

# CLASSIFICAÇÃO DE PADRÕES DE VARREDURA DE RADARES

JORGE C. P. FILHO, DIEGO B. HADDAD, LUIZ P. CALOBA

LPS, COPPE, UFRJ

21941-947, Rio de Janeiro, RJ, Brasil

PADS, COPPE, UFRJ

21941-947, Rio de Janeiro, RJ, Brasil

LPS, COPPE, UFRJ

21941-947, Rio de Janeiro, RJ, Brasil

E-mails: [jcpfilho@lps.ufrj.br](mailto:jcpfilho@lps.ufrj.br), [diego@pads.ufrj.br](mailto:diego@pads.ufrj.br), [caloba@ufrj.br](mailto:caloba@ufrj.br)

**Abstract**— This article describes a not-cognitive approach, feedforward Neural Networks and SVM (Support Vector Machine), to classifiers of pulsed Radar's pattern of scan. This work is very important as for defense tactical systems as for Intelligence strategical systems.

**Keywords**— Radar, Type of Scan, Neural Network, Support Vector Machine, Defense, Warfare

**Resumo**— Este artigo descreve abordagens não cognitivas, de Redes Neurais *feedforward* e SVMs (*Support Vector Machine*), para classificadores de padrões de varredura de radares pulsados. Este trabalho se revela de grande valia em sistemas táticos de defesa, bem como para sistemas estratégicos de inteligência.

**Palavras-chave**— Radares, Padrões de Varredura, Redes Neurais, SVM, Defesa, Guerra Eletrônica.

## 1 Introdução

No contexto da guerra eletrônica, não raro faz-se necessária uma identificação automática do tipo de varredura dos radares existentes na região, de forma a reconhecer a eventual presença de uma ameaça. Para tal, costuma-se utilizar um receptor MAGE (*ESM*), processando posteriormente as informações geradas pelo mesmo. Após uma clusterização não-supervisionada (processo de *deinterleaving* ou “desembaralhamento”) que distingue os diferentes radares, cumpre empregar um algoritmo de identificação que identifica o padrão de varredura de cada radar. Eis uma tarefa importante, pois, por exemplo, radares com varreduras do tipo cônicas e, especialmente, do tipo *lock-on* (na verdade, o estágio final da varredura cônica, quando ela consegue travar no alvo) podem representar ameaças sérias à sobrevivência da unidade, enquanto radares de varredura circular ou setorial não costumam se revelar como ameaças, vide Tabela 1.

Tabela 1. Padrões de varredura e seus empregos

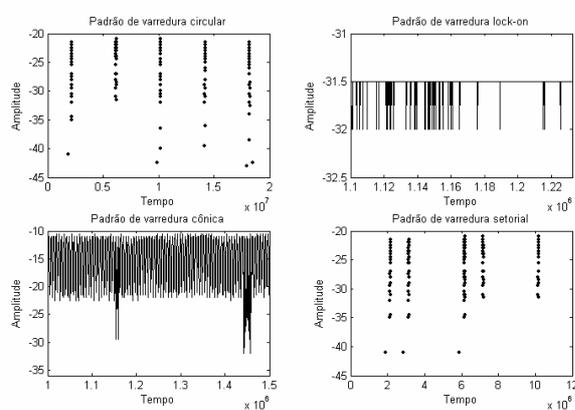
Padrão de VARREDURA	EMPREGO
Palmer	Controle de Armas/Busca
Circular	Busca
Setor	Busca
Helicoidal	Busca

Vertical	Determinador de altitude
Raster	Controle de armas/direção de tiro
Espiral	Controle de armas/Busca
Cônica	Acompanhamento de precisão
Chaveamento de Lóbulos	Acompanhamento de precisão
Horizontal/Vertical (TWS)	Busca e controle de armas
Monopulso	Controle de armas/direção de tiro

Os algoritmos de identificação em vigência costumam ser do tipo cognitivo. Porém, estes algoritmos apresentam desvantagens, entre as quais: sensibilidade ao ruído (o qual freqüentemente acompanha as medidas efetuadas) e dificuldades no tocante à manutenção e ao acréscimo de novas classes. De posse desta problemática, este artigo propõe alternativas que utilizam métodos de reconhecimento de padrões baseados em redes neurais e em máquinas de vetores suporte. Na realidade, os algoritmos tradicionais também são sensíveis em outros dois pontos nevrálgicos, a saber: perdas de pulsos e separação imperfeita na supracitada clusterização. Estas condições ocorrem comumente, implicando uma degradação no desempenho do sistema de classificação. O recurso às redes neurais e máquinas de vetores suporte almeja ao menos atenuar esses obstáculos do reconhecimento.

O sistema MAGE (ESM) oferece uma extensa gama de parâmetros, muitos dos quais não se revelaram significativos para um bom desempenho da tarefa de reconhecimento, como por exemplo o parâmetro AOA (*angle of arrival*, ângulo de chegada da onda eletromagnética). Após diversas simulações, verificou-se que os parâmetros mais significativos para a tarefa desejada são apenas dois, a saber: medidas de instante de chegada do pulso (TOA, *time of arrival*, em  $\mu$ s) e amplitude recebida (em dB). Assim, com apenas estes dois parâmetros, nossa abordagem deverá identificar os tipos de varredura, que são numerosos. Este artigo se restringe à identificação dos mais comuns, em número de quatro, a saber: *a) lock-on, b) cônica, c) circular e d) setorial*. A seguir, evidenciam-se os padrões de Amplitude x TOA das quatro estirpes de varredura:

Figura 1. Padrões de Amplitude x TOA



Alguns algoritmos cognitivos tentam estimar o período de varredura, e eventualmente a frequência de natação (a frequência da modulação senoidal presente na varredura cônica), juntamente com o padrão de varredura do radar; porém, sendo eles interdependentes, é comum encontrarem-se dificuldades na estimativa conjunta desses parâmetros. Para contornar esse problema da interdependência, este artigo pode embasar uma opção de dividir a tarefa em duas fases independentes: a primeira identificando o padrão de varredura, usando para isso um algoritmo não cognitivo e uma segunda fase que, após identificado o padrão, recorre a um algoritmo cognitivo para extração das medidas características tais como o período de varredura ou a frequência de natação.

O presente artigo apresenta uma proposta para solucionar a primeira fase acima descrita. Um reconhecimento com bom desempenho facilitaria enormemente a segunda tarefa.

## 2 Aquisição de dados e separação

### 2.1 Aquisição de dados

A base de dados foi coletada a partir de dois eventos de gravações, uma em julho de 2003 e outra em outubro de 2005, no IPqM (Instituto de Pesquisas da Marinha), Rio de Janeiro, RJ, tendo por cenário a baía de Guanabara. Cada evento gerou uma série de gravações, cada qual contemplando um período de 20 s, gerando 23 arquivos de 2 Megabytes de dados, uma taxa média de 800 Kbps. Essa base de dados é constituída por cenários digitalizados, com taxas de amostragem da ordem de dezenas de Mhz, suficiente para a caracterização de PDWs (*pulse descriptor word*), e foi conseguida graças a um sistema receptor passivo (ESM). Como não havia acesso à etapa pós-clusterização, os arquivos usados possuíam informação de vários emissores embaralhados, porém ordenados no tempo. Cada registro gravado possui basicamente os seguintes parâmetros do pulso: ângulo de chegada; tempo de chegada; qualidade da informação de ângulo; frequência; largura de pulso; amplitude (em dB) e *bit* indicador de modulação interna.

### 2.2 Separação

O sistema receptor passivo (ESM) processa indistintamente todos os radares presentes no cenário, o que evidencia a necessidade de um pré-processamento (que consiste numa separação cega de fontes), antes do reconhecimento do padrão de varredura, estimando nessa fase a IRP (intervalo de repetição dos pulsos).

Como o propósito deste artigo reside no reconhecimento de padrões de varredura, o algoritmo elaborado para separação de fontes não foi muito elaborado, fugindo ao escopo deste trabalho. Para tal, utilizou-se um clusterizador baseado em *k-means*, onde somente a frequência foi o parâmetro de entrada usado para clusterização. Para cada um dos arquivos, inicializou-se a *clusterização* com 250 *clusters* de centróides igualmente espaçados na banda de frequências (2 a 20 GHz). Os *clusters* com menos de 40 amostras foram descartados ao final do processo. Então, associamos a cada *cluster* o seu padrão, gerando nossa base de dados para treinamento supervisionado. Para os padrões que não foram enquadrados nas classes anteriormente descritas, foi criada uma nova classe denominada “RESTO”.

## 3 Pré-processamento e Extração de Características

### 3.1 Pré-processamento

Os padrões de Amplitude x TOA não se revelam muito tratáveis para extrações de características. Para contornar este problema, escolhemos uma abordagem nova: dividiu-se o

problema de reconhecimento em dois. Basicamente, a proposta consiste em, ao invés de identificar os padrões diretamente do gráfico amplitude x tempo, transformar esses padrões em dois sub-padrões, quais sejam: amplitude por amostra e TOA por amostra, como vistos nas Figuras 2 e 3. Nestas, verificamos que os padrões de amplitude para circular e setorial são os mesmos, bem como os padrões de TOA das varreduras cônica e *lock-on*, reduzindo o problema de quatro para três classes em cada classificador (sem considerarmos a classe desconhecida). Na Tabela 2, verificamos as possíveis combinações, assim como as classificações correspondentes.

Tabela 2. Combinações possíveis entre padrões de TOA e de Amplitude e classificação da varredura conhecidas.

#	Amplitude	TOA	Varredura
1	Patamares	Linear	<i>Lock-On</i>
2	Patamares	Distinto de linear	Padrão desconhecido
3	Senoidal	Linear	Cônica
4	Senoidal	Distinto de linear	Padrão desconhecido
5	Senóides retificadas	Linear	Padrão desconhecido
6	Senóides retificadas	Degraus uniformes	Circular
7	Senóides retificadas	Degraus não uniformes	Setorial
8	RESTO	Qualquer coisa	RESTO
9	Qualquer coisa	Não-linear	RESTO

Figura 2. Padrões de Amplitude por amostra

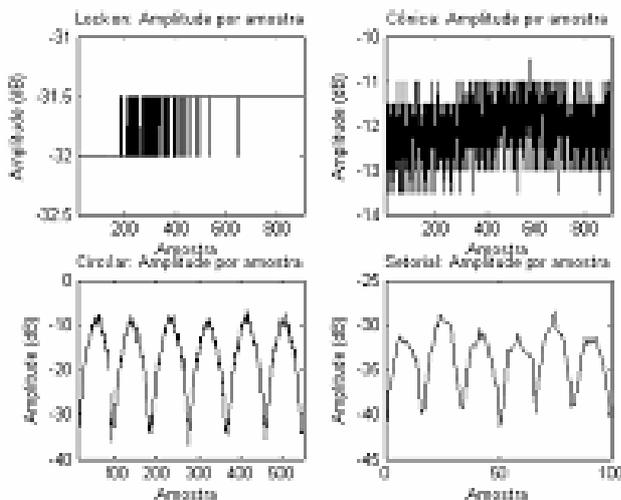
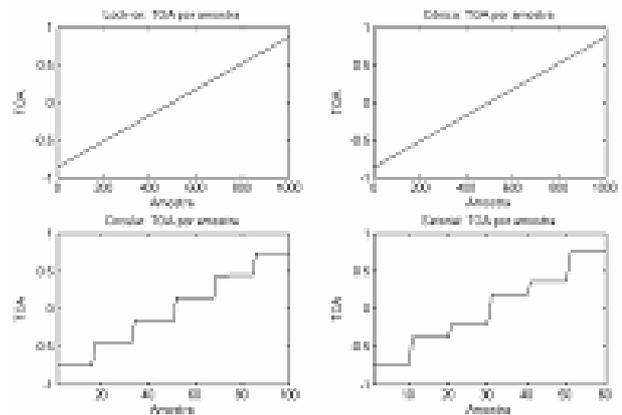


Figura 3. Padrões de TOA por amostra



Assim, o problema de reconhecimento do padrão de varredura radar foi dividido em dois problemas separados: um problema de reconhecimento do padrão da amplitude e o segundo de reconhecimento do padrão do tempo de chegada (TOA), que serão combinados ao final do processo para classificar o padrão de varredura. Para tanto, após a obtenção dos *clusters* na fase anterior geraram-se dois conjuntos de dados para cada *cluster*.

Todas as medidas obtidas de cada *cluster* foram escalonadas, conforme a expressão abaixo:

$$\tilde{X}_{ij} = \frac{X_{ij} - \overline{X}_i}{\sigma_i}, \quad (1)$$

onde  $\tilde{X}_{ij}$  representa a  $j$ -ésima amostra escalonada do  $i$ -ésimo *cluster*,  $\overline{X}_i$ ,  $X_{ij}$  e  $\sigma_i$  são respectivamente a média, a  $j$ -ésima amostra e o desvio-padrão do  $i$ -ésimo *cluster*.

### 3.2 Extração de características

Para ambos os classificadores (amplitude e TOA), foram concatenados os coeficientes LP (*Linear Predictor*) e a variância do erro de predição para confecção do vetor de característica associado a cada *cluster*. O preditor LPC de ordem  $N$  consiste num conjunto de coeficientes  $a(k)$  que minimizam o erro quadrático médio do seguinte preditor *forward*, aplicado em uma seqüência  $x(n)$ :

$$\hat{x}(n) = \sum_{k=1}^N a(k)x(n-k). \quad (2)$$

Para o classificador de amplitude, acrescentou-se ao vetor de características o desvio-padrão do *cluster*. Para o classificador de TOA, acrescentou o desvio-padrão da diferença entre as amostras do *cluster* e as amostras da reta obtida via regressão linear de cada *cluster*. Após testes, verificamos que a reta definida pela primeira e última amostra do *cluster* era sufici-

ente para garantir uma classificação de desempenho similar, com um custo computacional bastante inferior.

#### 4 Métodos de Classificação

Para exercitar os classificadores foram formadas as seguintes classes para os padrões de Amplitude:

- Patamares;
- Senoidal;
- Senóide Retificada;
- RESTO

A classe RESTO corresponde a qualquer representação em amplitude que não foi possível enquadrar nos três padrões anteriores.

Figura 4. Padrões de Amplitude a classificar.

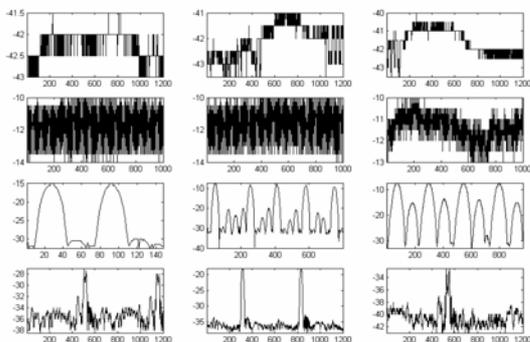
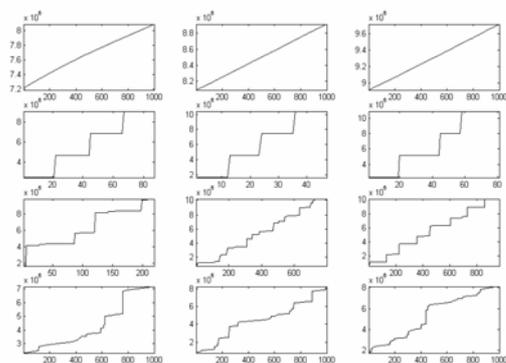


Figura 5. Padrões de TOA a classificar.



##### 4.1 Máquina de vetor Suporte

Concisamente, a Máquina de Vetor Suporte é uma máquina que implementa discriminantes lineares (hiperplanos) num espaço obtido por uma transformada do espaço de entrada, diferenciando uma classe, a positiva, de outra, a negativa (uma classificação binária, na sua forma tradicional).

A Máquina de Vetor Suporte visa construir um hiperplano que maximize a margem de separação entre os exemplares positivos e os negativos. Esse objetivo é obtido através de uma abordagem baseada

na Teoria Estatística de Aprendizagem, implementando aproximadamente o método de minimização do risco estrutural. Apesar da utilização de discriminantes lineares, a Máquina de Vetor Suporte não necessita, para efeitos de generalização, de classes linearmente separáveis. Tal se deve ao fato de a discriminação ser empregada num espaço de características, o qual é uma transformação não-linear (*kernel*) do espaço de entradas.

Esta operação pode ser justificada invocando-se o célebre Teorema de Cover, o qual afirma que padrões não-linearmente separáveis pertencentes a um espaço de entradas são com alta probabilidade, linearmente separáveis num espaço de características, desde que: (a) a transformação seja não-linear; (b) a dimensionalidade do espaço de características seja alta o suficiente.

Uma característica muito atraente das Máquinas de Vetores Suporte consiste na sua habilidade em se contornar a famosa "maldição da dimensionalidade", a qual, para nós neste artigo, não é crítica.

A SVM no espaço de características resolve um problema de programação não-linear que visa maximizar a margem entre os vetores de entrada transformados e o hiperplano separador, conforme o equacionamento abaixo na forma dual:

$$\text{Maximizar } D(\vec{\alpha}) = \left( \sum_{i=1}^n \alpha_i \right) - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(\vec{x}_i, \vec{x}_j)$$

s/a

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad \alpha_i \geq 0 \quad (3)$$

onde

$K$  é o Kernel aplicado à espaço de entrada.

$\alpha_i$  é o multiplicador de Lagrange.

$\vec{x}_i$  é o vetor de entrada.

$y_i$  é a classe associada ao  $i$ -ésimo vetor de entrada (+1 ou -1)

A classificação é obtida a partir da equação a seguir:

$$h(\vec{x}) = \text{sign} \left( \sum_{x_i \in SV} \alpha_i y_i K(\vec{x}_i, \vec{x}) + b \right) \quad (4)$$

##### 4.2 Rede Neural

Foram projetadas duas redes neurais *feedforward* contendo cada qual duas camadas, conexões completas, sendo ambas estáticas e com aprendizado supervisionado e função de ativação do tipo tangente hiperbólica.

Para o aprendizado das redes neurais foi utilizado *resilient backpropagation*, vide Riedmiller, tendo

sido empregado 70% do conjunto para treinamento e o restante dividido em partes iguais para teste e validação.

O programa elaborado para ambas as redes contabilizou a maior classe e balanceou as demais classes, de forma que o treinamento não privilegiasse nenhuma das classes.

Para as quatro classes de cada rede neural foi usada uma representação maximamente esparsa, ou seja, 4 neurônios de saída, onde um deles possui a resposta desejada em "1" e os demais em "-1".

## 5 Resultados

A melhor topologia encontrada em ambas as redes neurais, foi 3 coeficientes LP para a entrada, 20 neurônios na primeira camada e 4 neurônios na última. Outras formas de codificação foram tentadas: FFT, DCT, Amostragem Simples e DHT, todas com diminuto sucesso.

Nessa topologia a taxa de acerto obtida foi de 99,5% na Rede Neural de amplitude, e de 97,79% na Rede Neural TOA.

A seguir representamos a curva de aprendizado da rede neural de amplitude e TOA respectivamente.

Figura 6. Curva de aprendizado da rede de Amplitude.

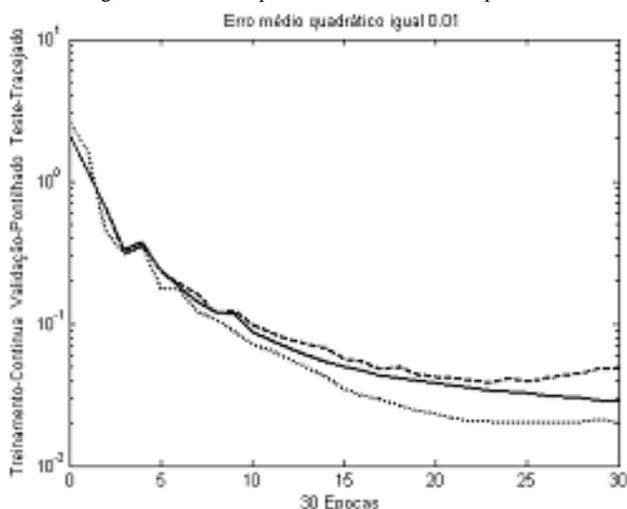
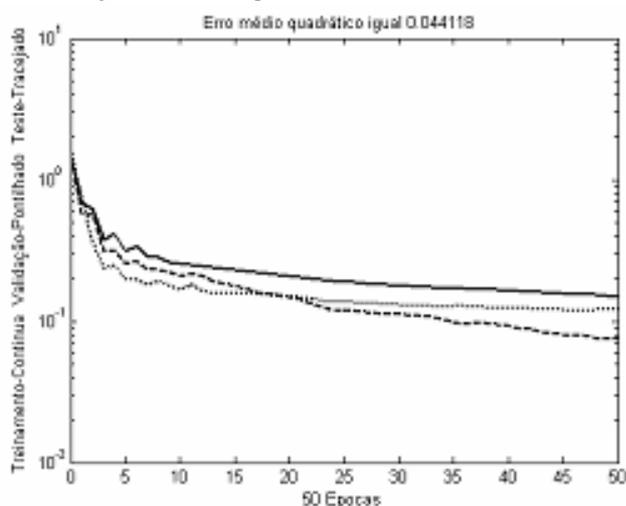


Figura 7. Curva de aprendizado da rede TOA



Embora existam implementações SVM multi-classes, adotou-se uma abordagem simples, resolvendo o problema multiclasse por meio de decisões binárias, as quais não são necessariamente ótimas. Observou-se que alterar a árvore de decisão resulta em desempenhos distintos, embora não muito diferentes entre si. O kernel utilizado, por obter melhores resultados, foi o polinomial de grau 2.

Entre as possíveis árvores de decisão, a que obteve os melhores resultados no tocante a TOA era constituída por três SVMs binárias, tomando decisões na seguinte seqüência: 1) TOA linear do resto; 2) TOA não-linear do TOA degrau e 3) TOA degrau uniforme de degrau não-uniforme. A taxa de acerto obtida foi de 98,98% (com o mesmo conjunto de treinamento que a da rede neural). Já para a árvore de decisão quanto à Amplitude, as decisões foram tomadas na seguinte ordem: 1) senoidal retificada do resto; 2) senoidal do resto e 3) patamares de RESTO, com uma taxa de acerto de 98,43%. Em todas as SVMs, a codificação LP utilizou 3 coeficientes, à exceção da terceira SVM de Amplitude, que usou 16 coeficientes.

## 6 Conclusão

A rede neural, como era esperado, demonstrou robustez ao ruído de forma diversa dos algoritmos cognitivos que são normalmente empregados (cujos resultados não são aqui comparados devido a razões de sigilo militar).

Tanto a rede neural quanto a SVM revelaram que provavelmente serão capazes de classificar mais que quatro classes, demonstrando um desempenho no mínimo equivalente aos algoritmos cognitivos ora empregados.

Conforme se pode observar, a rede neural de TOA apresentou maiores dificuldades que a Rede neural de Amplitude, pois o desvio padrão dos clusters antes do escalonamento não foi suficiente para garantir a convergência desta rede neural, tampouco para o classificador correspondente em SVM.

A SVM apresentou maior estabilidade no processo de treinamento que a Rede Neural, apresentando também uma velocidade na fase de treinamento superior.

Para a SVM não foi necessário balancear as classes na fase de treinamento, embora tal balanceamento possa vir a ser necessário em alguns casos.

Ambos os classificadores apresentaram boa capacidade de generalização, aceitando amostras pessimamente clusterizadas, ou seja, contendo mais de um emissor, não apresentando problemas de agrupar classes ou desmembrá-las.

A SVM apresentou resultados ligeiramente inferiores à Rede Neural de amplitude, contudo demonstrou um resultado ligeiramente superior a rede neural de TOA, o que sugere uma possível solução combi-

nada, empregando o classificador neural para Amplitude e o classificador SVM para TOA. Esta solução pode ser modificada a depender da codificação utilizada na fase de extração e da topologia empregada, tanto na rede neural quanto na SVM. Dessa forma, minimizamos a taxa de erro global, à medida que esta será, no pior caso, resultado de uma soma das taxas de erro de cada classificador.

### Referências Bibliográficas

- R. O. Duda, P. E. Hart and D. G. Stork (2000). Pattern Classification (2nd ed), *John Wiley & Sons*.
- Riedmiller, M., e H. Brown (1993). A Direct adaptive method for faster backpropagation learning: The RPROP algorithm, *Proceedings of the IEEE International Conference on Neural Networks*.
- Haykin, S. (1999). Neural Networks: A Comprehensive Foundation, *Prentice Hall*.
- Cover, T.M. (1965). Geometrical and Estatistical properties of systems of linear inequalities with applications in pattern recognition, *IEEE on Electronic Computers*, pp. 326-334
- C. Bishop, "Neural Networks for Pattern Recognition". *Oxford University Press*. 1995.
- Christopher J. C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition", *Data Mining and Knowledge Discovery*, 1998.
- John R. Deller, John H. L. Hansen, John G. Proakis, "Discrete-Time Processing of Speech Signals", *IEEE Press*, 2000.