1995.
- MASAHARU, H; HASEGAWA, H. Three-dimensional city modeling from laser scanner data by extracting building polygons using region segmentation method. *Int. Arch. Photog. Rem. Sens.*, Amsterdam, v. 33, Part B3, p. 556-562, 2000.
- WEIDNER, U.; FÖRSTNER, W. Towards automatic building reconstruction from high resolution digital elevation models. *ISPRS. J. Photog. Rem. Sens.*, v. 50, n. 4, p. 38-49, 1995.

Received on July 05, 2005.

Accepted on December 12, 2005.