

Uso das redes neurais de função de base radial e Growing Neural Gas na classificação de imagens de sensoriamento remoto

Alexandre Gomes de Lima¹
Ana Maria Guimarães Guerreiro²

¹ Instituto Federal de Educação, Ciência e Tecnologia do RN - IFRN/DIETINF
Av. Sen. Salgado Filho, 1559 - 59015-000 - Natal - RN, Brasil
alexandre.lima@ifrn.edu.br

² Universidade Federal do Rio Grande do Norte – UFRN/DCA
Caixa Postal 1524 - 59072-970 - Natal - RN, Brasil
anamaria@dca.ufrn.br

Abstract. Several works describe the use of artificial neural networks in remote sensing applications. However, it's relatively scarce the amount of publications about these applications involving the Growing Neural Gas (GNG) networks. This work describes a hybrid neural classifier based on the radial base functions (RBF) and GNG neural networks. The unsupervised learning is performed by GNG network in order to determine centers and number of hidden neurons RBF network. The supervised learning is performed by pseudo inverse matrix algorithm in order to find RBF network's synaptic weights. The proposed classifier doesn't require the number of centers be specified in advance. This number starts in two and is successively increased by GNG network until a desired performance criterion be achieved. The classification of one multispectral ETM/Landsat7 image, bands 1, 2, 3 and 4, involving part of city of Natal-RN is performed for seven ground cover classes. The results achieved by the proposed classifier and maximum likelihood Bayesian classifier are compared through the confusion matrix, hit coefficient, Kappa coefficient and generated images. This set of data shows a slight superiority from proposed classifier. Further this satisfactory result, the neural classifier is important to eliminate the try-and-error procedure usually realized to find RBF neural network's centers.

Palavras-chave: remote sensing, image processing, artificial neural network, growing neural gas, sensoriamento remoto, processamento de imagens, rede neural artificial.

1. Introdução

Métodos de classificação de padrões podem ser aplicados em imagens obtidas por sensoriamento remoto (SR) em atividades como mensuração de áreas e geração de mapas temáticos. Um exemplo é o trabalho apresentado por Étore et al. (2009) que utiliza os métodos de classificação bayseana por máxima verossimilhança (Maxver) e classificador não-supervisionado Iseog para mapear a vegetação do cerrado em uma imagem de SR.

Redes neurais artificiais (RNAs) constituem um conjunto de métodos que vêm sendo utilizados com sucesso em aplicações de classificação de padrões e processamento de imagens obtidas por sensoriamento remoto. Ji (2000) apresenta a classificação de uma imagem TM/Landsat com quatro bandas espectrais com a rede neural conhecida como mapa auto-organizável de Kohonen (SOM), obtendo resultados melhores do que os conseguidos pelo classificador Maxver. Del Frate et al. (2007) obtiveram resultados satisfatórios ao utilizar uma rede neural perceptron de múltiplas camadas (MLP) para realizar a classificação de imagens de SR de altíssima resolução espacial (1~2 metros) e detectar mudanças como o surgimento de novas edificações em imagens de datas distintas. Nishida e Bastos (1998) apresentam a classificação obtida por um classificador híbrido baseado nas redes neurais com função de base radial (RBF) e mapa auto-organizável de Kohonen.

Apesar da grande quantidade de trabalhos descrevendo o uso das RNAs em sensoriamento remoto, ainda é relativamente escassa a quantidade de publicações de trabalhos que utilizem a rede neural *Growing Neural Gas* (GNG) proposta por Fritzke (1995). Com isto em mente, este texto apresenta os resultados obtidos ao utilizar um classificador híbrido baseado nas redes RBF e GNG. O treinamento do classificador é semelhante ao apresentado

por Nishida e Bastos (1998), diferenciando-se principalmente na determinação da quantidade de centros da rede RBF. Os resultados obtidos pelo classificador neural são comparados com os obtidos por um classificador bayesiano por máxima verossimilhança (Maxver).

2. Redes Neurais Artificiais

As redes neurais artificiais são máquinas computacionais de processamento paralelo cujo modelo é inspirado na estrutura neural do cérebro. Entre os tipos de aplicações passíveis de utilização das redes neurais 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 de seu ambiente através de um processo de aprendizagem (Haykin 2001). Esta característica torna as redes neurais interessantes, pois elimina a necessidade de conhecimentos a priori, como a distribuição de probabilidade dos dados em questão. Adicionalmente, as redes neurais também conseguem adquirir conhecimento a partir de dados com ruído e generalizar entrada de dados não presentes na sua fase de aprendizagem.

A unidade básica de processamento de uma rede neural artificial é o neurônio, o qual se comunica com outros neurônios através de ligações denominadas conexões sinápticas. Cada conexão geralmente possui um valor numérico chamado peso sináptico, responsável por armazenar o conhecimento da rede neural. Desta forma, um processo ou algoritmo de aprendizagem tem como função modificar os pesos sinápticos de rede de forma ordenada para alcançar um objetivo de projeto desejado (Haykin 2001).

Em relação ao paradigma de aprendizagem, as RNAs podem ser classificadas em dois grupos: aprendizagem supervisionada e não-supervisionada. Na aprendizagem supervisionada os padrões de treinamento são rotulados com a classe à qual pertencem. Este rótulo é utilizado pelo algoritmo de treinamento para calcular o erro da rede em relação ao padrão apresentado e então realizar a correção, fazendo com que a rede neural adquira conhecimento. Na aprendizagem não-supervisionada, os padrões de treinamento não recebem rótulos. A rede realiza um *clustering* de dados, reunindo padrões semelhantes em grupos. Redes auto-organizáveis seguem o paradigma de aprendizagem não-supervisionado e seu treinamento geralmente se dá com base em um processo de aprendizagem competitiva (Haykin, 2001).

Uma rede RBF organiza seus neurônios em três camadas: camada de entrada, camada oculta e camada de saída. Na camada de entrada, os neurônios não realizam qualquer computação, servindo apenas como unidades sensoriais de captação dos dados de entrada. Cada neurônio da camada oculta é totalmente conectado aos neurônios de entrada e de saída. As conexões entre os neurônios ocultos e os neurônios de entrada não possuem pesos sinápticos. O conhecimento de cada neurônio oculto é determinado pelo seu centro – um vetor com dimensão igual ao dos vetores de entrada. Uma das formas de determinar os centros de uma rede RBF é realizar um *clustering* não-supervisionado a partir dos vetores de treinamento. A capacidade da rede RBF em separar padrões de forma correta é determinada pela quantidade de neurônios ocultos. Infelizmente não há um método que determine de forma direta a quantidade mínima de neurônios ocultos necessários a uma rede RBF. Essa quantidade deve ser determinada experimentalmente. Em problemas de classificação de padrões, a camada de saída normalmente possui um neurônio para cada classe em questão. As conexões entre os neurônios de saída e os neurônios ocultos possuem pesos sinápticos que podem ser determinados iterativamente pela regra delta de correção de erro, ou ser calculados de forma direta pelo método da matriz pseudo-inversa. Estes dois últimos métodos são baseados em aprendizagem supervisionada, ou seja, necessitam de padrões de treinamento rotulados.

A rede GNG é uma rede auto-organizável (i.e., não supervisionada) a seguinte estrutura: uma camada de entrada e uma camada de saída. A camada de entrada não realiza alguma

computação, servindo apenas como meio de entrada de dados. A camada de saída é formada por neurônios totalmente conectados aos neurônios de entrada. Cada neurônio de saída representa um *cluster* (agrupamento) de dados. Ao apresentar um padrão de entrada à rede, apenas um neurônio da camada de saída é ativado, indicando a que *cluster* o padrão pertence. Provavelmente a característica mais marcante da rede GNG é quantidade de neurônios da camada de saída, a qual aumenta à medida que os padrões são apresentados durante a fase de treinamento. O algoritmo de treinamento (Fritzke, 1995) sempre inicia a rede com dois neurônios e acrescenta novos neurônios assim que o ciclo de iteração atinge o múltiplo de um parâmetro λ . Cada neurônio possui um valor de erro que é calculado com base nos padrões de entrada. Um novo neurônio é inserido na vizinhança do neurônio com maior erro, fazendo com que a rede contemple todas as áreas do espaço de entrada. Eventualmente, neurônios também podem ser excluídos da rede. Estas características permitem que a rede cresça até que um critério de desempenho seja atingido, como uma quantidade máxima de neurônios ou um percentual de padrões classificados corretamente.

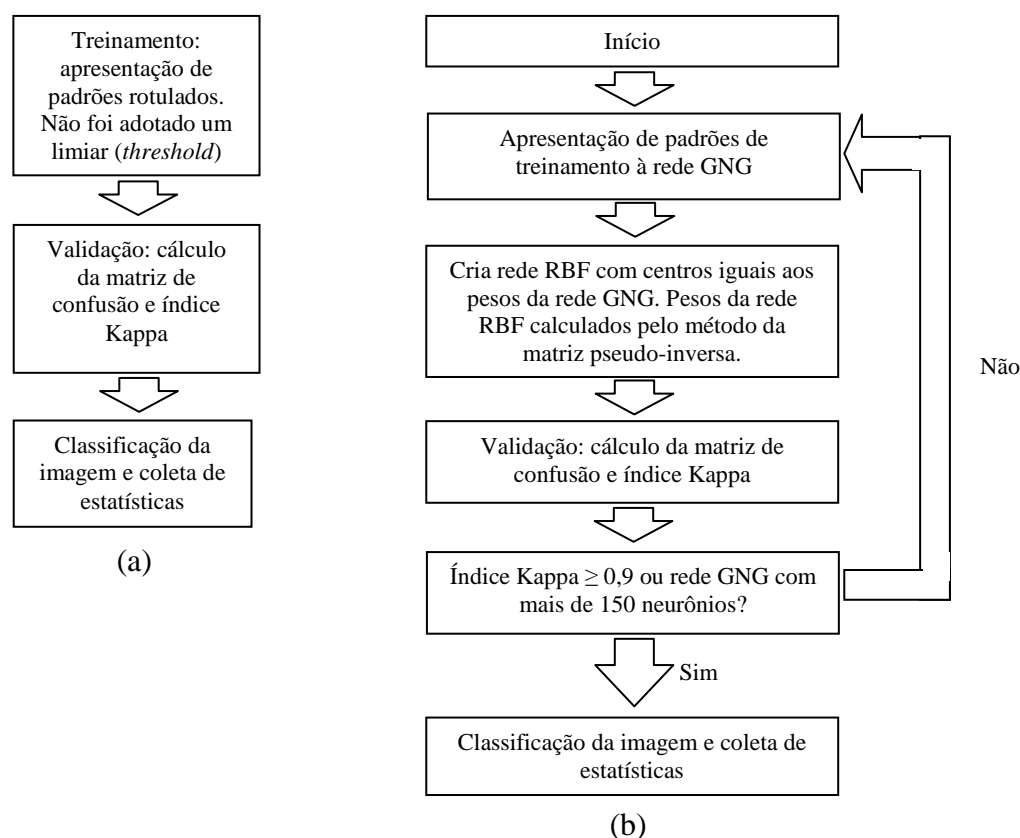


Figura 1 - processos adotados para o classificador Maxver (a) e o classificador neural (b).

2. Metodologia de Trabalho

No experimento foi utilizada um recorte de uma imagem multiespectral ETM/Landsat7, bandas 1, 2, 3 e 4, gerada em 4 de agosto de 2001, compreendendo parte da cidade de Natal/RN e adjacências. A Figura 3 exibe uma composição falsa-cor da imagem utilizada que ilustra as áreas das quais foram extraídos os padrões de treinamento (527 vetores) e validação (513 vetores).

Os vetores de validação (verdade de campo) e de treinamento foram selecionados pelos autores com base no seu conhecimento da área em questão.

Foram definidas as seguintes classes de uso do solo:

- **Vegetação** (verde) – inclui qualquer tipo de vegetação, das quais as mais abundantes na imagem são a vegetação típica das dunas e a vegetação de mangue presente no rio Potengi.
- **Água** (azul) – inclui as massas de água do rio Potengi e do oceano atlântico.
- **Nuvens** (branco) – formação de nuvens presentes na imagem.
- **Terra nua** (laranja) – áreas sem cobertura vegetal, incluindo dunas e praias. Não inclui as áreas de mangue sem vegetação.
- **Sombra** (preto) – sombra das nuvens presentes na imagem.
- **Ocupação urbana** (cinza) – construções, vias e rodovias.
- **Mangue descoberto** (vermelho) – região de mangue sem cobertura vegetal.

O experimento contemplou duas classificações, uma com o classificador Maxver e outra com o classificador neural. Foram utilizados os mesmos padrões de treinamento e de validação para os dois classificadores, sendo que todos os padrões foram normalizados para o intervalo [-1, 1].

A Figura 1.a ilustra o processo adotado para o classificador Maxver.

A rede RBF passou por um treinamento híbrido. Os centros e a quantidade de neurônios ocultos foram determinados de maneira não-supervisionada pela rede GNG, a qual foi configurada para adicionar um novo centro a cada 131 padrões apresentados. Este valor foi obtido dividindo a quantidade de padrões de treinamento por quatro. Os pesos sinápticos foram determinados pelo método da pseudo-inversa (Haykin, 2001) a partir dos vetores de treinamento. A Figura 1.b ilustra o processo adotado para o classificador neural, o qual foi inspirado no modelo de rede RBF incremental proposto por Fritzke (1995). Como critério de parada do treinamento foi utilizado um índice Kappa com valor mínimo igual a 0,9 ou quantidade máxima de centros maior ou igual a 150.

3. Resultados e Discussão

As Tabelas 1 e 2 apresentam, respectivamente, as matrizes de confusão resultantes da validação do classificador Maxver e do classificador neural. Os dados mostram que o classificador neural obteve um desempenho de classificação inferior ao classificador Maxver apenas para a classe *Mangue descoberto* e um desempenho superior para as classes *Vegetação*, *Ocupação urbana*, *Sombra* e *Nuvens*. Para as demais classes os dois métodos obtiveram o mesmo desempenho. Ambos classificadores apresentaram maior erro de classificação para a classe *Sombra* (respectivamente 46,43% e 39,29%). Isto se deve principalmente pela proximidade espectral da classe *Sombra* e de amostras da classe *Água* provenientes de áreas do curso do rio Potengi.

Tabela 1 - matriz de confusão de validação para o classificador Maxver.

	Mangue descoberto	Água	Vegetação	Ocupação urbana	Terra nua	Sombra	Nuvens	Total
Mangue descoberto	41	9	0	0	0	0	0	50
Água	0	91	0	0	0	0	0	91
Vegetação	0	0	180	0	2	0	0	182
Ocupação urbana	0	0	0	32	7	0	0	39
Terra nua	0	0	0	9	37	0	0	46
Sombra	1	8	0	0	4	15	0	28
Nuvens	0	0	0	0	11	0	66	77
Total	42	108	180	41	61	15	66	513

Tabela 2 - matriz de confusão de validação para classificador neural.

	Mangue descoberto	Água	Vegetação	Ocupação urbana	Terra nua	Sombra	Nuvens	Total
Mangue descoberto	37	13	0	0	0	0	0	50
Água	0	91	0	0	0	0	0	91
Vegetação	0	0	182	0	0	0	0	182
Ocupação urbana	0	0	0	38	1	0	0	39
Terra nua	0	0	0	9	37	0	0	46
Sombra	4	7	0	0	0	17	0	28
Nuvens	0	0	0	0	1	0	76	77
Total	41	111	182	47	39	17	76	513

A Figura 4 ilustra o resultado final de classificação da imagem pelos dois métodos.

Por análise visual é possível constatar que o classificador Maxver valorizou de forma acentuada a classe *Terra nua* em grande parte da imagem, mesmo em áreas urbanizadas. A exceção ficou por conta das áreas com intenso grau de urbanização composta principalmente por prédios e edifícios. Este fato ficou um pouco evidente na matriz de confusão do classificador (Tabela 1).

Diferentemente, o classificador neural apresentou uma tendência de valorizar a classe *Ocupação urbana*, atribuindo-lhe algumas áreas sem vegetação, as quais deveriam ser contempladas na classe *Terra nua*. Este fato também fica ligeiramente evidente na matriz de confusão (Tabela 2). Adicionalmente, é possível verificar que o classificador neural também classificou, erroneamente, áreas limítrofes entre dunas e vegetação e algumas pequenas regiões como *Mangue descoberto*. Este é um aspecto que não pode ser verificado através da respectiva matriz de confusão.




Figura 2 - evolução dos índices de desempenho do classificador neural em relação a quantidade de centros da rede RBF.

Na Tabela 3 constam os índices de acerto e índices Kappa (Richards e Jia, 2006) obtidos por cada método, o que demonstra um desempenho levemente superior do classificador neural. Para este último, os índices presentes na Tabela 3 referem-se aos obtidos na última iteração do processo de treinamento.

O gráfico da Figura 2 ilustra a evolução do desempenho do classificador neural na medida em que novos centros foram sendo adicionados a cada iteração. O treinamento do classificador neural foi encerrado após seis iterações, o que resultou em uma rede RBF com 26 centros.

Tabela 3 - índices de desempenho obtidos pelo classificador Maxver e a rede RBF.

Classificador	Índice de acerto	Índice Kappa
Maxver	0,90	0,87
Rede neural RBF	0,93	0,91


4. Conclusões

Os resultados obtidos mostram o potencial do classificador neural proposto, o que não é de surpreender visto que a classificação é realizada por uma rede neural RBF. A grande capacidade deste tipo de rede neural em separar padrões é um fato reconhecido na literatura, apresentando-se como uma alternativa viável às tradicionais redes perceptron de múltiplas camadas (Haykin, 2001). Uma característica negativa destes dois tipos de redes é a falta de um enunciado teórico que determine a quantidade de neurônios ocultos, fazendo com que esta tenha que ser descoberta experimentalmente. Este fato é relatado por Nishida e Bastos (1998), cujo experimento consistiu de um processo de tentativa e erro para determinar a quantidade de centros necessários à rede RBF. Assim, os autores acreditam que o classificador neural proposto é relevante, pois o mesmo evita a determinação antecipada de centros da rede. Essa característica colabora na diminuição de tentativas de se alcançar resultados satisfatórios, favorecendo a aplicação de classificar uma imagem.

Referências Bibliográficas

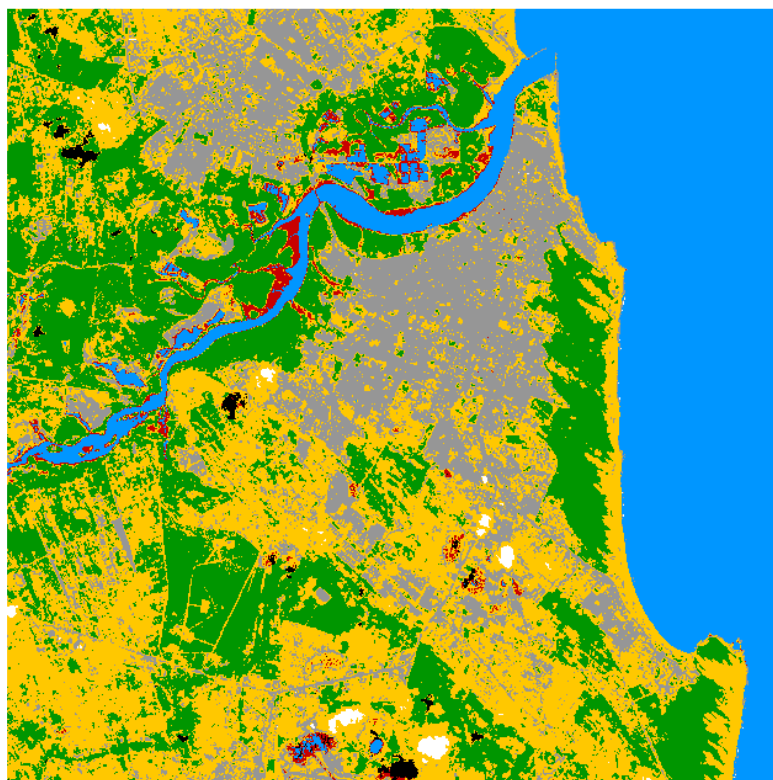
- Del Frate, Fabio; Pacifici, Fabio; Schiavon, Giovanni; Solimini, Chiara. Use of neural networks for automatic classification from high-resolution images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 4, p. 800-809, 2007.
- Étore, F. R.; Povh, F. P.; Saboya, L. M. F.; Vilela, M. F. Uso de classificadores para o mapeamento da vegetação nativa do cerrado. In: Simpósio Brasileiro de Sensoriamento Remoto, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 4279-4286. DVD, On-line. ISBN 978-85-17-00044-7. (INPE-15962-PRE/10571). Disponível em: <<http://urlib.net/dpi.inpe.br/sbsr@80/2008/11.14.00.00>>. Acesso em: 05 jul. 2010.
- Fritzke, Bernd. Fast learning with incremental RBF Networks. **Neural Processing Letters**, v. 1, n. 1, p. 2-5, 1994.
- Fritzke, Bernd. A growing neural gas network learns topologies. **Advances in Neural Information Processing Systems** 7, p. 625-632, 1995.
- Haykin, Simon. **Redes neurais: princípios e práticas**. 2ª ed. Porto Alegre: Bookman, 2001. 900p.
- INPE. Catálogo de Imagens. Disponível em <<http://www.dgi.inpe.br/CDSR>>. Acesso em: 03 de maio de 2010.
- 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.
- Nishida, Waleska; Bastos, Lia C. Classificação de imagens de sensoriamento remoto utilizando uma rede neural artificial com função de base radial. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 9. (SBSR), 1998, Santos. **Anais...** São José dos Campos: INPE, 1998. p. 1315-1326. CD-ROM. ISBN 85-17-00015-3. (INPE-6909-PRE/2875). Disponível em: <<http://urlib.net/sid.inpe.br/deise/1999/02.09.08.49>>. Acesso em: 25 ago. 2010.

Richards, John A. e Jia, Xiuping. **Remote Sense Digital Image Analysis: an Introduction**. 4ª ed. Springer, 2006.




CLASSE	TREINAMENTO	VALIDAÇÃO
Terra_Nua		
Água		
Mangue_descoberto		
Ocupação_urbana		
Sombra		
Vegetação		
Nuvens		

Figura 3 - composição falsa-cor da imagem utilizada, formada pelas bandas 1(B), 2(G) e 4(R).



(a)



(b)

Figura 4 - imagens resultantes da classificação pelo algoritmo Maxver (a) e rede RBF (b).