

PREPROCESSAMENTO EM SISTEMAS CONEXIONISTAS USANDO-SE WAVELETS E COMPONENTES PRINCIPAIS

Adriano Martins Moutinho

Depto. de Eletrônica e Telecomunicações – Universidade do Estado do Rio de Janeiro - Rua São Francisco Xavier 524, Bl. A, Sala 5036, 2559-900, Rio de Janeiro, RJ, Brasil
adriano_moutinho@hotmail.com

Luiz Biondi Neto

Depto. de Eletrônica e Telecomunicações – Universidade do Estado do Rio de Janeiro - Rua São Francisco Xavier 524, Bl. A, Sala 5036, 2559-900, Rio de Janeiro, RJ, Brasil
lbiondi@uerj.br

Pedro Henrique Gouvêa Coelho

Depto. de Eletrônica e Telecomunicações – Universidade do Estado do Rio de Janeiro - Rua São Francisco Xavier 524, Bl. A, Sala 5036, 2559-900, Rio de Janeiro, RJ, Brasil
phcoelho@uerj.br

Lidia Angulo Meza

Instituto de Ciência e Tecnologia – Universidade Veiga de Almeida
Rua Ibituruna, 108, 4º andar, Maracanã, 20271-020, Rio de Janeiro, RJ
lidia_a_meza@yahoo.com

Maurício José Ferrari Rey

Depto. de Estruturas e Fundações – Universidade do Estado do Rio de Janeiro - Rua São Francisco Xavier 524, Bl. A, Sala 5003, 2559-900, Rio de Janeiro, RJ, Brasil
mrey@uerj.br

Resumo

Este trabalho compara diversos métodos de pré-processamento usados em redes neurais artificiais (RNAs), e tenta escolher aquele que permita a melhor taxa de reconhecimentos corretos. Mesmo quando treinada com uma seqüência de dados consistentes um sistema conexionista pode não apresentar um bom desempenho.

Visando obter redes com maior poder de classificação há necessidade de se tratar o sinal de entrada, retirando-se as informações não relevantes.

As técnicas utilizadas para atingirmos esses objetivos são: compressão Wavelet, componentes principais e centralização.

Ao final é apresentado um estudo de caso, envolvendo o reconhecimento de dígitos manuscritos, comparando o desempenho da rede quando submetida aos sinais pré-processados usando-se as técnicas mencionadas.

Palavras-chave: Compressão Wavelet, Sistemas Conexionistas, Componentes Principais.

Abstract

This work compares several signal pre-processing methods used in artificial neural networks and tries to choose that one which yields the best correct recognition rate. Even when trained with a consistent data sequence, a connectionist system may not present a good performance. In order to obtain networks with greater classification power, there is a need to treat the input signal removing the non relevant information.

The used techniques to reach these objectives are: Wavelet Compression, Connectionist Systems, Principal Components

Finally a case study is included involving handwritten digits comparing the network performance when submitted to pre-processed signals using the mentioned techniques

Keywords: Wavelet Compression, Connectionist Systems, Principal Components.

1. Introdução:

As Redes Neurais Artificiais vêm sendo usadas com sucesso no reconhecimento de padrões gráficos há muitos anos [1, 2 e 4]. O projeto de RNAs consiste basicamente em duas etapas: treinamento e execução.

Durante a etapa de treinamento, a RNA recebe, sob forma matricial, o mapeamento entre os padrões de entrada e os respectivos alvos a serem atingidos. Os padrões de entradas referem-se aos dígitos obtidos de vários escritores diferentes e devidamente digitalizados.

O objetivo principal das RNAs é proceder o reconhecimento desses dígitos. Uma melhoria na capacidade de reconhecimento pode ser obtida através do pré-processamento aplicado aos padrões de entrada. Para isso foram usadas as técnicas de transformada wavelet [5 e 6], centralização e componentes principais [1 e 3].

As Wavelets são funções matemáticas que separam os dados segundo componentes de frequência diferentes e então analisam cada componente com uma resolução adequada à sua escala. As vantagens das transformadas de wavelets sobre os métodos tradicionais de Fourier [8] residem em sua capacidade de analisar sinais contendo descontinuidades [7].

Dessa forma, algumas características específicas de imagens e sinais de voz são mais facilmente extraídas usando a transformada de wavelet. A Figura 1 mostra o diagrama em blocos de uma aplicação típica da técnica de decomposição por wavelets. O sinal de entrada é então injetado em dois filtros, um passa alta e um passa baixa. A seguir os sinais resultantes são comparados com Wavelets geradas a partir de uma Wavelet mãe, com diversos tamanhos e frequências diferentes. As saídas finais do processo de compressão são sub-amostradas (*downsampling*) e representam as novas versões do sinal: uma aproximada e outra com detalhes.

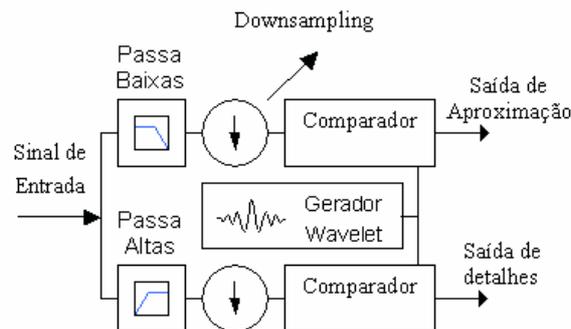


Figura 1 – Exemplo de decomposição Wavelet.

O uso de Wavelets no tratamento de imagens de dígitos manuscritos é ilustrado na Figura 2, que mostra o dígito 1 produzido originalmente por um escritor com resolução 32x32 pixels que é transformado em 16x16 pixels.

Nota-se que o sinal de aproximação é quase idêntico ao original, possuindo praticamente todas as suas características relevantes. Com a redução da dimensão da matriz de entrada a demanda computacional do processo de ajuste de pesos das RNAs decresce.

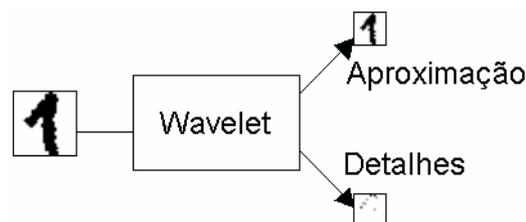


Figura 2 – Decomposição em Wavelets do dígito 1

O método de componentes principais [3] é uma técnica de redução da dimensão dos dados de entrada sem eliminar informações relevantes. A análise de componentes principais maximiza a taxa de redução da variância [1], sendo, portanto bastante adequada à nossa aplicação.

2. Introdução teórica

Nesta seção serão introduzidos conceitos teóricos sobre as técnicas de pré-processamento utilizadas nos sinais a serem treinados e testados com a rede neural.

2.1. Transformada de Wavelets

Matematicamente, o processo da análise de Fourier é a soma, sobre todo o intervalo de tempo, de um sinal $f(t)$, multiplicado por uma exponencial complexa.

Os resultados da transformação são os coeficientes de Fourier $F(\omega)$. Estes quando somados, devidamente multiplicados por suas respectivas senóides de frequência ω , resultam no sinal original. Graficamente, o processo pode ser representado como na figura 3, e através da equação 1:

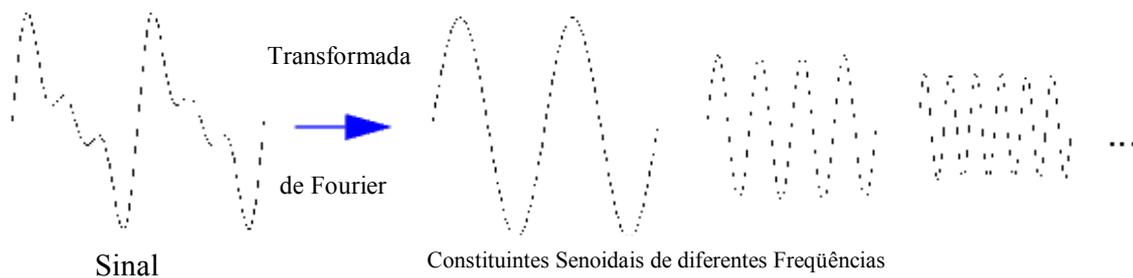


Figura 3 – Processo da Transformada de Fourier.

$$F(W) = \int_{-\infty}^{\infty} f(t) \cdot e^{j\omega t} dt$$

(Equação 1)

Similarmente, a transformada contínua de *Wavelet* (CWT) é definida como a soma sobre todo o intervalo de tempo do sinal multiplicado por versões escalonadas e deslocadas da função *Wavelet* ψ , que é obtida de forma a efetuar o casamento com os filtros passa baixa e passa alta da figura 1. A função geradora da transformada pode ser vista na equação 2.

$$C(escala, posição) = \int_{-\infty}^{\infty} f(t) \cdot \psi(escala, posição, t) dt$$

(Equação 2)

Os resultados do CWT são muitos coeficientes C da transformada de *Wavelet*, que são função da escala e da posição das ondas que constituem a transformada. A figura 4 mostra o processo que se assemelha a transformada de Fourier:

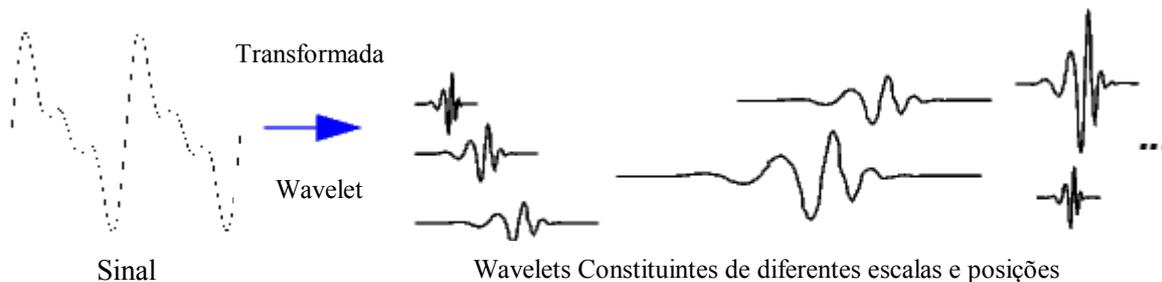


Figura 4 – Processo da Transformada de *Wavelet*.

2.2. Componentes Principais (PCA)

O método de componentes principais [3] é uma forma de reduzir a dimensão dos dados de entrada sem eliminar informação relevante. É especialmente útil no tratamento dos dados aplicados à rede neural, pois reduz a dimensão da entrada, possibilitando treinamentos mais rápidos e até mesmo o aumento da generalização.

Inicialmente considera-se um vetor X de dados de entrada tendo média nula, ou seja $E[X] = 0$. Considera-se então, que o vetor X é projetado em outro vetor unitário q . A projeção A é o produto interno dos dois vetores conforme mostra a equação 3:

$$A = X^T q = q^T X \quad (\text{Equação 3})$$

A variância do vetor projetado é função de q , e é representado por $\psi(q)$:

$$\psi(q) = \sigma^2 = E[A^2] = E[(q^T X)(X^T q)] = q^T R q \quad (\text{Equação 4})$$

O vetor R na Equação 4 é definido como matriz autocorrelação, sendo igual a:

$$R = E[XX^T] \quad (\text{Equação 5})$$

Deve-se encontrar então quais vetores q possibilitam que a variância da projeção seja extrema ou estacionária. Neste caso, pequenas perturbações em q não modificam o valor da variância [1]:

$$\psi(q) = \psi(q + \partial q) = (q + \partial q)^T R (q + \partial q) \quad (\text{Equação 6})$$

Desenvolvendo a equação 6 e eliminando os termos de segunda ordem temos:

$$\psi(q + \partial q) = \psi(q) + 2(\partial q)^T R q \quad (\text{Equação 7})$$

Assim, como a Equação 6 mostra que as perturbações não influenciam na variância, temos:

$$(\partial q)^T R q = 0 \quad (\text{Equação 8})$$

Adicionalmente, como a perturbação ∂q não pode mudar o módulo do vetor unitário q , pode-se admitir que ∂q e q são ortogonais, ou seja, apenas uma mudança de direção será tolerada:

$$\partial q^T q = 0 \quad (\text{Equação 9})$$

Combinando as Equações 8 e 9, sendo que nesta última adiciona-se um fator de escala λ pois os elementos q são adimensionais, temos:

$$(\partial q)^T (Rq - \lambda q) = 0 \quad (\text{Equação 10})$$

$$Rq = \lambda q \quad (\text{Equação 11})$$

A Equação 11 é um problema típico de álgebra linear e possui solução não trivial quando temos λ igual aos autovalores e q aos autovetores da matriz R . Assim, se existem m autovalores para a matriz R , temos:

$$Rq_j = \lambda_j q_j \quad \text{para } j = 1, 2, \dots, m \quad (\text{Equação 12})$$

Ou, equivalentemente, considerando que $q_j^T = q_j^{-1}$:

$$q_j^T R q_j = \lambda_j \quad \text{para } j = 1, 2, \dots, m \quad (\text{Equação 13})$$

Se considerarmos novamente o vetor a_j como a projeção de X sobre o unitário q_j , teremos:

$$a_j = q_j^T X \quad \text{para } j = 1, 2, \dots, m \quad (\text{Equação 14})$$

A Equação 14 é considerada como a fórmula de análise de componentes principais, que decompõe o vetor de entrada em projeções sobre q_j . O vetor X pode ser reconstituído completamente com a fórmula da equação 15, conhecida como equação de síntese:

$$X = \sum_{j=1}^m a_j q_j \quad (\text{Equação 15})$$

Se ao invés de reconstituirmos o vetor X completamente com todas as suas projeções, truncarmos o somatório da Equação 15 após n termos, um novo vetor \bar{X} terá sua dimensão reduzida a n . Por causa deste truncamento, temos um erro igual ao somatório de todas as variâncias das projeções eliminadas, ou seja:

$$\sum \xi_{TRUNCAMENTO} = \sum_{j=n+1}^m a_j q_j \quad (\text{Equação 16})$$

Segundo a Equação 14, a variância das projeções é $q_j^T R q_j$ e, segundo a Equação 13, $q_j^T R q_j$ é igual ao autovalor associado à projeção. Assim, a variância da projeção eliminada é igual ao autovalor associado:

$$\sum_{j=n+1}^m \sigma_{\text{Eliminada}}^2 = \sum_{j=n+1}^m \lambda_j \quad (\text{Equação 17})$$

Portanto, se calcularmos primariamente os m autovalores da matriz autocorrelação R de X e colocarmos os mesmos em ordem crescente, poderemos eliminar apenas as projeções dos menores autovalores, o que garantirá uma redução na dimensão de X com a menor perda possível de variância, ou seja, de informação [1].

Ao aplicarmos o método de componentes principais, deveremos ter um conjunto de dados o maior possível, para que a análise conclua corretamente quais são os elementos das imagens que realmente não possuem nenhuma informação relevante.

O método de componentes principais pede duas entradas: uma matriz contendo todas as figuras, e um valor em porcentagem pré-fixada. Os elementos que contribuírem com valores menores que esta porcentagem serão eliminados. Resultam como saídas duas matrizes: uma matriz de entrada de dimensão menor, contendo todas as figuras, e uma matriz de transformação que será usada na fase de testes, para transformar da mesma forma os dados que forem testados.

3. Reconhecimento Neural dos Dígitos

Para atingirmos nossos objetivos faremos uso de um banco de dados (BD) contendo 1000 imagens de dígitos manuscritos, produzidos por diferentes escritores. Esse BD depois de devidamente preparado será usado para treinar a rede, enquanto outro de mesmo tamanho será usado para a validação.

Para garantir-se o ponto ótimo de parada do algoritmo de treinamento das RNAs usa-se a técnica de validação. Ela consiste na aplicação de mais um conjunto de dados, diferentes dos usados no treinamento das RNAs.

O resultado desse novo conjunto de dados gera uma outra curva denominada de curva de generalização que indica o grau de reconhecimento atingido. O ponto no qual essa curva muda de concavidade é o ponto ótimo de parada do algoritmo de treinamento da RNA [1]. Assim evitam-se as situações indesejáveis de sobre-treinamento (*overfitting*) e sub-treinamento (*underfitting*) que em última análise prejudicam a generalização da rede.

A rede neural investigada recebe informações relativa a 32 entradas no caso de não existir pré-processamento e 16 caso exista. Possui 3 camadas ocultas uma de 64, duas de 20 neurônios e uma camada de saída de 10 neurônios, um correspondente a cada dígito. Todas as camadas têm função de ativação sigmóide. A Figura 5 mostra a arquitetura da RNA usada.

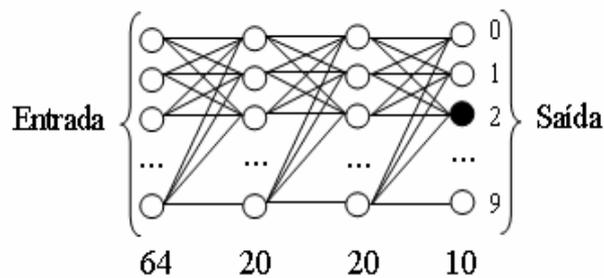


Figura 5 – Arquitetura da RNA

2.1 Reconhecimento sem Pré-processamento

A Figura 6 mostra as curvas de treinamento e validação obtidas na fase de treinamento da rede neural investigada, sem pré-processamento. A curva em preto é o somatório do erro quadrático (SSE) em função do número de épocas no treinamento. A curva em cinza representa a curva de validação do treinamento.

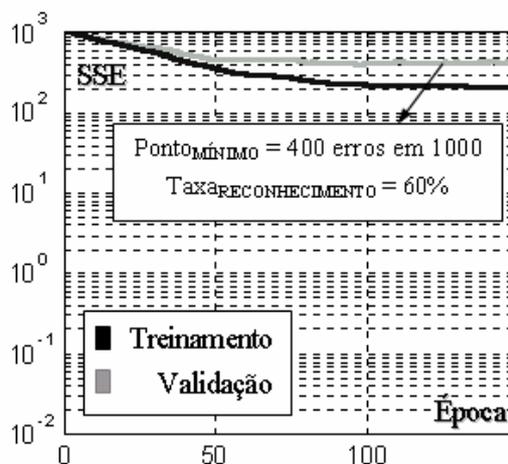


Figura 6 – Treinamento sem pré-processamento

O mínimo da curva de validação ocorre próximo à época 100 e vale aproximadamente 400. Assim, como tínhamos 1000 dígitos no treinamento, a taxa de reconhecimento chegou a 60 %, indicando, em princípio, a necessidade de algum tipo de pré-processamento.

Foram realizados mais de 1000 testes e os resultados confirmaram a taxa de reconhecimento prevista.

A Tabela 1 mostra os resultados de 5 testes satisfatórios para entradas manuscritas 3, 1, 2, 5 e 9 e que não fizeram parte do treinamento.

Tabela 1 – Resultados da Rede Neural sem Pré-processamento.

Saídas da Rede	1	2	3	4	5	6	7	8	9	0
3	.01	.03	.89	.01	.02	.00	.01	.02	.01	.01
1	.88	.03	.01	.01	.02	.01	.00	.02	.01	.01
2	.00	.98	.02	.03	.00	.00	.00	.02	.01	.01
5	.01	.03	.02	.01	.91	.01	.00	.02	.01	.01
9	.01	.03	.00	.01	.02	.00	.01	.02	.86	.01

2.2 Reconhecimento com Wavelet

A técnica de compressão por wavelet é utilizada para reduzir a dimensão dos arquivos dos dígitos de 32x32 para 16x16 pixels. Esses arquivos reduzidos representam as imagens relativas aos dígitos manuscritos sem perda de informação relevante.

Usando-se agora como padrão de treinamento os novos arquivos com dimensão reduzida obtém-se um reconhecimento de cerca de 70 %, isto é, 10 % maior que o treinamento sem pré-processamento. Outros métodos podem ser aplicados para melhorar o reconhecimento. A figura 7 mostra a evolução do treinamento utilizando Wavelets como técnica de pré-processamento.

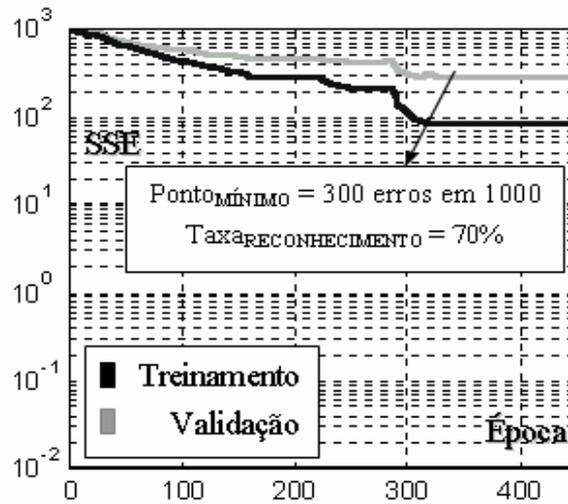


Figura 7 – Treinamento com Wavelet.

2.3 Reconhecimento com Centralização

A técnica de centralização visa uniformizar a informação fornecida pelas entradas que se apresentam com variações de posição de acordo com o escritor.

Analisando-se as imagens representativas dos dígitos é possível observar que não existem informações relevantes na sua posição horizontal e vertical. Isso ocorre porque as imagens dos dígitos centralizados são mais homogêneas, diminuindo a variância dos dados e sem retirar informações relevantes.

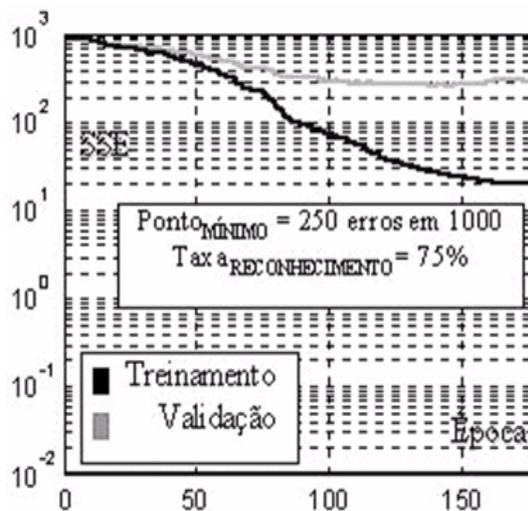


Figura 8 – Treinamento com Wavelet e centralização.

Os resultados do treinamento das RNAs utilizando a técnica de centralização alcançaram uma taxa de reconhecimento próxima de 70 %, analogamente ao reconhecimento com wavelet.

A centralização aliada a outras técnicas pode ser bastante útil. A Figura 8 mostra as curvas de treinamento e validação utilizando-se a técnica de centralização em conjunção com a compressão wavelet.

Nesse caso a taxa de reconhecimento correto é da ordem de 75%.

2.4 Reconhecimento com Eliminação de Espaços Brancos

Uma técnica semelhante a centralização é a técnica de retirada de espaços brancos.

O método consiste em detectar a janela mínima que corta a imagem do dígito sem perda de nenhuma linha que contenha pelo menos um ponto preto. A Figura 9 ilustra o método aplicado ao dígito “6”.

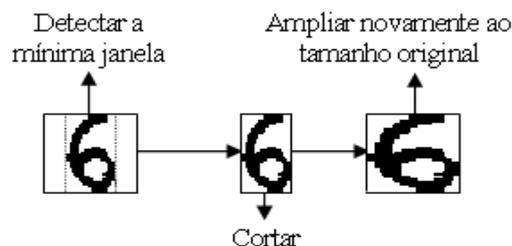


Figura 9 – Técnica de Retirada de Brancos

Como pode ser visto por simples inspeção da Figura 10 esse método também realiza uma centralização, já que o dígito é cortado exatamente entre as linhas e colunas limítrofes do dígito.

Essa técnica foi sugerida em [9] apresentando melhorias nos resultados. Essa técnica quando aplicada em conjunto com wavelets atinge uma taxa de reconhecimentos corretos de cerca 78%, como mostra a Figura 8.

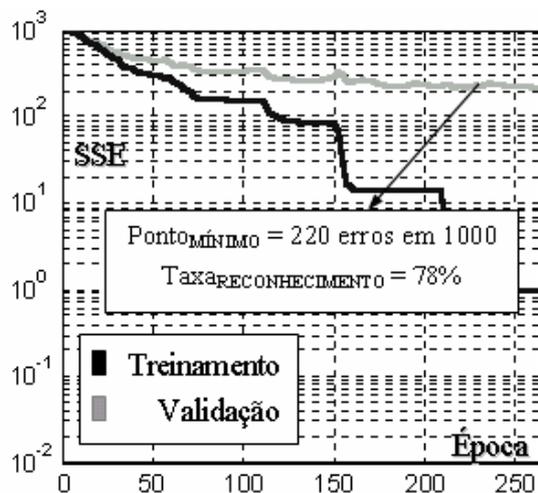


Figura 10 – Treinamento com wavelets e retirada de brancos

2.5 Método das Componentes Principais

O método de componentes principais também a dimensão da matriz de entrada excluindo os dados que possuem variância igual ou menor que do que um limiar pre-estabelecido pelo usuário.

Os testes executados com o BD disponível de indicaram que um valor de limiar de variância entre 0,0001 a 0,0005 é o mais adequado, mantendo-se as vantagens da redução da dimensão da matriz de entrada, sem comprometer as informações relevantes do sinal.

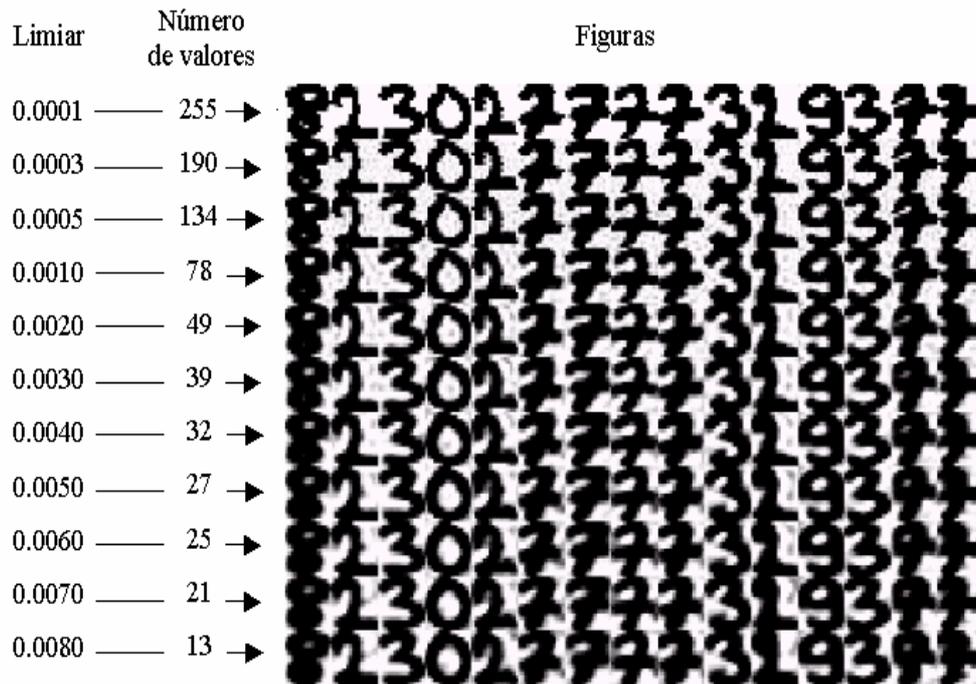


Figura 11 – Efeito do limiar da variância dos dígitos

Resultam como saídas desta técnica duas novas matrizes: uma de dimensão menor, contendo as informações referentes aos dígitos dígitos, e outra representando a transformação inversa que será usada para recuperar os resultados.

A Figura 12 mostra as curvas de reconhecimento e de validação usando-se, conjuntamente, as técnicas de componentes principais, wavelet e retirada de brancos, resultando numa taxa de reconhecimento de 83%.

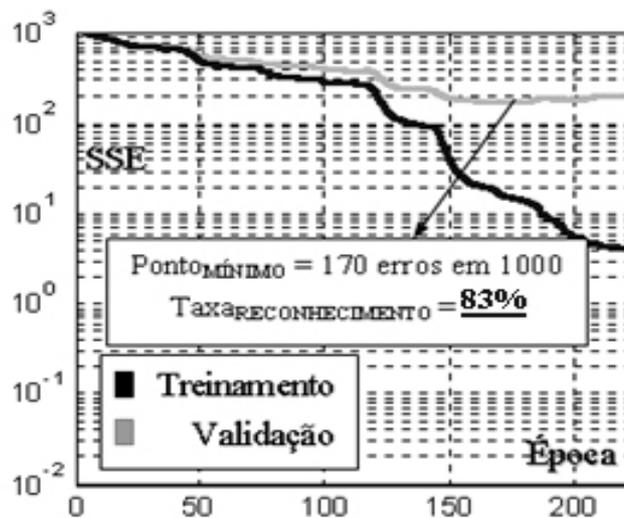


Figura 12 – Treinamento com Wavelet, retirada de espaços brancos e componentes principais .

3. Conclusões

A Tabela 2 sintetiza a evolução dos testes realizados com e sem pré-processamento. Nela pode ser verificado que enquanto não foi introduzida qualquer técnica de pré-processamento a taxa de reconhecimento correto mostrou-se baixa.

Usando-se apenas wavelet conseguiu-se um adicional de 10 % na taxa de reconhecimento que ainda era insuficiente.

Com o uso da técnica de centralização integrada com wavelets os resultados obtidos se mostraram melhores que os anteriores indicando que a utilização conjunta de varias técnicas de pré-processamento trariam resultados ainda melhores.

Usando-se a técnica de retirada de brancos em substituição à de centralização os resultados sofreram uma pequena melhora.

A melhor combinação de técnicas empregadas no BD disponível foi a que usou conjuntamente wavelet, retirada de brancos e componentes principais.

É importante ressaltar que ainda é possível obter taxas de reconhecimentos corretos superiores aos alcançados. Uma boa prática seria utilizar um BD pelo menos 100 vezes maior.

Tabela 2 - Quadro Comparativo

Pré-processamentos utilizados	Validação (SSE mínimo)	Taxa de acertos
Nenhum.	400	60 %
Wavelet	300	70 %
Wavelet e Centralização.	250	75 %
Wavelet e Retirada de Brancos.	220	78 %
Wavelet, Retirada de brancos e Componentes Principais.	170	83 %

4. Bibliografia

- [1] Haykin S. Neural Networks, a comprehensive Foundation, 2^a edition. Prentice Hall Press, New Jersey, 1999.
- [2] Shepherd, G.M. and C. Koch., The synaptic organization of the brain, Oxford University Press, New York, 1990.
- [3] Johnson R. A., Applied Multivariate Statistical Analysis, Prentice-Hall, EUA, 1998.
- [4] Zurada J. M., Introduction to Artificial Neural Systems, West Publishing Company, New York, 1992.
- [5] Kaiser G., A Friendly Guide to Wavelets, Birkhäuser, Boston, USA, 1994.
- [6] Raughveer M. Rao, Ajit S. Bopardikar, Wavelet Transforms Introduction to Theory and Applications, Addison-Wesley, Massachusetts, USA, 1998.
- [7] Wickerhauser V., Adapted Wavelet Analysis from Theory to Software, AK Peters, Boston, 1994.
- [8] Folland, G. B., Fourier Analysis and its Applications, Wadsworth and Brooks/Cole Mathematics Series, USA 1992.
- [9] Moutinho, A. M ., Cabral R., M. e Caon, C. Q., Classificação de dígitos manuscritos usando redes neurais artificiais. Rio de Janeiro: UERJ. Monografia de final de curso – Departamento de Engenharia Eletrônica e Telecomunicações, Universidade do Estado do Rio de Janeiro, 2002.
- [10] Moutinho, A. M. e Biondi, L. N., Comparação de métodos de pré-processamento aplicados a redes neurais artificiais. II congresso de Brasileiro de Computação, Universidade do Vale do Itajaí, Santa Catarina, 2002.