

# **Classificação de Imagens de Sensoriamento Remoto Utilizando uma Rede Neural Artificial com Função de Base Radial**

WALESKA NISHIDA, MSC. <sup>1</sup>

LIA C. BASTOS, DRA. <sup>1,2</sup>

<sup>1</sup> Universidade Federal de Santa Catarina - UFSC  
Programa de Pós-Graduação em Engenharia de Produção e Sistemas  
Caixa Postal 476 - CEP:88010/970 - Florianópolis, SC  
waleska@eps.ufsc.br  
lia@ecv.ufsc.br

<sup>2</sup> Universidade Federal de Santa Catarina - UFSC  
Departamento de Engenharia Civil  
Caixa Postal 476 - CEP:88010/970 - Florianópolis, SC

**Abstract:** This work presents a hybrid classifier for multispectral images using Radial Basis Function networks (RBF). A Kohonen Self-Organizing-Map is used in substitution to the k-means algorithm in unsupervised stage of training. The algorithm of the Pseudo-inverse is used for the determination of the weights of the supervised stage. The architecture proposal reduces the time required for processing. Also, it presents satisfactory results with small training samples. A practical application is accomplished and the results obtained between the classifier of Maximum Likelihood and the proposed hybrid classifier are compared.

**Keywords:** Artificial Neural Network, Classification of Image, Remote Sensing

## 1 Introdução

Dados obtidos por sensoriamento remoto tem sido utilizados, por exemplo, no gerenciamento de recursos renováveis, na classificação e avaliação de recursos terrestres, no mapeamento de uso do solo, no monitoramento de áreas de vegetação e plantações. Entretanto, os dados originais necessitam de tratamento a fim de transformá-los em informações utilizáveis.

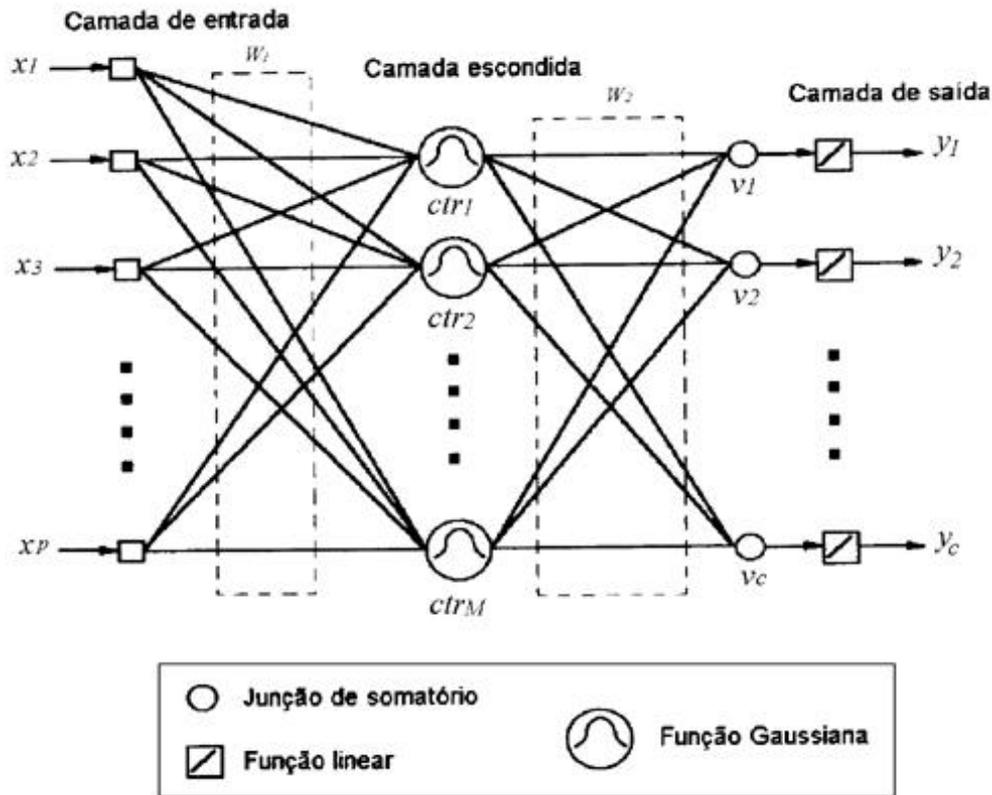
A técnica de classificação de imagens é uma das mais utilizadas em sensoriamento remoto. O objetivo da classificação é particionar a imagem em classes definidas pelo usuário. Diversos métodos de classificação tem sido adotados, como por exemplo, Distância Euclidiana, Máxima Verossimilhança, Método do Paralelepípedo.

No processo de classificação, as maiores deficiências estão associadas a resolução do sensor e ao estabelecimento da regra de decisão adotada para designar os pixels à classe. O primeiro conjunto de deficiências está diretamente relacionado com a aquisição dos dados. O segundo conjunto é afetado pela estrutura, premissas e hipóteses utilizadas no desenvolvimento do método de classificação a ser empregado e diversos trabalhos tem sido produzidos com o intuito de sanar essas deficiências. O uso de tecnologias baseadas em conceitos de Inteligência Artificial (IA) têm se mostrado uma alternativa promissora devido ao seu caráter inovador de análise dos dados. Entre as técnicas de IA, as Redes Neurais Artificiais (RNAs) têm sido utilizadas, com frequência, em problemas de classificação de imagens de sensoriamento remoto (Benediktsson, Swain e Ersoy (1990); Hepner, *et all* (1990); Yoshida e Omatu (1994); Kushadorno *et all* (1994); Binaghi e Rampini (1993); Schlüzen *et all* (1993); Machado *et all* (1993); Chakrabarti, Bindal e Theagarajan (1995); Hara *et all* (1994) e Foody, Mcculloch e Yates (1995)).

Um método comumente utilizado na classificação de imagens de sensoriamento remoto é o da Máxima Verossimilhança. Neste método admite-se que as classes de uso do solo seguem uma distribuição normal multivariada e a designação de um pixel a uma classe é feita de forma probabilística com o arbítrio de um limiar. O uso de RNAs favorece o processo de classificação uma vez que nenhuma forma de distribuição de probabilidade é assumida para o conjunto de dados. Neste trabalho, um classificador híbrido, treinado em duas etapas distintas, utilizando uma Rede Neural com Função de Base Radial, ou RBF, de *Radial Basis Function*, é apresentado. A fim de aprimorar a performance deste classificador, é proposta a utilização de um Mapa Auto-Organizável de Kohonen na etapa de treinamento não supervisionado. Os resultados obtidos pela RNA e por um classificador de Máxima Verossimilhança são comparados com base na matriz de confusão gerada através da cross-tabulação entre as imagens classificadas.

## 2 Rede Neural com Função de Base Radial (RBF)

A determinação de uma função de base radial usada como função de transferência, aplicada aos neurônios escondidos de uma RBF, é o fator primordialmente inovador desta arquitetura de RNA, ilustrada na **Figura 1**. A utilização de uma RBF favorece o processo de classificação, uma vez que nenhuma forma de distribuição de probabilidade é assumida para o conjunto de dados e a designação de um pixel a uma classe é realizada através da consideração, simultânea, dos efeitos de todas as bases radiais que identificam as classes sob estudo.



**Figura 1** - Arquitetura básica de uma RBF (Todesco, 1994).

- a primeira camada é constituída por  $p$  entradas ( $x_i, i = 1, \dots, p$ );
- a segunda, por  $M$  neurônios escondidos associados a  $M$  centros,  $ctr_j$  ( $j = 1, \dots, M$ ), e
- a terceira, uma camada constituída por  $c$  neurônios de saída  $v_k$  ( $k=1, \dots, c$ ).

As funções de base radial (funções de transferência da segunda camada) aplicadas aos  $M$  centros,  $ctr_j$ , são normalmente, funções Gaussianas (Hush e Horn, 1993), cujos resultados alimentam a camada de  $c$  neurônios de saída.

Segundo Bishop (1995), a função Gaussiana, não normalizada, calculada para cada uma das  $n$  entradas, pode ser obtida por:

$$j(x_{jn}) = \exp\left(-\frac{\|x_{jn} - ctr_j\|^2}{2s_j^2}\right) \quad (1)$$

onde:  $x_{jn}$  -  $n$ -ésimo vetor de entrada  $p$ -dimensional que alimenta o neurônio  $j$ , com  $n=1, \dots, N$ ;

$ctr_j$  - vetor correspondente ao  $j$ -ésimo centro  $p$ -dimensional, definido no período de treinamento, com  $j = 1, 2, \dots, M$  e

$s_j^2$  - variância presente neste  $j$ -ésimo centro (o desvio padrão define o *campo receptivo* de cada centro; a Gaussiana só apresentará resultados significativos para entradas inclusas neste campo receptivo).

A camada de saída em uma RBF tem como principal função reduzir a dimensionalidade de classes existentes na camada escondida. A partir dessa característica, a RBF possibilita que pixels representando uma determinada classe mas que apresentem variações nos níveis de cinza possam ser classificadas corretamente. A função de transferência normalmente utilizada na camada de saída é a função identidade. A utilização dessa função é muito importante uma vez que permite obtermos os pesos de forma direta (Bishop, 1995).

O treinamento de uma RBF é híbrido e ocorre em duas etapas. Na primeira etapa, os pesos são treinados de forma não supervisionada e na segunda, os pesos são obtidos através de um processo supervisionado. De forma geral, o aprendizado dos pesos na primeira etapa exige grande esforço computacional devido ao elevado número de operações requeridas.

### **3 RBF com Utilização de Mapas Auto-Organizáveis de Kohonen**

A RBF utilizada neste trabalho apresenta a mesma arquitetura ilustrada na **Figura 1**. Os dados de entrada da rede (1ª camada) são vetores de níveis de cinza  $x_i$ , com  $i$  variando de 1 até o número de bandas. Ou seja, cada elemento do vetor de entrada representa o nível de cinza de um pixel em uma banda. O número de neurônios na camada intermediária foi definido na fase de treinamento não supervisionado, a partir de um processo de tentativa e erro. A camada de saída foi definida de acordo com as classes de interesse a serem identificadas na imagem. Cada neurônio representa uma classe de uso do solo.

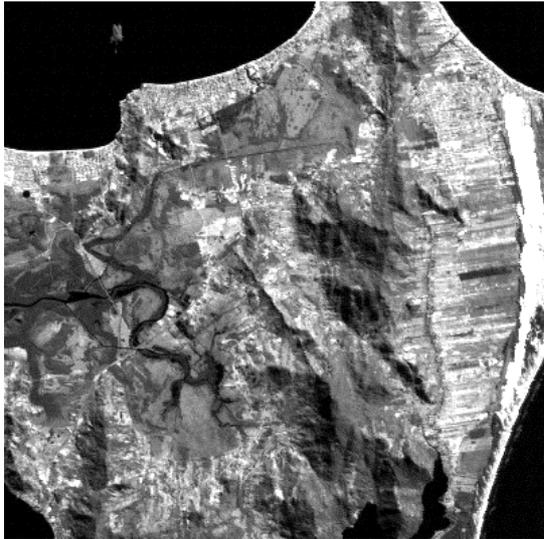
O treinamento da rede foi realizado em duas etapas. Na primeira, os pesos que unem as entradas aos neurônios da segunda camada, foram treinados utilizando-se o algoritmo de Kohonen (Haykin, 1994) visando acelerar o processo de convergência. Na segunda etapa, foi utilizado o algoritmo da Pseudo-inversa (Bishop, 1995) para a determinação dos pesos restantes. Os dados utilizados na segunda etapa de treinamento foram obtidos a partir de amostras coletadas sobre a imagem.

Para inicialização dos pesos da rede, utilizou-se pixels de cada classe. Um conjunto de teste, cujo tamanho corresponde a aproximadamente 10% do tamanho do conjunto de treinamento, foi utilizado para verificar a performance da RBF.

### **4 Aplicação Prática**

Duas imagens multiespectrais foram utilizadas para avaliar a performance da RBF. A primeira referente à região de Florianópolis, Santa Catarina, datada de maio de 1995 (órbita/ponto de 220/079), constituída pelas bandas 1, 2 e 3. A segunda é referente à região de São Francisco do Sul (órbita/ponto de 220/078), também em Santa Catarina, constituída pelas bandas 4, 5 e 7.

A **Figura 2**, ilustra as áreas selecionadas para classificação.



(a)



(b)

**Figura 2 - (a)** Área selecionada para classificação na imagem de Florianópolis (401x401 pixels). **(b)** Área selecionada para classificação na imagem de São Francisco do Sul (391x441).

Os dados utilizados para a classificação dessas imagens encontram-se sumarizados na **Tabela 1**.

**Tabela1** - Dados utilizados pela RBF.

Imagem	Entradas	Conjunto de Treinamento	Conjunto de Teste
Florianópolis	160.801 vetores	23.900 vetores	3.135 vetores
São Francisco do Sul	172.431 vetores	21.519 vetores	3.720 vetores

As classes de uso do solo identificadas na imagem de Florianópolis foram obtidas com base em fotografias aéreas em escala 1:25.000 e 1:8.000, de 1994. Visitas a campo e conhecimento da região complementaram o processo de identificação dessas classes, descritas como:

- |                                |                     |
|--------------------------------|---------------------|
| 1 - Vegetação Rasteira;        | 4 - Areia;          |
| 2 - Ocupação Urbana;           | 5 - Água e          |
| 3 - Vegetação Alta com Sombra; | 6 - Vegetação Alta. |

Para a imagem de São Francisco do Sul, as nove classes identificadas foram baseadas em trabalhos de campo e conhecimento da região e são descritas a seguir:

- |                                |                      |
|--------------------------------|----------------------|
| 1 - Vegetação Rasteira;        | 6 - Vegetação Alta;  |
| 2 - Mangue;                    | 7 - Rocha;           |
| 3 - Solo Úmido;                | 8 - Areia e          |
| 4 - Vegetação Alta com Sombra; | 9 - Ocupação Urbana. |
| 5 - Água;                      |                      |

#### 4.1 Resultados Obtidos

As arquiteturas de rede com melhores desempenhos para as imagens de Florianópolis e São Francisco do Sul são apresentadas na **Tabela 2**.

**Tabela 2** - Arquiteturas da RBF que obtiveram melhores desempenhos para as regiões de Florianópolis e São Francisco do Sul

Região	Número de Entradas	Número de Centros	Camada de Saída
Florianópolis	3	22	6
São Francisco do Sul	3	43	9

Os valores percentuais de acerto para os conjuntos de testes, bem como para os índices Kappa, obtidos durante o processo de determinação do número de centros, encontram-se na **Tabela 3**. Os índices Kappa foram determinados segundo Gong e Howarth (1992).

**Tabela 3** - Resultados obtidos através das classificações pela RBF

Região	Nº de centros	Acerto (%)	Índice Kappa
Florianópolis	22	89.40	0.8687
São Francisco do Sul	43	84.71	0.8084

Para a verificação do desempenho do classificador neural híbrido, uma comparação com o classificador de máxima verossimilhança foi realizada. Uma vez que a extração das amostras de treinamento em qualquer processo de classificação supervisionado é essencial no processo de classificação, diferentes conjuntos de treinamento foram testados. A redução do conjunto de treinamento foi o principal objetivo da análise, pois amostras menores tendem a facilitar o trabalho do analista e diminuir os erros de amostragem.

A **Figura 3** apresenta os resultados da classificação obtidos pela RBF e pela Máxima Verossimilhança, para a imagem de Florianópolis, utilizando um conjunto de treinamento composto por 3.135 pixels. Este conjunto de treinamento representa 1.95% do tamanho total da imagem a ser classificada.

Analisando a **Figura 3** verifica-se um melhor desempenho da RBF em relação ao classificador de Máxima Verossimilhança. Esta superioridade pode ser observada principalmente nas classes Areia e Água. O resultado da classificação pela Máxima Verossimilhança apresenta pixels da classe Água designados às classes Areia e Vegetação Alta com Sombra.

A matriz de confusão entre a classificação pela RBF e a classificação pela Máxima Verossimilhança, para a imagem de Florianópolis, é descrita a seguir, na **Tabela 4**.

**Tabela 4.** Matriz de confusão entre a RBF (linhas) e a Máxima Verossimilhança (Colunas) para Florianópolis.

	1	2	3	4	5	6	Total
1	33988	4656	230	1	0	1057	39932
2	931	27155	577	1932	0	28	30623
3	763	395	21859	3088	0	3882	29987
4	0	343	4	4128	0	0	4475
5	0	0	697	298	23018	0	24013
6	2095	12	4175	24	0	25465	31771
Total	37777	32561	27542	9471	23018	30432	160801

Índice Kappa de Concordância = 0.8068

O mesmo processo utilizado na classificação da imagem de Florianópolis, foi utilizado para a classificação da imagem de São Francisco do Sul. O conjunto de treinamento utilizado nas classificações pela RBF e pela Máxima Verossimilhança constitui-se de 3.720 pixels (2.15% do tamanho da imagem a ser classificada).

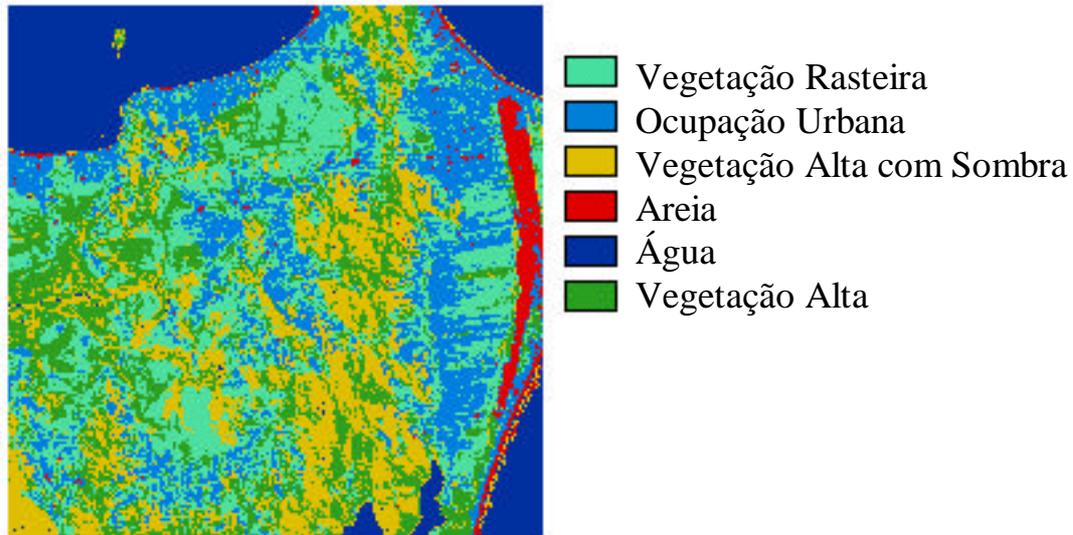
Os resultados obtidos das classificações são apresentados na **Figura 4**. Neste caso, o desempenho da RBF sobre o do classificador de Máxima Verossimilhança também é melhor. Na classificação de Máxima Verossimilhança ( **Figura 4 (b)**), observa-se uma confusão entre as classes Água e Vegetação Alta com Sombra e as classes Areia e Ocupação Urbana.

A matriz de confusão entre a classificação pela RBF e a classificação pela Máxima Verossimilhança, para a imagem de São Francisco do Sul, é descrita a seguir, na **Tabela 5**.

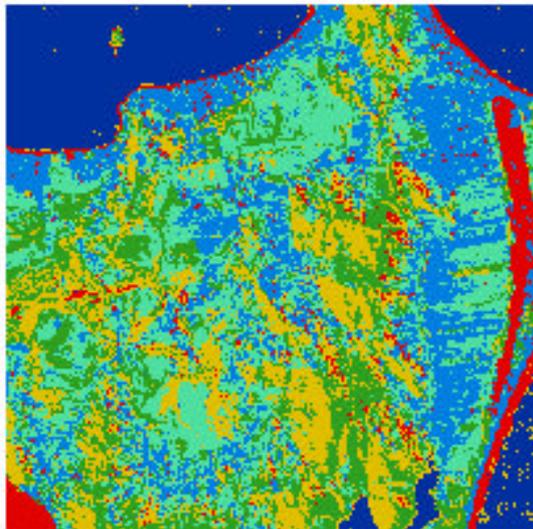
**Tabela 5.** Matriz de confusão entre a RBF (linhas) e a Máxima Verossimilhança (Colunas) para São Francisco do Sul.

	1	2	3	4	5	6	7	8	9	Total
1	50868	252	4275	0	0	6547	2164	31	6	64143
2	0	9778	394	46	0	34	0	0	5	10257
3	2	64	16540	0	0	26	0	177	127	16936
4	0	190	0	4664	0	10	0	32	203	5099
5	0	0	0	3867	23863	0	0	0	0	27730
6	0	2092	0	24	0	17624	1	17	8	19766
7	68	0	1683	0	0	0	7187	215	161	9314
8	0	0	0	0	0	0	0	1339	110	1449
9	0	141	2639	0	0	0	8	3612	11337	17737
Total	50938	12517	25531	8601	23863	24241	9360	5423	11957	172431

Índice Kappa de Concordância = 0.7935



(a)

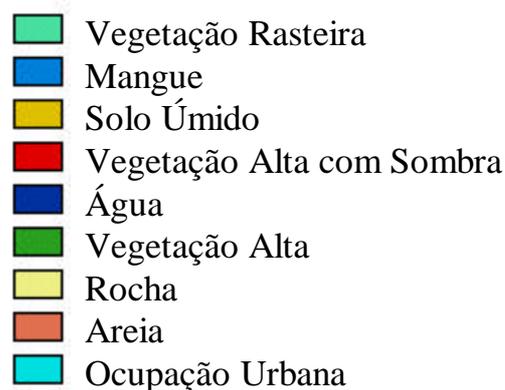
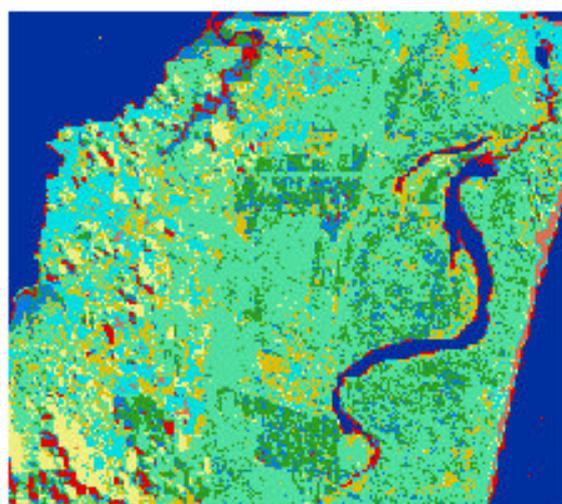


(b)

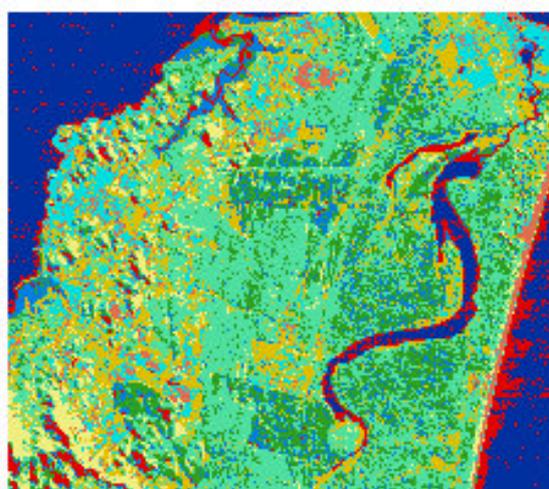
**Figura 3 - (a)** Classificação pela RBF-KOHONEN/Pseudo-inversa. 22 centros treinados por Kohonen em 130 iterações, utilizando um conjunto de treinamento mínimo. **(b)** Classificação pela Máxima Verossimilhança, utilizando o mesmo conjunto de treinamento.

Esta superioridade no desempenho da rede utilizando conjuntos de treinamento mínimos deve-se, principalmente, à sua capacidade de generalização, que permite o reconhecimento de padrões nunca apresentados à rede.

Para amostras menores, os resultados do classificador neural e do de Máxima Verossimilhança são similares. O cruzamento das imagens de Florianópolis, resultantes dos dois processos de classificação, bem como das imagens de São Francisco do Sul, apresentam índices Kappa de 0.8210 e 0.7446 respectivamente.



(a)



(b)

**Figura 4 - (a)** Classificação pela RBF-KOHOEN/Pseudo-inversa, com 43 centros, treinados em 130 iterações, utilizando um conjunto de treinamento mínimo. **(b)** Classificação pela Máxima Verossimilhança, utilizando um conjunto de treinamento mínimo.

## 5 Considerações Finais

Os classificadores estatísticos habitualmente usados na classificação de imagens multiespectrais apresentam limitações. Entre essas limitações destacam-se a necessidade de informações *a priori* sobre os dados a serem classificados e a necessidade de amostras de tamanhos significativos para obtenção de resultados satisfatórios. Neste trabalho, foi proposta uma Rede Neural Artificial com Função de Base Radial como alternativa aos classificadores baseados em conceitos estatísticos.

A arquitetura de rede RBF utilizando-se o algoritmo de Kohonen reduziu o tempo computacional e proporcionou resultados satisfatórios com menores conjuntos de amostras de treinamento. Foram apresentadas como entradas para a RBF proposta, vetores referentes aos níveis de cinza das bandas disponíveis das imagens. De acordo com a região a ser classificada,

classes foram identificadas através de informações geográficas, estudos de campo e interpretação de fotografias aéreas. O número de neurônios de saída foi determinado pelo número de classes identificadas na região imageada.

Para avaliar a performance da rede, além de análises visuais de especialistas, foi tomado como base o resultado obtido da classificação pela Máxima Verossimilhança com o mesmo conjunto de treinamento, tabulações cruzadas foram efetuadas e índices de concordância de pixels classificados igualmente foram obtidos. Percentuais de acerto e índices Kappa de precisão das classificações totais foram calculados durante a fase de testes.

Para conjuntos de treinamento de tamanhos maiores (20% da imagem total), as performances da RBF e do classificador de Máxima Verossimilhança, mostraram-se equilibradas. Utilizando conjuntos de treinamento mínimos (2.5% do tamanho da imagem total), a RNA apresentou resultados superiores aos obtidos pelo classificador estatístico. Considerando o fato de que a extração de amostras é uma fase desgastante em processos de classificação de imagens, a possibilidade de extrair um conjunto de treinamento mínimo (menos de 3% do tamanho da imagem total) e obter resultados satisfatórios, constitui-se num fato relevante.

## 6. Referências Bibliográficas

- Anderberg, Michael R. *Cluster Analysis For Applications*. Em Probability and Mathematical Statistics, vol 19, Academic Press, Inc., USA, NY - New York, 1973.
- Benediktson, J. A.; Swain, P. H.; & Ersoy, O K. *Neural Network Approaches versus Statistical Methods in Classification of Multisource Remote Sensing Data*. IEEE Transactions on Geoscience and Remote Sensing, Vol. 28, No. 4, julho de 1990, p. 540-552.
- Binaghi, E. & Rampinni, A. *Fuzzy Decision Making in the Classification of Multisource Remote Sensing Data*. Optical Engineering, Vol.32, No.6, 1993.
- Bishop, C. M. *Neural Networks for Pattern Recognition*. Oxford University Press Inc., USA, NY - New York, 1995.
- Chakrabarti, S.; Bindal, N. & Theagarajan, K. *Robust Radar Target Classifier Using Artificial Neural Networks*. IEEE Transactions on Neural Networks, Vol. 6, No. 3, maio de 1995, p. 760-767.
- Foody, G. M.; McCulloch M. B. & Yates, W. B. *Classification of Remotely Sensed Data by an Artificial Neural Network: Issues Related to Training data Characteristics*. Photogrammetric Engineering & Remote Sensing, Vol. 61, No. 4, abril de 1995, p. 391-401.
- Gong, P. & Howarth, P. *Frequency-Based Contextual Classification and Gray-Level Vector Reduction for Land Use Identification*. Photogrammetric Engineering Remote Sensing, Vol. 58, No. 4, 1992, p. 423-437.
- Hara, Y.; Atkins, R. G.; Yueh, S. H.; Shin, R. T. & Kong, J. A. *Application of Neural Networks to Radar Image Classification*. IEEE Transactions on Geoscience and Remote Sensing, Vol. 32, No. 1, janeiro de 1994, p. 100-109.
- Haykin, S. *Neural Networks - A Comprehensive Foundation*. Macmillan College Publishing Company, USA, NY - New York, 1994.

- Hepner, G. F.; Logan, T.; Ritter, N. & Bryant, N. *Artificial Neural Network Classification Using a Minimal Training Set: Comparison to Conventional Supervised Classification*. Photogrammetric Engineering and Remote Sensing, vol 56, No. 4, abril de 1990, p. 469-473.
- Hush, Don R. & Horne, Bill G. *Progress in Supervised Neural Networks - What's New Since Lippmann?* IEEE Signal Processing Magazine, janeiro de 1993, p. 8-39.
- Kushadorno, D.; Fukue, K.; Shimoda, H. & Sakata, T. *A Spatial Land Cover Classification with the Aid of Neural Network*. Proceedings of SPIE - The International Society for Optical Engineering, Vol. 2315, 1994, Society of Photo-Optical Instrumentation Engineers, Bellingham, WA, USA, p.702-710.
- Machado, R. J.; Barbosa, V. C. & Liporace, F. S. *Applying Neural Networks for Deforestation Monitoring of the Amazon Region*. Versão revisada do artigo "Monitoring the Deforestation of the Amazon Region with Neural Networks", publicado nos Proceedings of The Interantional Joint Conference on Neural Networks (IJCNN' 93), Nagoya-Japan, 1993, p. 1239-1242.
- Nishida, W. *Uma Rede Neural Artificial para Classificação de Imagens Multiespectrais de Sensoriamento Remoto*. Dissertação de Mestrado, Universidade Federal de Santa Catarina - UFSC, Programa de Pós Graduação em Engenharia de Produção - PPGEP, Florianópolis - SC, 1998.
- Schlünzen, E. T. M.; Trindade, M. L. B; Shimabukuro, M. H; Schlünzen Jr., K. & Neto, M. L. A. *Perspectivas da Aplicação de Redes Neurais na Classificação de Dados Multiespectrais de Sensoriamento Remoto*. Anais do VII SBSR - Simpósio Brasileiro de Sensoriamento Remoto, 1993, p. 438-444.
- Todesco, José L. *Reconhecimento de Padrões Usando Rede Neural Artificial com uma Função de Base Radial: Uma aplicação na Classificação de Cromossomos Humanos*. Tese de Doutorado, Universidade Federal de Santa Catarina - UFSC, Programa de Pós-Graduação em Engenharia de Produção - PPGEP, Florianópolis - SC, 1995.
- Yoshida, T. & Omatu, S. *Neural Network Approach to Land Cover Mapping*. IEEE Transactions on Geoscience and Remote Sensing, vol. 32 No. 5, setembro de 1994, p. 1103-1109.