

COMPUTAÇÃO APLICADA À AGRICULTURA DE PRECISÃO

Bruna Honda – Acadêmica do Curso de Ciência da Computação – Centro Universitário UNISEB. bruna.honda@hotmail.com

Lúcio André Castro Jorge - Doutor em Engenharia Elétrica USP, São Carlos – SP (EMBRAPA); Docente do Centro Universitário UNISEB. lacjorge@gmail.com

Resumo

As pesquisas apresentadas neste artigo visa o desenvolvimento de um sistema que seja capaz de processar imagens multiespectrais da cobertura do solo, obtidas por meio do sensoriamento remoto. Destaca-se também o projeto SISCOB desenvolvido pela EMBRAPA como uma ferramenta que auxilia na gestão agrícola e como parte do desenvolvimento do projeto. Inicialmente será apresentada uma breve introdução sobre as tecnologias envolvidas no processo para o desenvolvimento do software. Em seguida, desenvolve-se uma revisão bibliográfica sobre as técnicas computacionais utilizadas neste projeto. Por fim, serão apresentados os resultados obtidos utilizando o software desenvolvido nesta pesquisa.

Palavras-chave: sensoriamento remoto, agricultura de precisão, processamento de imagens, imagens multiespectral.

Abstract

The research provided in this article is to develop a software that is capable of processing multispectral images of soil cover, which are obtained through remote sensing. Also noteworthy is the project SISCOB* developed by EMBRAPA* as a tool that assists in the management and agricultural development as part of the project in question. Initially it will be a brief introduction to the technologies involved in the process of software development. Then develops a literature review on the computational techniques used in this project. Finally, we present results obtained using software developed in this research.

Keywords: remote sensing, precision agriculture, multispectral images.

1. Introdução

A aplicação de processamentos computacionais na área agrícola permite o desenvolvimento de softwares, onde cada qual possa suprir as necessidades de informação para o agricultor, resultando em grandes benefícios ao setor agropecuário.

Técnicas computacionais, sensoriamento remoto e sistemas de posicionamento global são utilizados em conjunto para o desenvolvimento de softwares especialistas que ajudam na gestão agrícola, podendo obter através desses sistemas dados que auxiliam fortemente na agricultura de precisão.

A agricultura de precisão trata-se de um “gerenciamento de cada parâmetro em um local específico para reduzir o desperdício, aumentar os lucros e manter a qualidade do meio ambiente.” (ADAMCHUK, PERK E SCHERPERS, 2003, p.1).

Portanto, através das informações obtidas pelos sistemas especialistas o agricultor pode mapear e realizar o manejo do cultivo e das terras em devidas proporções de insumos em cada unidade do campo, de forma mais inteligente e eficaz, assim, tem-se menos gastos com substâncias, agride menos o meio ambiente e gera-se uma maior lucratividade.

A área computacional aplicada neste projeto trata-se da utilização técnicas de processamento digital de imagens e inteligência artificial. Essas técnicas são utilizadas para realizar todos os procedimentos nas imagens capturadas, a fim de gerar resultados satisfatórios para a visualização. Assuntos como sensoriamento remoto, imagens multiespectrais e comportamento espectral também serão tratados resumidamente.

Outro assunto abordado é a utilização de índices de vegetação, que demonstram diferentes comportamentos da vegetação através dos índices que são calculados utilizando os valores dos pixels de cada banda da imagem.

Por fim, será apresentado o projeto e os resultados obtidos.

2. Revisão bibliográfica

2.1. Sensoriamento Remoto

O SR pode ser entendido como a utilização de sensores para coletar informações dos alvos sem que haja um contato físico com ele. Essas informações são obtidas pelos sensores, posicionados em longas ou curtas distâncias, através da captura das ondas eletromagnéticas, também denominada radiação eletromagnética (REM), que são emitidas ou refletidas pelos objetos. A REM é ordenada no espectro eletromagnético de acordo com seu comprimento e frequência (figura 1). Desta forma, cada sensor é responsável pela captação da intensidade de radiação do objeto, resposta espectral, compondo imagens e dados a respeito do alvo.




Figura 1. Espectro Eletromagnético.

FONTE: http://www.vision.ime.usp.br/~ronaldo/mac0417-03/aula_02.html

A coleta das ondas podem ser realizadas em diversos níveis, laboratorial, campo, sub-orbital ou orbital (figura 2), dependendo da necessidade de detalhamento da resposta espectral de cada alvo em questão.



Figura 2. Níveis de coleta de dados de sensoriamento Remoto.

FONTE: Revista Ceres, Sensoriamento Remoto e Sistemas de Informações Geográficas aplicados ao estudo dos recursos agrônômicos e florestais - Yosio Edemir Shimabukuro¹, Eduardo Eiji Maeda², Antonio Roberto Formaggio ¹, 2009.

Os sensores podem ser divididos em sensores passivos por não possuírem sua própria fonte de energia, dependendo de outras fontes para receber as ondas emitidas ou refletidas pelos alvos e os ativos que por sua vez, possuem sua própria fonte de energia. “A grande vantagem dos sensores ativos está em sua capacidade de realizar imageamentos a qualquer horário, independentemente de luz solar e mesmo estando coberta de nuvens” (MOREIRA, 2001).

Para a agricultura de precisão esta tecnologia é uma importante fonte de aquisição de dados, podendo periodicamente averiguar o estado nutricional das plantas, variabilidade e os parâmetros do solo, condições vegetais para manejo, mapeamento de produtividade de cada colheita, doenças, infestações por pragas entre outros.

Dispositivos que possuem diversos sensores podem realizar o imageamento multiespectral ou também hiperespectral de áreas de interesse, portanto, para obter dados significativos é importante atentar-se aos sensores utilizados para não desprezar faixas espectrais de grande significância.

2.2. Comportamento espectral

O comportamento espectral do alvo refere-se ao processo de interação entre a radiação eletromagnética com os objetos, a interação é diferente para cada tipo de alvo devido sua composição, ou seja, cada objeto absorve ou reflete a onda eletromagnética incidente de modo diferente. Essa diferença de interação permite entender como cada um deles irá aparecer na imagem (figura 3) ou em gráficos.




Figura 3. Interação REM com a folha. FONTE:
http://www.agr.feis.unesp.br/hrsilva/SERE_CAP_14/Aula_25_03_04_Imagem%20sere.htm

Na agricultura, a utilização de sensores que capturam ondas verde, vermelho e infravermelho próximo (NIR), por exemplo, é possível verificar o estado nutricional da cultura, através da análise do comportamento espectral.

Uma explicação sobre este acontecimento é pelo fato da clorofila produzida pelas folhas e outros tecidos vegetais são pigmentos verdes que funcionam como um fotorreceptor da luz visível no processo de fotossíntese, quando a folha está em seu estado de fotossíntese ativo a reflectância na região do NIR é maior e absorve mais a luz vermelha e azul do que no estado de senescência (figura 4).

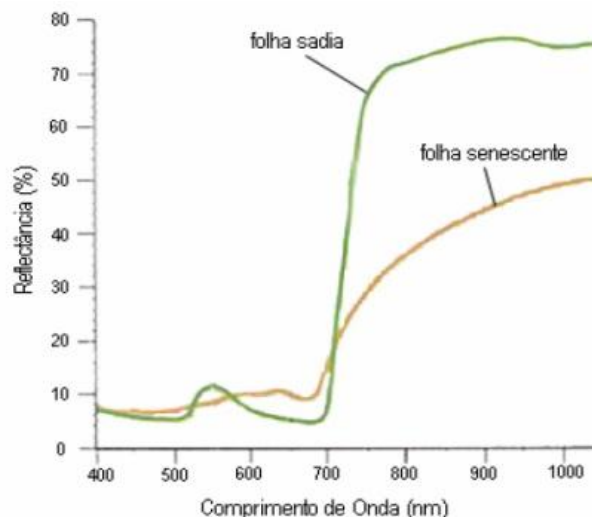


Figura 4. Curvas de reflectância espectral de folhas saudáveis e senescentes.
 Fonte: <http://dspace.c3sl.ufpr.br/dspace/bitstream/handle/1884/1666/dissertacao.pdf?sequence=2>

Portanto, para cada elemento da cobertura do solo a resposta espectral dos alvos estará em função do seu comportamento espectral, pois cada um absorverá e refletirá maiores ou menores quantidades de radiação eletromagnética em função da sua estrutura física, da composição química e biológica.

2.3. Índices de vegetação

Os índices são utilizados para facilitar a interpretação de dados das imagens obtidas pelos sensores, realçando o comportamento espectral da vegetação e minimizando o efeito do solo ou outros objetos. Os índices mais conhecidos são: Vegetação Diferença Normalizada (*Normalized Difference Vegetation Index*, NDVI), Índice de Vegetação Ajustado ao Solo (*Soil Adjusted Vegetation Index*, SAVI), Índice de Vegetação Normalizada Verde (“Green” NDVI) e o índice que é a razão entre o Verde e o infravermelho-próximo (GNIR).

O uso das bandas na região do verde, vermelho e infravermelho-próximo é por causa do seu comportamento espectral, obtendo assim melhores imagens resultantes através da utilização dos índices de vegetação.

O NDVI, apresentado por Rouse et al., em 1974, é um indicador de densidade de biomassa verde, as imagens geradas usando este índice, pode-se monitorar a cultura e ter uma previsão de safra. Utiliza-se o intervalo do comprimento das ondas do visível vermelho (0,58 – 0,68 μ m) e do infravermelho próximo (0,725 – 1,1 μ m), equação 1.

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)}; \quad (1).$$

O índice SAVI, proposto por Huete (1988), diminui o efeito do solo sobre diferentes densidades da cobertura vegetal no solo, ou seja, ele considera a influência do solo na vegetação. O índice é obtido através da equação (2), onde L é uma constante de ajuste, que minimiza a influência do solo, sendo ele claro ou escuro, variando de 0 a 1, para vegetação muito baixa sugere-se L=1.0, intermediária L=0.5 e altas densidade L=0.25. Onde, NIR (Near Infrared) e Red(Red).

$$SAVI = \frac{NIR - Red}{NIR + Red + L} \times (1 + L); (2).$$

O Green NDVI, utilizado por Gitelson et al. 1996, um variante do NDVI, é utilizada para identificar diferentes taxas de concentração de clorofila na vegetação, visto que, a banda verde é mais sensível para detectar níveis nutricionais de uma plantação. Esse índice é muito utilizado no início do período de uma safra, onde os níveis nutricionais são variados. Equação (3), onde NIR(Near Infrared) e G (Green).

$$GNDVI = \frac{NIR - G}{NIR + G}; (3).$$

E por fim, o índice GNIR, proposto por Bausch & Duke, 1996, identifica o estresse nutricional de nitrogênio. Equação (4), onde G(Green) e NIR (Near Infrared).

$$GNIR = \frac{G}{NIR}; (4).$$

2.4. Imagens multiespectrais

As imagens multiespectrais são compostas por imagens monocromáticas, figura 5, onde cada pixel da imagem possui apenas uma banda espectral, de um mesmo objeto ou cena, podendo ser capturadas por diferentes comprimentos de ondas eletromagnéticas, tais como, infravermelho, luz visível, raio-x ou qualquer outra faixa do espectro eletromagnético. Cada imagem, portanto é uma referência de uma banda.




Figura 5. Imagem multiespectral.

FONTE: (http://www.poli.usp.br/d/ptr2355/2009_1/SR_2009_Classificacao_9_jun_2009.pdf)

Cada pixel da imagem multiespectral possui coordenadas espaciais (x,y) que é representado por um conjunto de valores de brilho representado por um vetor n , onde n é a dimensão da quantidade de bandas espectrais utilizadas (figura 6).




Figura 6. Representação da imagem multiespectral.

FONTE: (http://www.poli.usp.br/d/ptr2355/2009_1/SR_2009_Classificacao_9_jun_2009.pdf)

As imagens geradas por cada banda podem ser visualizadas em níveis de cinza, ou podem ser combinadas para sintetizar imagens coloridas. Cada figura abaixo representa uma imagem em tons de cinza nas bandas NIR, vermelha, verde e a combinação das 3 bandas.




Figura 7. NIR




Figura 8. Red




Figura 9. Green




Figura 10. NIR, Red e Green

Desta maneira, ao uso de imagens multiespectrais permite realizar a extração de importantes informações para a análise da vegetação.

2.5. Técnicas de processamento digital de imagens e inteligência artificial

A segmentação de imagens consiste em subdividir uma imagem em regiões, onde cada região possua propriedades homogêneas e uniformes, como por exemplo, textura, nível de cinza, contraste ou cor. Essa subdivisão simplifica a visualização da imagem, podendo utilizar

posteriormente algoritmos para buscar informações na imagem segmentada e classificar essas regiões em padrões.

Existem diversas técnicas de segmentação, a limiarização (thresholding), a detecção de bordas, a extração de regiões, morfologia matemática e outras abordagens como a utilização de redes neurais também permitem a segmentação de imagens.

2.6. Limiarização

A segmentação através da limiarização divide a imagem em duas classes, o objeto e o fundo, transformando uma imagem $f(x,y)$ em uma imagem de saída $g(x,y)$ do seguinte modo: $g(x,y) = 1$ para $f(x,y) \geq T$ e $g(x,y) = 0$ para $f(x,y) < T$, onde T é o limiar que separa os grupos dominantes. No histograma (figura 11), é possível verificar dois picos intensidades (modos), o limiar pode ser um valor entre esses modos.




Figura 11. Histograma com dois modos.

Após a limiarização o histograma encontra-se com apenas com os valores de intensidade 0 ou 1.




Figura 12. Histograma após a limiarização.

2.7. Segmentação por região

Essa técnica de segmentação consiste em dividir uma imagem em regiões com características similares, através do crescimento de regiões por agregação de pixels e a divisão e fusão de regiões. O crescimento de regiões segundo Gonzales e Woods (2000) é “um procedimento que agrupa pixels ou sub-regiões em regiões maiores, que comecem com um

conjunto de pontos e, a partir deles, vai anexando pixel a pixel, os de propriedades similares, tais como nível de cinza, textura e cor e, a partir deles, crescem as regiões”. Esses pontos, também são chamados de sementes, insere uma semente na posição (x,y) e partir dela os pixels adjacentes serão anexados caso tenha alguma similaridade. Na figura 13 foi realizada a segmentação por região usando o critério de similaridade, a intensidade dos pixels.



Figura 13. Segmentação por região.

A divisão e fusão de regiões (Split-Merge), diferente do crescimento por regiões, a segmentação inicia-se a partir de toda imagem, subdividindo-a em quadrantes cada vez menores até que os adjacentes atendam algum critério de similaridade. A figura 14 foi segmentada através dessa técnica.




Figura 14. Segmentação Split-Merge.

2.8. Detecção de borda

Diferentemente das outras metodologias, esta técnica não busca similaridade entre os pixels, mas consiste em segmentar a imagem com base nas mudanças abruptas de intensidade, essa técnica baseia-se na descontinuidade, podendo ser um ponto isolado, uma linha ou a borda de um objeto.

A maneira simples para detectar as bordas é a utilização de operadores gradientes que podem ser aplicados através da convolução de máscaras com a imagem, operador Sobel, Roberts, Prewitt, Laplaciano, entre outras, podem resultar a segmentação.

As figuras a seguir mostra a segmentação utilizando o operador Sobel, uma máscara 3x3 para encontrar os gradientes verticais e horizontais.

$$\begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix}; \text{máscara Sobel.}$$




Figura 15. Convolução utilizando a máscara Sobel horizontal.




Figura 16. Convolução utilizando a máscara Sobel vertical.

Cada operador terá como característica identificar os ângulos, pontos e linhas, sendo que a escolha de um deles vai depender da necessidade da aplicação e das condições da imagem para alcançar um resultado satisfatório.

2.9. Segmentação por cor

Segmentar uma imagem baseada em cores é um processo no qual extraem uma ou mais regiões conectadas que satisfaçam o critério de homogeneidade, no caso as componentes cores. As componentes são definidas em um modelo de espaço de cores, esse espaço pode ser representado pelos principais sistemas de representação das cores, o HSI e o RGB. Através do espaço HSI, utiliza-se a matiz (H) da imagem, que representa as cores e a saturação da imagem como máscara para isolar outras regiões de interesse do matiz. A componente intensidade quase não é utilizada para segmentação de imagens coloridas. A segmentação no

espaço RGB possui bons resultados, segundo Gonzales e Woods, 2009, “Apesar de ser mais intuitivo trabalhar no espaço HSI, a segmentação é uma área na qual os melhores resultados geralmente são obtidos por meio da utilização dos vetores de cores RGB”. Esse método consiste em usar uma amostra de conjunto de cores representativas das cores de interesse e obter um valor médio da cor que se deseja segmentar.

Jorge (2001) utilizou segmentação por cor de imagens aéreas, utilizando algoritmos de redes neurais artificiais, obtendo resultados satisfatórios.

2.10. Segmentação por textura

A textura de uma imagem pode ser entendida como a existência de um ou mais padrões locais que podem ser repetidos um vez ou outra, de modo que não fica claro qual é o padrão, como ele é repetido, se a textura está ligada a toda imagem ou se alguns objetos ou regiões não tem nenhuma textura.

Segmentar textura é particionar uma imagem em regiões, de modo que cada uma terá uma textura simples e distinta dos seus vizinhos. Os modelos de textura podem ser classificados em três classes principais: estruturas de imagens piramidais, campos randômicos e métodos estatísticos. As estruturas de imagens piramidais têm como objetivo gerar valores que representem a resposta de um banco de filtros em escalas variadas e orientações diferentes. Os filtros usados para este propósito é o filtro Laplaciano e o filtro Gabor. Os campos randômicos utilizam processo estocástico para a escolha do pixel, são eles, Campos Randômicos de Markov Gaussiano e Campos Randômicos de Gibbs. Ambos seguem a declaração das propriedades de Markov: “a probabilidade que o pixel tem de ter certo nível de cinza dados todos os outros pixels da imagem é igual à probabilidade que o pixel tem de ter o mesmo nível de cinza dados somente os seus pixels vizinhos” LIU, J.; WANG, L. LI, S.Z. MRMRF et al.(1999, apud JORGE, 2001).

Os métodos estatísticos agrupam várias técnicas como: Matriz de coerência, Transformada Discreta de Fourier e Transformada Discreta de Cosseno e Fractais.

2.11. Segmentação por redes neurais artificiais

A rede neural consiste de unidades de processamento, denominadas neurônios, interligados de forma paralela que reagem coletivamente a um dado estímulo produzindo uma resposta. O processo da rede neural é aprender um tipo de conhecimento, armazená-lo e usá-

lo para executar alguma classificação, cada conhecimento estará nas estruturas das conexões entre os neurônios que estão interligados.

A segmentação de imagens por redes neurais do tipo MLP Mult-Layer Perceptron de 3 camadas (entrada, intermediária e de saída) é constituída por unidades do tipo Perceptron, com aprendizado supervisionado e utilizando adaptação por correção de erros. De acordo com Jorge, 2001, “O número de neurônios de entrada depende do número de características para cada pixel e o número de neurônios na camada de saída é igual ao número de classes”.

Na figura consiste de uma rede MLP com três camadas que foi utilizada por JORGE, 2001 para o reconhecimento de classes de cobertura do solo, onde a entrada é o valor RGB.




Figura 17. Topologia da rede MLP.
Fonte: JORGE, 2001, p. 50.

3. Projeto SISCOB

É um software desenvolvido pela Embrapa (2009), tendo como características a utilização de técnicas de processamento e classificação de imagens digitais. Esse software permite o usuário realizar a análise da cobertura do solo, quantificar as alterações ocorridas na cultura, monitoramento de doenças e pragas e deficiências na lavoura, o que leva o agricultor saber de fato onde atuar e ter o monitoramento das necessidades específicas das áreas de cultivo.

As figuras a seguir, mostram o resultado da segmentação e classificação de imagens através de uma rede neural, de uma plantação de citros (figura 11) e a identificação de áreas com doenças em uma plantação de soja (figura 18).

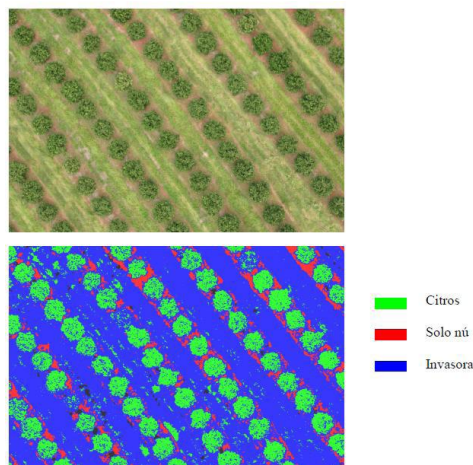


Figura 18. Plantao de citros.

Fonte: JORGE, L.A.C.; CRESTANA, S. Cap. 7 - Processamento de Imagens em Cincia do Solo - razes, morfologia e cobertura do solo, Embrapa Instrumentao Agropecuria, 71 p. So Carlos – SP.




Figura 19. Plantao de soja.

Atravs dessas figuras  possvel verificar que o estudo e as pesquisas das tcnicas computacionais ligadas ao processamento de imagens e inteligncia artificial, permitem o desenvolvimento de softwares cada vez melhores para a gesto da agricultura de preciso.

3.1. Desenvolvimento do projeto

Com base nas pesquisas realizadas foi desenvolvido um software que realiza o processamento digital de imagens adquiridas através do SR. A partir do sistema SISCOB, foi desenvolvido um sistema que irá calcular os índices de vegetação para a geração de imagens que serão posteriormente segmentadas e classificadas para análise da cobertura do solo. Desta forma poderão ser analisadas mudanças fisiológicas e estruturais da cobertura do solo, devido ao uso de imagens multiespectrais.

O software foi desenvolvido com a linguagem JAVA, que pode ser instalado em qualquer sistema operacional, foi utilizada a biblioteca ou *Application Programming Interface* (API), *Java Advanced Imaging* (JAI), que possui métodos para a representação e processamento de imagens e também a API de técnicas de inteligência artificial *Waikato Environment Knowledge Analysis* (WEKA) para a implementação da rede neural artificial. A rede neural usada é o MLP que irá classificar pixel a pixel da imagem e atribuir cada um deles a uma classe, no fim terá uma imagem segmentada (figura 20).




Figura 20. Processo de classificação pixel a pixel.

O MLP tem como característica ser uma rede supervisionada, ou seja, é necessário ensinar a rede utilizando amostras de pixels que irá constituir uma classe, dessa forma os pixels de entrada na rede neural serão classificados de acordo com as amostras fornecidas para a rede.

A MLP utiliza o algoritmo backpropagation, que consiste de dois passos o processamento direto (Feedforward) e o processamento reverso (Backforward). O feedforward consiste em receber os valores na entrada realizar o processamento desses valores e o resultado é passado para a camada seguinte, quando a última camada é alcançada os valores são comparados com as saídas desejadas. O processo backforward, um sinal de erro

é calculado na saída e é propagada no sentido inverso por todas as camadas. O algoritmo backpropagation repete o processamento até que o erro médio quadrático seja minimizado.

Para gerar resultados satisfatórios no processo de segmentação, os parâmetros do Weka foram testados e configurados, de modo que o erro médio quadrático fosse o menor de acordo com os valores atribuídos a esses parâmetros. Alguns dos parâmetros são:

- LearningRate (η): Taxa de aprendizado, determina a velocidade do aprendizado.
- Momentum (α): Valor que influencia no tempo de treinamento, convergir mais rápido.
- HiddenLayers: Quantidade de camada intermediária.
- TrainingTime: Duração do ciclo, ou época, de aprendizado.

Para a escolha da quantidade de neurônios da camada escondida foi utilizada a Regra do valor médio, equação 5.

$$q = \frac{p+M}{2}; (5).$$

q = quantidade de unidades na camada escondida;

p = número de entradas;

M = número de saídas da rede.

Os erros médios quadráticos dos testes realizados podem ser visto nos gráficos abaixo respectivamente utilizando taxas de aprendizado iguais a 0.3, 0.4 e 0.9.

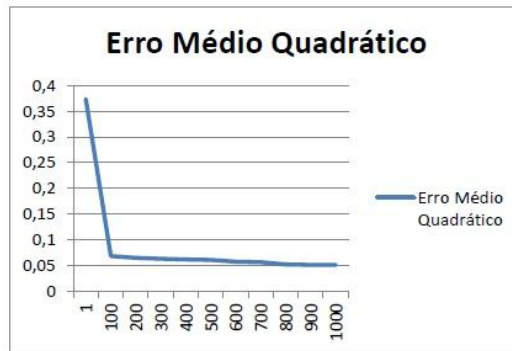


Gráfico 1. Erro médio quadrático, neta = 0,3.

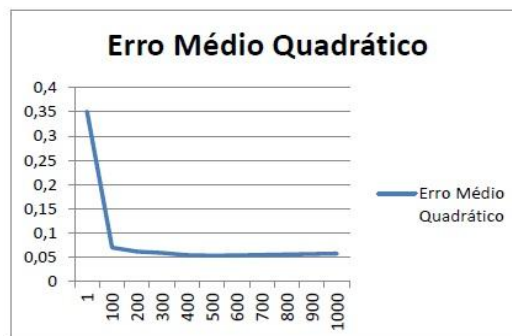


Gráfico 2. Erro médio quadrático, neta = 0,4.




Gráfico 3. Erro médio quadrático, neta = 0,9.

A tabela a seguir demonstram os valores dos parâmetros e os resultados dos testes.

Tabela 1. Teste utilizando 645 amostras, 5 classes e q camadas escondidas.

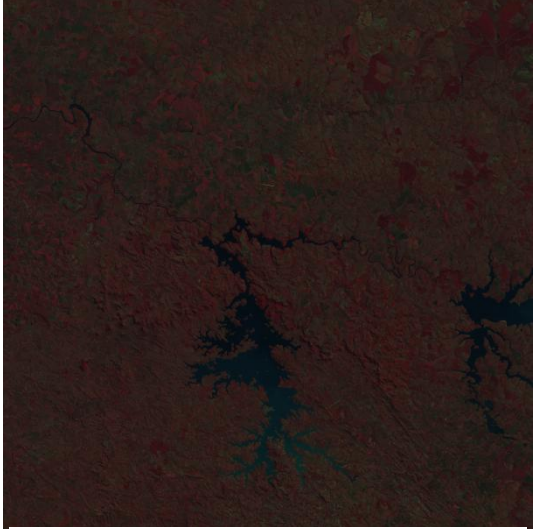
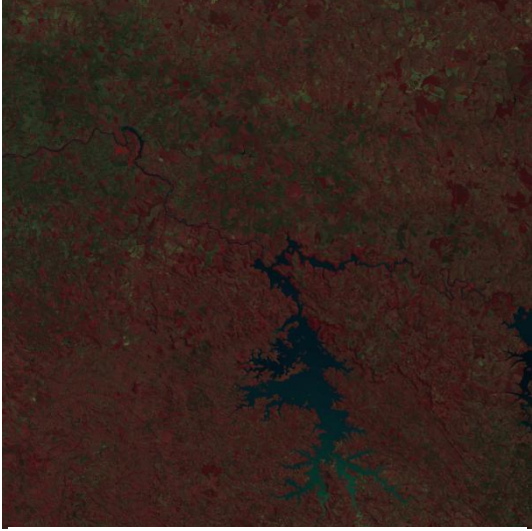

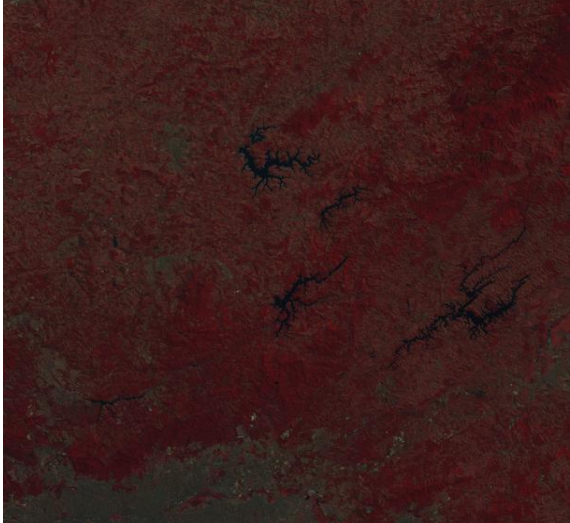
Treinamento	LearningRate	Momentum	TrainingTime	Taxa de acerto
1	0,2	0,2	500	98,2946%
2	0,3	0,2	500	98,1395%
3	0,4	0,2	500	98,9147%
4	0,2	0,2	1000	99,0698%
5	0,3	0,2	1000	99,2248%
6	0,4	0,2	1000	98,7597%
7	0,3	0,5	500	98,4496%
8	0,3	0,5	1000	98,6047%

Através da análise resultados, pode-se verificar que a taxa de aprendizado igual a 0,3 existe a convergência do erro, utilizando a taxa igual a 0,4 o erro em determinada época começa a subir e taxa igual a 0,9 existe a oscilação do erro. Desta forma, utilizando a taxa de aprendizado igual 0,3 obtêm-se os melhores resultados.

4. Resultados e conclusão

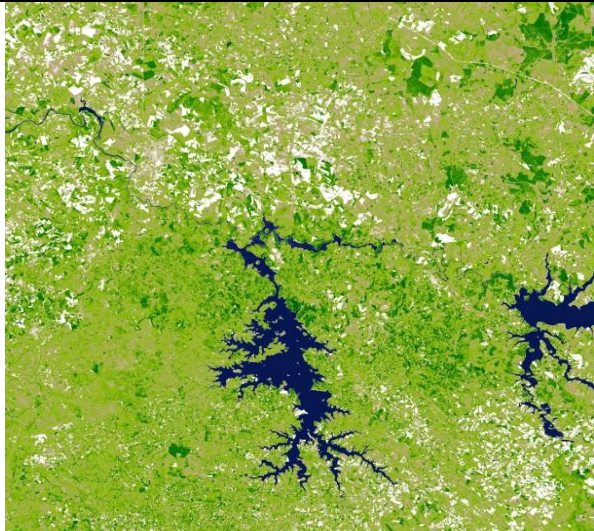

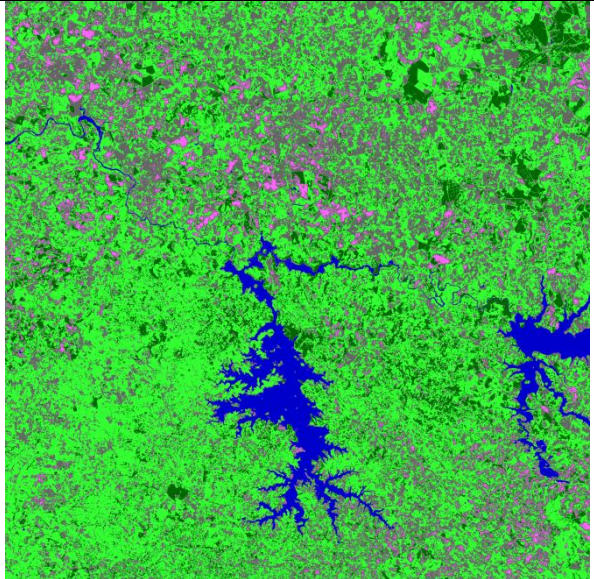
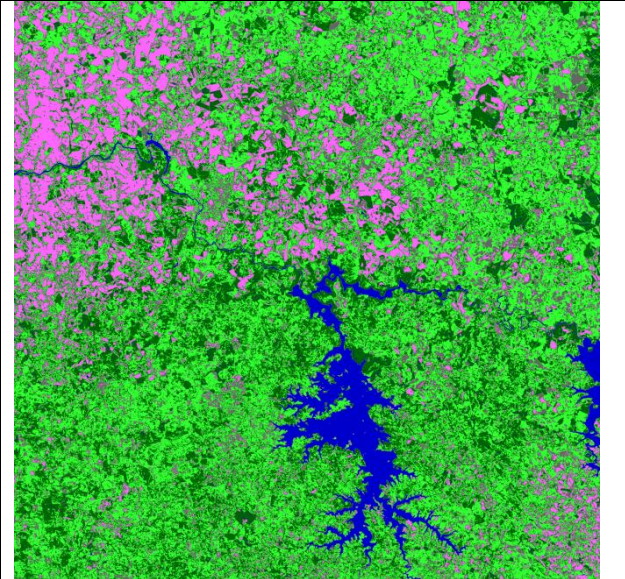
As imagens utilizadas para realizar os processamentos foram retiradas do site *Global Land Cover Facility*, <<http://glcfapp.glcf.umd.edu:8080/esdi/index.js>>, são imagens do satélite Landsat TM (bandas 2, 3 e 4). Na tabela são apresentadas quatro imagens.

Tabela 4. Imagens

	
<p>Imagem (a) órbita ponto 221/76, ano 1986. Landsat TM, bandas 2,3 e 4.</p>	<p>Imagem (b) órbita ponto 221/76, ano 1990. Landsat TM, bandas 2,3 e 4.</p>
	
<p>Imagem (c) plantação de citros, EMBRAPA, 2011.</p>	<p>Imagem (d) órbita ponto 216/076, 2004. Landsat TM, bandas 2,3 e 4.</p>

As imagens foram realçadas utilizando o índice de vegetação NDVI, neste processo é possível verificar o estado da vegetação. Posteriormente, os pixels foram atribuídos às classes criadas, resultando em uma imagem segmentada (tabela).

Tabela 5. Imagens segmentadas.

	
<p>Imagem (a) baseada no NDVI.</p>	<p>Imagem (b) baseada no NDVI.</p>
	
<p>Imagem (a) segmentada utilizando 645 amostras para o treinamento da rede.</p>	<p>Imagem (b) segmentada utilizando 645 amostras para o treinamento da rede.</p>
<p>Porcentagens totais dos padrões solo_descoberto : 3.2541485 % vegetação : 10.700301 % agricultura : 49.888577 % zona_urbana : 31.609142 % rio : 4.5478334 %</p>	<p>Porcentagens totais dos padrões solo_descoberto : 7.0544095 % vegetação : 16.079586 % agricultura : 45.917553 % zona_urbana : 26.85896 % rio : 4.0894914 %</p>

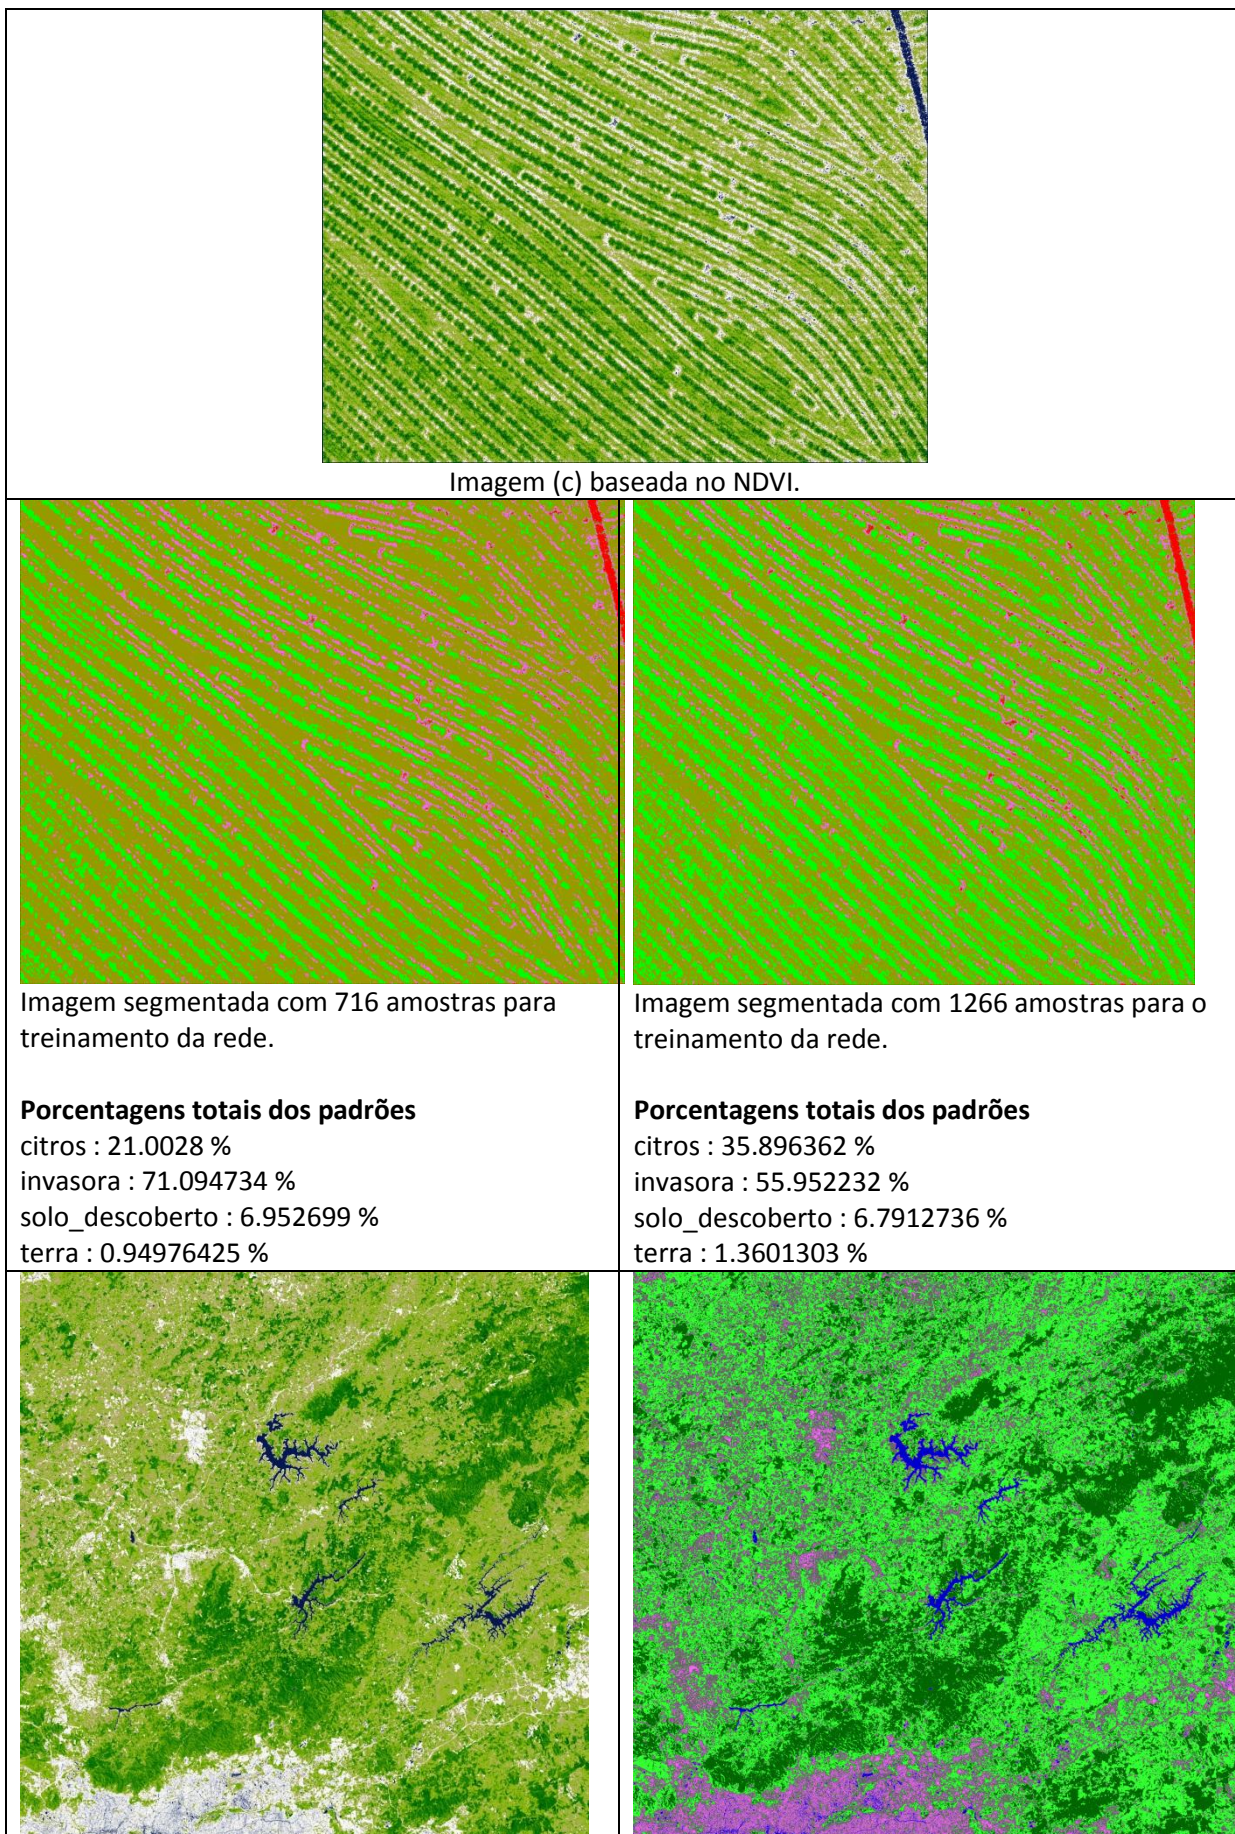


Imagem (d) baseada no NDVI.	<p>Imagem (d) segmentada com 645 amostras para treinamento da rede.</p> <p>Porcentagens totais dos padrões</p> <p>solo_descoberto : 3.6444254 %</p> <p>vegetação : 24.949152 %</p> <p>agricultura : 43.5931 %</p> <p>zona_urbana : 26.036295 %</p> <p>rio : 1.7770263 %</p>
-----------------------------	--

Este artigo teve como objetivos, introduzir as técnicas de segmentação de imagens e a aplicação dos conceitos apresentados no desenvolvimento de um sistema para a análise da cobertura do solo utilizando imagens além do espectro visível.

Através dos testes realizados com as imagens de satélite que são mais complexas, o software se mostrou eficaz no processamento das imagens, gerando resultados satisfatórios, considerando o erro médio quadrático e a taxa de erro.

Por fim, o sistema conseguiu gerar resultados que permita o usuário distinguir e separar as áreas com diferentes densidades de área verde, como também, analisar as imagens aéreas de forma que fosse possível verificar a variabilidade espacial de cada espaço de uma colheita. Portanto, esta aplicação obteve resultados que podem auxiliar no processamento de imagens para a agricultura de precisão.

REFERÊNCIAS

ADAMCHUK, Viacheslav I.; PERK, Richard L.; SCHEPERS, James S. **Precision Agriculture: Applications of Remote Sensing in Site-Specific Management**. Universidade de Nebraska, 2003. Disponível em: <<http://digitalcommons.unl.edu/cgi/viewcontent.cgi?article=1706&context=extensionhis>>. Acesso em: 01 set. 2011.

CÔCCO, Lilian Cristina. **Aplicação de Redes Neurais Artificiais para Previsão de Propriedades da Gasolina a partir da sua Composição Química**. 2003. 153 f. Dissertação (Mestrado) - Curso de Engenharia de Materiais e Processos, Universidade Federal do Paraná, Curitiba, 2003.

DAINESE, Renata Cilene; MOREIRA, Mauricio Alves; MOLIN, Jose Paulo; AGUIAR, Jaime. **Análise do potencial de parâmetros espectro-temporais de imagens orbitais para mapeamento de produtividade de cana-de-açúcar**. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO 2004, 2004, Piracicaba. Anais do Congresso Brasileiro de Agricultura de Precisão - ConBAP 2004. Piracicaba: ESALQ/USP, 2004. p. 1-13.

FIGUEIREDO, Divino. **Conceitos Básicos de Sensoriamento Remoto**, 2005. Disponível em:
<http://www.conab.gov.br/conabweb/download/SIGABRASIL/manuais/conceitos_sm.pdf>.
Acesso em: 01 set. 2011.

GONZALES, R.C; WOODS, R.E. **Processamento Digital de Imagens**. 3.ed. São Paulo: Peason Prentice Hall, 2009.

GONZALEZ, Rafael C.; WOODS, Richard E. **Processamento de Imagens Digitais**. Editora Edgard Blucher, Brazil, 2000. 509 p.

HATFIELD, J.L; GITELSON, Anatoly A.; SCHERPERS, J.S, WALTHALL, C.L. **Application of Spectral Remote Sensing for Agronomic Decisions, University of Nebraska** – Licon, p. 117 – 131, 2008.

HAYKIN, Simon. **Perceptron de Múltipla Camada. In: HAYKIN, Simon. Redes Neurais Princípios e Práticas: Perceptrons de Múltiplas Camadas**. 3.ed. Porto Alegre: Bookman, 2001. Cap. 4, p. 183-202.

JORGE, Lúcio André Castro. **Determinação da Cobertura do Solo em Fotografias Aéreas do Projeto ARARA**. 2001. 112 f. Dissertação (Mestrado) - Curso de Ciências Matemáticas e de Computação, Universidade de São Paulo USP, São Carlos, 2001.

JORGE, Lúcio André Castro. **Metodologia para Utilização de Aeromodelos em Monitoramento Aéreo: Análise de Imagens**, Embrapa Instrumentação Agropecuária, 11 p. São Carlos – SP, 2003.

JORGE, Lúcio André Castro; CRESTANA, S. **Capítulo 7 - Processamento de Imagens em Ciência do Solo - raízes, morfologia e cobertura do solo**, Embrapa Instrumentação Agropecuária, São Carlos, 71 p. São Carlos – SP.

MARQUES FILHO, Ogê; VIEIRA NETO, Hugo. **Processamento Digital de Imagens**. 1 ed. Rio de Janeiro: Brasport, 1999. 307 p.

MONDAL, P; BASU, M.; BADHORIA, P.B.S. **Critical Review of Precision Agriculture Technologies and Its Scope of Adoption in India**. American Journal of Experimental Agriculture, p. 50-68, 2011.

MORAES, E.C. **Fundamentos de Sensoriamento Remoto**, São José dos Campos, 2002. Disponível em: <http://www.grss-unicamp.com/CAP1_IntroSR_INPE.pdf>. Acesso em: 01 set. 2011.

MORAN, M.S.; INOUE, Y.; BARNES, E.M. **Oportunities and limitatios for image-based remote sensing in precision crop management**. Remote Sensing Environment, v.61, p.319-346, 1997.

MOREIRA, M.A. Sistema de Sensores. DSR/INPE - **Curso de Sensoriamento Remoto aplicado a estudos ambientais**, 38 p. jun 2003.

ROSENDO, Jussara Dos Santos. **Índices de Vegetação e Monitoramento do Uso do Solo e Cobertura Vegetal na Bacia do Rio Araguari-MG Utilizando Dados do Sensor Modis**. 151 f. Dissertação (Mestrado em Geografia) – Instituto de Geografia, Universidade Federal de Uberlândia, Uberlândia, 2005.

SHIMABUKURO, Yosio Edemir; MAEDA, Eduardo Eiji; FORMAGGI, Antonio Roberto. **Sensoriamento Remoto e Sistemas de Informações Geográficas aplicados ao estudo dos recursos agrônômicos e florestais**. Disponível em: <http://www.ceres.ufv.br/CERES/revistas/V56N004_00409.pdf>. Acesso em: 30 set. 2011.