

Utilização de imagens do sensoriamento remoto para detectar defeitos nas superfícies de pavimentos asfálticos

XIV Simpósio Brasileiro de Sensoriamento Remoto - SBSR

Edgar Ricardo Ferreira¹
Carlos Antônio Oliveira Vieira²

¹ Colégio Técnico Universitário da Universidade Federal de Juiz de Fora
Rua Bernardo Mascarenhas, 1283 - 36080-001 – Juiz de Fora - MG, Brasil
edgarjf@superig.com.br

² Universidade Federal de Viçosa – Departamento de Engenharia Civil
Setor de Engenharia de Agrimensura
Campus de UFV – DEC - 36570-000 - Viçosa - MG, Brasil
carlos.vieira@ufv.br

Abstract. Brazil is a country where its facilities of transports are concentrated in highways. Among the countless actions that are contemplated in a Pavements Management System (PMS), the one of largest relevance are those concerned to the prioritization of the maintenance activities and pavements' rehabilitation, aiming to obtain the best possible return for the invested resources, giving safe, comfort and economic pavements to the users. One of those activities in the study of the rehabilitation of the pavement is a survey of the surface defects, characterized by a series of events that influence directly in the lack of continuity of the pavement surface. In order to perform the pavements' surface inventory it was used an orbital images with highest resolution (QuickBird 2), as an alternative to the current field techniques. It was performed a sampling in order to generate independent training and validation sets. Then, it is proceeded to an analysis of the spectral and textural information objectifying to find a pattern for the surface defects that characterize the conditions of rolling of the investigated highways. The obtained results confirm the difficulty to detect the defects on the roads using orbital images, due to their spatial resolution. However, it is possible that with the advances in technologies (increase of the spatial resolution in orbital sensors), it will be possible to reach this objective.

Palavras-chave: pavement distress, images of the high resolution, functional classification, artificial neural networks, defeitos nos pavimentos, imagens de alta resolução, classificação funcional, redes neurais artificiais.

1. Introdução

1.1 Generalidades

O Brasil é um país em que suas instalações de transportes estão concentradas no modo rodoviário, que contribui com cerca de 90% da matriz de transporte de passageiros e cerca de 61% da matriz de transporte de cargas, CNT (2007). Segundo o Departamento Nacional de Infra-Estrutura de Transportes – DNIT (2008), do total de rodovias do Brasil, cuja extensão até 20/11/2006 era de 1.627.292,2 km, cerca de 12% estava pavimentada, ou seja, algo em torno de 196 mil km.

Na pesquisa rodoviária de 2007 a CNT (2007) analisou 100% da malha rodoviária federal pavimentada e também os principais trechos sob gestão estadual e sob concessão, totalizando 87.592 km, onde constatou que cerca de 46,7% da malha pesquisada, em relação às condições da superfície do pavimento, necessitam de algum tipo de intervenção, uma vez que o pavimento encontra-se desgastado, com trincas, remendos, buracos ou até mesmo totalmente destruído.

Uma das atividades no estudo da reabilitação do pavimento é o levantamento dos defeitos de superfície, caracterizados por uma série de eventos que influenciam diretamente na descontinuidade da superfície do pavimento.

1.2 Os defeitos de superfície nos pavimentos asfálticos

Pavimento é a estrutura construída sobre um terreno de fundação, de nome subleito, e que

deverá resistir à ação das cargas de roda dos veículos e às ações do tempo. Existem diferentes tipos de revestimentos, mas todos eles têm por finalidade proteger o pavimento, aumentar a resistência à derrapagem, melhorar o conforto ao rolamento e resistir aos esforços causados pelo tráfego e pelo intemperismo.

A água é uma grande inimiga dos pavimentos, devendo-se evitar que ela penetre no interior do mesmo, pois se isso ocorrer, ela pode influenciar negativamente nas camadas do mesmo, diminuindo sua capacidade de resistir aos esforços gerados pelo tráfego e deteriorando precocemente a superfície do pavimento.

Avaliar um pavimento é estimar suas características atuais e futuras de rolamento e segurança e de suporte para dar subsídio a um sistema de gerenciamento de pavimento – SGP. Os objetivos de uma avaliação superficial são identificar os tipos de defeitos, sua severidade e sua extensão. Hoje, um grande desafio é melhorar as técnicas de avaliação superficial e, a tendência mundial, está voltada para a utilização de imagens do pavimento, que podem ser obtidas a nível orbital, sub-orbital ou terrestre, entendendo essa última possibilidade o uso de uma câmera industrial acoplada a um veículo que transite diretamente na via.

Esse trabalho se concentrará no uso de imagem orbital de alta resolução na tentativa de se fazer a detecção de defeitos nas superfícies dos pavimentos asfálticos utilizando técnicas de reconhecimento de padrão. Segundo Vieira (2000), o desenvolvimento de um sistema automático de reconhecimento de padrões envolve pelo menos quatro fases: 1) descrição do objeto - onde serão definidas medidas ou variáveis discriminatórias, para representar computacionalmente os objetos de interesse; 2) extração de características - onde será selecionado um subconjunto de variáveis, da lista de medidas geradas na fase anterior, que melhor discriminarão os objetos de interesse; 3) regra de decisão, onde serão definidos os classificadores paramétricos (ex.: Máxima Verossimilhança, Mínima Distância Euclidiana, etc.) ou não-paramétricos (ex.: redes neurais artificiais, etc.) e; 4) avaliação do modelo, onde será acessada a precisão de detecção ou identificação, do sistema de automático de reconhecimento de padrões.

1.3 Regra de decisão utilizando redes neurais artificiais (RNA)

As RNAs são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. As RNAs apresentam, devido às suas características típicas, a habilidade de adaptação e aprendizagem pelo ambiente o que lhe permite lidar com dados imprecisos e situações indefinidas. A modelagem das RNAs tem como objetivo fornecer meios para que o computador extraia características dos dados, a partir de um conjunto supervisionado de treinamento e, assim, possa armazenar o conhecimento adquirido e aplicá-lo em situações reais, Haykin (2001).

A utilização de uma RNA na solução de uma tarefa passa, antes de tudo, por uma fase de aprendizagem (ou treinamento), quando a rede extrai informações relevantes de padrões de informação apresentados para ela, criando assim uma representação própria para o problema. A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, principalmente dos pesos das conexões entre as unidades de processamento (neurônios artificiais), que guardam, ao final do processo, o conhecimento que a rede adquiriu sobre o problema em questão.

A forma como os neurônios são organizados na RNA é denominada de topologia (ou arquitetura) e, tipicamente, é constituída por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída.

Outro aspecto é que uma rede neural pode aceitar diferentes dados de entrada como, por exemplo, características espectrais de imagens do sensoriamento remoto, abordagem desse trabalho.

A Figura 1 apresenta a topologia característica de uma RNA com quatro camadas: uma camada de entrada, com quatro neurônios artificiais representando as variáveis discriminatórias; duas camadas ocultas, com cinco neurônios cada e; uma camada de saída, com três neurônios representando as classes informacionais.

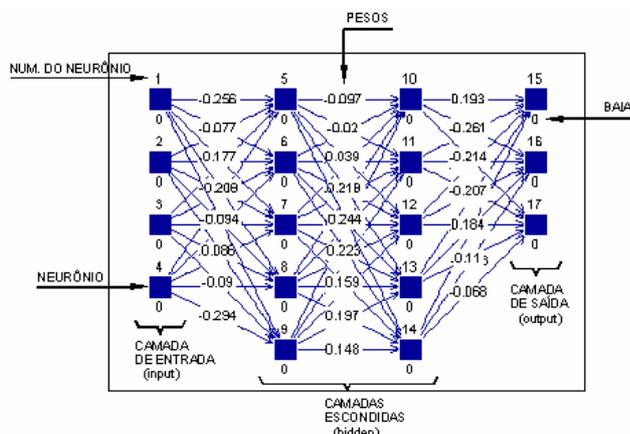


Figura 1. Topologia característica de uma RNA e algumas denominações.

Poucas iniciativas aparecem na literatura sobre detecção de defeitos de superfície de pavimentos asfálticos utilizando sensoriamento remoto e o uso de classificador não-paramétrico. Devido às resoluções das imagens de satélite, mesmo as de alta resolução, como imagens dos sensores *Ikonos II* e *QuickBird 2*, sabe-se que identificar defeitos sobre o pavimento é uma tarefa com um nível de dificuldade muito grande. Por isso, optou-se pelo uso de RNAs como uma expectativa de contornar essa dificuldade.

1.4 Objetivo desse trabalho

Este trabalho tem por objetivo analisar a possibilidade de se fazer a detecção de defeitos superficiais nos pavimentos asfálticos, com o uso do sensoriamento remoto através de imagens orbitais de alta resolução, utilizando técnicas estatísticas de reconhecimento de padrões e redes neurais artificiais (RNA) como regra de decisão, de forma a minimizar custos e tempos de levantamentos no campo, assim como melhorar a repetitividade dos dados levantados.

2. Metodologia do trabalho

2.1 Descrição da área de estudo

A área de estudo, objeto da pesquisa, foram dois trechos de rodovias situadas no município da cidade de Viçosa (MG), conforme Figura 2. Um trecho foi da BR-120, que liga Viçosa a Teixeira e o outro foi da mesma BR, que liga Viçosa a Coimbra. Na escolha dessa área prevaleceu a disponibilidade de uma imagem *QuickBird 2* da região e os trechos selecionados foram devidos a apresentaram uma razoável boa identificação visual das classes informacionais em estudo.

2.2 Material e métodos

A metodologia adotada consistiu em inicialmente, definir as classes informacionais mais representativas que poderiam ser observadas na imagem (Figura 2), assim: 1) asfalto bom; 2) asfalto ruim; 3) sombra no asfalto; e, 4) veículos sobre o asfalto. A expressão asfalto ruim é para caracterizar asfalto com defeitos. Embora a pesquisa seja para distinguir problemas superficiais no asfalto, as sombras no asfalto e veículos sobre o asfalto são feições que teriam que ser avaliadas, pois elas interferem na análise sobre o asfalto bom e asfalto ruim. Assim, tem-se que extrair previamente essas feições do pavimento para poder fazer a análise apenas

do asfalto. Dessa forma, havendo asfalto ruim em área de sombra sobre o asfalto e havendo asfalto ruim sob veículos, esses não serão avaliados.

Optou-se por uma classificação pixel a pixel (fase de descrição dos objetos) e utilizou-se a imagem multiespectral composta de 4 bandas (nas regiões do espectro eletromagnético correspondente ao azul, verde, vermelha e infravermelha próxima) como variáveis discriminantes (fase de extração de características). Foram selecionadas amostras independentes, as quais foram divididas em amostras de treinamento e amostras de teste, respectivamente. Nas amostras de treinamento foram extraídas as seguintes quantidades para cada classe: Classe 1 - 200 amostras de “asfalto bom”; Classe 2 - 140 amostras de “asfalto ruim”; Classe 3 - 80 amostras de “sombra no asfalto” e; Classe 4 - 80 amostras de “veículos sobre o asfalto”. Já para as amostras de teste selecionou-se exatamente a metade, ou seja: Classe 1 - 100 amostras de “asfalto bom”; Classe 2 - 70 amostras de “asfalto ruim”; Classe 3 - 40 amostras de “sombra no asfalto” e; Classe 4 - 40 amostras de “veículos sobre o asfalto”.

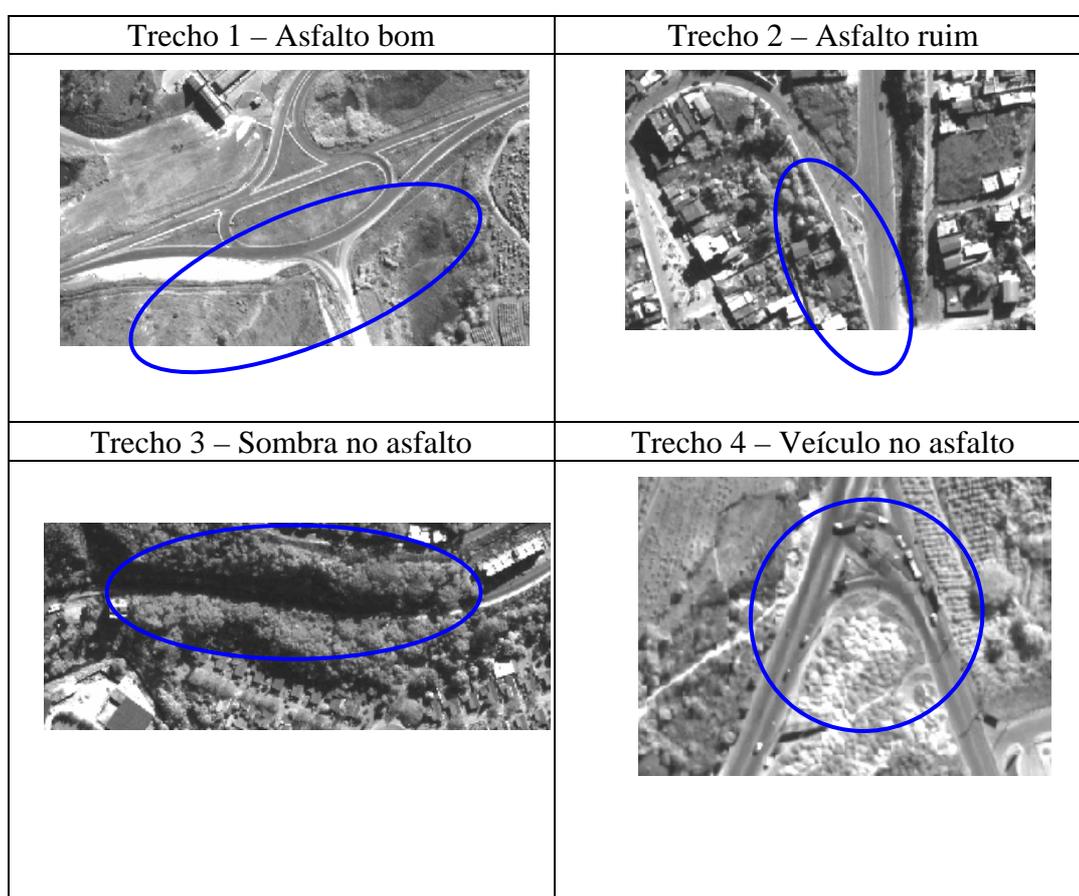


Figura 2. Caracterização das 4 classes informacionais. Imagem Quickbird 2 pancromática com 0,6m de resolução espacial.

No processo de seleção desses padrões (valores dos níveis de cinza), colocou-se lado a lado a imagem pancromática e a imagem multiespectral. Esse procedimento foi adotado para facilitar a identificação de pixels pertencentes às classes de estudo, devido a imagem pancromática ter uma resolução espacial 4 vezes melhor que a da imagem multiespectral (Figura 3).

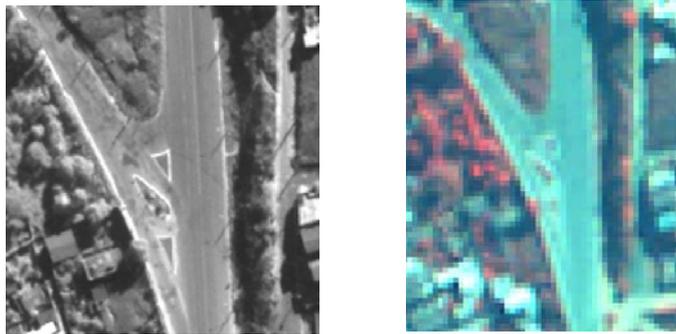


Figura 3 – Imagem pancromática (esquerda) e imagem multiespectral (direita).

O software utilizado para a extração dos valores do pixel foi o *Erdas Image 8.5* da ERDAS Inc.

Na Tabela 1 são apresentados exemplos de alguns valores de níveis de cinza, extraídos da imagem multiespectral, durante a fase de amostragem. Observa-se uma similaridade entre os valores espectrais das classes 1 e 2, dada a resolução espacial da imagem multiespectral.

Tabela 1 – Exemplos de valores de níveis de cinza obtidos para as 4 classes nas quatro bandas espectrais.

Classe 1 - ASFALTO BOM				Classe 2 - ASFALTO RUIM			
Banda 1	Banda 2	Banda 3	Banda 4	Banda 1	Banda 2	Banda 3	Banda 4
203	283	206	219	203	397	225	236
199	309	231	245	189	285	210	215
199	315	227	225	189	292	211	232
Classe 3 - SOMBRA NO ASFALTO				Classe 4 - VEÍCULO NO ASFALTO			
116	118	53	38	295	527	437	471
130	141	63	48	208	492	383	472
113	121	46	37	252	424	322	404

Com os dados obtidos na fase anterior passou-se a fase de classificação propriamente dita, utilizando-se inicialmente o algoritmo da Máxima Verossimilhança. Posteriormente, foi realizada uma classificação supervisionada usando uma RNA. O software utilizado foi o *Java Neural Network Simulator 1.1- JavaNNS*, desenvolvido pelo *Institute for Parallel and Distributed High Performance System* da Universidade de *Stuttgart*.

Normalmente a modelagem de RNA exige as seguintes etapas: 1) preparação dos dados, onde os dados foram re-escalados para o intervalo 0 e 1, para evitar saturação na rede no início do treinamento; 2) definição da topologia interna da rede a qual seguiu o procedimento descrito por Hirose *et al.* (1991); 3) escolha dos parâmetros da rede: os pesos iniciais foram gerados aleatoriamente variando de -0,3 a 0,3, Vieira (2000). Utilizou-se função de ativação logística e taxa de aprendizagem 0,2 e *momentum* com valor fixo de 0,9; 4) usar as funções de aprendizagem *Backpropagation* e *Backpropagation* com *Momentum*. A melhor topologia de rede seria aquela que apresentasse o menor erro médio quadrático.

A Figura 4 apresenta duas topologias utilizadas durante o processo de treinamento. Foram geradas nesse processo 27 topologias diferentes.

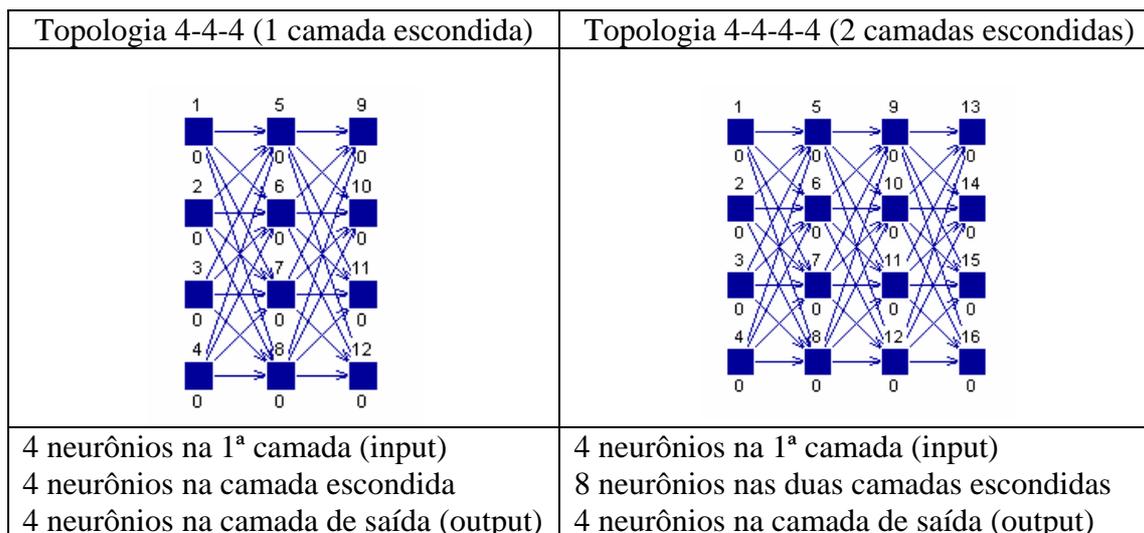


Figura 4. Exemplos de topologias de redes utilizadas.

Após o treinamento, as amostras de teste, coletadas independentemente, foram utilizadas para a validação dos resultados, onde foram geradas as matrizes de erro e índices derivados para análises estatísticas. Equações e detalhes dos índices utilizados para avaliar classificadores no contexto do Sensoriamento Remoto podem ser encontrados em Congalton e Green (1999). Vieira (2000) implementou diversos aplicativos que não só possibilita essa avaliação da classificação, como também permite a interface entre os softwares utilizados nessa pesquisa.

3. Resultados e discussões

Os resultados da classificação usando o algoritmo da Máxima Verossimilhança (Maxver) com as 250 amostras de teste estão apresentados na Tabela 2.

Uma medida estatística que pode ser derivada da matriz de erro é a exatidão global, que representa o grau de concordância entre as amostras de referências e a classificação Maxver (diagonal da matriz de erro) dividido pelo número total de amostras de validação. O valor obtido de exatidão global foi de 78,8%, que é um valor relativamente alto para imagens de altíssima resolução, considerando as classes e as variáveis discriminantes em estudo. Acredita-se que esse bom resultado foi obtido em parte porque as amostras selecionadas realmente tinham uma distribuição normal para essas classes, que é uma das suposições assumidas pelo classificador Maxver.

Tabela 2 – Matriz de Erros para o Maxver.

MATRIZ DE ERROS						
Classe	1	2	3	4	Total	Omissão
1	66	13	1	0	80	82.5
2	29	56	2	1	88	63.5
3	5	1	36	0	42	85.7
4	0	0	1	39	40	97.5
Total	100	70	40	40	250	
Comissão	66.0	80.0	90.0	97.7		

Outro índice que pode ser derivado da matriz de erro é o Kappa estatístico (0,706) e a sua variância (0,001353) que representam uma ponderação entre as concordâncias e discrepâncias dos dados de referência e os dados classificados pelo Maxver. Com o índice Kappa e sua

variância é possível aplicar o teste estatístico Z, que para esta matriz obteve o valor de 19,190, que é maior que o valor tabelado de 1,96, e portanto significativo, para 95% níveis de confiança, e portanto melhor do que uma classificação aleatória. Embora a variância do índice Kappa tenha sido um pouco alta, os outros resultados estatísticos foram bastante animadores, mesmo no caso de asfalto ruim em que 63,5% das amostras foram classificadas corretamente.

Em relação à utilização das redes neurais artificiais, após uma bateria de testes os resultados não foram animadores. A rede não convergia para os dados de treinamento amostrados, especificamente para essas classes. Na Figura 5 é apresentado o gráfico típico do erro médio quadrático que foi encontrado ao longo de todas as tentativas, evidentemente com pequenas variações.

Segundo Hara *et al.* (1994) uma RNA está bem treinada quando o desvio padrão do erro permanece constante, no mínimo, 3 casas decimais. Esse parâmetro não foi atingido em nenhuma das 27 topologias testadas.

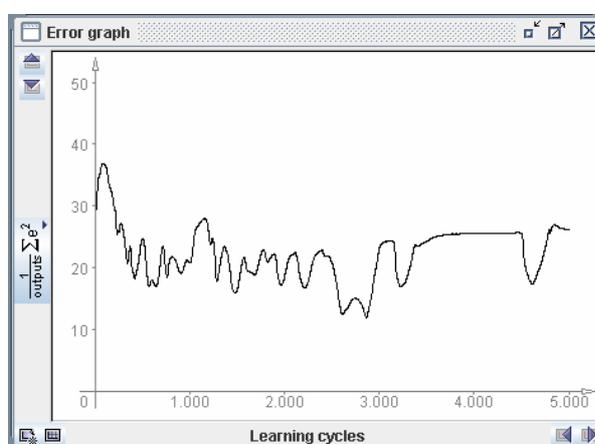


Figura 5 – Gráfico do erro médio quadrático, denotando a não convergência da RNA

4. Conclusões

Este trabalho teve como objetivo analisar a possibilidade de se fazer a detecção dos defeitos superficiais de pavimentos asfálticos, com o uso do sensoriamento remoto através de imagens orbitais de alta resolução, utilizando técnicas estatísticas de reconhecimento de padrões e redes neurais artificiais (RNA). Contudo, os resultados obtidos demonstram, em linhas gerais, que o uso de imagens do sensoriamento remoto de altíssima resolução para o inventário do estado da superfície de estradas pavimentadas apresenta grande dificuldade para detectar defeitos, principalmente devido à resolução espacial dos sensores disponíveis, muito embora se tenha a expectativa de que com a melhoria de novas tecnologias do sensoriamento remoto, principalmente a nível de resolução espacial, em breve esse objetivo possa ser alcançado.

Especificamente baseado nos experimentos desenvolvidos apresenta-se as seguintes conclusões.

Quanto à análise estatística (algoritmo da Máxima Verossimilhança): 1) a classificação obteve excelentes índices de exatidão global e Kappa e o teste estatístico Z comprovou que a classificação foi significativamente melhor do que uma classificação aleatória e; 2) percebe-se que o algoritmo teve dificuldade em separar a classe 2 (asfalto ruim) da classe 1 (asfalto bom), mas mesmo assim o resultado foi surpreendentemente aceitável.

Quanto à Rede Neural Artificial: 1) A rede não convergiu para os dados de treinamento apresentados; 2) Para a resolução espacial do sensor utilizado, a resposta espectral das classes asfalto bom e asfalto ruim são muito semelhantes e; 3) Acredita-se que a RNA não convergiu porque as classe 1 (asfalto bom) e classe 2 (asfalto ruim) tinham valores espectrais muito

parecidos, dessa forma, a RNA não conseguia distinguir bem essas classes, causando grande confusão. Possivelmente o problema de seleção de padrões mais representativos poderia ser reduzido com o uso de uma imagem com melhor resolução espacial.

Pesquisas futuras poderiam ser desenvolvidas utilizando imagens sub-orbitais ou terrestres para, não só detectar, mas fazer o inventário do estado da superfície de pavimentos asfálticos. A utilização de imagens a laser, juntamente com imagens espectrais, poderiam contribuir para uma melhor caracterização do estado da superfície dos pavimentos.

Considerando a importância do uso dessas recentes técnicas (RNA) e dos produtos do sensoriamento remoto no contexto de conservação rodoviária, pesquisas deveriam ser desenvolvidas para atestar seu potencial e otimizar o seu uso.

Agradecimentos

Ao NUGEO (Núcleo de Geoprocessamento Prof. Celestino Aspiazú) da UFV pelo uso de suas instalações, quando do desenvolvimento dessa pesquisa. A bolsa concedida pela CAPES/PICDT ao doutorando Edgar Ricardo Ferreira. Aos Departamentos de Engenharia Civil da UFV e de Construções Cíveis do CTU/UFJF pelo apoio.

Referências bibliográficas

Balbo, J. T. **Pavimentos asfálticos: Patologias e Manutenção**. São Paulo: Plêiade, 1997.

Bishop, C. M. **Neural network for pattern recognition**. Institute for Adaptive and Neural Computation Division of Informatics Edinburgh University. Oxford University Press. 1995.

Barella, R. M. **Inventário de defeitos superficiais de pavimentos com o auxílio de imagens digitais**. 2001. 230 p. Dissertação (Mestrado em Transportes) - Escola Politécnica da Universidade de São Paulo, São Paulo. 2001.

Congalton, R. G.; Green, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. New York: Lewis Publishers, 1999.

Confederação Nacional do Transporte – CNT. **Pesquisa rodoviária 2007: relatório gerencial**. Brasília, D.F., 2007.

DNIT. Disponível em: <http://www.dnit.gov.br/menu/rodovias/rodoviasfederais/arquivos/PNV2006ResumoGerais_2006.xls>. Acesso em: 5. mar.2008.

Haykin, S. **Redes neurais: princípios e práticas**. 2 edição. 900p. Traduzido: Paulo Martins Engel. Ed. Bookman. Porto Alegre – RS. 2001.

Hara, *et al.* 1994, **Application of neural networks to radar image classification**. IEEE Transactions on Geoscience and Remote Sensing, 32, p. 100-109.

Hirose *et al.* **Back-propagation algorithm which varies the number of hidden units**. Neural Networks, n. 4, p. 61-66, 1991.

Silva, P. F. A. **Manual de patologia e manutenção de pavimentos**. São Paulo: Pini, 2005.

Venturieri, A.; Santos, J. R. **Técnicas de classificação de imagens para análise de cobertura vegetal**. In: ASSAD, E. D.; SANO, E. E. Sistema de Informações Geográficas: aplicações na agricultura. 2. ed. Ver. Ampl. Brasília: Embrapa-SP: Embrapa-CPAC, 1998. p. 351-371.

Vieira, C. A. O. **Accuracy of Remotely Sensing Classification of Agricultural Crops: a Comparative Study**. 2000. 327 p. Thesis (Doctor of Philosophy). University of Nottingham. 2000.