



Exacta

ISSN: 1678-5428

exacta@uninove.br

Universidade Nove de Julho  
Brasil

Luz Alves, Wonder Alexandre; Alves de Araújo, Sidnei  
Avaliação da utilização de dois diferentes modelos de redes neurais na classificação de imagens com  
base em características texturais  
Exacta, vol. 4, núm. 1, janeiro-junho, 2006, pp. 77-86  
Universidade Nove de Julho  
São Paulo, Brasil

Disponível em: <http://www.redalyc.org/articulo.oa?id=81040107>

- Como citar este artigo
- Número completo
- Mais artigos
- Home da revista no Redalyc

redalyc.org

Sistema de Informação Científica  
Rede de Revistas Científicas da América Latina, Caribe, Espanha e Portugal  
Projeto acadêmico sem fins lucrativos desenvolvido no âmbito da iniciativa Acesso Aberto

# Avaliação da utilização de dois diferentes modelos de redes neurais na classificação de imagens com base em características texturais

Wonder Alexandre Luz Alves

Graduado em Ciência da Computação – Uninove.  
wonder@woniz.com, São Paulo – SP [Brasil]

Sidnei Alves de Araújo

Mestre em Engenharia Elétrica – Mackenzie;  
Doutorando em Engenharia Elétrica – Poli-USP;  
Professor na graduação [Ciência da Computação] – Uninove.  
saraujo@uninove.br, São Paulo – SP [Brasil]

Este trabalho explora a classificação de texturas por redes neurais artificiais (RNAs). São utilizados dois diferentes modelos de redes neurais: um supervisionado (*perceptron* de múltiplas camadas) e outro não supervisionado (mapas auto-organizáveis de Kohonen). Em ambos os casos, os atributos que descrevem as texturas e são utilizados para classificá-las advêm de abordagens estatísticas de primeira e segunda ordens. Neste estudo, faz-se uma análise comparativa entre os resultados experimentais de cada modelo de rede.

**Palavras-chave:** Inteligência artificial.

Processamento de imagens digitais.

Reconhecimento de padrões. Redes neurais artificiais.

Texturas.



## 1 Introdução

Nos últimos anos, tem-se observado um rápido crescimento nas bases de imagens digitais decorrente dos avanços tecnológicos, o que torna necessário o uso de mecanismos de indexação e posterior recuperação de imagens. Por ser executada manualmente, essa indexação torna-se uma tarefa, além de enfadonha, sensível a interpretações e sujeita a erros. Para solucionar o problema, tem-se estudado métodos automáticos de indexação e recuperação de imagens, baseados em algum tipo de característica (cor, forma, textura ou região de uma imagem). Nesse contexto, utilizam-se atributos de texturas como uma das principais características na classificação de imagens digitais. Para isso, propõem-se vários métodos (AKSOY; HARALICK, 1998; MEDEIROS, 2001; FELIPE; TRAINA, 2002; MARTINS; GUIMARÃES; FONSECA, 2002). Ressalta-se, no entanto, a importância da realização de novos estudos, em razão de não haver, até o momento, um método genérico ou uma abordagem formal que sejam úteis para uma grande variedade de imagens.

Constam da literatura recente vários trabalhos de classificação de imagens empregando diferentes técnicas, tais como árvores de decisão (SHIBA et al., 2005) e redes neurais artificiais (RNAs) (BENDER; OSÓRIO, 2003; MARTINS; GUIMARÃES; FONSECA, 2002).

Shiba e colaboradores (2005) propuseram um método baseado em árvores de decisão para classificação de imagens de sensoriamento remoto descritas pelas três bandas do sistema de cores RGB (em inglês, *red*, *green*, *blue*). Para reconhecimento e recuperação de imagens descritas por atributos de cores, Bender e Osório (2003) sugeriram uma rede neural do tipo *multi-layer perceptrons* (MLP) – ou *perceptrons* de múltiplas camadas, em português. Martins, Guimarães e Fonseca (2002)

optaram por um método fundamentado em uma rede neural híbrida *self-organizing maps* (SOM) e *learning vector quantization* (LVQ), para classificação de imagens de sensoriamento remoto a partir dos atributos de textura extraídos com uso de filtros de Gabor.

Felipe e Traina (2002) desenvolveram uma ferramenta para recuperação e indexação de imagens médicas por meio de suas texturas caracterizadas pelos descritores de Haralick.

Neste trabalho, foram aplicados dois diferentes modelos de redes neurais para classificação de imagens pela análise de textura, utilizando histogramas de primeira ordem e descritores de Haralick baseados em matrizes de co-ocorrência. A partir dos resultados obtidos, foi demonstrado que ambos os modelos de redes neurais são capazes de classificar imagens por meio dos descritores de texturas utilizados. Além de apresentar os resultados de cada um dos modelos de rede, realizamos uma análise comparativa, procurando fornecer alguns indícios que evidenciam aquele que, entre os dois modelos de rede neural, oferece melhores soluções para o problema enfocado.

## 2 Texturas em imagens digitais

Conforme enumerações a seguir.

### 2.1 Imagens digitais

Uma imagem digital pode ser entendida como uma matriz em que os índices de linha e coluna identificam um ponto na imagem, e o valor do elemento da matriz aponta o nível de cinza naquele ponto. Cada elemento dessa matriz é chamado de *pixel* (GONZALEZ; WOODS, 2002; PRATT, 1991). Dessa forma, uma imagem digital é normalmente definida como uma função bidimensional  $f(i, j)$ , com  $i, j \in \mathbb{Z}^2$ . Uma imagem em níveis

de cinza  $G_y$  pode ser descrita como uma função (Equação 1), cujo contradomínio representa diferentes níveis de cinza, por exemplo, o intervalo real de 0 a 1. Esse intervalo é geralmente “discretizado”<sup>1</sup> computacionalmente, resultando em um intervalo inteiro de 0 a 255.

$$G_y: Z^2 \rightarrow [0, \dots, 255]$$

(1)

## 2.2 Texturas

Embora não haja consenso a respeito da definição de textura, pode-se referenciá-la como um conjunto de determinados padrões existentes nas superfícies físicas, perceptíveis ao olho humano, e que trazem grande quantidade de informações sobre a natureza da superfície, como suavidade e rugosidade (GONZALEZ; WOODS, 2002).


As três principais abordagens utilizadas em processamento de imagens para descrição de texturas são: estatística, estrutural e espectral. Abordagens estatísticas caracterizam texturas como suaves, ásperas, granulares etc. As técnicas estruturais baseiam-se em primitivas de imagens para a descrição de textura. As técnicas espectrais levam em conta propriedades do espectro de Fourier, permitindo a detecção de periodicidade global em imagens por meio da identificação de pontos máximos de espectro (GONZALEZ; WOODS, 2002). Neste trabalho, consideramos a abordagem estatística para descrever texturas em imagens digitais.

## 2.3 Abordagem estatística para descrição de texturas

A extração de características pela abordagem estatística propicia a descrição de imagens por meio de regras estatísticas que governam a distribuição e a relação entre os diferentes níveis de cinza. Inúmeras medidas podem ser extraídas da distribuição desses níveis em imagens

digitais, entre as quais podemos citar o cálculo de média, variância, desvio-padrão, energia ou entropia. A abordagem estatística pode ser dividida em duas importantes vertentes: a de primeira ordem, na qual se extraem características a partir do uso de histogramas, e a de segunda, que leva em conta o posicionamento relativo da ocorrência dos níveis de cinza. A principal diferença entre as duas é que, dadas duas imagens que contenham a mesma quantidade de níveis de cinza, mas com posicionamento diferente, a abordagem de primeira ordem apresentará um único histograma, enquanto, na de segunda, os histogramas serão diferentes.

Haralick, Shanmugan e Dinstein (1973) propõem uma metodologia para descrição de texturas baseada em estatística de segunda ordem, em que se definem características provenientes do cálculo de matrizes denominadas “matrizes de co-ocorrência” que consistem em uma tabulação de quantas combinações diferentes de níveis de cinza ocorrem em uma imagem, em uma determinada direção. Para obtenção dessas matrizes, considera-se a variação da distância e direção ( $d$ ,  $\theta$ ) entre *pixels* vizinhos. Normalmente, são utilizados quatro direcionamentos:  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ , conforme Ilustração 1.



**Ilustração 1: Janela das variações angulares ( $\theta$ ) utilizadas no cálculo das matrizes de co-ocorrência, considerando  $d = 1$**

Fonte: Os autores.



As matrizes de co-ocorrência servem de base para elaboração de diversas medidas estatísticas conhecidas como descritores de Haralick. Utilizamos, neste trabalho, oito descritores: segundo momento angular (SMA), contraste (Cont), entropia (ENT), momento da diferença inversa (MDI), correlação (COR), variância (VAR), dissimilaridade (DIS) e média (MED). As equações desses descritores são dadas, respectivamente, em (2), (3), (4), (5), (6), (7), (8) e (9), a seguir.

Para cada *pixel*  $P(i, j)$  processado na imagem, é considerada uma janela em torno dele com distância  $d = 1$ , nas quatro direções  $\theta$ .  $N_g$  denota a quantidade de níveis de cinza em uma imagem.

O SMA fornece a medida da homogeneidade local dos níveis de cinza em uma imagem.

$$SMA(d, \theta) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} [P(i, j)]^2 \quad (2)$$

O Cont reflete a quantidade de variação local de níveis de cinza em uma imagem.

$$Cont(d, \theta) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - j)^2 P(i, j) \quad (3)$$

A ENT fornece o grau de dispersão de níveis de cinza de uma imagem.

$$ENT(d, \theta) = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - j) \log_2[P(i, j)] \quad (4)$$

O MDI denota a homogeneidade da matriz de co-ocorrência.

$$MDI(d, \theta) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1 + (i - j)^2} P(i, j) \quad (5)$$

A COR mede a dependência linear dos níveis de cinza nas combinações dos pares de *pixels* em uma determinada direção.  $\mu_x$  e  $\mu_y$  denotam as médias nas direções  $x$  e  $y$ , enquanto representam os desvios-padrão.

$$COR(d, \theta) = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} ijP(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (6)$$

A VAR diz respeito à heterogeneidade da matriz de co-ocorrência em forma de desvio dos valores  $P$  da matriz.

$$VAR(d, \theta) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - j)^2 \cdot P(i, j) \quad (7)$$

A DIS mede o quanto o nível de cinza dos pares de *pixels* são diferentes entre si.

$$DIS(d, \theta) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} |i - j| \cdot P(i, j) \quad (8)$$

MED expressa a média da matriz de co-ocorrência.

$$MED(d, \theta) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} i \cdot P(i, j) \quad (9)$$

### 3 Redes neurais artificiais (RNAs)

Têm sido amplamente utilizadas em modelos automáticos de classificação e recuperação de imagens. O uso das RNAs para tal atividade está diretamente relacionado à sua capacidade de aprender por meio de exemplos e de generalizar a informação aprendida. Outra característica importante das RNAs é a capacidade de auto-organização, em que a rede atribui um padrão de entrada a uma classe entre um con-

junto de classes conhecidas. O procedimento empregado no aprendizado de uma rede neural é chamado de algoritmo de treinamento e sua função principal é a modificação dos pesos sinápticos, de uma forma ordenada, para alcançar o objetivo (HAYKIN, 2001; RUSSEL; NORVIG, 1995).

### 3.1 Multi-layer perceptrons (MLP)

É um modelo de aprendizado supervisionado de RNA, caracterizado por ter, além das camadas de entrada e saída, uma ou mais camadas ocultas. O algoritmo de aprendizado do MLP, conhecido como algoritmo de retropropagação de erro (*backpropagation*), baseia-se em aprendizagem por correção de erro. O treinamento é composto de duas fases. Na primeira, quando um padrão é apresentado à rede pela camada de entrada, o sinal de ativação se propaga até a camada de saída, produzindo uma resposta. Na segunda, a saída obtida é comparada com a desejada, e um sinal de erro, produzido. Esse sinal é então retropropagado desde a camada de saída até a de entrada, e os pesos sinápticos vão sendo ajustados para que a resposta da rede se aproxime da desejada.

### 3.2 Self-organizing maps (SOM)

Os mapas auto-organizáveis ou redes de Kohonen são modelos de RNAs não supervisionados, ou seja, não é preciso fornecer os pares de entrada e saída desejados. Uma de suas principais características é a capacidade de auto-organização, o que as tornam mais interessantes que os modelos supervisionados. A rede SOM funciona basicamente da seguinte forma: quando um padrão  $p_i$  é apresentado à rede, um neurônio é escolhido para representá-lo por meio de um processo de competição. Durante o treinamento, a rede aumenta a semelhança entre o neurônio escolhido e seus vizinhos em relação

ao padrão  $p_i$ . Dessa forma, é construído um mapa em que neurônios topologicamente próximos respondem, de forma similar, aos padrões de entrada com características semelhantes (BRAGA; CARVALHO; LUDERMIR, 2000; HAYKIN, 2001).

## 4 Classificação de texturas pela aprendizagem

O problema de classificação de texturas pela aprendizagem envolve dois conjuntos de treinamento: 1) com base nas características de imagens descritas por histogramas de primeira ordem; 2) nos descritores de Haralick. Denotamos esses dois conjuntos por  $P1 = \{p1_1, p1_2, \dots, p1_n\}$  e  $P2 = \{p2_1, p2_2, \dots, p2_n\}$ . Enquanto em  $P1$  cada padrão  $p1_i$  ( $i$  é o índice do elemento do conjunto  $P1$ ) é descrito por um vetor com 256 elementos (256 níveis de cinza), em  $P2$ , utiliza-se um vetor com apenas oito elementos para descrever um padrão  $p2_i$  ( $i$  é o índice do elemento do conjunto  $P2$ ). Além disso, deve haver dois conjuntos de testes com as mesmas características de  $P1$  e  $P2$  para avaliar o desempenho dos modelos neurais. Denotamos os conjuntos de testes por  $Q1 = \{q1_1, q1_2, \dots, q1_n\}$  e  $Q2 = \{q2_1, q2_2, \dots, q2_n\}$ . Espera-se que, após treinamento dos modelos neurais, eles sejam capazes de classificar corretamente as imagens de  $Q1$  e  $Q2$ , de acordo com as descrições de suas texturas.

## 5 Resultados experimentais

Para os experimentos, foram utilizadas imagens de tecidos biológicos encontradas em Kuhnel (1991), Schneider e Schneider (1998) e na Universidad Nacional del Sur (2000?). Selecionamos 50, a partir das quais extraímos os



conjuntos de treinamento (P1 e P2), e outras 50 diferentes para formar os conjuntos de testes (Q1 e Q2), totalizando cem imagens. Tanto nos conjuntos de treinamento quanto nos de testes, as imagens foram divididas em cinco classes, cada uma delas com dez imagens. Realizamos os testes combinando os dois modelos de redes neurais e as duas abordagens estatísticas (primeira e segunda ordens). Os resultados desses experimentos são descritos a seguir.

### 5.1 Classificação de texturas descritas por estatística de primeira ordem

Nesta seção, são apresentados os resultados dos experimentos realizados com os modelos SOM e MLP na classificação de imagens com base em histogramas de primeira ordem.

#### 5.1.1 Rede SOM treinada com histogramas de primeira ordem

Para este treinamento com a rede SOM, utilizamos uma arquitetura com 256 neurônios na camada de entrada e um mapa de saída com 36 neurônios (matriz quadrada 6 x 6). Para averiguar o desempenho da rede, o algoritmo de treinamento foi executado com o conjunto de padrões P1 por mil épocas, utilizando uma taxa de aprendizado de 0,01. Os resultados obtidos foram bastante satisfatórios, conforme mostrado na Tabela 1.

**Tabela 1: Resultados da classificação de textura pela rede SOM usando estatística de primeira ordem**

Classe	Acertos	Erros	Acerto (%)
1	10	0	100
2	10	0	100
3	10	0	100
4	10	0	100
5	10	0	100

Fonte: Os autores.

#### 5.1.2 Rede MLP treinada com histogramas de primeira ordem

Foi utilizado um modelo com quatro camadas, sendo 256 neurônios de entrada, 90 na primeira camada oculta, 45 na segunda e cinco de saída, usando função de ativação sigmóide ( $1/1 + e^{-ax}$ ). O treinamento da rede MLP foi realizado com os seguintes parâmetros: mil épocas, taxa de aprendizado  $\eta = 0,05$  e termo de momento  $t = 0,9$ . Após treinamento da rede, fizemos os testes com Q1, cujos resultados estão apresentados na Tabela 2.

**Tabela 2: Resultados da classificação de textura pela rede MLP usando estatística de primeira ordem**

Classe	Acertos	Erros	Acerto (%)
1	7	3	70
2	10	0	100
3	10	0	100
4	10	0	100
5	10	0	100

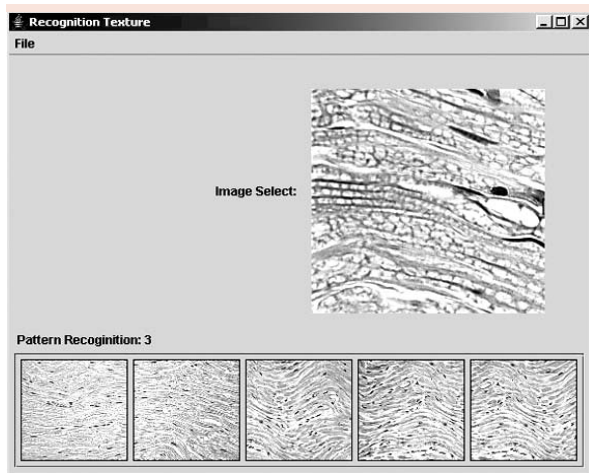
Fonte: Os autores.

Neste caso, a rede MLP conseguiu reconhecer quase todos os padrões, apresentando apenas três erros na classe 1. A Ilustração 2 mostra uma situação na qual uma imagem do conjunto Q1 é selecionada e, na sequência, a aplicação desenvolvida mostra a classe a que pertence tal imagem.

### 5.2 Classificação de texturas descritas por estatística de segunda ordem

Nesta seção, apresentamos os resultados dos experimentos realizados com os modelos SOM e MLP, adotando os descritores de Haralick. Os parâmetros usados para o treinamento do modelo SOM são os mesmos descritos em 5.1.1, com exceção da quantidade de neurônios de entrada, oito (de acordo com os descritores considerados). Para o modelo MLP, além da quantidade de neurônios





**Ilustração 2: Resultado do reconhecimento de textura por MLP usando histograma de primeira ordem**

Fonte: Os autores.

da camada de entrada, as camadas ocultas foram alteradas para seis e oito neurônios. Vale ressaltar que, nesta segunda etapa, tanto para o modelo SOM quanto para o MLP, foi utilizado o conjunto de treinamento P2.

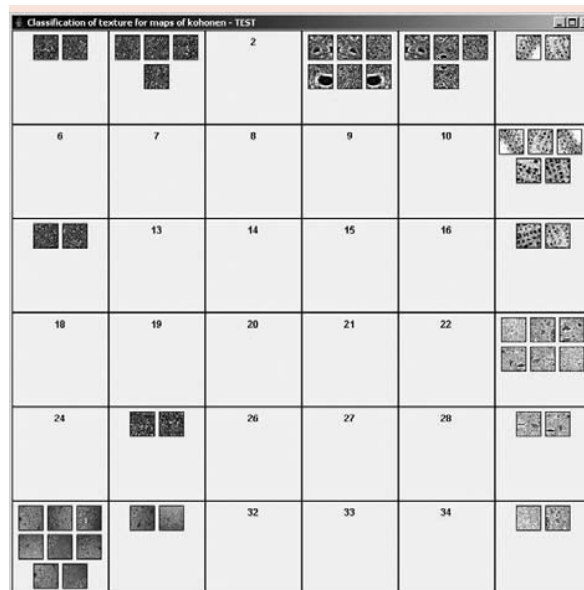
### 5.2.1 Rede SOM treinada com os descritores de Haralick

Para esta sessão de treinamento, a rede foi configurada com oito neurônios na camada de entrada e 36 neurônios no mapa de saída. Após o treinamento, o resultado da rede é apresentado em uma janela (*frame*) da aplicação, na qual as imagens com texturas similares estão organizadas em uma determinada região (Ilustração 3). Os resultados são apresentados na Tabela 3.

**Tabela 3: Resultados da classificação de textura pela rede SOM usando estatística de segunda ordem**

Classe	Acertos	Erros	Acerto (%)
1	10	0	100
2	10	0	100
3	10	0	100
4	10	0	100
5	10	0	100


Fonte: Os autores.



**Ilustração 3: Mapa de saída após treinamento da rede SOM usando descritores de Haralick**

Fonte: Os autores.

Conforme visto na Ilustração 4, após o conjunto de padrões de testes Q2, notamos que a rede conseguiu classificar todos os padrões corretamente.



**Ilustração 4: Resultado obtido pela rede SOM usando descritores de Haralick, depois de processado o conjunto Q2**

Fonte: Os autores.





### 5.2.2 Rede MLP treinada com os descritores de Haralick

Esse experimento, cujos resultados são mostrados na Tabela 4, foi o que apresentou maior taxa de erro (8% em média). Neste caso, a rede detectou erro em duas das cinco classes de imagens.

**Tabela 4: Resultados da classificação de textura pela rede MLP usando estatística de segunda ordem**

Classe	Acertos	Erros	Acerto (%)
1	10	0	100
2	10	0	100
3	7	3	70
4	9	1	90
5	10	0	100

Fonte: Os autores.

### 5.3 Análise comparativa dos modelos neurais e dos métodos de extração de características texturais

As Tabelas 5 e 6 mostram o desempenho médio dos dois modelos neurais. Observe-se que, no modelo MLP, somente duas classes tiveram todas as suas imagens reconhecidas. Já a rede SOM conseguiu reconhecer todos os padrões dos dois conjuntos Q1 e Q2.

**Tabela 5: Média dos resultados obtidos por SOM, considerando os conjuntos de testes Q1 e Q2**

Classe	Conjunto Q1		Conjunto Q2		Erro (%) Q1 + Q2
	Acertos	Erros	Acertos	Erros	
1	10	0	10	0	0
2	10	0	10	0	0
3	10	0	10	0	0
4	10	0	10	0	0
5	10	0	10	0	0
Média					0

Fonte: Os autores.

**Tabela 6: Média dos resultados obtidos por MLP, considerando os conjuntos de testes Q1 e Q2**

Classe	Conjunto Q1		Conjunto Q2		Erro (%) Q1 + Q2
	Acertos	Erros	Acertos	Erros	
1	10	0	7	3	15
2	10	0	10	0	0
3	10	0	7	3	15
4	10	0	9	1	5
5	10	0	10	0	0
Média					7

Fonte: Os autores.

Nas Tabelas 7 e 8, são mostrados os resultados médios dos experimentos, considerando as duas abordagens estatísticas para extração de características texturais das imagens. Nota-se que os resultados com base na abordagem estatística de primeira ordem foram melhores, apresentando apenas 3% de erro (na média), enquanto o percentual de erros dos experimentos em que se utilizou a abordagem de segunda ordem foi, em média, 4%.

Apesar de o processo de classificação por estatística de primeira ordem ser mais lento (dado que o vetor de entrada é composto de um número de elementos maior que na abordagem de segunda ordem), os resultados dessa abordagem mostraram-se melhores. Constatou-se também que a rede SOM apresentou melhor performance que a MLP, para as duas abordagens estatísticas.

**Tabela 7: Média dos resultados usando estatística de primeira ordem**

Classe	SOM		MLP		Erro (%) SOM + MLP
	Acertos	Erros	Acertos	Erros	
1	10	0	7	3	15
2	10	0	10	0	0
3	10	0	10	0	0
4	10	0	10	0	0
5	10	0	10	0	0
Média					3

Fonte: Os autores.

**Tabela 8: Média dos resultados usando estatística de segunda ordem**

Classe	SOM		MLP		Erro (%) SOM + MLP
	Acertos	Erros	Acertos	Erros	
1	10	0	10	0	15
2	10	0	10	0	0
3	10	0	7	3	15
4	10	0	9	1	5
5	10	0	10	0	0
Média					4

Fonte: Os autores.

## 6 Considerações finais

Neste trabalho, exploramos a aplicabilidade das RNAs em classificação de imagens usando descrição de texturas por métodos estatísticos de primeira e segunda ordens. Experimentos realizados mostraram que o modelo SOM, utilizando a abordagem tanto de primeira quanto de segunda ordem, obteve resultados melhores que os da rede MLP treinada com o algoritmo *backpropagation*. Além disso, demonstramos que os resultados foram, em média, melhores quando utilizada a abordagem estatística de primeira ordem. Vale ressaltar que este estudo pode estimular a continuação de outros trabalhos na tentativa de obter melhores resultados com redes MLP e estatística de segunda ordem, já que o treinamento de MLP é mais rápido que o do modelo SOM e que tal implementação pode oferecer melhores condições para uma aplicação que venha a ser utilizada na prática.

### Evaluation of the use of two different models of neural networks in the classification of images based on textural features

This work explores the classification of textures by artificial neural networks. Two different

models of neural networks are used: one supervised (multiple layers perceptron) and the other non-supervised (Kohonen auto-organizable maps). In both cases, the attributes that describe the textures and those ones used to classify them, result from statistic approaches of first and second orders. In this study, a comparative analysis between the experimental results of each model of networks is carried out.

**Key words:** Artificial intelligence. Artificial neural networks. Digital images processing. Recognition of patterns. Textures.

## Notas

- 1 N. Ed.: embora a palavra discretizado não exista no português, trata-se de um termo técnico amplamente utilizado em física, engenharia e matemática. Simplesmente quer dizer que os valores utilizados neste intervalo não são contínuos.

## Referências

- AKSOY, S.; HARALICK, R. M. *Textural features for image database retrieval*. Seattle: University of Washington, 1998. Disponível em: <[http://www.cs.bilkent.edu.tr/~saksoy/papers/cbaiv198\\_texture.pdf](http://www.cs.bilkent.edu.tr/~saksoy/papers/cbaiv198_texture.pdf)>. Acesso em: 18 jan. 2006.
- BENDER, T. C.; OSÓRIO, F. S. Reconhecimento e recuperação de imagens utilizando redes neurais artificiais do tipo MLP. In: ENCONTRO NACIONAL DE INTELIGÊNCIA ARTIFICIAL, 4., 2003, Campinas. *Anais...* Campinas: Enia, 2003.
- BRAGA, A. de P.; CARVALHO, A. C. P. de L. F.; LUDERMIR, T. B. *Redes neurais artificiais: teoria e aplicações*. 1. ed. Rio de Janeiro: LTC, 2000.
- FELIPE, J. C.; TRAINA, A. J. M. Utilizando características de textura para identificação de tecidos em imagens médicas. In: WORKSHOP DE INFORMÁTICA MÉDICA, 2., 2002, Gramado. *Anais...* Gramado: WIM, 2002. Disponível em: <[http://gbdi.icmc.usp.br/publicacoes/arquivos/Felipe2002\\_WIM\\_TexturaDeTecidosEmImagensMedicas.PDF](http://gbdi.icmc.usp.br/publicacoes/arquivos/Felipe2002_WIM_TexturaDeTecidosEmImagensMedicas.PDF)>. Acesso em: 18 jan. 2006.
- GONZALEZ, R. C.; WOODS, R. E. *Digital image processing*. 2. ed. Nova Jersey: Prentice Hall, 2002.



HARALICK, R. M.; SHANMUGAN, K.; DINSTEN, I. Texture feature for image classification. *IEEE Transaction on Systems, Man, and Cybernetics*, Nova York, v. 3, n. 1, p. 610-621, 1973.

HAYKIN, S. *Redes neurais: princípio e prática*. 2. ed. Porto Alegre: Bookman, 2001.

KUHNEL, W. *Atlas de citologia, histologia e anatomia microscópica para teoria e prática*. 7. ed. São Paulo: Guanabara Koogan, 1991.

MARTINS, M. P.; GUIMARÃES, L. N. F.; FONSECA, L. M. G. Classificador de texturas por redes neurais. In: CONGRESSO BRASILEIRO DE COMPUTAÇÃO, 2., 2002, Itajaí. *Anais... Itajaí*: CBComp, 2002. Disponível em: <<http://www.cbcomp.univali.br/anais/pdf/2002/ina007.pdf>>. Acesso em: 18 jan. 2006.

MEDEIROS, G. C. F. *Uso de texturas para o acompanhamento da evolução do tratamento de úlceras dermatológicas*. 2001. Dissertação (Mestrado em Engenharia Elétrica)–Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2001. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/18/18133/tde-26042001-125441/>>. Acesso em: 18 jan. 2006.

PRATT, W. K. *Digital image processing*. 2. ed. Nova York: John Wiley & Sons, 1991.

RUSSEL, S.; NORVIG, P. *Artificial intelligence: a modern approach*. 1. ed. Nova Jersey: Prentice Hall, 1995.

SCHNEIDER, M. L.; SCHNEIDER, V. *Atlas de diagnóstico diferencial em citologia ginecológica*. 1. ed. Rio de Janeiro: Revinter, 1998.

SHIBA, M. H. et al. Classificação de imagens de sensoriamento remoto pela aprendizagem por árvore de decisão: uma avaliação de desempenho. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. *Anais... Goiânia*: SBSR, 2005. p. 4319-4326. Disponível em: <<http://martedpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.23.11.44/doc/4319.pdf>>. Acesso em: 18 jan. 2006.

UNIVERSIDAD NACIONAL DEL SUR. *Atlas de anatomía y de histología*. 1. ed. Bahía Blanca: UNS, 2000?. Disponível em: <<http://www.anatomohistologia.uns.edu.ar/plantilla.asp?zona=atlas>>. Acesso em: 2 fev. 2005.

Recebido em: 18 jan. 2006 / aprovado em: 28 abr. 2006

#### Para referenciar este texto

ALVES, W. A. L.; ARAÚJO, S. A. de. Avaliação da utilização de dois diferentes modelos de redes neurais na classificação de imagens com base em características texturais. *Exacta*, São Paulo, v. 4, n. 1, p. 77-86, jan./jun. 2006.