

Comparação dos métodos de classificação supervisionada de imagem Máxima Verossimilhança e Redes Neurais em ambiente urbano

Rômulo José da Costa Ribeiro^{1,2 e 3}

Gustavo Macedo de Mello Baptista³

Edilson de Souza Bias³

¹ Universidade de Brasília - UnB

Instituto Central de Ciências - ICC Norte - Gleba A Campus Universitário Darcy Ribeiro -

Asa Norte Caixa postal 04431 – 70910-900 - Brasília – DF

rjcribeiro@uol.com.br

² União Pioneira de Integração Social – UPIS

SEPS 712/912, Conj. A - Asa Sul – 70390-125 – Brasília – DF

³ Universidade Católica de Brasília – UCB

QS 07 lote 01 EPCT – 71966-700 – Águas Claras – Taguatinga – DF

gmbaptista@pos.ucb.br; edilsonb@ucb.br

Abstract

The supervised classification of images is a process that assists the analyst in the identification of superficial phenomena in images of remote sensing. The traditional methods, although to present good results, in some cases present a little difference in the surface phenomena. The search for more accurate methods becomes basic for the best classification of the images. In this work it was present the comparison enters the traditional's classification method of maximum likelihood and neural networks. The last one, although to present better resulted than the first method, it is more delayed and demands many attempts and errors until getting an acceptable result. But it can be an interesting method for attainment of better results.

Palavras-chave: Image classification, maximum likelihood, neural networks, classificação de imagens, máxima verossimilhança, redes neurais.

1. Introdução

A configuração de uma cidade é extremamente dinâmica, haja vista a sua evolução, principalmente, pós Revolução Industrial, com o surgimento dos subúrbios e a ocupação de sua periferia, principalmente, devido à migração de áreas agrícolas para áreas urbanas (Mumford, 1998). Esse processo migratório persiste até hoje, de forma mais acelerada devido a busca da população rural por melhor qualidade de vida, o que se confirma a partir de dados que cerca de 90% da população mundial vive em cidades (Moreira, 1999). No Brasil, a população urbana corresponde a mais de 80% da população total do país (IBGE, 2001).

Para o melhor conhecimento dessa dinâmica, dispõe-se de uma forte ferramenta: as imagens de sensores remotos. Ao permitirem o imageamento de um mesmo lugar em diferentes datas, há a possibilidade de se acompanhar a evolução dos limites das manchas urbanas. Desta forma, pode-se avaliar tanto a velocidade quanto a forma de crescimento, isto é, se os limites estão sendo ampliados em direção a áreas não permissíveis, ou o quanto a cidade já está ocupando área não permissível, permitindo-se a elaboração de políticas que visem à alteração deste quadro.

A utilização de imagens de sensores remotos tem se mostrado de suma importância para o conhecimento da realidade urbana. Mas, devido à complexidade cada vez maior desta realidade, tem se buscado o aprimoramento de técnica de interpretação automatizada de tais imagens.

O surgimento das redes neurais artificiais vem com o intuito de melhorar a classificação supervisionada de tais imagens. Apesar de a literatura salientar melhores resultados obtidos com esse algoritmo em detrimento aos demais, as redes neurais são extremamente complexas

e de difícil montagem, sendo a obtenção do resultado final somente obtida depois de muitas tentativas e erros.

Apesar disto, o uso de redes neurais tem crescido, pois a necessidade de melhores resultados também é crescente. Recentemente alguns softwares comerciais têm disponibilizado este método de classificação, de forma estruturada, simplificando sua utilização. Mesmo que ainda se tenha que utilizar o sistema de tentativa e erro, a acurácia final pode compensar.

O objetivo do presente estudo é comparar dois métodos de classificação supervisionada de imagens, um tradicional (Máxima Verossimilhança) outro por redes neurais, a fim de se verificar qual método oferece melhores resultados para classificação de imagens em áreas urbanas.

2. Área de Estudo

A área investigada pertencente à Região Administrativa XVIII (RA XVIII) – Lago Norte. Alguns anos após a inauguração de Brasília a Empresa Urbanizadora da Nova Capital do Brasil – NOVACAP havia elaborado vários projetos de urbanização e ocupação da Península Norte, que se deu de forma lenta e natural. Somente em 10 de janeiro de 1994, por meio da Lei nº 641/94 e do Decreto nº 15.516/94 foi criada a RA XVIII, composta pelo Setor de Mansões do Lago (SML), Setor de Habitações Individuais Norte (SHIN), Vila Varjão do Torto e pelo Centro de Atividades – CA (**Figura 1**). (CODEPLAN, 2003)




Figura 1 – Localização da RA XVIII – Lago Norte, Distrito Federal (CODEPLAN, 1997; IBGE, 2002).

A RA XVIII possui quatro grandes situações interessantes para a análise urbana:

- Áreas com baixas densidades populacionais, que chegam a menos de 10 habitantes por hectare (hab/ha), e alta concentração de renda, área da península do Lago Norte e SML (área em verde);
- Áreas com crescimento descontrolado, constituída por comércios, serviços e kitnets, favorecendo altas densidade populacional e circulação de pessoas, área do Centro de Atividades (CA) (área em azul claro);

- Áreas de chácaras ou tidas como agrícolas, área norte da referida região administrativa (área em ocre);
- Áreas de invasão, caracterizadas por população de baixa renda, alta concentração de pessoas, pouca ou ausência de infra-estrutura e equipamentos urbanos, área da Vila Varjão do Torto (área em vermelho).

Estas quatro situações convivem juntas gerando vários tipos de pressões urbanísticas e sociais, demandando estudos e intervenções que minimizem estas pressões, buscando melhoria das condições de vida das populações marginalizadas, sem agredir as áreas de entorno ou impedir o desenvolvimento da região.

Visando, ainda, a manutenção e atendimento das necessidades das áreas de alta renda já consolidadas e procurando o desenvolvimento da área de comércio e serviços, sem que nenhuma destas situações venha a agredir ou buscando minimizar a agressão já existente ao meio ambiente.

3. Materiais e Métodos

3.1. O Satélite Landsat

A série Landsat é composta por satélites lançados pela NASA desde 1972, com o intuito do imageamento das características ambientais da superfície terrestre. Em cada nova plataforma foram colocadas as tecnologias mais recentes desenvolvidas para a época, visando cada vez mais a melhor na geração de dados por esse satélite.

Em 1999 foi lançado o mais recente satélite da série, o Landsat 7, composto pelo sensor de varredura mecânica ETM+ (Moreira, 2001). A novidade deste sensor é que além das sete bandas existentes no sensor TM, com resolução espacial de 30 m (bandas 1, 2, 3, 4, 5 e 7), foi adicionada uma banda pancromática com resolução espacial de 15 m, melhorando significativamente a capacidade de identificação de objetos na superfície, especialmente em áreas urbanas. Além disso, o sensor ETM+ apresenta a banda 6 com resolução espacial de 60 m (contra a de 120 do sensor TM) e apresentadas em duas versões, sendo uma de alto e outra de baixo ganho. Este sensor apresentou problemas de navegação a partir de maio de 2003.

3.2. Classificação pelo Método da Máxima Verossimilhança

Este é o método tradicional mais comumente utilizado quando é necessária a obtenção de classes informacionais a partir de imagens de sensores remotos. A distribuição espectral das classes de uso do solo é considerada como sendo gaussiana ou normal, isto é, objetos pertencentes à mesma classe apresentarão resposta espectral próxima à média de valores para aquela classe.

Este método parte do princípio que a classificação errada de um pixel não tem mais significado do que a classificação errada de qualquer outro pixel na imagem (Richards, 1993). O método considera a ponderação das distâncias médias, utilizando parâmetros estatísticos de distribuição dos pixels dentro de uma determinada classe (Crósta, 1993).

Para a obtenção de um bom resultado com esta classificação é necessária a escolha de um número razoavelmente elevado de pixels para cada amostra de treinamento da classe, e que estes tenham uma distribuição estatística próxima da distribuição normal (Crósta, 1993).

Outro fator importante para a sua eficácia, é a obtenção de uma precisão razoável da estimativa do vetor médio e da matriz de covariância de toda a classe espectral. Fato este dependente da quantidade de pixels incluídos nas amostras de treinamento (Sulsoft, 2003).

Este método de classificação parte do pressuposto que o usuário conheça previamente a área analisada, bem com a distribuição das classes, para que desta forma, quando da aplicação

da classificação, a seleção de amostras de treinamento possa ser o mais eficiente possível (Crósta, 1993).

3.3. Classificação por Redes Neurais *Perceptron* com Algoritmo *Backpropagation*

Novas tecnologias têm sido desenvolvidas para melhoria dos métodos tradicionais de classificação de imagens de sensoriamento remoto. Nos últimos 10 anos tem crescido o interesse por pesquisas utilizando redes neurais artificiais aplicadas ao reconhecimento de padrões de classes. O grande diferencial é que este novo método utiliza sistema de amostragem, não requerendo a natureza paramétrica da distribuição estatística dos dados, nem o conhecimento prévio desta distribuição (Galo, 2000).

Existem vários modelos de redes neurais artificiais desenvolvidos para os mais diversos fins.

Neste contexto, está inserida a rede *neural perceptron multicamadas*, a qual assume regiões de decisão semelhantes àquelas formadas por um classificador estatístico, porém com entradas não correlacionadas e distribuições diferentes para os dados (Lippmann, 1987). Além disto, essas redes são treinadas por um algoritmo iterativo de aprendizagem, chamado *backpropagation* que habilita a desenvolver um comportamento associativo correto quando confrontadas com situações com características similares (Galo, 2000).

Métodos que utilizam redes neurais artificiais podem ser aplicados a diferentes situações, devido à flexibilidade na entrada dos dados para a classificação, a possibilidade de incorporar dados de outras fontes ao conjunto de dados de entrada, e ao fato de sua aplicação não implicar necessidade de uma distribuição estatística dos dados.

A rede neural *perceptron* multicamadas é capaz de reconhecer diferentes classes e resolver o problema de superposição de regiões. A estrutura de *perceptron* multicamadas pode ser definida como uma rede de alimentação progressiva, com uma ou mais camadas escondidas entre os neurônios de entrada e de saída (Lippmann, 1987).

Na descrição da arquitetura básica de uma rede neural *perceptron* multicamadas, Gonzalez & Woods (1993) mostram um modelo que consiste de camadas de neurônios estruturalmente idênticos, arranjados de modo que a saída de cada neurônio em cada camada, alimente a entrada de cada um dos neurônios da camada seguinte (Figura 2). O número de neurônios da primeira camada corresponde à dimensionalidade do vetor de atributos dos dados de entrada. A camada de saída terá tantos neurônios quantas forem as classes a serem separadas. O problema maior está na definição do número de camadas escondidas, e do número de neurônios que as compõem. Na prática este problema tem sido geralmente resolvido por tentativa e erro, ou pela experiência prévia no domínio de uma dada situação. (Galo, 2000)




Figura 2 – Estrutura esquemática de uma rede *perceptron*, com uma cada escondida (Adaptada de Gonzales & Woods, 1993. Modificada de Galo, 2000).

A **Figura 2** mostra a estrutura esquemática de uma rede *perceptron* com duas camadas: uma escondida, chamada *J* e outra de saída, chamada *Q*. Os vetores X_1, X_2, \dots, X_n , representam o conjunto de dados de entrada. Os pesos ajustados durante o treinamento são representados por W_{jx_i} e W_{qj} , e as *M* classes de saídas são representadas por w_1, w_2, \dots, w_M .

Lippmann (1987) considera que o algoritmo *backpropagation* permite o ajuste de pesos em cada uma das camadas da rede, sendo projetado para minimizar a soma do erro quadrático entre a saída calculada por uma estrutura multicamadas e a desejada. Este algoritmo atua de modo iterativo, propagando o erro regressivamente, de modo a ajustar os pesos, a partir dos neurônios da camada de saída para os nós das camadas anteriores (Galo, 2000).

O sistema utiliza a rede neural aplicada à técnica de classificação de camadas *feed-forward*. Esta técnica utiliza o padrão *backpropagation* para o aprendizado supervisionado. O aprendizado ocorre pelo ajuste dos pesos nos nós para minimizar as diferenças entre a ativação do nó de saída e a saída desejada. O erro é retroalimentado através da rede e o ajuste do peso é feito usando um método recursivo. Este método foi utilizado para melhorar a performance de análise de dados não-lineares.

Vários trabalhos têm demonstrado a eficácia da utilização de redes neurais para a classificação de imagens de satélite. “A classificação digital consiste em associar determinado pixel a determinada categoria ou classe por meio de critérios estabelecidos. A classificação tem como objetivo: ordenar, discriminar e categorizar” (Ribeiro & Centeno, 2001).

3.4. Definição dos Principais Tipos de Uso do Solo

Os tipos de usos do solo, geralmente, são constituídos por um volume grande de dados espacializados, extraiu-se, basicamente, as informações relativas a três classes, sendo que os espaços pouco urbanizados foram constituídos de áreas esparsas com baixo grau de ocupação, áreas agrícolas, áreas de desmatamentos, solos expostos, áreas de queimada e voçorocas; as extensões de feições naturais representadas pelas matas, cerrados, campos e veredas; e áreas urbanas, constituídas por alto grau de ocupação, malham viária densa e estruturada. Esse plano de informação foi elaborado com base na imagem do satélite ETM+/Landsat 7, de 04 de maio de 2002.

Partindo-se da premissa que este novo método é mais preciso que os métodos tradicionais, decidiu-se por sua utilização, que foi comparado com o método Máxima Verossimilhança. A análise da matriz de confusão dos dois métodos de classificação e a análise visual comparativa entre os resultados e a imagem original, foi fundamental para a avaliação do produto final.

4. Resultados

O uso do solo foi obtido a partir da classificação da imagem do Landsat 7 ETM+ de 04 de maio de 2002 (**Figura 3**). Para tal, foi adotada a cena com resolução de 15 metros obtida a partir da fusão da banda pancromática com as multiespectrais.



Figura 3 – Imagem do satélite ETM+/Landsat 7, de 04 de maio de 2002, composição colorida RGB das bandas 3, 4 e 5, reamostrada para 15 metros.

O resultado obtido pelo método de classificação Máxima Verossimilhança pode ser visualizado na **Figura 4**. Já o resultado obtido pelo método de classificação de redes neurais, é apresentado na **Figura 5**.

Para a obtenção da imagem classificada por redes neurais, modificaram-se os parâmetros de sensibilidade, e por tentativa e erro, obteve-se um resultado aceitável. Para tanto, foram processadas 27 classificações, escolhendo-se os melhores resultados, e, a partir destes, modificaram-se novamente os parâmetros, na tentativa de melhorar o resultado. Foram geradas mais 5 classificações, sendo que o resultado da 32ª classificação foi o selecionado. A escolha dos melhores resultados baseou-se no conhecimento prévio da área de estudos.




Figura 4 – Principais tipos de uso do solo, obtidos pela classificação Máxima Verossimilhança.




Figura 5 – Principais tipos de uso do solo, obtidos pela classificação por redes neurais.

Pode-se verificar que para a classe fracamente urbanizada há uma melhor separação, na classificação por redes neurais, de vegetação lenhosa de não lenhosa à montante do braço do Ribeirão do Torto, que corresponde ao braço inferior do Lago Paranoá, mas há mistura entre asfalto e o canteiro central na área da península do Lago Norte. Este é um problema típico de classificação supervisionada de imagens com baixa resolução radiométrica.

Para a escolha do melhor resultado obtido pela classificação por redes neurais, compararam-se as matrizes de confusão e o coeficiente kappa, das 32 classificações, com a matriz de confusão e o coeficiente kappa da classificação Máxima Verossimilhança.

A matriz de confusão compara o resultado da classificação com dados de verdade de solo, obtendo uma acurácia global e o coeficiente kappa. Usaram-se as áreas de interesse de classificação como verdade de solo. O coeficiente kappa apresenta uma vantagem na comparação de resultados, pois incorpora os pixels mal classificados, não apenas os bem classificados como na acurácia global. Esta última superestimaria a acurácia da classificação, e o coeficiente kappa apresentaria uma avaliação mais adequada (Sulsoft, 2003).

Apesar de os dois métodos apresentarem valores elevados, tanto na Acurácia Global, como no coeficiente kappa, o obtido por meio de redes neurais apresentou valores comparativamente mais elevados.

O 32º resultado foi o que apresentou melhor resultado, quando comparado ao método Máxima Verossimilhança (**Quadro 1**).

Quadro 1 – Comparação dos resultados obtidos pelos dois métodos de classificação.

Método de Classificação	Acurácia Global	Coefficiente kappa
Máxima Verossimilhança	99,2282	0,9879
Redes Neurais	99,5590	0,9931

A comparação visual entre as duas classificações (**Figuras 4 e 5**) e a imagem original (**Figura 3**) mostrou que a classificação por redes neurais apresentou melhor identificação das classes, obtendo uma melhor separação entre as mesmas.

6. Considerações Finais

Após a realização do trabalho verificou-se que a utilização de instrumentos de sensoriamento remoto é um forte aliado para o conhecimento da realidade urbana. A associação deste com bancos de dados populacionais, como os censos demográficos, permite o conhecimento do perfil populacional e possíveis tendências. Sendo que estas análises podem ser feitas de forma extremamente rápida e dinâmica, permitindo o acompanhamento da evolução física, ambiental e social urbana.

A utilização do método de classificação por redes neurais mostrou-se mais eficiente que o método tradicional, mas a definição dos parâmetros e seu treinamento foram muito demorados, sendo necessária a execução de 32 classificações, com parâmetros diferentes, para que se chegasse a um resultado aceitável. A utilização de um *software* comercial facilitou o uso de redes neurais, mas ainda são necessários muito tempo e laborioso processo de tentativas e erros para a obtenção de bons resultados.

A utilização de uma imagem de sensoriamento remoto de média resolução espacial (15 metros), mostrou-se adequada, principalmente em relação ao custo de aquisição e a resolução espectral da mesma. Imagens de maior resolução espacial podem vir a melhorar a classificação, devido à melhor identificação de objetos no solo. Mas deve-se ficar atentos também quanto as resoluções espectral e radiométrica dos dados, pois tendem a gerar melhores separações entre os alvos investigados.

Bibliografia

- CODEPLAN, Companhia de Desenvolvimento do Planalto Central. Disponível em: <<http://www.codeplan.df.gov.br>>. Acesso em: 08/08/2003.
- CRÓSTA, A. P., **Processamento Digital de Imagens de Sensoriamento Remoto**, Campinas, SP, UNICAMP, ed. rev., 1993.
- GALO, M. L. B. T., **Aplicação de redes Neurais Artificiais e Sensoriamento Remoto na Caracterização Ambiental do Parque Estadual Morro do Diabo**. Tese de Doutorado, Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, SP, 2000.
- GONZALEZ, R. C. & WOODS, R. E., **Recognition and Interpretation. Digital Image Processing**, 1993. In: GALO, M. L. B. T., Aplicação de redes Neurais Artificiais e Sensoriamento Remoto na Caracterização Ambiental do Parque Estadual Morro do Diabo. Tese de Doutorado, Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, SP, 2000.
- IBGE, **Censo Demográfico de 2000. Características da População e dos Domicílios. Resultado do Universo**, Rio de Janeiro, RJ, IBGE, 2001. CD-ROM.
- LIPPMANN, R. P., **An introduction to computing with neural nets**. IEEE ASSP Magazine, v.4., 1987. In: GALO, M. L. B. T., Aplicação de redes Neurais Artificiais e Sensoriamento Remoto na Caracterização Ambiental do Parque Estadual Morro do Diabo. Tese de Doutorado, Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, SP, 2000.
- MOREIRA, I., **O Espaço Geográfico – Geografia Geral e do Brasil**, São Paulo, SP; Ática, 1999.
- MOREIRA, M. A., **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**, São José dos Campos, SP, Instituto Nacional de Pesquisas Espaciais, INPE, 1ª ed, 2001.
- MUMFORD, L., **A Cidade na História. Suas Origens, Transformações e Perspectivas**, São Paulo, SP; Martins Fontes, 4ª edição, 1998.
- RIBEIRO, S. R. A. & CENTENO, J. S., **Classificação do Uso do Solo Utilizando Redes Neurais e o Algoritmo MAXVER**. In: Simpósio Brasileiro de Sensoriamento Remoto, 10, Foz do Iguaçu, PR, Anais, 2001. CD-ROM.
- RIBEIRO, R. J. C., **Geotecnologia em Apoio à Aplicação de Instrumentos de Política Urbana**. Brasília, DF, Dissertação de Mestrado, Universidade de Brasília, Faculdade de Arquitetura e Urbanismo, Programa de Pós-Graduação, 2003.
- SULSOFT, **Guia do ENVI em Português**. Disponível em: <<http://www.envi.com.br>>. Acesso em: 06/07/2003.