

MAPEAMENTO DE PLANTAS DANINHAS EM CULTURA DE CAFÉ A PARTIR DE IMAGENS MULTIESPECTRAIS DE ESCALAS GRANDES USANDO REDES NEURAS ARTIFICIAIS

Mapping of weed in coffee crop from multispectral images of great scales using artificial neural network

Lauriana Rúbio Sartori¹
Maria de Lourdes Bueno Trindade Galo²
Nilton Nobuhiro Imai²

¹ **Universidade Estadual Paulista – UNESP**
Faculdade de Ciências e Tecnologia – FCT
Programa de Pós-Graduação em Ciências Cartográficas
Rua Roberto Simonsen, 305 – CEP: 19060-900 – Presidente Prudente, SP, Brasil
lauriana@pos.prudente.unesp.br

² **Universidade Estadual Paulista – UNESP**
Faculdade de Ciências e Tecnologia – FCT
Departamento de Cartografia
Rua Roberto Simonsen, 305 – CEP: 19060-900 – Presidente Prudente, SP, Brasil
{mlourdes, nnimai}@prudente.unesp.br

RESUMO

Numa cultura agrícola é importante identificar áreas infestadas por plantas daninhas com a finalidade de oferecer informações adequadas ao manejo. Partindo-se do pressuposto de que dados multiespectrais de escalas grandes são capazes de fornecer informação adequada e suficiente para a geração de um mapa da distribuição espacial e densidade de plantas daninhas em culturas de café, este artigo apresenta uma abordagem para discriminação dos graus de infestação por plantas daninhas em cultura de café a partir de dados multiespectrais de alta resolução espacial. Para isso, foi realizada uma classificação por Redes Neurais Artificiais – RNA e o mapa temático produzido foi submetido à análise da qualidade temática. A avaliação do resultado mostrou que a classificação por RNA aplicada para discriminar classes de infestação de plantas daninhas em imagens multiespectrais de alta resolução espacial constitui-se num método eficiente confirmando a hipótese inicial.

Palavras chaves: Imagem multiespectral; Imagem multiespectral de alta resolução espacial; Plantas daninhas; Classificação por Redes Neurais Artificiais.

ABSTRACT

It is important to identify weed density and position in an agriculture field to give suitable information to the management. This work presents a method to discriminate infestation degree of weed in coffee crop from multispectral image which has high degree of spatial resolution considering this data has enough information to map density and spatial distribution of weeds in this situation. In this sense, the high resolution multispectral image was classified by an artificial neural networks approach. The thematic accuracy of the results was estimated in order to evaluate the proposed method. The result showed that neural network is an efficient approach for the purpose, which validate the hypothesis of the investigation.

Keywords: Multispectral image; High spatial resolution multispectral image; Weed; Artificial Neural Networks classification.

1. INTRODUÇÃO

A distribuição de plantas daninhas em campos cultivados tem sido foco de interesse de agricultores. Porém, à medida que surgiu a possibilidade de realizar o gerenciamento localizado de recursos em sistemas de produção agrícola, a necessidade de mapeamento de áreas infestadas por plantas daninhas passou a ser premente.

Tradicionalmente, conforme Shiratsushi (2001), os agricultores adotam estratégias de manejo que consideram homogênea toda a área agrícola, adotando como referência a infestação média destas plantas. Entretanto, a distribuição das plantas não é uniforme e um gerenciamento localizado reduziria tanto os gastos com herbicidas quanto o impacto ambiental decorrente de seu controle.

Segundo Rew et al. (1999), o Sensoriamento Remoto aéreo tem se mostrado uma técnica promissora para o mapeamento de plantas daninhas em culturas agrícolas e pastagens. Por se tratar de um fenômeno que se manifesta localmente no contexto de uma área agricultável, a detecção e mapeamento de áreas infestadas por plantas daninhas requerem a utilização de imagens multiespectrais com maior nível de detalhamento espacial (da ordem do centímetro).

Nesse contexto, e tendo em vista a necessidade de validar um Sistema de Sensoriamento Remoto Aerotransportado, desenvolvido no âmbito do Departamento de Cartografia da FCT/Unesp, foram adquiridas imagens multiespectrais de alta resolução espacial de um campo agrícola experimental cultivado com café, no qual se constata a ocorrência de áreas infestadas por plantas daninhas.

A hipótese na qual se baseia este trabalho é de que dados multiespectrais de escalas grandes são capazes de fornecer informação adequada ou suficiente para a geração de um mapa da distribuição espacial de plantas invasoras em culturas de café. Para avaliar esse pressuposto, as imagens foram submetidas a uma classificação por Redes Neurais Artificiais (RNA) e uma posterior análise da qualidade temática.

2. IMAGENS MULTIESPECTRAIS E CLASSIFICAÇÃO USANDO REDES NEURAIS ARTIFICIAIS

Neste item apresentada-se uma breve fundamentação sobre os processamentos aplicados à imagem multiespectral antes da geração do mapa temático, com o intuito de destacar as feições de interesse na cena. Também são apresentados os conceitos básicos relacionados com a classificação por redes neurais artificiais (RNA). Essa abordagem de classificação permite incorporar aos dados de entrada, informações de natureza não espectral e mesmo resultantes de processamentos com e entre bandas espectrais, como dados de textura e índice de vegetação. Além disso, tem a capacidade de distinguir limites

complexos entre classes e permite avaliar a incerteza e a qualidade temática da classificação.

2.1 Imagens e transformações de dados multiespectrais

Uma imagem multiespectral constitui um conjunto de cenas tomadas simultaneamente de uma mesma área, obtidas por um sensor que registra a radiação eletromagnética em diferentes intervalos espectrais.

Antes das imagens multiespectrais serem transformadas em informações sobre a área em estudo, elas devem ser submetidas a alguns procedimentos definidos segundo a especificidade da situação e dos objetivos a serem alcançados. Esses procedimentos, segundo Novo (1992), dividem-se em três conjuntos: técnicas de pré-processamento, que permitem a transformação de dados brutos em dados corrigidos radiométrica e geometricamente; técnicas de realce, as quais objetivam melhorar a visualização da cena para posterior interpretação visual ou classificação digital; e técnicas de classificação, visando o reconhecimento dos objetos da cena, a partir da análise quantitativa dos níveis de cinza.

Entre os possíveis pré-processamentos, os que merecem maior destaque no contexto deste trabalho é a retificação geométrica e georreferenciamento da imagem. A retificação é a eliminação dos deslocamentos devido à inclinação do sistema sensor em relação à normal do alvo, mas não dos deslocamentos devido ao relevo. O georreferenciamento é realizado a fim de tornar a imagem compatível com um sistema de referência adequado.

Algumas feições são melhor representadas na imagem quando alguns processamentos específicos são aplicados aos dados multiespectrais. Transformações de imagens no espaço espectral permitem gerar novos conjuntos de componentes espectrais ou bandas, tornando distinguíveis essas feições. Neste trabalho, as bandas espectrais foram submetidas a transformações para gerar índices de vegetação e componentes puros de mistura espectral. Os índices de vegetação buscam ressaltar o comportamento espectral da vegetação em relação ao solo e outros alvos da superfície terrestre. A partir do modelo de mistura, cada componente de um pixel, como por exemplo, solo, sombra e vegetação, é representado separadamente em três imagens: uma associada à proporção de solo em cada pixel, outra de sombra e outra de vegetação.

Um índice de vegetação espectral é um valor resultante da transformação de duas ou mais bandas espectrais, utilizando-se operações de soma, diferença, razão ou qualquer outra combinação entre as bandas. Pelo fato de representar características biofísicas da vegetação, como: índice de área foliar (IAF), fitomassa, peso da vegetação úmida, peso da vegetação seca, porcentagem de cobertura vegetal, produtividade, etc, o pressuposto para a definição de um índice de vegetação é a utilização de uma banda na qual haja um aumento na

reflectância com o aumento da vegetação sadia (infravermelho próximo) em relação à outra banda que registre um decréscimo na reflectância com o aumento dessa vegetação (vermelho).

A razão simples é o índice de vegetação mais simples e útil. Corresponde à razão entre valores de radiância (L) ou reflectância (ρ) ou transformados a partir dos números digitais, representados nas bandas do infravermelho próximo e do vermelho. Esse índice é definido pela Equação 1:

$$\text{Razão Simples} = \frac{IVP}{V} \quad (1)$$

em que, IVP e V referem-se, respectivamente, à radiância ou reflectância nas faixas do infravermelho próximo e vermelho.

O índice de vegetação diferença normalizada (NDVI) tem a seguinte formulação (Equação 2):

$$\text{Diferença Normalizada} = \frac{IVP - V}{IVP + V} \quad (2)$$

O modelo linear de mistura é uma técnica usada para avaliar a mistura contida em cada elemento de resolução, e permite quantificar a proporção de componentes puros contidos no pixel (SHIMABUKURO e SMITH, 1991). Considerando o campo de visada instantâneo (IFOV) do sistema sensor, para cada oixel da imagem, são registradas informações que representam a soma das radiâncias de todos os componentes puros ali contidos. Assim, a reflectância espectral de cada pixel pode ser modelada como uma combinação linear de componentes puros, sendo esse, conforme Novo e Shimabukuro (1994), o pressuposto em que se baseia o modelo de mistura.

A classificação de uma imagem consiste em decidir a qual classe pertence um determinado pixel ou grupo de pixels da cena. Richards e Jia (1999) definem classificação como um método para rotular os pixels da imagem, a partir de suas características espectrais, sendo que essa rotulação é implementada por um programa computacional apto a reconhecer pixels espectralmente similares. O autor destaca dois tipos de dados multiespectrais: não supervisionado e supervisionado. Conforme Moreira (2001), o método não supervisionado não utiliza nenhum conhecimento “a priori” sobre as classes existentes na imagem e define uma estratificação da cena, atribuindo um pixel, ou grupo de pixels, a uma determinada classe espectral, sem que o analista tenha conhecimento das características dessa classe na superfície terrestre. Segundo Richards e Jia (1999), nas abordagens supervisionadas o analista, a partir de um conhecimento prévio da cena, fornece informações específicas ao sistema de análise, possibilitando o seu treinamento no reconhecimento de classes pré-definidas, caracterizadas por feições bem definidas na superfície terrestre. A partir de elementos amostrais, que correspondem a padrões conhecidos das classes, são estimados os

parâmetros estatísticos de cada classe e realizado o treinamento do algoritmo de classificação.

2.2 Aplicação de Redes Neurais Artificiais (RNA) em classificação

O desenvolvimento inicial dos modelos de redes neurais artificiais foi motivado pela tentativa de reproduzir o alto desempenho do cérebro humano em tarefas cognitivas extremamente complexas. Tais modelos de redes neurais artificiais representam um tipo especial de processamento da informação que consiste em muitas células primitivas que trabalham em paralelo, conectadas através de ligações diretas. A principal função dessas células é distribuir padrões de ativação através de suas conexões, de maneira similar ao mecanismo básico do cérebro humano (ZELL et al., 1995).

Existem, atualmente, vários modelos de redes neurais, desenvolvidos para as mais diversas aplicações. Entre eles, podem ser citadas as estruturas de perceptron as quais, com o desenvolvimento de algoritmos de treinamento mais adequados, evoluíram para configurações com múltiplas camadas, capazes de reconhecer várias classes e resolver o problema de sobreposição das regiões de decisão no espaço multiespectral (LIPPMANN, 1987).

As redes com múltiplas camadas têm sido utilizadas com sucesso para a solução de vários problemas envolvendo altos graus de não-linearidade. Seu treinamento é do tipo supervisionado, utilizando um algoritmo que realiza uma retropropagação do erro (*error backpropagation*), derivado da regra delta generalizada e baseado numa regra de aprendizagem que “corrige” o erro durante o treinamento (HAYKIN, 1994 apud BOCANEGRO, 2002). Lippmann (1987) define as redes multicamadas como redes de alimentação progressiva, com uma ou mais camadas de elementos de processamento (neurônios ou nós), chamadas camadas escondidas, entre os elementos de entrada e saída. As redes de alimentação progressiva (*feedforward*) têm seus elementos de processamento arranjados de maneira que a saída de cada neurônio em uma camada deve alimentar a entrada de cada neurônio da camada seguinte.

Segundo Gonzalez e Woods (1992), o processo de treinamento pelo algoritmo *backpropagation* começa com a definição de um conjunto arbitrário de pesos para as conexões da rede, é iterativo e envolve duas fases distintas em cada ciclo de iteração. Na primeira, um vetor de treinamento com a respectiva saída desejada é apresentado à rede e propagado através de suas camadas para computar uma saída para cada nó. As saídas dos nós da camada de saída são comparadas com as saídas desejadas e, a partir disso os termos de erro são gerados. A segunda fase envolve uma passagem de volta através da rede a partir da última camada, durante a qual o erro é repassado para cada nó e os pesos correspondentes são convenientemente alterados. Em uma sessão de treinamento bem sucedido, este erro diminui com o

aumento do número de iterações e o procedimento converge para um conjunto estável de pesos.

Estando a rede treinada e, portanto, com os pesos das conexões ajustados, esta é aplicada a todo conjunto de dados (imagem) e os padrões são classificados como pertencente a uma determinada classe, quando a saída para esta classe for alta, e baixa para as demais classes (GONZALEZ E WOODS, 1992).

3. MATERIAL E MÉTODO

Neste item são relatados os procedimentos utilizados no levantamento, processamento e análise dos dados e definição das classes. Posteriormente, são apresentados os processamentos utilizados para a classificação por redes neurais e as análises de incerteza.

3.1 Área de estudo e levantamento de campo

A imagem aérea utilizada foi adquirida no dia 17/07/2004 em uma área experimental da Universidade Federal de Lavras (UFLA), Lavras/MG. A área de interesse inclui uma plantação de café infestada por plantas daninhas entre as linhas de plantio.

A aquisição da imagem foi realizada utilizando o Sistema de Sensoriamento Remoto Aerotransportado (SRA), constituído por uma câmara digital multiespectral, receptor GPS e um computador, o qual permite configurar os parâmetros de aquisição das imagens. A câmara de vídeo digital multiespectral MS3100-CIR é fabricada pela DuncanTech e dispõe de uma configuração “colorido infravermelho” (CIR), na qual imagens correspondentes às bandas espectrais dos comprimentos de onda da luz vermelha, verde e do infravermelho próximo podem ser adquiridas.

A altura de voo do avião foi em torno de 600 metros definindo um elemento de resolução no terreno de, aproximadamente, 16 cm.

Com a antena do receptor GPS instalada na parte externa da aeronave foi determinada a posição da câmara no instante de aquisição da imagem. Essa posição foi utilizada, juntamente com as coordenadas dos pontos de apoio levantados em campo, para retificar e georreferenciar a imagem. Além dos pontos de apoio destinados ao tratamento da geometria da imagem, foram levantados elementos amostrais “in situ”, avaliados segundo o grau de infestação por plantas daninhas. Cada elemento amostral foi posicionado com receptor GPS (Global Positioning System) e fotografado.

Os elementos amostrais definidos para verificação “in situ” constaram de áreas quadradas de 1 (um) metro de lado, as quais foram descritas segundo a porcentagem de ocorrência de diferentes espécies de plantas invasoras. A identificação das diferentes espécies em cada elemento amostral foi feita pelo pesquisador Professor Dr. Itamar Souza, da UFLA

(Universidade Federal de Lavras) especialista em plantas invasoras. Vinte (20) tipos diferentes de plantas daninhas foram identificados na área, porém sua distinção específica é praticamente inviável na imagem multiespectral.

3.2 Processamento da imagem

A imagem multiespectral tomada simultaneamente a realização da coleta de dados em campo foi submetida aos pré-processamentos de retificação e georreferenciamento. Foram utilizados nove pontos de controle para a retificação e seis para o georreferenciamento. O erro do tratamento da geometria foi estimado a partir de outros seis pontos e, em seguida, foi feita a análise de tendência e precisão.

As três bandas espectrais da imagem, já tratadas geometricamente, (Verde – Vd, Vermelho – Vm e Infravermelho – IVP) foram submetidas a transformações espectrais, produzindo imagens índice de vegetação e componentes puros do pixel, usando um modelo de mistura espectral, as quais realçam as feições de interesse e facilitam o processo de extração dos dados de treinamento. Com a transformação em índices de vegetação foram geradas imagens razão simples e diferença normalizada. A utilização do modelo de mistura produziu as imagens-fração solo, sombra e vegetação. Essas imagens foram analisadas visualmente e selecionadas aquelas que melhor destacam variações na vegetação, considerando a representação das características necessárias para a extração dos dados de treinamento. As imagens que registram os elementos amostrais também foram utilizadas como dado de entrada para a classificação pela rede neural.

3.3 Definição das classes e adensamento da amostra de treinamento e validação

Como já descrito, vinte (20) tipos diferentes de plantas daninhas foram identificados na área de estudo. Entretanto, pela impossibilidade de realizar a distinção específica dos tipos de erva daninha na imagem multiespectral, cada elemento amostral foi novamente categorizado considerando a presença global de plantas daninhas.

Devido ao pequeno número de elementos amostrais na área de estudo (apenas vinte e nove), foi realizado um adensamento da amostra com base no padrão observado nas imagens índice de vegetação razão-simples, imagem-fração solo e imagem-fração sombra e nos dados coletados em campo. Ou seja, foram selecionados, visualmente, pontos cuja resposta fosse semelhante ao padrão observado na imagem para elementos coletados em campo.

Devido à necessidade de adensamento dos elementos amostrais e à impossibilidade de atribuir valores de porcentagem de plantas daninhas a cada um dos novos elementos, o grau de infestação por ervas daninhas foi generalizado para as seguintes classes:

- Ausência de plantas daninhas, ou seja, predominância de solo;
- Baixa infestação de plantas daninhas;
- Média infestação de plantas daninhas;
- Alta infestação de plantas daninhas;

Em porcentagem de plantas daninhas, as classes especificadas acima são as seguintes:

$$\begin{aligned} 0\% \leq \textit{solo} < 20\% , \\ 20\% \leq \textit{baixa} < 45\% , \\ 45\% \leq \textit{média} < 70\% , \\ 70\% \leq \textit{alta} < 100\% . \end{aligned}$$

Além das quatro classes especificadas e para as quais foram coletados elementos em campo e na imagem, criou-se a classe café caracterizada pela presença apenas de plantas de café. Para essa classe também foram adquiridos elementos amostrais na imagem.

A análise visual da imagem permitiu a adição de elementos amostrais destinados ao processo de classificação da imagem, bem como avaliação de resultados. Desta forma, a amostra adotada para avaliação da qualidade foi obtida pela combinação do conjunto amostral levantado no campo com os elementos identificados na imagem resultando numa amostra de 166 pixels. Para o treinamento da Rede Neural Artificial, foram adquiridos 3623 pixels para a classe Solo; 1977 pixels em áreas de baixa infestação por plantas daninhas; 1439 em áreas de alta infestação dessas plantas e 2818 pixels incluídos na amostra do cafezal, totalizando 10.883 pixels nessa amostra de treinamento. O tamanho da amostra corresponde a 4,86% da cena, que tem 223692 pixels.

3.4 Classificação pela rede neural artificial

A classificação da imagem foi feita usando o simulador de redes neurais SNNS (Stuttgart Neural Network Simulator). Para o treinamento da RNA foram utilizados elementos amostrais representativos de cada classe, conforme descrito no item 3.3. O arquivo com os dados de treinamento foi convertido em formato compatível com o SNNS, através de um programa implementado pelo Professor Doutor Maurício Galo, do Departamento de Cartografia da FCT/Unesp. Em seguida, foi definida a arquitetura da rede, ou seja, o número de camadas escondidas e o número de nós (elementos de processamento) de cada camada, os parâmetros de aprendizagem da rede, além do critério de término das iterações ou ciclos de treinamento.

Os mapas temáticos gerados foram analisados a partir de coeficientes estimados da matriz de confusão entre o resultado obtido e os dados considerados como verdade terrestre, bem como por meio da incerteza por classe.

Análise da incerteza

O programa denominado SNNS-PBM, implementado pelo Professor Doutor Maurício Galo, permite gerar uma imagem para cada classe mostrando uma estimativa da probabilidade (P_{ij}) de cada pixel estar associado a cada classe.

Essas probabilidades (P_{ij}) são estimadas a partir dos valores de ativação determinados para cada pixel da imagem, após sua classificação pela RNA. Assim, cada pixel possui seis valores de ativação, ou seja, um para cada classe de saída. O cálculo da probabilidade é feito conforme a expressão (3).

$$P_{ij} = \frac{O_{ij}}{O_{1j} + O_{2j} + O_{3j} + O_{4j} + \dots + O_{ij}} \quad (3)$$

em que, P_{ij} representa a probabilidade de um dado pixel j estar associado à classe i ; $O_{1j} \dots O_{ij}$ são os valores de ativação de saída da rede, referentes a um dado pixel j , para cada uma das i classes, $i = 1, 2, \dots$ e $j = 1, 2, \dots$

Em seguida, foram geradas imagens da incerteza por classe. A incerteza em relação a uma dada classe i para cada pixel j é dada pela Equação (4):

$$I_{ij} = 1 - P_{ij} \quad (4)$$

Como a imagem gerada para representar a estimativa de probabilidade é codificada em 8 bits, então as imagens de incerteza foram obtidas pela diferença entre o valor 255 e a imagem da estimativa de probabilidade.

Os mapas de incerteza para cada classe foram fatiados para representar regiões de baixa, média e alta incerteza na associação de um pixel a uma determinada classe. O Quadro 01 mostra os intervalos utilizados para esse fatiamento.

QUADRO 01: INTERVALOS DE CLASSE DE INCERTEZA

Classe de incerteza	Limite inferior	Limite superior
Baixa	0	86
Média	86	172
Alta	172	255

4. MAPAS TEMÁTICOS PRODUZIDOS E QUALIDADE

Os mapas temáticos, tanto aquele resultantes da aplicação da Rede Neural Artificial, como os mapas de classe de incerteza, são apresentados a seguir. Além dos resultados expressos nos mapas, faz-se uma breve análise da qualidade do georreferenciamento e uma discussão sobre a abordagem adotada para selecionar os planos de entrada para a classificação por redes neurais.

4.1 Qualidade geométrica da imagem retificada e georreferenciada

O controle de qualidade do georreferenciamento foi avaliado considerando-se o resíduo de seis (6) pontos, os quais estão listados no Quadro 02. Os valores apresentados nas colunas E e N e, na última linha é mostrada a resultante das discrepâncias.

QUADRO 02 – ERROS OBTIDOS NOS PONTOS DE VERIFICAÇÃO DO GEORREFERENCIAMENTO E RESULTANTE DAS DISCREPÂNCIAS

Ponto	Erro em metros	
	E (metros)	N (metros)
13	0,03744	0,01936
15	0,04368	-0,07264
10	0,12464	0,20304
16	-0,02576	0,0464
11	0,10352	0,16688
1	-0,00272	-0,09024
Resultante das discrepâncias	0,3915	

A resultante das discrepâncias foi de 0,39 metros, indicando que um ponto qualquer medido na imagem pode estar distante de até 39 cm da sua posição real. Assim, a imagem obtida tem qualidade posicional compatível com sistemas de aplicação localizada de herbicida, os quais se baseiam em coordenadas fornecidas por receptores GPS, os quais adotam, usualmente, a correção baseada em *Wide Area DGPS*, cuja incerteza é da ordem de 1 metro.

Foi verificado que as coordenadas E e N não apresentam tendência e, portanto, o georreferenciamento atende à precisão correspondente à classe A. Dessa maneira, tais resultados permitem desenvolver atividades posteriores com a imagem retificada e georreferenciada.

4.2 Índices de vegetação e componentes de mistura espectral

O índice de vegetação razão simples (RS) destacou melhor variações nos tipos de cobertura vegetal, quando comparado com o índice diferença normalizada (NDVI). Isso confirma o que foi verificado por Sartori (2003) quando comparou valores de RS e NDVI, obtidos para elementos amostrais da cultura de soja em diferentes estágios de desenvolvimento. O trabalho mostra que o NDVI destaca melhor a vegetação quando o grau de cobertura não é total, ou seja, o início do desenvolvimento da cultura. Já a RS não é tão sensível nessa fase, apresentando maior sensibilidade às variações que ocorrem quando a cultura já cobre a maior parte do solo. Como a imagem em estudo possui a maior parte do solo coberto por café ou plantas daninhas, optou-se por utilizar a imagem RS como dado de entrada para as análises posteriores.

A imagem-fração vegetação apresentou informação similar à RS. Assim, o uso de dois planos de entrada similares apenas tornaria o processo lento, sem informação adicional. Dessa maneira, a imagem-fração vegetação não foi utilizada nos processamentos posteriores, sendo usadas as imagens-fração solo e sombra. Assim sendo, os dados de entrada usados na classificação pela Rede Neural Artificial foram a imagem razão simples e as imagens-fração solo e sombra.

4.3 Classes mapeadas pela RNA

Foi utilizada uma estrutura de Rede Neural constituída de duas camadas escondidas, a primeira com vinte e um (21) elementos de processamento (nós) e a segunda com sete (7) nós. A camada de entrada foi configurada com três (3) nós, correspondentes aos três planos de entrada (razão simples, imagem fração solo e imagem fração sombra). Para a camada de saída foram definidos seis (6) nós, referentes às seis classes de interesse: solo, baixa infestação, média infestação, alta infestação, café e fundo. Essa última classe, denominada fundo, foi especificada para representar regiões sem informação ou cujo valor em todas as bandas é zero. Isso foi necessário, pois a área de estudo não ocupa toda a imagem e, assim, foi necessário atribuir o valor zero para os pixels que não pertencem à região de interesse. Para o treinamento da RNA adotou-se o valor 0,1 para taxa de aprendizagem. Os pesos ajustados no treinamento foram definidos após 3500 iterações, resultando em um erro médio quadrático igual a 0,0165, considerado aceitável. A Figura 1(b) apresenta um recorte da área de cultivo, classificada pela RNA. Em 1(a) é mostrada uma composição colorida “infravermelha falsa-cor” da área recortada a fim de facilitar a análise visual do resultado da classificação.

Na Figura 1(b), as linhas de café (cor vermelho escuro), facilmente percebidas na imagem “infravermelha falsa-cor”, foram confundidas com outras classes no mapeamento. Muitas dessas linhas foram mapeadas como pertencentes à classe alta infestação por plantas daninhas (cor laranja). A região de transição entre cada planta de café e a área livre, onde podem ocorrer as plantas daninhas, apresentam resposta espectral classificada como classe de alta infestação ou média infestação.

Em relação às classes de grau de infestação por plantas daninhas, as comparações exigem uma análise mais detalhada e pontual. Isto porque as três classes de infestação variam abruptamente no espaço. Assim, as diferenças entre elas são melhor percebidas na matriz de confusão.

A amostra de validação usada também para gerar a matriz de confusão, como especificado anteriormente, foi obtida a partir de 29 elementos obtidos em campo e 137 obtidos por interpretação visual da imagem índice de vegetação razão simples, imagem-fração solo e imagem-fração sombra com base nos dados levantados em campo.

Essa matriz de confusão é mostrada no Quadro 03.

QUADRO 03 - MATRIZ DE CONFUSÃO ENTRE OS DADOS DE REFERÊNCIA/CAMPO(COLUNAS) E OS DADOS RESULTANTES DA CLASSIFICAÇÃO.

	S	B	M	A	C	F
Solo (S)	47	2	0	0	0	49
Baixa (B)	1	28	1	0	0	30
Média (M)	0	1	21	0	0	22
Alta (A)	0	0	11	16	2	29
Café (C)	0	0	0	0	36	36
Fundo (F)	0	0	0	0	0	0
Total	48	31	33	16	38	166

Os valores referentes à exatidão global e coeficiente kappa, estimados a partir da matriz de confusão expressa no Quadro 02, foram 89,16% e 86,24%, respectivamente.

Dos 31 pontos de “verdade terrestre” pertencentes à classe baixa, dois foram classificados como solo e um como média infestação. Em relação aos 33 pontos da classe média infestação, 21 foram classificados corretamente. Já para a classe alta infestação, todos os 16 foram corretamente classificados.

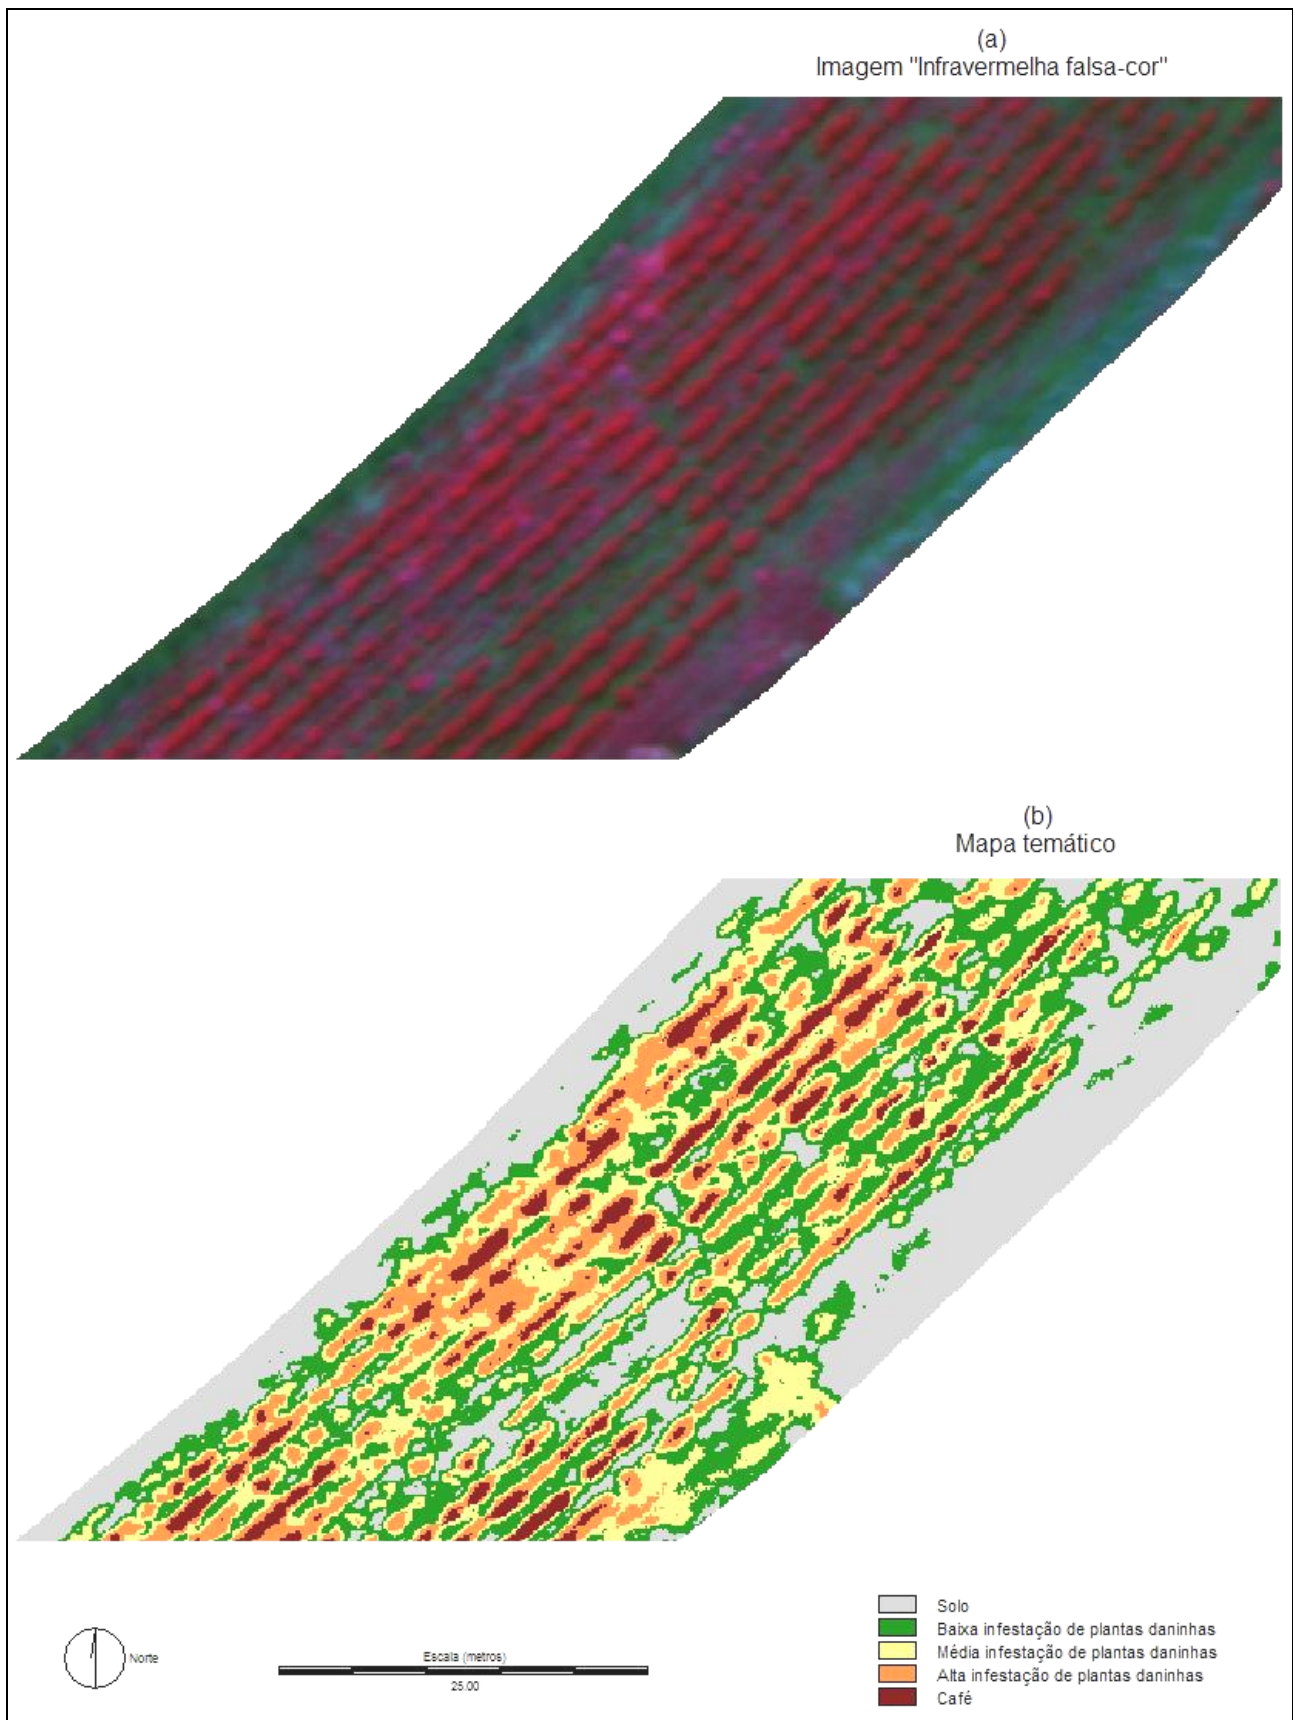


Fig. 1 – (a) Imagem “infravermelha falsa-cor”; (b) Mapa resultante do processo de classificação pela RNA.

4.4 Incerteza por classe

A Figura 2 apresenta os mapas de incerteza estimada para cada classe de cobertura de interesse (Solo, Café, Baixa, Média e Alta infestação por plantas daninhas). Nas imagens de incerteza, as áreas com baixa, média e alta incerteza em relação a uma determinada classe são apresentadas, respectivamente, em preto, cinza e branco.

As classes solo e café são mais fáceis de serem analisadas, pela facilidade em distinguir essas áreas na imagem “infravermelha falsa-cor” apresentada na Figura 1(a). As áreas mapeadas como sendo da classe baixa incerteza de ser solo correspondem basicamente àquelas pertencentes à classe solo, da mesma forma que a classe café definiu locais de baixa incerteza na cena. Portanto, regiões de baixa incerteza para uma classe temática específica terão alta incerteza para as demais classes.

As maiores incertezas observadas no mapeamento foi na classificação de pontos de média infestação por plantas daninhas como sendo da classe de alta infestação. Apesar disso, o manejo localizado não fica prejudicado, pois a confusão ocorreu entre duas classes cuja taxa de aplicação de herbicida é próxima.

5. CONCLUSÕES

A partir dos resultados obtidos verifica-se que a hipótese inicial do trabalho foi confirmada, ou seja, as imagens multiespectrais de alta resolução espacial, adquiridas pelo Sistema de Sensoriamento Remoto Aerotransportado, possuem potencial para discriminar graus de infestação por plantas daninhas em culturas de café.

A abordagem metodológica mostrou-se adequada para a extração da informação e incluiu a definição de procedimentos de análise da qualidade do georreferenciamento e da incerteza da informação temática representada. A análise da qualidade geométrica da imagem georreferenciada mostrou que a informação é compatível com sistemas de aplicação localizada de herbicida, os quais se baseiam em coordenadas fornecidas por receptores GPS, adotando abordagem *Wide Area DGPS*, cuja incerteza é da ordem de 1 metro. Tais resultados permitiram desenvolver atividades posteriores com a imagem georreferenciada.

A definição das classes relacionadas com os graus de infestação por plantas daninhas foi uma etapa que exigiu duas generalizações das classes de porcentagem de ervas: primeiramente, as porcentagens específicas de cada elemento amostral foram somadas e, em seguida, devido à necessidade de coletar um maior número de elementos amostrais e à impossibilidade de avaliar a quantidade de porcentagem apenas pela análise visual da imagem “infravermelha falsa-cor”, foi preciso converter os valores percentuais em informação categórica. A coleta dos elementos amostrais foi uma fase crítica devido à necessidade de consistência entre as categorias e sua devida associação com os critérios estabelecidos para cada classe. A classificação pela RNA foi adequada para definir as classes genéricas associadas aos graus de infestação por plantas daninhas. A exatidão global e o coeficiente Kappa induzem a um ótimo desempenho do classificador, porém erros e inconsistências foram observados. O maior erro encontrado no mapeamento foi a classificação de pixels de média infestação de plantas daninhas como sendo da classe de alta infestação. Mesmo assim, o manejo localizado não ficaria prejudicado, pois a confusão ocorreu entre duas classes nas quais o procedimento de controle pode ser similar.

Os mapas de incerteza/classe indicam que as classes solo e café apresentaram maior consistência na classificação, pelo fato da imagem “infravermelha falsa-cor”, permitir uma maior distinção dessas classes em relação às classes de ervas, produzindo mapas de baixa incerteza de solo e café, nos locais onde essas classes efetivamente ocorreram.

Finalmente, é importante reafirmar que, apesar do resultado obtido na classificação resultar em alto valor da exatidão global e coeficiente Kappa, foi possível verificar por análise visual da imagem infravermelha falsa-cor, que algumas áreas de café foram mapeadas como pertencente à classe de alta infestação. Tratando-se de gerenciamento localizado de recursos em sistemas de produção agrícola (Agricultura de Precisão), o controle localizado das plantas daninhas pode ser feito entre as linhas de plantas de café, de modo que não há risco na aplicação de herbicida.

Mapas de incerteza




Fig. 2 – Imagens indicando a incerteza por classe para a classificação por RNA.

AGRADECIMENTOS

Os autores agradecem à CAPES pela concessão da bolsa de Mestrado para o desenvolvimento deste trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

BOCANEGRA, C.W.R. **Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes**. 2002. 108f. Dissertação (Mestrado em Engenharia Civil – Transportes) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. São Paulo: Edgard Blücher, 1992. 509p.

LIPPMANN, R. P. (1987). An introduction to computing with neural nets. **IEEE ASSP Magazine**, 1987, v.4, p.4-22.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais (INPE), 2001. 250p.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. São Paulo, Edgard Blücher, 1992.

NOVO, E. M. L. M.; SHIMABUKURO, Y.E. Spectral mixture analysis of inland tropical waters. **International Journal of Remote Sensing**, v.15, n. 6, p. 1351-56, 1994.

REW, L. J.; LAMB, D. W.; WEEDON, M. M.; LUCAS, J. L.; MEDD, R. W.; LEMERLE, D. **Evaluating airborne multispectral imagery for detecting wild oats in seedling triticale crop**. Proceedings of the 2nd European Conference on Precision Agriculture, Odense, 1999. p.265-274.

RICHARDS, J. A.; JIA, X.; **Remote sensing digital image analysis: an introduction**. 3.ed. New York: Springer Verlag, 1999. 363p.

SARTORI, L. R. **Imageamento multiespectral de campo: um estudo do comportamento espectral da soja – parte 1**. 2003. UNESP/FCT – Presidente Prudente. Relatório final referente ao Trabalho de Bolsa de Iniciação Científica financiada pela fundação PIBIC/Reitoria.

SHIMABUKURO, Y. E.; SMITH, J. A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE**

Transactions on Geoscience and Remote Sensing, v.29, n.1, p.16-20, 1991.

SHIRATSUSHI, L. S. **Mapeamento da variabilidade espacial das plantas daninhas com a utilização de ferramentas da agricultura de precisão**. 2001. 96f. Dissertação (Mestrado em Agronomia – Fitotecnia) – Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba.

ZELL, A. **SNNS: Stuttgart Neural Network Simulator**. User Manual, Version 4.1. Stuttgart, University of Stuttgart, 1995 (Report No. 6/95).