



## SISCOB – SOFTWARE PARA ANÁLISE DE COBERTURA DO SOLO

LÚCIO A. C. JORGE<sup>1</sup>, DANIEL J. C. B. SILVA<sup>2</sup>

<sup>1</sup>Pesquisador, Embrapa Instrumentação Agropecuária, São Carlos – SP, Fone: (0XX16) 2107.2845, lucio@cnpdia.embrapa.br

<sup>2</sup>Graduando em Engenharia de Computação, Universidade Federal de São Carlos, São Carlos – SP

Apresentado no  
Congresso Brasileiro de Agricultura de Precisão – ConBAP 2010  
Ribeirão Preto – SP, 27 a 29 de setembro de 2010

**RESUMO:** Este trabalho apresenta o software gratuito desenvolvido para análise da cobertura do solo por processamento de imagens, denominado SISCOB. Este sistema está sendo utilizado no projeto Rede de Agricultura de Precisão coordenado pela Embrapa e será integrado nas ferramentas de análise da cobertura de todas as estações experimentais do projeto. Também está sendo distribuído gratuitamente no site da Embrapa [www.cnpdia.embrapa.br/labimagem](http://www.cnpdia.embrapa.br/labimagem). Neste artigo, apresenta-se as técnicas e ferramentas implementadas, os testes e a aplicação no estudo de citros realizado na Fazenda Entre Rios da empresa Fisher SA. São apresentadas todas as funcionalidades e a discussão sobre a criação dos bancos de padrões para análise.

**PALAVRAS-CHAVE:** sensoriamento remoto, imagens aéreas, cobertura do solo, rede neural, agricultura de precisão

## SISCOB - SOFTWARE FOR ANALYSIS OF SOIL COVER

**ABSTRACT:** This paper describes free soil cover software called SISCOB. This system has being used in Precision Farming Network Project at Embrapa and has being integrated on analysis tools at experimental places. Therefore it is free distributed at Embrapa site [www.cnpdia.embrapa.br/labimagem](http://www.cnpdia.embrapa.br/labimagem). This paper, presents new techniques and tools of SISCOB, and describes tests and applications on citrus images from Entre Rios farm from Fisher enterprise. It is presented all functionalities and discussions about care on databases creations.

**KEYWORDS:** remote sensing, aerial images, soil cover, neural networks, precision farm

**INTRODUÇÃO:** Segundo Plant (2001), agricultura de precisão é compreendida pelo uso da tecnologia de informação em todo ciclo da produção agrícola, um processo em prol da agricultura sustentável. Assim todas as ações auxiliadas pela tecnologia atual tem o objetivo de aumentar a eficiência na utilização de insumos e recursos naturais (Zhang et al., 2002), tornando a tomada de decisão mais precisa, minimizando erros. Muitos cultivos são avaliados a partir de sua área de solo coberto visando determinar os impactos da chuva e prever possíveis processos erosivos. Entretanto as técnicas de inspeção de cobertura vegetal são muito trabalhosas além de depender das condições naturais que limitam a análise e comprometem a precisão. Sendo assim, analisar o desenvolvimento de uma cultura a partir da área de solo coberto é de suma importância a fim de determinar a área de incidência de luz solar para fotossíntese, a competição entre a cultura e a planta infestante e o efeito da cobertura vegetal para o controle de erosão (JORGE e CRESTANA, 2007). O uso de técnicas de processamento de imagens a partir de fotografia aérea da cultura destaca-se como uma ferramenta de grande potencial para aquisição de parâmetros que auxiliam na tomada de decisão, reduzindo o tempo de observação no campo e influência de condições atmosféricas (JORGE e CRESTANA, 2007). Assim a análise de imagens aéreas desponta como um artifício capaz de identificar aspectos importantes da área agrícola como as propriedades e o estado de conservação do solo (MORAN et al.,

1997). Portanto, é evidente a demanda de um sistema especialista capaz de automatizar a análise de imagens de cobertura vegetal, para que permita a inspeção e quantificação rápida e precisa dos diferentes tipos de flora ou o solo exposto presentes na área analisada, auxiliando, assim, a tomada de decisão. Também importante é o processamento rápido e especializado possibilitando geração de mapas de zonas homogêneas de manejo.

### MATERIAL E MÉTODOS:

O SISCOB foi desenvolvido em linguagem JAVA com o objetivo de poder ser portátil para diferentes sistemas operacionais. Utiliza o processamento de digital de imagens. Foi utilizada a biblioteca de programação ou, *Application Programming Interface* (API), disponível na linguagem de programação Java, *Java Advanced Imaging* (JAI). Esta biblioteca permite a prototipação rápida de aplicativos de imagens.

Também através da API de técnicas de inteligência artificial *Waikato Environment Knowledge Analysis* (WEKA) foi implementada uma rede neural artificial do tipo *MultiLayer Perceptron* (MLP) que permite para criar um aplicativo dinâmico para estudo da cobertura do solo por meio do reconhecimento de padrões. Na Figura 1 é apresentado a topologia da MLP utilizada

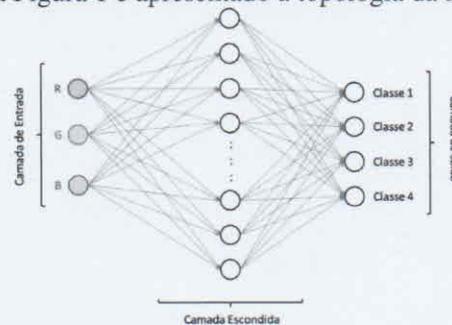


Figura 1 – Topologia da rede neural MLP

Para a construção do classificador de imagens a partir de uma rede neural supervisionada, é necessário a determinação das classes de padrões bem como os padrões destas. Nesta etapa, um especialista se faz necessário para, através de janelas de seleção na imagem, determinar os padrões de cada classe, guiando-se pelas diferentes tonalidades de cores presentes na imagem. Na Figura 2, pode ser observada a interface para seleção de padrões de numa imagem de citrus.

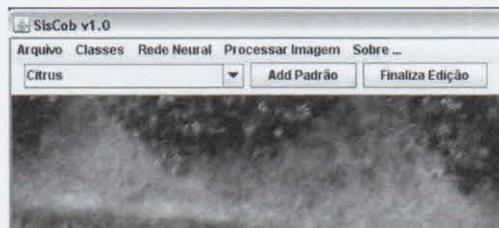


Figura 2 – Determinação de um padrão da classe “citrus” através de janelas de seleção

A segunda etapa é a criação de um classificador a partir da rede neural MLP com o algoritmo de backpropagation (BP) ou retro-propagação de erro. O algoritmo BP é caracterizado por dois passos principais: o processamento direto e o processamento reverso. O primeiro consiste em submeter uma entrada à rede neural e o resultado é propagado por todas as camadas da rede até a saída. Já o segundo, um sinal de erro é calculado na saída e este é propagado no sentido inverso por todas as camadas da rede neural. Segundo Jorge & Crestana (2007) a regra de aprendizado denominada “Regra Delta” ou Minimização do Erro Médio Quadrático (LMS) tem a função de determinar um conjunto de pesos e polarizações das conexões entre os neurônios de modo que a função erro seja minimizada. A saída de cada neurônio na rede neural é produzida através de uma função de ativação sigmoidal. O treinamento do algoritmo BP é descrito pelo fluxograma de operação a seguir.

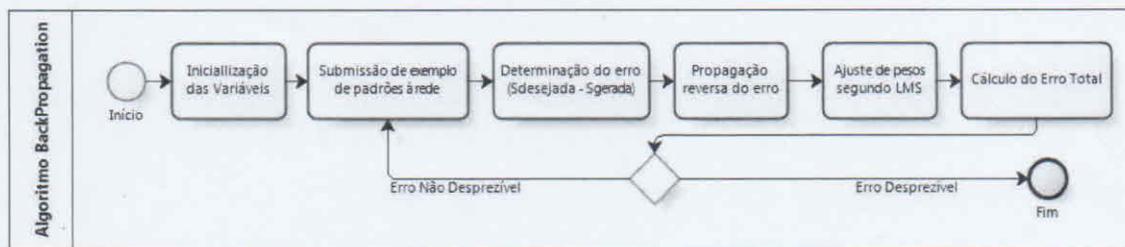


Figura 3 – Fluxograma de funcionamento do BP

A primeira etapa trata da inicialização de todos os parâmetros de treinamento e a seguir são apresentados à rede os exemplos de padrões de classes colhidas pelo especialista. O próximo passo consiste na determinação do erro fazendo a diferença entre a saída desejada e a saída gerada e fazer com que este se propague reversamente pela rede. Por fim, os pesos das conexões entre os neurônios da rede neural são ajustados segundo o LMS e se o erro total calculado for desprezível o treinamento encerra-se, senão o processo reinicia até que o erro seja desprezível.

Assim o software foi desenvolvido baseado na rede neural MLP em que os padrões de entrada são os valores RGB da imagem a ser classificada. Após a fase de treinamento, tem-se a classificação ou análise de uma ou um lote de imagens. Adotou-se o seguinte fluxo de operações até a classificação de uma imagem pela rede neural sendo que os resultados obtidos são expostos em tabelas.

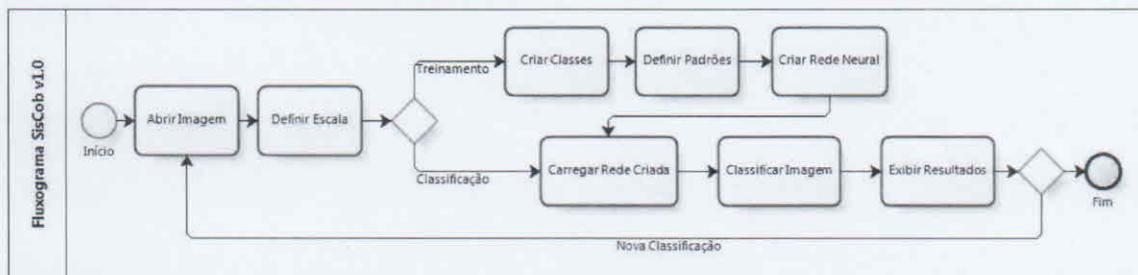


Figura 4 – Fluxograma de operações do SisCob

Para o desenvolvimento deste trabalho foram utilizadas algumas bibliotecas de programação, também designadas por *Application Programming Interface* (API), disponíveis na linguagem de programação Java como: a *Java Advanced Imaging* (JAI), a *Java Excel* (JXL) e a *Waikato Environment Knowledge Analysis* (WEKA).

**RESULTADOS E DISCUSSÃO:** Os métodos utilizados na classificação da imagem com rede neural MLP foram implementados na linguagem JAVA resultando em um aplicativo simples tanto para a aquisição de padrões e treinamento quanto para a classificação. Uma aquisição de padrões mais precisa e minuciosa resulta em um treinamento e resultado melhores. Sendo assim, um recurso de zoom foi implementado para auxiliar este processo, assegurando que a janela selecionada não contenha informações indesejadas. Para o caso de cultura de citrus, por exemplo, o zoom auxilia na precisão em determinar padrões de plantas e de solo exposto. A seguir são exemplificadas coletas de um mesmo padrão “Citrus\_” em que na figura 5 seleciona-se somente a planta e na figura 6 uma mescla de planta e solo é selecionada.



Figura 5 – (a) Seleção da planta somente; (b) Seleção mesclada de solo e planta.

O tipo de seleção representado na figura 6 pode comprometer o resultado da classificação se é de interesse desta determinar solo exposto e planta como classes de padrões distintos, por isso o cuidado na aquisição de padrões.

Depois de coletados os padrões de todas as classes desejadas e feito o treinamento obteve-se os seguintes resultados de classificação das imagens.

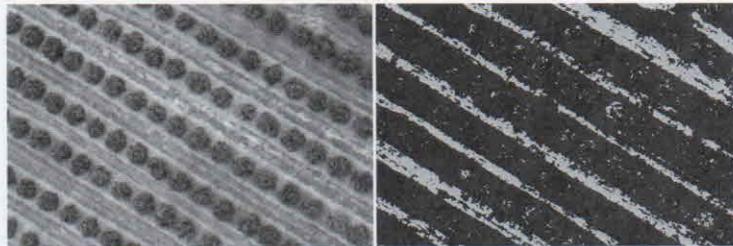


Figura 7 – Imagem original e classificada de plantação de citrus

Além da representação dos resultados em imagens classificadas foi possível quantificar tanto em porcentagem quanto em área os padrões encontrados na imagem como mostrados a figura 8.

Porcentagem	
Porcentagem dos Padrões:	
Porcentagens totais dos padrões	
Citrus : 52,28031 %	Área : 316,578 m2
Invasora : 19,65951 %	Área : 119,045 m2
Solo : 28,060177 %	Área : 189,914 m2

Figura 8 – Resultados da classificação

Foi realizado um experimento com 210 imagens na área de citros. O conjunto de imagens foi distribuído para 3 especialistas diferentes para utilizar o SISCOB para determinar a porcentagem de área coberta pela cultura dos citros, por plantas invasoras e solo nu. Cada um dos técnicos gerou sua própria RN e respectivos treinamentos, ou seja, a RN1, a RN2 e a RN3, utilizando o número de amostras para treinamento variável de acordo com o critério de cada um. O primeiro utilizou dez imagens no treinamento, o segundo utilizou sete imagens e o terceiro cinco. O número de coletas em cada imagem variou de acordo com o critério de cada um dos treinadores. Após a fase de treinamento, foi executada a análise de todo o lote. Alguns exemplos de classificações podem ser observados na Figura 9 (a), (e), (i) e (m) imagens originais; (b), (f), (j) e (n) imagens classificadas pela RN1; (c), (g) (k) e (o) imagens classificadas pela RN2 e (d), (h), (l) e (p) imagens classificadas pela RN3.

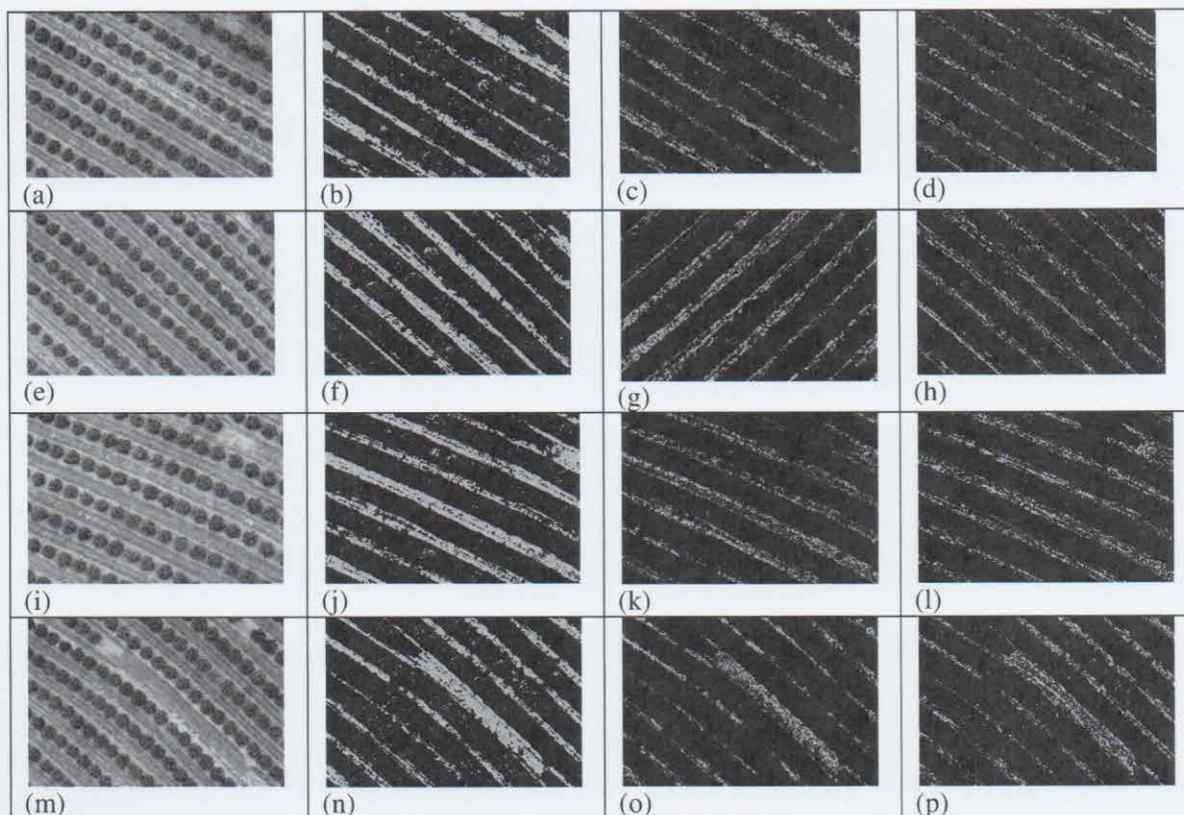


Figura 9: (a), (e), (i) e (m) Imagens originais; (b), (f), (j) e (n) classificadas pela RN1; (c), (g) (k) e (o) classificadas pela RN2 e (d), (h), (l) e (p) classificadas pela RN3.

Na tabela 1, podem ser observados os valores determinados para as imagens da Figura 9. Em virtude destes resultados, pode-se afirmar que as ferramentas do SISCOB para treinamento devem ser utilizadas com cuidado e que podem ser obtidos resultados muito diferentes caso o treinamento não seja feito com cuidado adequado e com número suficiente de amostras. Os resultados do primeiro técnico se aproximaram mais do que se considera o resultado adequado para a análise.

Tabela 1: Valores de área obtidos pelas RN dos técnicos 1, 2 e 3.

Figura	área de citros		área de invasora		área de solo nu	
	%	m2	%	m2	%	m2
RN1						
b	52.28	459.58	19.65	172.82	28.06	246.67
f	46.52	409.01	22.59	198.64	30.87	271.42
j	45.36	398.81	24.63	216.52	30.00	263.75
n	54.11	475.73	20.93	184.034	24.94	219.31
RN2						
c	48,19	594.36	11.10	136.89	40.69	501.88
g	45.93	566.46	13.42	165.53	40.63	501.13
k	50.29	620.18	12.62	155.62	37.08	457.32
o	50.56	623.51	10.86	134.00	38.57	475.65
RN3						
d	43.11	398.14	9.86	91.06	47.02	434.23
h	42.83	395.57	11.04	102.02	46.11	425.84
l	44.95	415.17	12.22	112.93	42.81	395.33
p	43.98	406.15	12.36	114.18	43.65	403.10

**CONCLUSÕES:** O uso de redes neurais para a classificação de imagens de cobertura do solo mostrou-se muito rápido e eficiente. Assim, com o SisCob v1.0 é possível classificar e quantificar precisamente classes de padrões presentes nas imagens, podendo, portanto, auxiliar o usuário na tomada de decisão.

**REFERÊNCIAS:**

MORAN, M. S. New imaging sensor technologies suitable for agricultural management. In: Remote Sensing in Agriculture (Bryson, R. J.; Howard, W.; Riding, A. E.; Simmonds, L. P.; Steven, M. D., eds). Aspects of Applied Biology 60:1-10, 2000.

PLANT, R. E. Site-specific management: the application of information technology to crop production. Computers and Electronics in Agriculture, 30:9-29, 2001.

ZHANG, N., WANG, M., WANG, N. Precision agriculture-a worldwide overview. Comp. Electron. Agric. 36:113-132, 2002.

JORGE, L. A. de C.; CRESTANA, S. Processamento de imagens em ciência do solo: raízes, morfologia e cobertura do solo. In: MARTIN NETO, L.; VAZ, C. M. P.; CRESTANA, S. (Ed.). Instrumentação, o avançada em ciência do solo. São Carlos, SP: Embrapa Instrumentação, Agropecuária, 2007. p. 341-438.