

# FILTROS NEURAIIS ESPACIAIS PARA REDUÇÃO DE RUÍDO IMPULSIVO USANDO REDES PERCEPTRON E REDES RBF

RAQUEL E. PATIÑO-ESCARCINA\*, JOSE ALFREDO FERREIRA COSTA\*

\**Laboratorio de Sistemas Adaptativos - Centro de Tecnologia  
Universidade Federal do Rio Grande do Norte  
Natal, RN, Brasil*

Emails: raquel.patino@gmail.com, alfredo@dee.ufrn.br

**Abstract**— The amount of images existing in different supplies like documents, databases, internet, etc. is ever increasing. In many cases these images could be degraded because of some noise added in digitalization or transmission. In order to improve visual quality of these images, several methods were proposed like spatial filters. However, in many cases they can cause a blurring effect when trying to reduce noise. Tools for reducing noise while minimizing the loss of information is a topic of research. Previous approaches show that multilayer perceptron neural (MLP) network can be used as image filters. In this work, a Radial Basic function Network (RBF) is using as spatial filter for noise reduction. The efficiency of this network was compared with a MultiLayer Perceptron (MLP) networks and with other traditional filters defining conditions like training set and mask size used.

**Keywords**— Filters, Noise Reduction, Perceptron, Efficiency

**Resumo**— A quantidade de imagens existentes nestes dias em diferentes fontes tais como documentos, bancos de dados, internet, etc. é crescente. Em muitos casos estas imagens podem estar degradadas devido a presença de ruído inserido por problemas na digitalização ou na transmissão (codificação). Para tentar melhorar a qualidade visual destas imagens, vários métodos são propostos entre os quais citamos filtros espaciais. Porém em muitos casos estes filtros espaciais também podem causar um efeito de borramento na imagem ao tentar reduzir o ruído presente. Pesquisas tem sido feitas na busca de ferramentas que possam reduzir ruído tentando minimizar a perda de informação nos detalhes da imagem Neste trabalho a rede RBF é usada como um filtro espacial para a redução de ruído impulsivo comparando seu desempenho com a rede *MultiLayer Perceptron* (MLP) e com outros filtros espaciais tradicionais. Segundo os testes realizados, a rede MLP obtém melhores resultados que a rede RBF e que os filtros tradicionais mesmo com diferentes conjuntos de treinamento e com tamanhos de filtros diferentes.

**Keywords**— Filtros espaciais, Redução de Ruído, Perceptron, RBF, Eficiência

## 1 Introdução

Processamento de imagens é o termo usado para denominar as operações realizadas sob uma imagem para melhorar a qualidade visual. Estes objetivos são alcançados com a implementação de diversos algoritmos através de funções matemáticas, as quais transformam a imagem original em uma nova imagem. Porém, em vários casos estas transformações são difíceis de serem modeladas dado que podem envolver uma série de cálculos matemáticos complexos. Assim, é importante explorar novas ferramentas de processamento de imagens e analisar as técnicas existentes para poder estabelecer sua eficiência. Como exemplo, temos os filtros espaciais que podem reduzir o ruído para melhorar a qualidade nas imagens.

Os filtros tradicionais que reduzem ruído causam um efeito de borramento que faz com que a imagem perca detalhes que são importantes para outras etapas de processamento como por exemplo segmentação, etc. É por isso que é desejável reduzir o ruído na imagem aplicando filtros que reduzindo o ruído conservem os pixels que não possuíam ruído sem perda de informação.

Os filtros espaciais aplicados para reduzir ruído usam uma máscara que é uma sub-matriz que percorre a imagem gerando uma nova imagem.

O tamanho desta matriz vai influenciar no resultado do processamento. Este trabalho apresenta as redes neurais Perceptron de múltiplas camadas (MLP) e redes de base radial (RBF) como filtros espaciais avaliando sua eficiência ao variar o tamanho da máscara e o conjunto de treinamento.

## 2 Redes Neurais MLP e Redes RBF

A rede neural MLP é uma rede supervisionada amplamente usada em diversas áreas pelo seu bom desempenho. Esta organizada em camadas de neurônios os quais são conectados com os neurônios na camada seguinte Na maioria dos casos, uma rede MLP com uma camada escondida é suficiente para a solução de problemas, porém podem ser agregadas mais camadas. O algoritmo base de treinamento é o *Backpropagation* que usa o erro médio quadrático como função objetivo Por este algoritmo, os pesos das conexões entre os neurônios são atualizados iterativamente até encontrar um mínimo global na função objetivo. A rede RBF (*Radial Basic Function*) é similar a rede MLP. É supervisionada e organizada em camadas. A principal diferença entre a rede RBF e a rede MLP é a camada escondida. A RBF tem só uma camada escondida, onde os neurônios representam *clusters* no espaço de entrada e tem uma função

de base radial como função de ativação.

Dada a similaridade destas redes, existe na literatura muitos trabalhos comparando-as para determinar a eficiência delas. (Jung-Wook et al., 2002) determinou que o desempenho da RBF era maior ao MLP na identificação on-line de um gerador síncrono, já (Oliveira et al., 2004) determinou que as redes MLP tem um melhor desempenho na detecção de series temporais. Assim outros trabalhos vem ressaltando diferentes características de cada uma destas redes (Yampolskiy and Novikov, 2003), (Foody, 2004), (Papaioannou et al., 2006), etc.

Em (Patiño-Escarcina and Costa, 2007) a rede MLP foi usada para reduzir ruído impulsivo em imagens monocromáticas com um filtro de  $3 \times 3$ . Esta rede mostrou um grande desempenho em relação a outros filtros tradicionais. Sendo as redes MLP e RBF muito similares, neste trabalho a rede RBF será usada como filtro para reduzir ruído impulsivo comparando seu desempenho com a MLP de similar arquitetura e ambas redes neurais serão comparadas com filtros tradicionais para determinar sua eficiência.

### 3 Filtragem usando Redes MLP e RBF

No domínio espacial, a redução do ruído é conseguida através da convolução de uma máscara(filtro) com toda a imagem. Convolução é o processo de calcular a intensidade de um determinado pixel em função da intensidade de seus vizinhos ponderados por uma matriz de pesos chamada máscara de convolução. Esta máscara de convolução tem diversos tamanhos sendo a mais usada a de  $3 \times 3$ , porém, máscaras com tamanhos diferentes podem dar resultados significativos pelo que é importante analisar outros tamanhos de filtros.

Podem-se encontrar diversos trabalhos propondo a utilização da redes neurais MLP para filtrar imagens (Patiño-Escarcina and Costa, 2007), (Venkatesh et al., 2006), (Kenji et al., 2002), (Kenji et al., 2003), (Spreeuwiers, 1991), (Yin et al., 1993), (Zhang, 2001), (Arakawa and Harashima, 1990), etc. Nestes trabalhos, a rede MLP obtém um ótimo desempenho. Porém, sendo a rede RBF similar e em muitos casos superior à MLP, acredita-se que é interessante avaliar seu comportamento no problema de reduzir ruído impulsivo em imagens monocromáticas.

O processo de filtragem neural é similar à convolução espacial: a entrada é uma imagem a ser processada e as respostas da rede neural vão gerar a imagem filtrada. Este processo é mostrado na figura 1.

No treinamento, um padrão de entrada é formado pelos pixels em uma submatriz do tamanho do filtro de uma imagem ruidosa e a saída desejada será um pixel sem ruído que é a resposta da

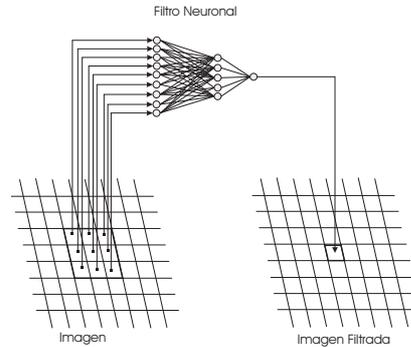


Figura 1: Processo de Filtragem usando Redes Neurais Supervisionadas

convolução da imagem com o filtro. Neste sentido, a rede neural tem que aprender o processamento feito pelo filtro para conseguir um pixel sem ruído.

### 4 Estabelecimento do Conjunto de Treinamento

Foram projetados 4 filtros neurais RBF treinados com 1000 padrões escolhidos aleatoriamente. O primeiro filtro foi treinado com padrões de uma imagem corrompida com 5% de ruído, o segundo com 10%, o terceiro e o quarto com 20% e 40% de ruído impulsivo, respectivamente. Para a rede MLP foram implementados 4 filtros equivalentes treinados similarmente com padrões de imagens corrompidas por 5%, 10%, 20% e 40%.

Estes filtros serão denominados pela porcentagem de ruído presente nos padrões de treinamento, por exemplo o filtro neural MLP treinado com padrões de uma imagem corrompida com 5% de ruído é chamado de MLP 5% assim temos MLP 10%, MLP 20% e MLP 40%. No caso da rede RBF foi tomado o mesmo critério RBF 5%, RBF 10%, RBF 20% e RBF 40%.

### 5 Estabelecimento do tamanho da Máscara

Os testes serão feitos com filtros de tamanho  $3 \times 3$ ,  $5 \times 5$  e  $7 \times 7$  que são os mais comuns. A arquitetura das rede MLP e RBF tem na primeira camada  $n$  entradas que denotam o tamanho do filtro escolhido. Para os filtros MLP, a camada intermédia tem  $k$  neurônios intermediários, estabelecidos pela média entre o número de entradas e o número de saídas (Yuan et al., 2003). A camada de saída tem um único neurônio que representa o pixel central de máscara.

A arquitetura dos filtros RBF foi escolhida com mesmo critério que na rede MLP, porém depois do treinamento com 5000 épocas não foram obtidos bons resultados, Assim, foram testados varias arquiteturas e foi estabelecido que para um filtro de  $3 \times 3$  o número de centros na camada es-

condida será 10, com uma máscara  $5 \times 5$  o número de centros foi estabelecido em 20 e com a máscara de  $7 \times 7$  foi estabelecido em 30 centros.

## 6 Método de Análise de Eficiência

Para estabelecer a eficiência da rede neural RBF no problema de reduzir ruído impulsivo foi usada o método proposto em (Patiño-Escarcina and Costa, 2007) para poder comparar-la com a rede MLP e com filtros tradicionais. Neste método é proposto usar 3 fatores de eficiência e combiná-las para obter um índice total para cada filtro  $y$  como mostrado na equação 1. Onde, o conjunto de teste contém  $P$  imagens e  $q$  representa a  $q$ -ésima imagem em  $P$

$$Ef(y) = \frac{\sum_{q=1}^P f_1(q) + 0.5 f_2(q) - 0.5 f_3(q)}{P} \quad (1)$$

O fator 1 ( $f_1$ ) dado pela equação 2 mede a relação sinal/ruído entre a imagem filtrada  $G_q$  e a imagem ideal sem ruído  $I_q$ . No índice total, este fator tem um peso de 1 devido a que é avaliado em toda a imagem. Onde  $N$  e  $M$  são as dimensões da  $q$ -ésima imagem,  $\mu_I$  é a média das intensidades da matriz  $I_q$  e  $erro(i, j)$  esta definido pela equação 3.

O fator 2 ( $f_2$ ) dado pela equação 4 mede a porcentagem da redução de ruído nos pixels ruidosos  $(i, j)$ .  $I_q(i, j)$  define a intensidade do pixel  $(i, j)$  na matriz sem ruído,  $G_q(i, j)$  é a intensidade do pixel  $(i, j)$  na imagem filtrada (saída do filtro) e  $M_q(i, j)$  define a intensidade do pixel  $(i, j)$  na imagem ruidosa (imagem a ser filtrada).  $R$  é o número de pixels ruidosos em  $M_q$ .

O fator 3 ( $f_3$ ) é calculado pela equação 5 que é avaliada só nos pixels não ruidosos  $(i, j)$  de  $M$ . Onde  $S$  é o número de pixels que não foram corrompidos com ruído na imagem  $M$  e  $\mu_S$  esta definido pela equação 6.

$$f_1(q) = SNR(q) = 10 \log_{10} \frac{\sum_{i=1}^N \sum_{j=1}^M (I(i, j) - \mu_I)^2}{\sum_{i=1}^N \sum_{j=1}^M (erro(i, j))^2} \quad (2)$$

$$error(i, j) = I_q(i, j) - G_q(i, j) \quad (3)$$

$$f_2(q) = \frac{\sum_{i,j}^R \left( 100 - \frac{|G_q(i, j) - I_q(i, j)|}{100|M_q(i, j) - I_q(i, j)|} \right)}{R}, \quad \forall i, j / I_q(i, j) \neq M_q(i, j) \quad (4)$$

```
FOR Para cada tamanho de filtro DO
  FOR Para cada filtro DO
    FOR Para cada porcentagem de ruído DO
      FOR i:=1 to 27 DO {//número de imagem}
        a=Ler imagem(i)
        b=Simular_ruído(a, porcentagem de ruído)
        c=Filtrar(b)
        calcular fatores de eficiência
      END
    END
  END
  Calcular a media para cada fator de eficiência
END
END
```

Figura 2: Procedimento para calcular a eficiência nos filtros

$$f_3(q) = 4 * \sqrt{\frac{1}{S} \sum (G_q(i, j) - M_q(i, j) - \mu_S)^2}, \quad \forall (i, j) / I_q(i, j) = M_q(i, j) \quad (5)$$

$$\mu_S = \frac{\sum^S G_q(i, j) - M_q(i, j)}{S} \quad (6)$$

## 7 Experimentos

A eficiência dos filtros foi testada usando 27 imagens diferentes as quais foram corrompidas com ruído impulsivo em diversos porcentagens e depois filtradas comparando os resultados com as imagens ideais (livre de ruído). As porcentagens de ruído com as quais as imagens foram corrompidas para testar os filtros são: 2%, 4%, 8%, 16% e 32%. Os experimentos foram feitos acordo é explicado na figura 2.

## 8 Resultados

Com exemplo visual dos testes realizados, a figura 3 mostra o resultado da filtragem neural de uma imagem corrompida com 2% de ruído impulsivo para filtros de  $3 \times 3$ . Pode-se observar que o resultado da filtragem para a rede MLP 5% foi melhor.

A figura 4 apresenta os resultados para o primeiro fator, o sinal/ruído entre a imagem resultante de cada filtro e a imagem ideal (imagem sem ruído), a figura 5 mostra os resultados para o segundo fator e a figura 6 apresenta o 3 fator de eficiência para filtros de  $3 \times 3$ . As figuras 7, 8 e 9 mostram os resultados para os 3 fatores de eficiência para filtros de tamanho  $5 \times 5$  e as figuras 10, 11, 12 mostram os resultados para filtros de tamanho  $7 \times 7$ . Nas gráficas para o 3 fator em todos os tamanhos de máscara foi omitido o resultado do filtro media devido a que os resultados são muito altos indicando o pior índice. Pelos resultados obtidos na figura 4 do sinal/ruído medida entre a imagem degradada e a imagem sem ruído, podemos dizer que o filtro MLP de  $3 \times 3$  treinado



(a) Percep 5%

(b) RBF 5%



(c) Percep 10%

(d) RBF 10%

Figura 3: Exemplos do Resultado de Filtragem com Filtros Neurais RBF e MLP com vizinhança  $3 \times 3$

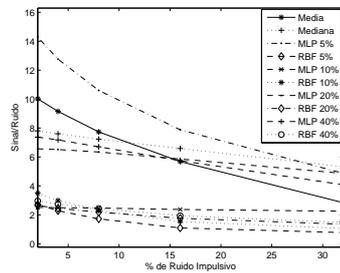


Figura 4: Fator 1 : Sinal/Ruído vs Porcentagem de Ruído na Imagem para máscara de  $3 \times 3$

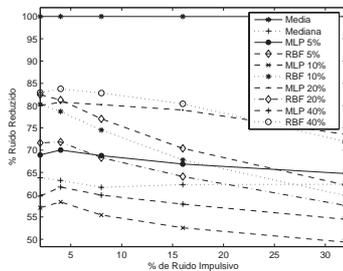


Figura 5: Fator 2 : Porcentagem de Ruído Reduzido em Pixels Ruidosos vs Porcentagem de Ruído na Imagem para máscara de  $3 \times 3$

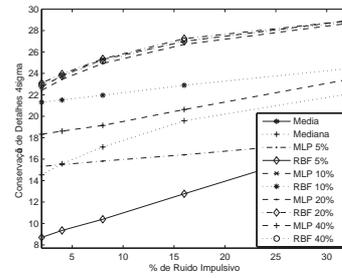


Figura 6: Fator 3 : Conservação de Detalhes ( $4\sigma$ ) vs Porcentagem de Ruído na Imagem para máscara de  $3 \times 3$

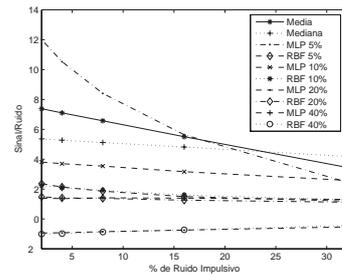


Figura 7: Fator 1 : Sinal/Ruído vs Porcentagem de Ruído na Imagem para máscara de  $5 \times 5$

com 5% consegue reduzir melhor o ruído para imagens corrompidas com até 32% de ruído impulsivo. Este resultado é importante porque mesmo a rede sendo treinada com padrões com pouco ruído consegue reduzir até 32% de ruído impulsivo.

Analisando o segundo fator de eficiência para filtros de  $3 \times 3$ , a figura 5 mostra que o filtro mediana é mais eficiente na redução de ruído impulsivo para os pixels ruidosos, porém observando os resultados para o terceiro fator, vemos que ao mesmo tempo que filtro reduz o ruído impulsivo, adiciona ruído aos pixels que não tinham ruído deteriorando a qualidade na imagem.

Pelo fator 3 de eficiência calculado para filtros de  $3 \times 3$ , a figura 6 mostra que o filtro RBF 5% conserva mais os detalhes da imagem filtrada porém para o fator 1 na figura 4 obtém um dos piores índices. Estes resultados são mostrados na figura 3 ao observar a imagem filtrada por este filtro.

Concluindo, para filtros de tamanho  $3 \times 3$ , o filtro Perceptron treinado com padrões com 5% de ruído é mais eficiente na redução de até 32% ruído impulsivo. Para filtros de tamanho  $5 \times 5$ , o MLP de 5% foi mais eficiente em relação aos outros filtros. Para filtros de tamanho  $7 \times 7$ , a rede RBF treinada com padrões com 10% de ruído impulsivo é mais eficiente na redução de ruído. As figuras 13, 14 e 15 apresentam o resultado do cálculo da eficiência pela equação 1 para os filtros testados.

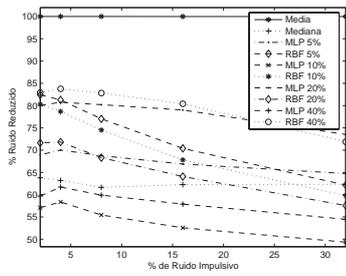


Figura 8: Fator 2 : Porcentagem de Ruído Reduzido em Pixels Ruidosos vs Porcentagem de Ruído na Imagem para máscara de  $5 \times 5$

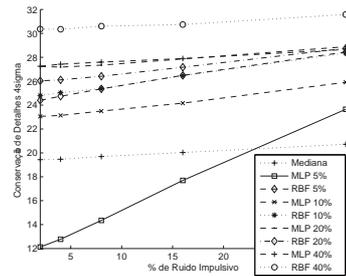


Figura 9: Fator 3 : Conservação de Detalhes ( $4\sigma$ ) vs Porcentagem de Ruído na Imagem para máscara de  $5 \times 5$

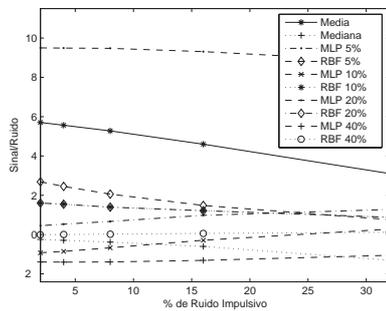


Figura 10: Fator 1 : Sinal/Ruído vs Porcentagem de Ruído na Imagem para máscara de  $7 \times 7$

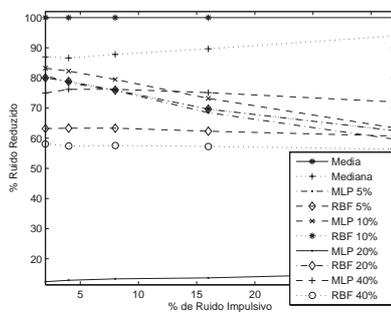


Figura 11: Fator 2 : Porcentagem de Ruído Reduzido em Pixels Ruidosos vs Porcentagem de Ruído na Imagem para máscara de  $7 \times 7$

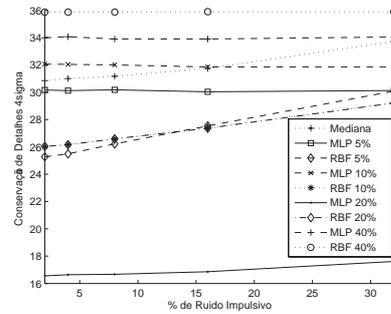


Figura 12: Fator 3 : Conservação de Detalhes ( $4\sigma$ ) vs Porcentagem de Ruído na Imagem para máscara de  $7 \times 7$

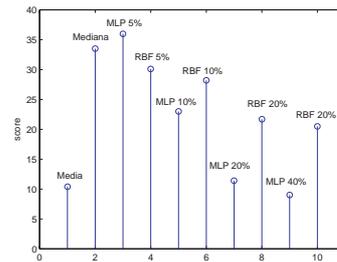


Figura 13: Eficiência na Redução de Ruído Impulsivo com uma Máscara de  $3 \times 3$

## 9 Conclusões

As redes neurais MLP e RBF são ferramentas que tem-se mostrado muito eficientes na solução de diversos problemas. Nosso trabalho tenta fazer uma análise da eficiência destas redes para a redução de ruído impulsivo. Foram fixados parâmetros tais como arquitetura, coeficiente de aprendizado e analisado o conjunto de treinamento e o tamanho do filtro para avaliar a eficiência. Em análises feitas, os resultados apontaram o filtro MLP treinado com padrões com 5% de ruído impulsivo mais eficiente na redução de ruído impulsivo em imagens degradadas com até 32 % para uma máscara de  $3 \times 3$ . Isto, devido a que recupera os pixels ruidosos e adiciona menor ruído nos pixels não ruidosos conservando assim detalhes da imagem. Para filtros com tamanho de  $5 \times 5$  estes resultados também foram alcançados, porém para filtros de tamanho  $7 \times 7$  a rede RBF treinada com padrões com 10% de ruído obtém maior eficiência na redução de ruído. Em geral, os filtros neurais apresentam uma maior eficiência na redução de ruído impulsivo em comparação com os filtros tradicionais.

## Agradecimentos

Este trabalho é suportado pelo Conselho Nacional de Desenvolvimento Científico e Tec-

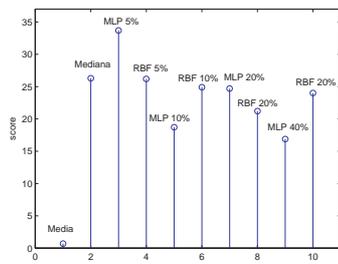


Figura 14: Eficiência na Redução de Ruído Impulsivo com uma Máscara de  $5 \times 5$

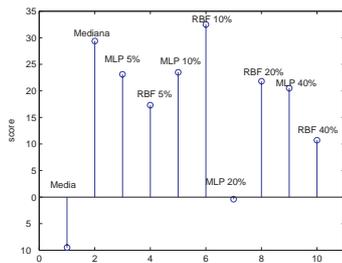


Figura 15: Eficiência na Redução de Ruído Impulsivo com uma Máscara de  $7 \times 7$

nológico CNPq/Brasil.

## Referências

- Arakawa, K. and Harashima, H. (1990). A nonlinear digital filter using multi-layered neural networks, *IEEE International Conference on Communications*, Vol. 2, pp. 424–428.
- Foody, G. M. (2004). Supervised image classification by mlp and rbf neural networks with and without an exhaustively defined set of classes, *International Journal of Remote Sensing* **25**(15).
- Jung-Wook, P., Harley, R. G. and Venayagamoorthy, G. K. (2002). Comparison of mlp and rbf neural networks using deviation signals for indirect adaptive control of a synchronous generator, *International Joint Conference on Neural Networks*, pp. 919–924.
- Kenji, S., Isao, H. and Sugie, N. (2002). Efficient approximation of neural filters for removing quantum noise from images, *IEEE Transactions on Signal Processing* **50**: 1787–1799.
- Kenji, S., Isao, H. and Sugie, N. (2003). Neural edge enhancer for supervised edge enhancement from noisy images, *IEEE Transactions on Pattern Analysis and Machine Intelligence* **25**: 1582–1596.
- Oliveira, A. L. I., Neto, F. B. L. and de Lemos Meira, S. R. (2004). Combining mlp and rbf neural networks for novelty detection in short time series., in R. Monroy, G. Arroyo-Figueroa, L. E. Sucar and J. H. S. Azuela (eds), *MICAI*, Vol. 2972 of *Lecture Notes in Computer Science*, Springer, pp. 844–853.
- Papaioannou, I. V., Roussaki, G. and Anagnostou, M. E. (2006). Comparing the performance of mlp and rbf neural networks employed by negotiating intelligent agents, *IEEE/WIC/ACM International Conference on Intelligent Agent Technology (IAT 2006 Main Conference Proceedings) (IAT'06)*, pp. 602–612.
- Patiño-Escarcina, R. E. and Costa, J. A. F. (2007). An evaluation of mlp neural network efficiency for image filtering, *Seventh International Conference on Intelligent Systems Design and Applications ISDA 2007*, p. To appear.
- Spreeuwers, L. J. (1991). Neural network edge detector, in G. R. Arce, C. G. Boncelet and E. R. Dougherty (eds), *Proc. SPIE Vol. 1451, p. 204-215, Nonlinear Image Processing II, Gonzalo R. Arce; Charles G. Boncelet; Edward R. Dougherty; Eds.*, pp. 204–215.
- Venkatesh, Y. V., Raja, K. and Ramya, N. (2006). Multiple contour extraction from graylevel images using an artificial neural network, *IEEE Transactions on Image Processing* **15**(4): 892–899.
- Yampolskiy, R. and Novikov, D. (2003). Study of the choice between mlp and rbf neural networks for character recognition, *Western New York Image Processing Workshop*, pp. 84–87.
- Yin, L., Astola, J. and Neuvo, Y. (1993). A new class of nonlinear filters-neural filters, *IEEE Transactions on Signal Processing* **41**(3): 1201–1222.
- Yuan, H. C., Kiong, F. L. and Huai, X. Y. (2003). A method for estimating the number of hidden neurons in feed-forward neural networks based on information entropy, *Computers and Electronics in Agriculture* **40**(1-3).
- Zhang, X.-P. (2001). Thresholding neural network for adaptive noise reduction, *IEEE Transactions on Neural Networks* **12**(3): 567–584.