

## Rede neural artificial (perceptron) aliada a índices de vegetação na estimativa de áreas com plantas de soja

Carlos Antonio da Silva Junior<sup>1</sup>  
Marcos Rafael Nanni<sup>1</sup>  
Everson Cezar<sup>1</sup>  
Aline de Carvalho Gasparotto<sup>1</sup>  
Franciele Romagnoli<sup>1</sup>  
Guilherme Fernando Capristo Silva<sup>1</sup>  
Anderson Antonio da Silva<sup>1</sup>  
Roney Berti de Oliveira<sup>2</sup>

<sup>1</sup> Universidade Estadual de Maringá - UEM  
Av. Colombo 5790 – 87020-900 - Maringá - PR, Brasil  
{carlos-junior89; franciele\_romagnoli; guilhermecapristo; anderson\_agrouem;  
alinegaspa}@hotmail.com, marcos.nanni@gmail.com e eversoncezar@yahoo.com.br.

<sup>2</sup> Universidade do Estado de Mato Grosso - UNEMAT  
Av. Perimetral Rogério Silva s/n - 78580-000 – Alta Floresta - MT, Brasil  
roneybertioliveira@gmail.com

**Abstract.** Artificial neural network (ANN) classifiers are tools that have been successfully used in agriculture mainly for soybean flowering and physiological maturity, soybean prediction yield, maize grain quality, classification of grains as seeds, maize yield and direction of agricultural tractors. Current research develops and evaluates settings of ANNs to discriminate and estimate areas of soybean plantations by employing the vegetation index with and without temporal series. Study area comprises the state of Paraná, south Brazil. The images used to process ANN were NDVI, PVI and EVI indices, both Julian day 017 and CEI index, derived from time-series MOD13Q1 product from MODIS sensor Terra satellite. The definition of samples and their spectral signatures, the architecture and training of ANN, network application obtained at the end, the classified map were performed. Samples were defined as polygon soybean, non-soybean and other uses (mainly streams). ANN architecture was performed by the classification module employing MLP (Multi-layer Perceptron) artificial neural networks trained by using backpropagation algorithm. Classification quality was assessed quantitatively with the coefficients of Overall Accuracy (OA) and Kappa ( $\kappa$ ), both derived from the confusion matrix. Crop Enhancement Index (CEI), a vegetation index with series-temporal discrimination of soybean areas (pixels with higher than 0.28 rates), proved to be equivalent to ANN to discriminate soybean areas. The major and unique contribution of current study for remote sensing in agriculture was to show that vegetation indices coupled to artificial neural network techniques may improve the results of crop mapping, especially in soybean areas.

**Palavras-chave:** backpropagation neural network, remote sensing, soybean mapping, time-series, rede neural de retropropagação, sensoriamento remoto, mapeamento de soja, séries-temporais.

### 1. Introdução

Redes neurais artificiais (RNA) são técnicas computacionais que apresentam modelos matemáticos que auxiliam na solução de diversos problemas, tendo como base a organização de neurônios do cérebro humano. Tratada comumente como Inteligência artificial. O princípio é que a RNA seja capaz de tomar decisões com base na aprendizagem, sendo que o conhecimento será adquirido por meio de experiência indicada por um usuário, ou seja, aprendendo, errando e fazendo novas descobertas.

Como em um sistema nervoso é composto por diversos neurônios, a RNA é também formada por unidades de pequenos módulos, em que simulam o funcionamento de um neurônio (Haykin, 2008).

Conforme menciona Braga et al. (2007), uma das características mais importantes das redes neurais artificiais é a capacidade de aprender com exemplos. O conhecimento é adquirido por meio de intensidades das conexões entre os neurônios. Assim, consistindo em um processo iterativo de ajuste de parâmetros e pesos, que armazenam no final do processo conhecimento do ambiente externo.

Na utilização de redes neurais artificiais na agricultura, a visão humana para julgamento de treinamento assume papel importante. A seleção visual na forma de polígonos em processo de criação de amostras é um exemplo de tais julgamentos. As amostras de treinamento em polígonos são importantes, porque tem fortes ligações com o rendimento final. Ou seja, funciona na percepção de identificação de talhões de áreas agrícolas, reflectância, textura, dentre outros (Oide et al., 1995).

Portanto, o desenvolvimento de mapeamento sistemático de culturas agrícolas no Brasil é um desafio, principalmente devido sua larga extensão cultivada e diversos tipos de culturas implantadas. O desafio da sistematização, principalmente no que diz respeito à cultura da soja é de relevância notória para o país, pois enorme parte de sua economia é voltada para tal atividade, que ainda não é conhecida com exatidão.

O objetivo deste estudo é desenvolver e avaliar configurações de RNA para discriminar e estimar áreas da cultura da soja por meio de informações do índice de vegetação com e sem série-temporal, para o ano-safra 2010/2011.

## 2. Material e Métodos

A área de estudo compreendeu o estado do Paraná, na região sul do Brasil, localizado nas coordenadas geográficas de Latitude 22°29' a 26°43' S e Longitude 48°20' a 54°38' W (Figura 1). A altitude média é variável, em que 52% do território são superiores a 600m e somente 3% são inferiores a 300m. Para o clima, são caracterizados três tipos predominantes, em que segundo a classificação de Köppen-Geiger são: Cfa, Cfb e Cwa

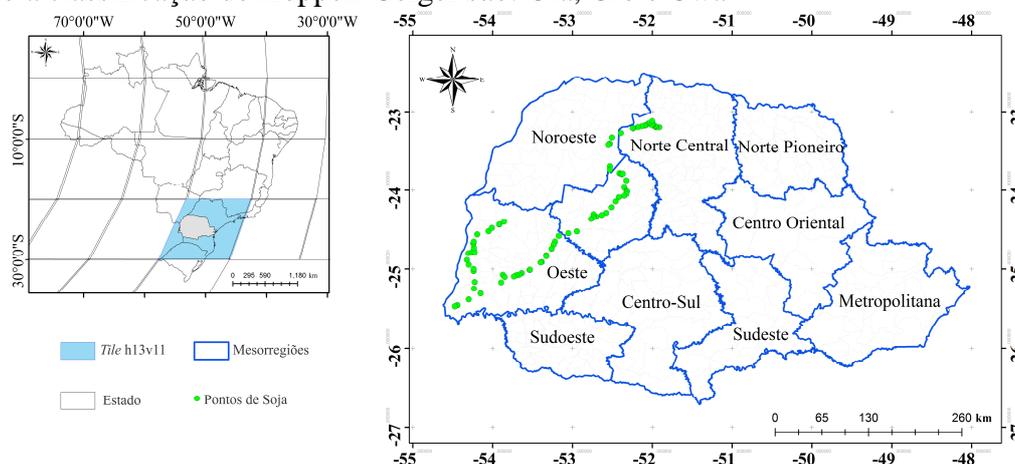


Figura 1. Área de estudo concentrada no *tile* h13v11 do sensor MODIS compreendendo o estado do Paraná.

Um dos primeiros aspectos a serem considerados no mapeamento remotamente da soja é o fato de que sua fenologia é um processo progressivo. Portanto, a análise de cultivo da soja envolve o uso de uma série temporal de imagens de satélite. Para lidar com esta situação, as aquisições das imagens foram selecionadas que cobrem a área de estudo em diversos períodos de um ano agrícola, com o objetivo de destacar dinâmica temporal da cultura da soja, permitindo ao mesmo tempo a melhor distinção de outras classes de cobertura do solo.

Para tanto, foram utilizados os valores de EVI (*Enhanced Vegetation Index*) do produto MOD13Q1, *tile* h13v11, coleção 5.0, das imagens MODIS compostas de 16 dias (Huete, 1997) do satélite Terra, com resolução espacial de 250 m, baixados da USGS LP-DAAC.

O EVI é um índice que foi desenvolvido para atenuar os efeitos do solo (ajustado pelo SAVI) e da atmosfera (ajustado pelo ARVI) no mapeamento de vegetação. Além do EVI, foram utilizadas para posteriores análises as imagens contidas no produto MOD13Q1: vermelho, infravermelho próximo e o NDVI. Além disso, para o cálculo do índice CEI (*Crop Enhancement Index*), desenvolvido por Rizzi et al. (2009), são necessários obter os valores de máximo e de mínimos do EVI do plantio da cultura e desenvolvimento vegetativo, respectivamente, por meio de série-temporal.

Todas as imagens foram obtidas originalmente no formato HDF (*hierarchical data format*) e projeção sinusoidal, foram processadas de acordo com o desenvolvimento de rotinas de automatização em lote (Silva Junior, 2014). Assim, os dados foram reprojados para coordenadas Lat./Long., DATUM WGS-84 (*World Geodetic System 1984*) e automaticamente convertidos para o formato GeoTIFF.

Em seguida, foi realizado o índice de vegetação ortogonal PVI (*Perpendicular Vegetation Index*) para a imagem MODIS dia Juliano 017, em que permite anular a reflectância do solo, pois onde a cultura da soja está na fase inicial do seu desenvolvimento ainda há solo presente na imagem, causando uma mistura espectral. Para a execução do PVI foram realizadas as regressões de linha do solo, utilizando as bandas espectrais do infravermelho próximo e vermelho, conforme menciona Nanni e Demattê (2006).

A metodologia para o desenvolvimento da rede neural artificial (RNA) para o mapeamento de áreas com soja consistiu em duas etapas distintas: pré-processamento e treinamento da RNA para classificação dos índices de vegetação. As imagens utilizadas para o processo da RNA foram os índices NDVI, PVI e EVI, todos do dia Juliano 017.

Em relação ao treinamento da RNA, foram utilizados os processos de acordo com metodologia proposta por Andrade (2013), assim sendo realizada a definição das amostras e suas respectivas assinaturas espectrais, definição da arquitetura e treinamento da RNA, aplicação da rede e obtenção do mapa classificado.

Todos os processos referentes à RNA foram executados na plataforma IDRISI Selva, desenvolvido pela *Graduate School of Geography* da Universidade de Clark. Neste segmento, foram definidos e selecionados entre 50 a 65 polígonos de diversos tamanhos para melhor detalhar as áreas onde estava sendo cultivada a cultura da soja.

A plataforma IDRISI Selva não reconheceu apenas duas classes, apresentando erro no mapa final classificado. Portanto, para este processo foram definidas as amostras em polígonos de soja, não-soja e demais usos (principalmente cursos d'água). Em seguida foram definidos os limiares espectrais de cada imagem pelo módulo *Makesig*, em que consiste a extração das informações espectrais de cada imagem com base nas amostras selecionadas. Em relação à arquitetura da RNA, foi executado o módulo de classificação por redes neurais artificiais do tipo MLP (*Multi-layer perceptron*). Os elementos da camada de saída foram definidos com base no número de classes a serem definidas na imagem, sendo neste caso três nós com valores identificados na criação das amostras e processados pelo módulo *Makesig*. Para o processo de melhor identificação da configuração da arquitetura para o mapeamento da cultura da soja foi utilizado alguns testes para as quantidades de camadas, quantidade de neurônios por camada e função de ativação.

A rede neural artificial foi treinada utilizando o algoritmo *backpropagation* (Haykin, 2008). Estritamente, *backpropagation* refere-se ao método para calcular o gradiente da soma de acordo com a função de erro quadrático relacionado aos pesos para uma rede *feedforward*, que nada mais é que uma aplicação simples, no entanto eficiente perante a regra da cadeia de cálculo elementar. Para isso, assume que existem  $n$  classes,  $m$  neurônios na camada escondida e um neurônio na camada de saída, conforme mostrado na Figura 2.

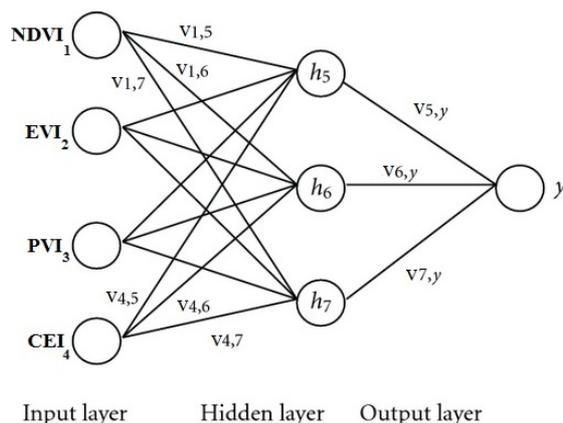


Figura 2. Modelo MLP de neurônio utilizado no mapeamento da soja.

O algoritmo de aprendizagem de *backpropagation* é essencialmente um método de otimização que é capaz de encontrar os coeficientes de peso e os limiares para a rede neural e dado conjunto de treinamento. A rede que se presume ser constituído por neurônios do comportamento dos quais é descrito pela Equação 1.

$$y = S\left(\sum_{i=1}^N w_i x_i + \Theta\right) \quad (1)$$

em que a função de saída não linear S é definido pela Equação 2.

$$S(\varphi) = \frac{1}{1 + e^{-\gamma\varphi}} \quad (2)$$

em que  $\gamma$  determina a inclinação da curva na origem das coordenadas. Os valores de entrada e de saída são considerados no intervalo  $[0, 1]$ . Nas formulas seguintes, o parâmetro S indica a camada de saída,  $h$  a camada oculta e  $i, j$  os indicadores. O indicador  $i$  representa os neurônios de saída e o  $j$  os de entrada. O  $i$ -th significa o neurônio de saída da camada escondida e o peso de conexão  $i$ -th de saída e  $j$ -th neurônio da camada escondida anterior.

Para esta etapa foi utilizado o método heurístico, variando a configuração do treinamento dos seguintes parâmetros: taxa de aprendizado, taxa *momentum*, número de amostras de treinamento (*pixels*) e iterações. Posteriormente com a rede treinada, foi realizado a separação das classes e identificadas como soja e não-soja para geração de mapa final classificado.

As performances das configurações da rede neural artificial foram avaliadas com base em erro *Root Mean Square Error* (RMSE), precisão da previsão e erro padrão de previsão (SSE). Além disso, foi utilizado o coeficiente de correlação ( $r$ ) entre a saída e preditos, juntamente com a inclinação e intersecção de modelo de regressão linear. A equação para o RMSE foi calculada pela Equação 3.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{SSE}{n - p}} \quad (3)$$

em que,  $n$  é o número de observações,  $p$  é o número de parâmetros a serem estimados e SSE e MSE são a soma dos erros ao quadrado e o erro quadrático médio, respectivamente.

Neurônios entre camadas adjacentes que definem a estrutura da rede neural (Figura 2), não são totalmente ligados, devido ao fato de que cada uma das saídas é afetada por alguma entrada específica. Por exemplo, a primeira saída (isto é, a  $h_5$  ( $V_{5,y}$ )) da rede neural proposta é uma função de quatro entradas, conforme apresentada na Equação 1. Uma função de

transferência tangente hiperbólica sigmoide com a Equação 4 é aplicada às camadas escondidas e de saída.

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (4)$$

Para a avaliação da qualidade dos mapas temáticos índice de vegetação (CEI), e redes neurais artificiais (RNA), foi feito usando um conjunto totalmente independente dos pontos de amostra. Esta abordagem foi adotada porque permite a avaliação entre todos os processos de classificações.

Para gerar o conjunto independente de amostras, como apoio foi utilizado um aparelho GPS da marca Trimble, modelo GeoExplorer 2008 Series e percorrendo o estado do Paraná coletando coordenadas em que continha plantio da cultura da soja, um total de 172 pontos, conforme detalhe dos pontos em verde da Figura 1. Em relação aos pontos de não-soja, foram coletados por um especialista qualificado por meio da interpretação visual de uma série temporal de imagens MODIS. Estes 346 pontos estavam distribuídos por toda a área e foram gerados aleatoriamente e de forma independente. O tamanho deste conjunto de amostras é considerado satisfatório de acordo com Congalton e Green (2009).

A qualidade da classificação foi avaliada quantitativamente através dos coeficientes de Exatidão Global (EG) e índice Kappa ( $\kappa$ ), ambos extraídos da matriz de confusão. Além disso, foram extraídos os erros e a precisão sob os pontos de vista do produtor e do usuário (Antunes et al., 2012). Essas métricas permitem avaliar melhor a classificação final das áreas de soja. De posse dos valores e sob a hipótese de igualdade entre dois coeficientes de exatidão advindos de classificações diferentes ( $\kappa_1 = \kappa_2$ ).

### 3. Resultados e Discussão

Ao se analisar os dados obtidos pelos métodos utilizados nas estimativas de áreas de soja (RNA e CEI), constatou-se que as classificações apresentaram igualdade perante o teste Z para os parâmetros Kappa ( $\kappa$ ) e Exatidão Global (EG) (Tabela 1). No entanto, a classificação por redes neurais artificiais apresentou valor  $\kappa$  inferior, possivelmente por alguma confusão ocorrida pelo usuário no treinamento dos neurônios, ou seja, nos polígonos selecionados. O valor  $\kappa$  mostra a conformidade da classificação obtida.

A previsão do índice CEI apresentar igualdade pelo teste Z perante o resultado pela RNA era esperado, pois o índice faz parte de um *input layer* da MLP (*Multi-layer perceptron*).

O  $\kappa$ , que avalia a concordância ou discordância entre as classificações realizadas variou entre 0,34 (RNA) e 0,40 (CEI) (Tabela 1), o que segundo classificação proposta por Landis e Koch (1977), é de razoável qualidade ( $\kappa > 0,21$  e  $0,81$ ). Assim, pode-se dizer que os mapas temáticos gerados para a cultura da soja principalmente quando utilizado o CEI, aproximaram-se da realidade de campo.

Para medir a precisão de cada categoria (soja e não-soja), utilizou-se o erro do ponto de vista do produtor e do consumidor (Tabelas 2), por meio da análise dos erros de inclusão e dos erros de omissão presentes nas classificações (Antunes et al., 2012). Ao se analisar os dados dos erros do produtor e consumidor (inclusão e omissão, respectivamente), ressalta-se que o menor valor para o erro de inclusão para a classe soja foi obtido com o índice CEI, com um erro de 0,56, enquanto que para essa mesma classe o erro de omissão ocorrida nesta classificação foi de 0,08. Isso significa que 56% das áreas classificadas como soja 99,92% corresponderam realmente a essa classe (Tabela 2).

A determinação do número de neurônios é o problema mais fundamental em aprendizado de redes neurais, pois não existe na literatura uma regra geral que determine de forma precisa qual deve ser o número de neurônios de uma RNA para a solução de um determinado

problema (Braga et al., 2007). Além disso, praticamente não há trabalhos científicos com a utilização de RNA para estudos de áreas de soja. A Tabela 3 mostra as configurações utilizadas para teste na tentativa de obter a rede que melhor classificasse as imagens e em destaque está à arquitetura que apresentou melhor resultado. A execução da RNA possuiu um tempo de processamento que variava de 10 a 15 horas.

Tabela 1. Matrix de confusão das classificações obtidas das áreas de soja para RNA e CEI.

		Referencia			
		CEI			
		Soja	Não-Soja	$\Sigma$	
Classificação	Soja	75	07	82	$\kappa = 0,40$ EG = 0,70
	Não-Soja	97	167	264	
	$\Sigma$	172	174	346	
		RNA			
Classificação	Soja	67	08	75	$\kappa = 0,34$ EG = 0,67
	Não-Soja	105	166	271	
	$\Sigma$	172	174	346	
		$Z = 0,88$		$p\text{-valor} = 0,1891^{ns}$	

Tabela 2. Erro e precisão do ponto de vista do produtor e consumidor para as classes estudadas.

Método de Análise		Produtor		Consumidor	
		Erro	Precisão	Erro	Precisão
Soja	CEI	0,56	0,44	0,08	0,91
	RNA	0,61	0,39	0,11	0,89
Não-Soja	CEI	0,04	0,96	0,37	0,63
	RNA	0,05	0,95	0,39	0,61

Tabela 3. Configurações das redes neurais artificiais aplicadas no mapeamento da soja.

Configuração	Pixel	Layers Ocultos	Neurônios		Taxa de Aprendizagem	Momentum	Iterações	EMQ		Precisão(%)
			1º Layer	2º Layer				Train.	Teste	
1	1515	1	6	-	0.01	0.55	10000	0.2896	0.2903	83.32
2	1473	1	7	-	0.01	0.50	10000	0.2796	0.2832	85.01
3	1457	1	8	-	0.01	0.55	10000	0.3008	0.2991	82.16
4	1518	2	10	6	0.01	0.50	10000	0.2602	0.2738	83.23
5	1463	2	6	5	0.01	0.55	10000	0.2664	0.2651	85.52

A arquitetura que apresentou melhor resultado foi a configuração 2, uma rede neural artificial com 7 neurônios em uma única camada escondida. Outros parâmetros definidos foram: um conjunto de 1.473 pixels por categoria para o conjunto de teste e treinamento, taxa de aprendizado de 0,01 e fator de momentum de 0,5 para aprimorar a convergência da rede.

A configuração 2 alcançou um valor de precisão de 85,01, ou seja, maior configuração escolhida, porém quando analisado o resultado final da classificação, a arquitetura não teve um bom desempenho na separação das classes soja e não-soja (ou seja, outros usos da terra). Este fato pode ser explicado pela utilização de um número maior de camadas do que o necessário, que leva a rede a ter dificuldades para convergir.

De acordo com a Tabela 3, pode-se relatar que a rede neural teve superior desempenho com uma camada escondida, variando a quantidade de neurônios na camada e o conjunto de pixels. As camadas intermediárias trabalham com estimativas de erro, as quais em maior quantidade levaram a problemas de convergência da rede. Observando os resultados obtidos em maiores áreas de soja, percebeu-se que aumentando o número de pixels do conjunto de

treinamento e teste, a rede produziu melhores resultados com um número de neurônios da primeira camada variando entre 6 e 10. Em áreas menores, a rede que obteve melhores resultados também possuía um número pequeno de neurônios na camada intermediária. O que justifica este resultado é que quanto maior for o número de neurônios na camada, maior será a complexidade da rede e maior será sua abrangência em termos de soluções possíveis (Braga et al., 2007).

A Figura 3 ilustra o progresso do treinamento de uma MLP, tanto no treinamento e erro de teste. Em que mostra o número de padrões aprendidos versus formação de iterações. O número total de padrões aprendidos foi de 10.000. Para o aprendizado da configuração 2 (Tabela 3), os parâmetros foram muito mais conservadores como para a formação dos testes de treinos e erros (Figura 3b). Por menos de 10.000 vezes de iteração de treinamento, o EMQ para dados de teste foi reduzida para menos de 0,50 e estabilizado nesse nível (Tabela 3 e Figura 3).

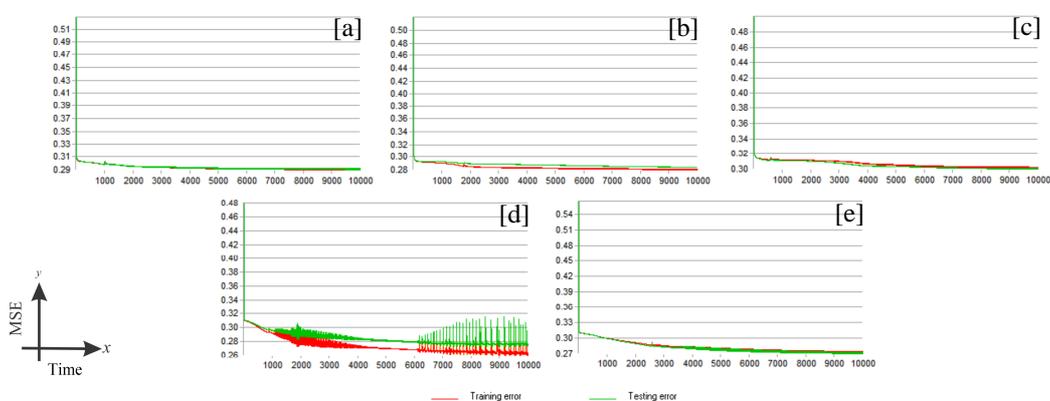


Figura 3. Erro de treinamento e teste para as respectivas configurações (a-1, b-2, c-3, d-4 e e-5) utilizadas nas redes neurais artificiais.

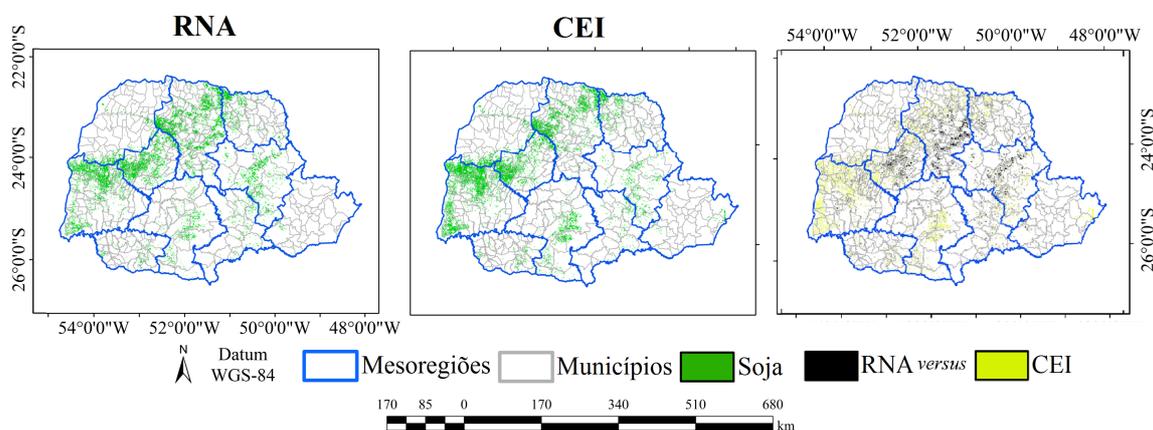


Figura 4. Distribuição espacial de áreas cultivadas com soja no ano-safra 2010/2011 conforme suas respectivas técnicas de classificação e suas discordâncias.

A Figura 4 mostra o mapa de soja classificado por meio de RNA e CEI. Ao observar a Figura 4, pode-se perceber semelhança entre a distribuição espacial da estimativa das áreas de soja na classificação pelo índice CEI e RNA.

Em complemento à análise quantitativa, gerou-se um mapa de discordâncias (Figura 4). Trata-se de um mapa temático contendo os pixels que o classificador RNA rotulou a classe soja diferente daquela atribuída pelo índice CEI. O mapa de discordância apresentou um total de 147,42 *pixels*. Sendo: 36.855,37 hectares, correspondendo a pixels com classificação divergente.

Apesar de a RNA ter em sua entrada o PVI que tem em seu cálculo a coerência de diminuição do efeito do solo, ainda assim há mistura espectral dos *pixels* percebe-se, inspecionando a Figura 4, que as divergências se concentram massivamente região sul do Estado e áreas costeiras, uma vez que, além da mistura espectral inerente desses pixels, há muita reflexão pela areia de praias que fazem com que o índice CEI em seu fatiamento atribua como soja, *pixels* com elevado índice.

#### 4. Conclusões

A RNA fornece um novo método de configuração com auxílio de um analista experiente para automatizar o mapeamento e discriminação de plantações de soja no Brasil. O número de variáveis de entrada da rede não é limitado para o treinamento, apenas alterando a configuração da RNA.

O critério de configuração da RNA que obteve superioridade no mapeamento da cultura da soja foi para o limite de 10.000 iterações ou erro médio quadrático (EMQ) de 0,0001 para a parada do treinamento do número de iterações do algoritmo *backpropagation*, com EMQ de 0,2796 para os dados de treinamento e 0,2832 para os dados de teste.

#### Agradecimentos

Ao Conselho de Desenvolvimento Científico e Tecnológico (CNPq) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão das bolsas de estudos.

#### Referências Bibliográficas

- Andrade, L.N.; Vieira, T.G.C.; Lacerda, W.S.; Volpato, M.M.L.; Davis Junior, C.A. Aplicação de redes neurais artificiais na classificação de áreas cafeeiras em Machado-MG. **Coffee Science**, v.8, n.1, p.78-90, 2013.
- Antunes, J.F.G.; Mercante, E.; Esquerdo, J.C.D.M.; Lamparelli, R.A.; Rocha, J.V. Estimativa de área de soja por classificação de imagens normalizada pela matriz de erros. **Pesquisa Agropecuária Brasileira**, v.47, n.9, p.1288-1294, 2012.
- Braga, A.P.; Carvalho, A.C.P.L.F.; Ludermit, T.B. **Redes neurais artificiais: teoria e aplicações**. 2ed. Rio de Janeiro: LTC, 2007. p.226.
- Congalton, R.G.; Green, K. **Assessing the accuracy of remotely sensed data: Principles and practices**. (2nd Edition). Boca Raton, FL, USA: CRC Press, 2009. p.183.
- Haykin, S. **Redes Neurais: princípios e prática**. Trad. Paulo Martins Engel. 2nd ed. Porto Alegre: Bookman, 2008. p.893.
- Huete, A.R.; Liu, H.Q.; Batchily, K.; Leeuwen, W. Van. A comparison of vegetation indices over a global set of TM images for EOS- MODIS. **Remote Sensing of Environment**, v.59, n.3, p.440- 451, 1997.
- Nanni, M.R.; Demattê, J.A.M. Comportamento da linha do solo obtida por espectrorradiometria laboratorial para diferentes classes de solo. **Revista Brasileira de Ciência do Solo**, v.30, n.6, p.1031-1038, 2006.
- Oide, M.; Ninomiya, S.; Takahashi, N. Perceptron neural network to evaluate soybean plant shape. **Proceedings of 1995 1st IEEE International Conference on Neural Networks**, Perth, Australia, 27-1 November-December 1995. p.560-563.
- Rizzi, R.; Risso, J.; Epiphanyo, R.D.V.; Rudorff, B.F.T.; Formaggio, A.R.; Shimabukuro, Y.E.; Fernandes, S.L. Estimativa da área de soja no Mato Grosso por meio de imagens MODIS. In: Simpósio Brasileiro de Sensoriamento Remoto, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p.387-394.
- Silva Junior, C.A. **Estimativa e discriminação de áreas de soja [Glycine max L.] no estado do Paraná com dados mono e multitemporais do sensor MODIS**. 2014. 181f. Dissertação (Mestrado em Agronomia) – Universidade Estadual de Maringá, Maringá, 2014.