

## Aplicação de redes neurais artificiais na identificação automatizada de coqueiros a partir de uma imagem de alta resolução

Alexandre Gomes de Lima<sup>1</sup>  
Robinson Luís Alves de Souza<sup>1</sup>

<sup>1</sup> Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte - IFRN  
Av. Sen. Salgado Filho, 1559, Tirol - 59015-000 - Natal - RN, Brasil  
{alexandre.lima, robinson.alves}@ifrn.edu.br

**Abstract.** Methods of pattern classification have been applied routinely in processing images obtained by remote sensing. Artificial neural networks are presented as an alternative computational method to traditional parametric classifiers and have been successfully used in remote sensing applications. This paper describes a case study supported by neural networks that aimed to recognize coconut trees present in a high resolution aerial image. Methodology was organized on two steps: image segmentation and recognition of coconut trees, both of which were supported by Radial Basis Function and Growing Neural Gas neural networks. The Success rates achieved, above 80%, reinforce the hypothesis that neural networks are suitable methods for remote sensing applications.

**Palavras-chave:** remote sensing, image processing, computer vision, sensoriamento remoto, processamento de imagens, visão computacional.

### 1. Introdução

Atualmente a tecnologia de sensoriamento remoto se apresenta como uma ferramenta essencial em atividades de análise do uso da terra como mensuração de áreas, planejamento urbano e avaliação de lavouras. No entanto, o grande volume de dados gerados pelos sensores remotos requer a utilização de métodos computacionais que automatizem a interpretação destas informações. Neste contexto, o processamento digital de imagens e a classificação de padrões vêm sendo utilizados com sucesso em uma gama de aplicações de sensoriamento remoto.

Tradicionalmente, classificadores paramétricos são utilizados em aplicações de sensoriamento remoto. No entanto, vários trabalhos foram publicados nos últimos anos descrevendo a utilização de redes neurais artificiais (RNAs) em aplicações de sensoriamento remoto como os descritos por Ji (2000), Ribeiro et al. (2008) e Oliveira et al. (2009).

RNAs são máquinas computacionais de processamento paralelo inspiradas na estrutura neural do cérebro. Dentre as aplicações que podem ser apoiadas por RNAs podemos citar classificação de padrões, filtragem de sinais, controle adaptativo e regressão não linear. Diz-se que as redes neurais são inteligentes devido a sua capacidade de adquirir conhecimento a partir da interação com o ambiente através de um processo de aprendizagem (Haykin 2001). Esta é uma característica bastante interessante das RNAs, pois permite a sua utilização em situações nas quais não estão disponíveis informações antecipadas a respeito dos dados de entrada, como a sua distribuição de probabilidade. Além disso, as redes neurais também conseguem adquirir conhecimento a partir de dados com ruído e generalizar respostas para entradas não presentes na sua fase de aprendizagem.

O paradigma de aprendizagem adotado no treinamento de uma RNA é inerente à sua natureza. Assim, alguns modelos de redes neurais são baseados em aprendizagem supervisionada, como as redes perceptron de múltiplas camadas (MLP), aprendizagem não supervisionada, como as redes SOM e GNG (*Growing Neural Gas*), ou aprendizagem híbrida, como as redes RBF.

Além da geração de mapas temáticos, RNAs podem ser utilizadas em outros tipos de aplicações como a identificação de mudanças ocorridas em uma área ao longo do tempo (Frate et al, 2007) e a identificação de objetos como edificações (Faria, 2004). Neste contexto, este artigo apresenta um estudo de caso que teve como objetivo a identificação e contagem de

coqueiros presentes em uma área de plantação captada por uma fotografia aérea de altíssima resolução. A aplicação foi apoiada por RNAs e gerou resultados com taxas de acerto superiores a 80%.

## 2. Metodologia de Trabalho

O experimento realizado teve como objetivo utilizar um classificador baseado em redes neurais para realizar a contagem automática de coqueiros presentes em uma fotografia aérea ilustrada na Figura 1, a qual exibe parte de um coqueiral localizado no município de São Gonçalo do Amarante/RN. A inspiração para este estudo de caso foi o trabalho descrito por Vibha et al. (2009), o qual utilizou a técnica de *template matching* para reconhecimento de árvores em uma imagem multiespectral QuickBird de altíssima resolução espacial.



Figura 1 – Imagem aérea do estudo de caso. Adaptado de SEMURB (2008).

O processo adotado neste estudo de caso consistiu de duas etapas: segmentação e identificação.

### 2.1 Etapa de segmentação

A etapa de segmentação foi motivada pela segmentação de faces descrita por Gouveia (2010), e teve como objetivo produzir uma imagem que facilitasse a posterior identificação dos coqueiros. A segmentação se resumiu a uma classificação, *pixel a pixel*, da imagem presente na Figura 1, na qual foram consideradas as classes *Coqueiro* e *Outros*. Desta forma, cada *pixel* da Figura 1 foi convertido para a cor preta (classe *Outros*) ou para a cor branca (classe *Coqueiro*). A segmentação foi realizada pelo classificador neural híbrido descrito por Lima (2011). Este classificador se resume a uma rede neural RBF com seleção de parâmetros apoiada por uma rede neural GNG.

Por ter se tratado de uma classificação supervisionada, foram selecionados 110 padrões rotulados com a classe *Coqueiro* e 617 padrões rotulados com a classe *Outros*, totalizando 727 amostras para a fase de treinamento. Cada padrão representou um *pixel* da Figura 1, sendo constituído pelas componentes RGB do respectivo *pixel*. Para validação, foram selecionadas 10 amostras para a classe *Coqueiro* e 28 para a classe *Outros*. O classificador híbrido foi treinado até que atingisse um índice Kappa mínimo de 0,7.

## 2.2 Etapa de identificação

A etapa de identificação teve como objetivo reconhecer os coqueiros presentes na Figura 1. Esta etapa consistiu de uma classificação supervisionada sobre a imagem binária resultante da etapa de segmentação. O mesmo tipo de classificador híbrido utilizado na etapa anterior foi adotado na identificação dos coqueiros.

Na etapa de localização de coqueiros, mais uma vez foram definidas as classes *Coqueiro* e *Outros*. No entanto, cada amostra não representou um pixel isolado, e sim uma janela de 12x12 pixels. Assim, cada padrão foi composto por 144 componentes, no qual cada componente representa o valor de brilho de um pixel na imagem binária. Aqui, o conjunto de treinamento contemplou 9 padrões da classe *Coqueiro* e 10 padrões da classe *Outros*, enquanto que o conjunto de validação foi formado por 6 padrões da classe *Coqueiro* e 6 padrões da classe *Outros*. O classificador foi treinado até atingir um índice Kappa mínimo de 0,75.

A Tabela 1 resume informações das duas etapas envolvidas no estudo de caso.

Tabela 1 – especificação das etapas de segmentação e de identificação.

Etapa	Classificador	Abordagem	Imagem Fonte	Amostras de Treinamento	Amostras de Validação
Segmentação	Neural híbrido	<i>Pixel a pixel</i>	Figura 1	110 ( <i>Coqueiro</i> ) 617 ( <i>Outros</i> )	10 ( <i>Coqueiro</i> ) 28 ( <i>Outros</i> )
Identificação	Neural híbrido	Janela de 12x12 <i>pixels</i>	Figura 2	9 ( <i>Coqueiro</i> ) 10 ( <i>Outros</i> )	6 ( <i>Coqueiro</i> ) 6 ( <i>Outros</i> )

Ainda na etapa de identificação, após o treinamento do classificador, fez-se percorrer uma janela 12x12 ao longo da imagem binária. Cada instância da janela foi apresentada ao classificador para que este categorizasse a janela em uma das classes definidas. A cada identificação da classe *Coqueiro*, foi realizado o registro da posição da janela na imagem.

Os incrementos utilizados para avançar a janela foram de 3 *pixels* no sentido horizontal e de 5 *pixels* no sentido vertical. Uma consequência destes valores de avanço foi a sobreposição de janelas, resultando em múltiplas identificações de um mesmo coqueiro. Como a rede neural gera um sinal de saída (valor entre zero e um) para cada janela de entrada, foi utilizado um algoritmo para considerar apenas a janela com maior sinal de saída.

Ao finalizar a movimentação da janela, foram realizadas a contabilidade de coqueiros identificados e a marcação, na imagem original (Figura 1), das ocorrências encontradas.

A Figura 2 exibe a sequência de passos constituintes da etapa de identificação de coqueiros.

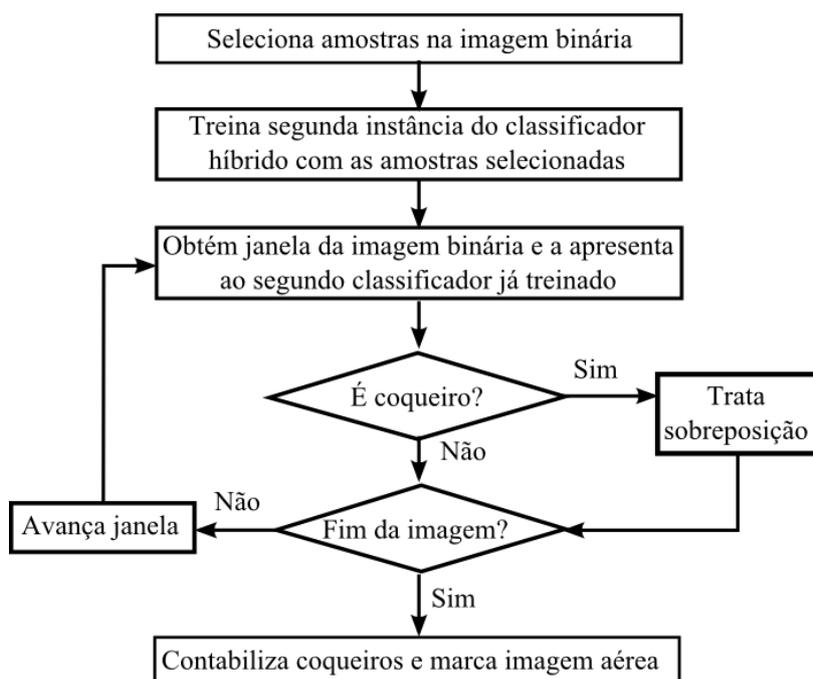


Figura 2 – passos da etapa de identificação de coqueiros.

### 3. Resultados e discussão

A Figura 3 ilustra a imagem binária produzida na etapa de segmentação, enquanto que a Figura 4 exibe a imagem resultante da etapa de identificação, ou seja, a fotografia aérea original com as marcações indicativas dos coqueiros identificados.

A etapa de segmentação foi encerrada após quatro épocas de treinamento do classificador, resultando em uma rede RBF com 14 centros e obtendo um índice Kappa igual 0,70. A Tabela 2 exibe a matriz de confusão obtida pelo classificador da segmentação, já treinado, quando apresentado aos padrões de validação da respectiva etapa.

Tabela 2 – matriz de confusão da etapa de segmentação.

	<b>Outros</b>	<b>Coqueiro</b>	<b>Não-classificado</b>
<b>Outros</b>	0,82	0,04	0,14
<b>Coqueiro</b>	0,10	0,90	0,00

A etapa de identificação foi encerrada após três épocas de treinamento, resultando em uma rede RBF com três centros e obtendo um índice Kappa igual a 0,76. A Tabela 3 exibe a matriz de confusão obtida pelo classificador da identificação, já treinado, quando apresentado aos padrões de validação da respectiva etapa.

Tabela 3 – matriz de confusão da etapa de identificação.

	<b>Outros</b>	<b>Coqueiro</b>	<b>Não-classificado</b>
<b>Outros</b>	0,71	0,00	0,28
<b>Coqueiro</b>	0,00	1,00	0,00

Para a imagem binária, o classificador de identificação acusou a ocorrência de 173 coqueiros, incluindo 9 falso-positivos e 7 coqueiros com ocorrências duplicadas (ver Figura 5). Também foi verificado que 10 coqueiros não foram identificados (ver Figura 5).

A partir do total real de 166 coqueiros identificados por análise visual da fotografia, é possível determinar alguns índices de desempenho. Considerando apenas a quantidade de

coqueiros identificados pelo classificador e a quantidade real, obtém-se uma taxa de acerto de 95,78%.

Outra análise a ser realizada é determinar o erro com base nos falso-positivos, nas ocorrências duplicadas e nas omissões. Desta forma, o erro de inclusão (falso-positivos e ocorrências duplicadas) é de 9,64%, enquanto que o erro de omissão é de 6,03%. Se considerarmos que o erro total é de 15,67% (erro de inclusão mais erro de omissão), a taxa de acerto cai para 84,33%, o que ainda pode ser considerado um bom resultado.

Já a sensibilidade, que é a proporção de verdadeiros positivos, resultou em um índice igual a 0,9458.

Um aspecto importante no desempenho da identificação foi a utilização do algoritmo para evitar as sobreposições. A Figura 6 exibe o resultado da identificação sem o uso deste algoritmo, mostrando as sobreposições geradas para a maioria dos coqueiros. Ao comparar as Figura 5 e 6, é possível verificar que erros de omissão aconteceram mesmo sem a utilização do algoritmo. Adicionalmente, na Figura 5 é possível constatar a ocorrência de sobreposições mesmo com a utilização deste algoritmo.

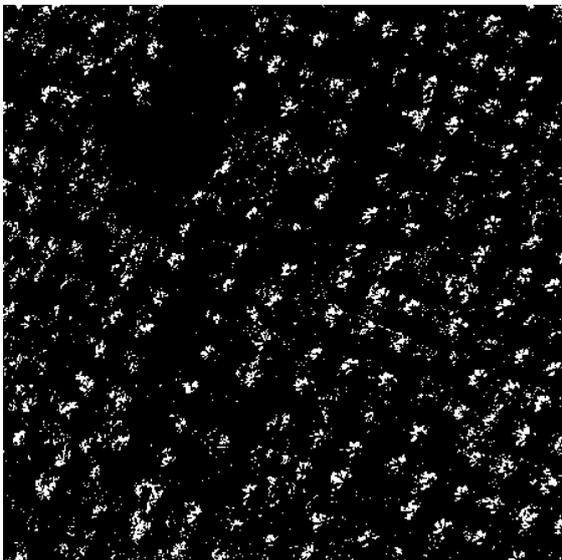


Figura 3 - Imagem binária produzida pelo processo de segmentação

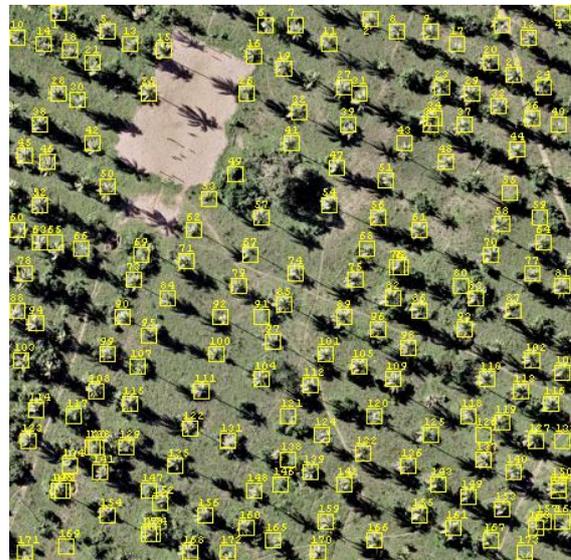


Figura 4 - Fotografia aérea com marcações dos coqueiros localizados.

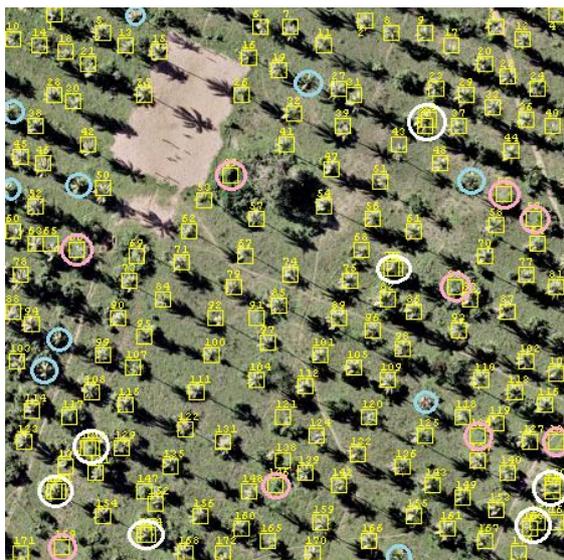


Figura 5 - Indicação dos erros de identificação. Os círculos brancos indicam as sobreposições, os círculos rosa indicam falso-positivos e os círculos azuis mostram os coqueiros não identificados.

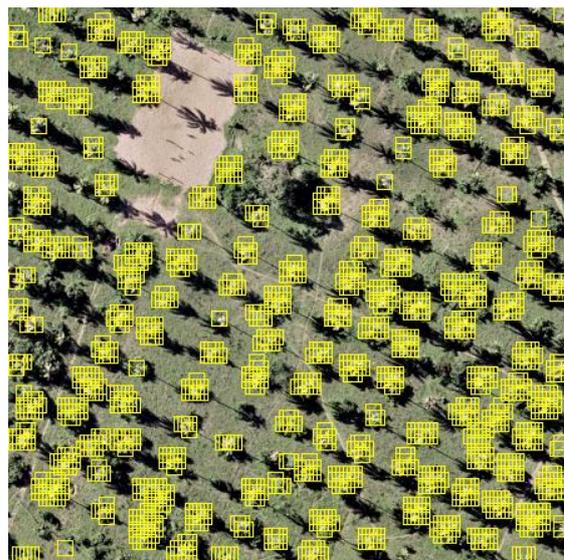


Figura 6 - Imagem resultante da etapa de identificação sem a utilização do algoritmo que trata as sobreposições.

#### 4. Conclusões

Este trabalho verificou a aplicação de redes neurais artificiais em uma aplicação de sensoriamento remoto com o objetivo de detectar ocorrências de coqueiros em uma imagem de alta resolução. As ótimas taxas de acerto obtidas reforçam a viabilidade de uso das RNAs em aplicações de sensoriamento remoto. Vale ainda salientar que não foi necessária a utilização de descritores de forma, descritores de texturas ou de operações de transformação da imagem.

A metodologia em duas etapas de processamento acrescenta flexibilidade à aplicação, possibilitando o uso de diferentes métodos em cada uma das etapas, inclusive de outros métodos de segmentação.

A indisponibilidade de uma imagem multiespectral foi um fator limitante do experimento, retirando a possibilidade de seleção das bandas mais apropriadas para identificação dos alvos, o que provavelmente levaria a melhores resultados.

Os resultados obtidos na utilização do classificador neural híbrido, tanto neste trabalho como em Lima (2011) e em Lima e Guerreiro (2011), reforçam a ideia de que RNAs apresentam-se como um método adequado a aplicações de processamento de imagens obtidas por sensoriamento remoto.

#### Referências Bibliográficas

Faria, M. B. e Centeno, J. A. S. Identificação de edificações presentes em imagem de alta resolução utilizando redes neurais e dados do laser scanner. In: Simpósio de Ciências Geodésicas e Tecnologias da Geoinformação (SIMGEO), 1, 2004, Recife. *Anais...* Recife: 2004, v. 1, p. 1-9.

Frate, F. D.; Pacici F.; Schiavon G.; Solimini C. Use of neural networks for automatic classification from high-resolution images, *IEEE Transactions on Geoscience and Remote Sensing*, v. 45, n. 4, p. 800-809, 2007.

Gouveia, W. R. *Detecção de faces humanas em imagens coloridas utilizando redes neurais artificiais*, 2010. 100 p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade de São Paulo, São Carlos, 2010.

Haykin, S. *Redes Neurais: princípios e práticas*, 2ª ed, Porto Alegre: Bookman, 2011.

Ji, C. Y. Land-use classification of remotely sensed data using Kohonen self-organizing feature map neural networks, **Photogrammetric Engineering Remote Sensing**, v. 66, n. 12, p. 1451-1460, 2000.

Lima, A. G. **Classificador neural híbrido para imagens obtidas por sensoriamento remoto**, 2011. 53p. Dissertação (Mestrado em Engenharia Elétrica e de Computação) – Universidade Federal do Rio Grande do Norte, Natal, 2011.

Lima, A. G. e Guerreiro, A. M. G. Uso das redes neurais de função de base radial e growing neural gas na classificação de imagens de sensoriamento remoto. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 15, 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 7247-7254. DVD, Internet. ISBN 978-85-17-00056-0 (Internet), 978-85-17-00057-7 (DVD). Disponível em: <<http://urlib.net/3ERPFQTRW/39UFN8H>>. Acesso em: 14 nov. 2012.

Oliveira, D. N.; Sousa, B. F. S.; Braga, A. P. S.; Silva, F. A. T. F.; Teixeira, A. S. Aplicação de Mapas de Kohonen em imagem de satélite do semi-árido e comparação com o método da máxima verossimilhança. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 7877-7884. DVD, On-line. ISBN 978-85-17-00044-7. (INPE-15966-PRE/10575). Disponível em: <<http://urlib.net/dpi.inpe.br/sbsr@80/2008/11.17.13.56.38>>. Acesso em: 10 nov. 2012.

Ribeiro, H. M.C.; Almeida A. C.; Rocha B. R. P.; Krusche A. V. Water quality monitoring in large reservoirs using remote sensing and neural networks. **IEEE Latin American Transactions**, v. 6, n. 5, p. 419-423, 2008.

SEMURB, **Fotografias aéreas da cidade de Natal-RN**. DVD-ROM, 2008.

Vibha, L. P.; Shenoy, K. R. D.; Venugopal, L. M. P. Robust technique for segmentation and data counting of trees from remotely sensed data, In: IEEE Proceedings of International Advances Computing Conference (IACC), 2009, Patiala. **Anais...** Patiala: IEEE, 2009. Artigos, p.1437-1442. On-line. ISBN 9781424429271. Disponível em <<http://ieeexplore.ieee.org>>. Acesso em: 16/10/2009.