

Aplicação das Redes RBF na Detecção Inteligente de Sinais Digitais

Marcelo A. C. Fernandes¹, Adrião D. D. Neto² e João B. Bezerra³

^{1,2,3}Universidade Federal do Rio Grande do Norte - UFRN

Departamento de Engenharia Elétrica - DEE

Laboratório de Engenharia de Computação e Automação - LECA

59.072-970 Campus Universitário - Lagoa Nova - Natal - RN

E-mails: ¹marcelo@leca.ufrn.br, ²adriao@leca.ufrn.br e ³jbb@leca.ufrn.br

Abstract

Este trabalho propõe uma estratégia para implementar o processo de detecção de sinais em sistemas de comunicação digital, cujo esquema de sinalização possa ser representado por uma constelação finita de sinais. Esta estratégia se caracteriza no uso de uma rede de Funções Radiais de Base (rede RBF), chamada aqui de detetor RBF, cujo propósito de sua implementação e a substituição do detetor de máxima-verossimilhança usualmente presente nos sistemas de comunicação digital. As características funcionais, a estratégia de treinamento e um estudo comparativo de desempenho, frente ao detetor de máxima-verossimilhança e a outros modelos de detetores, baseados em Redes Neurais Artificiais (RNA), são apresentados neste trabalho.

1. Introdução

A aplicação de redes neurais artificiais (RNA) modelando detetores associados a sistemas de comunicação digital, pode ser encontrado em [1][2][3][4][5]. Observa-se nestes trabalhos que RNA do tipo perceptron de uma camada e do tipo perceptron de múltiplas camadas (MLP), obtém um satisfatório desempenho na caracterização destes detetores. Entretanto o uso do perceptron de uma camada é limitado por realizar apenas classificações lineares, não podendo então, atuar em sistemas cujo modelo de ruído é não-linear. Já o uso do MLP supera o problema de classificação não-linear, por outro lado, o mesmo tem um treinamento muito lento quando se tentar modelar detetores associados a sistemas com constelações grandes. Baseado nestes resultados, este trabalho apresenta um detetor baseado em redes RBF com propósito de substituir o detetor de máxima-verossimilhança associado aos sistemas de comunicação digital cujo esquema de modulação possa ser caracterizado em um espaço N -dimensional, tais como os sistemas de comunicação digital que utilizam modulação do tipo ASK, PSK e QAM [6][7]. Bem como os sistemas que utilizam modulação do tipo CPFSK quando modelados por uma máquina de Mealy [8]. Existem duas razões principais que justificam o uso da rede RBF. A primeira é que a rede RBF pode realizar classificações não-lineares, superando o problema

do perceptron de uma camada e podendo assim atuar em sistema cujo o modelo de ruído e não-gaussiano. Segundo o processo de treinamento das redes RBF é bem mais rápido que o do MLP.

O trabalho está organizado da seguinte forma: A Seção 2 apresenta as características da rede RBF. Na Seção 3 está apresentada a arquitetura do detetor RBF. A metodologia de treinamento bem como sua aplicabilidade em sistemas de comunicação digital está apresentada na Seção 4. A Seção 5 apresenta os resultados e teste realizados para vários esquemas de modulação digital estudados e finalmente, a Seção 6 apresenta as conclusões deste trabalho.

2. Redes de Funções Radiais de Base (redes RBF)

As redes de funções radiais de base (redes RBF) têm tido recentemente uma significativa posição dentro do domínio das redes neurais artificiais [9][10][11]. A principal razão para esse resultado é a simplicidade do processo de treinamento e a eficiência computacional. A estrutura da rede RBF é do tipo múltiplas camadas, o método de treinamento é do tipo feedforward e o treinamento pode ser supervisionado, método que foi aplicado neste trabalho, ou híbrido, no qual combina-se um método não-supervisionado com um supervisionado. Esse tipo de rede pode ser usada em problemas de aproximação de funções, predição e classificação. A última aplicação se apresenta no contexto deste trabalho.

A estrutura básica de uma rede RBF, apresentada na Fig. 1, consiste de apenas três camadas. A primeira camada é a conexão do modelo como o meio. A segunda camada ou camada escondida, realiza uma transformação não-linear do espaço vetorial de entrada para um espaço vetorial interno que geralmente tem uma dimensão maior. A última camada, a camada de saída, transforma o espaço vetorial interno em uma saída, através de um processo linear. Os neurônios da camada escondida são funções radiais de base.

As funções radiais de base produzem uma resposta significativa, diferente de zero, somente quando o padrão de entrada está dentro de uma região pequena localizada no espaço de entrada. Cada função requer um centro e um

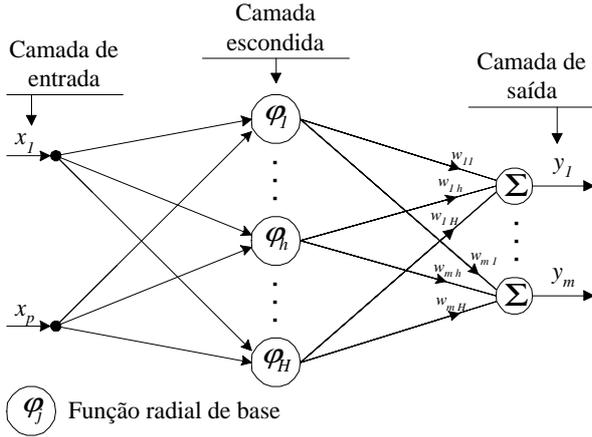


Figura 1: Estrutura de uma rede RBF.

parâmetro escalar. A função que é mais utilizada com função de radial de base é a função de Gauss

$$\varphi(\mathbf{v}) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{v} - \mathbf{c}\|^2\right). \quad (1)$$

Assim, uma componente y_j do vetor de saída, \mathbf{y} , da rede RBF é caracterizada como

$$y_j = F_k(\mathbf{x}) = \sum_{h=1}^H w_{kh} \varphi_h(\mathbf{x}_s), \quad \begin{matrix} j = 1, 2, \dots, m, \\ s = 1, 2, \dots, N. \end{matrix} \quad (2)$$

Substituindo a Eq. (1) na Eq. (2),

$$y_j = F_j(\mathbf{x}) = \sum_{h=1}^H w_{jh} \exp\left(-\frac{1}{2\sigma_h^2} \|\mathbf{x}_s - \mathbf{c}_h\|^2\right). \quad (3)$$

Onde w_{jh} é o peso sináptico entre o neurônio h da camada escondida com o neurônio j da camada de saída, \mathbf{x}_s é o s -ésimo vetor de entrada, de um conjunto de treinamento \mathbf{X} , e \mathbf{c}_h é o vetor de centro, relativo ao neurônio h da camada escondida, definido por

$$\mathbf{c}_h = [c_{h1}, c_{h2}, \dots, c_{hp}]^T. \quad (4)$$

3. Estrutura do Detetor RBF

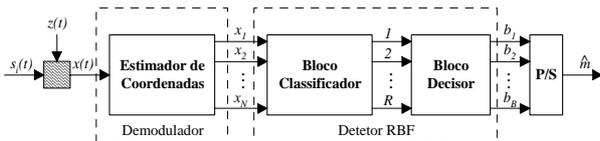


Figura 2: Estrutura do detetor RBF.

O detetor proposto neste trabalho é formado por dois blocos, como apresentado na Fig. 2. O primeiro bloco, chamado aqui de bloco classificador, utiliza uma

rede RBF para classificar as coordenadas estimadas, x_1, x_2, \dots, x_N do sinal de entrada $x(t)$, associado a um dos M símbolos que compõem um determinado sistema de sinalização digital. A classificação é feita com base no critério de Bayes [12]. Assim, para um sistema com R regiões a classificar, r_1, r_2, \dots, r_R , como está apresentado na Fig. 3, serão necessários R neurônios na camada de saída da rede RBF utilizada. O número de centros, H , utilizados na camada escondida da RBF é igual ao número de pontos que compõem a constelação. O motivo dessa imposição está apresentado na próxima seção. O segundo bloco, denominado de decisor, é formado por um circuito combinacional que transforma as R saídas do bloco classificador nas respectivas palavras binárias associadas aos M símbolos que compõem uma determinada constelação.

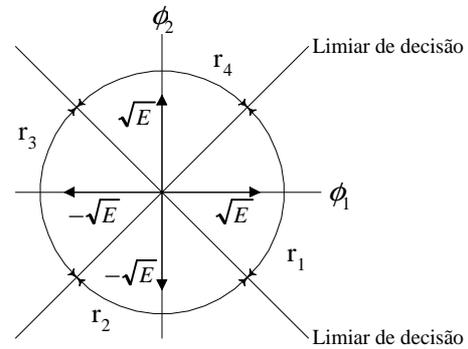


Figura 3: Representação geométrica das regiões de decisão para sistema com $M = 4$ e $N = 2$.

A Fig. 4 mostra um exemplo da estrutura do detetor RBF, quando o mesmo é aplicado ao sistema 8-PSK. A Tab. 1 caracteriza a tabela verdade do circuito combinacional correspondente. É importante ressaltar que o detetor RBF tem a característica de ter sua estrutura invariável quanto ao tipo de modulação, bem como ser independente do modelo de ruído utilizado.

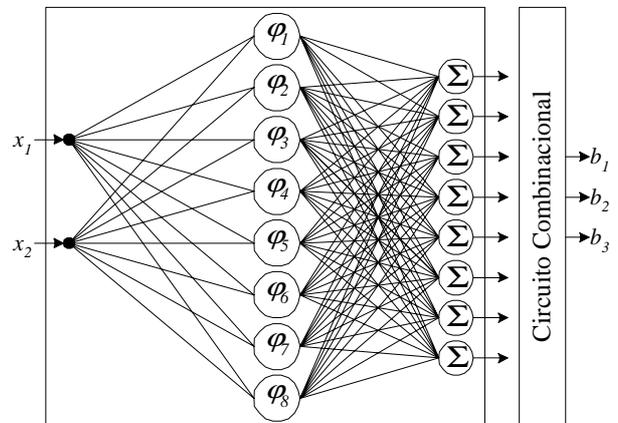


Figura 4: Arquitetura do detetor RBF.

Tabela 1: Tabela verdade do circuito combinacional do bloco decisor para um sistema 8-PSK.

r_1	r_2	r_3	r_4	r_5	k_6	k_7	k_8	b_3	b_2	b_1
1	0	0	0	0	0	0	0	0	0	0
0	1	0	0	0	0	0	0	0	0	1
0	0	1	0	0	0	0	0	0	1	1
0	0	0	1	0	0	0	0	0	1	0
0	0	0	0	1	0	0	0	1	1	0
0	0	0	0	0	1	0	0	1	1	1
0	0	0	0	0	0	1	0	1	0	1
0	0	0	0	0	0	0	1	1	0	0

4. Treinamento do Detetor RBF

Como está apresentado em [12], existem várias maneiras de se treinar uma rede RBF. No detetor proposto neste trabalho, foi utilizado o treinamento denominado de centros fixos, selecionados aleatoriamente para a camada escondida, e na determinação dos ganhos da camada de saída foi utilizado o método da pseudo inversa. Os passos desse treinamento estão apresentados em [12].

Devido a algumas características peculiares ao problema estudado neste trabalho e alguns estudos feitos através de simulações, como contribuição deste trabalho foram realizadas algumas mudanças no passo 1 do algoritmo de treinamento original e que serão apresentadas abaixo.

1. Gerar R conjuntos de D pontos para cada elemento da constelação, onde o i –ésimo conjunto é representado pela matriz $\mathbf{U}^{(i)}$, que é dada por:

$$\mathbf{U}^{(i)} = \begin{bmatrix} u_{11}^{(i)} & \cdots & u_{1k}^{(i)} & \cdots & u_{1D}^{(i)} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ u_{j1}^{(i)} & \cdots & u_{jk}^{(i)} & \cdots & u_{jD}^{(i)} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ u_{N1}^{(i)} & \cdots & u_{Nk}^{(i)} & \cdots & u_{ND}^{(i)} \end{bmatrix}. \quad (5)$$

A matriz $\mathbf{U}^{(i)}$ representa um conjunto de D pontos discretos ao redor do círculo de decisão do i –ésimo elemento de sinal, caso esteja-se trabalhado com um ruído gaussiano, se não $\mathbf{U}^{(i)}$ será caracterizado por amostras do i –ésimo elemento de sinal contaminado pelo ruído, como está apresentado nas Fig. 5 e Fig. 6;

2. Após gerados os R conjuntos calcula-se para cada conjunto $\mathbf{U}^{(i)}$ um centro \mathbf{c}_h , onde

$$\mathbf{c}_h = [c_{h1}, c_{h2}, \dots, c_{hj}, \dots, c_{hN}]^T \quad (6)$$

e

$$c_{hj} = \frac{1}{D} \sum_{k=1}^D u_{jk}. \quad (7)$$

Assim, pode-se determinar a priori a localização dos centros da RBF localizada no bloco classificador sem se fazer uso de uma seleção aleatória. Dessa forma a rede RBF que compõe o detetor utilizará R funções radiais de base na sua camada escondida se atuar em um sistema com R regiões a classificar;

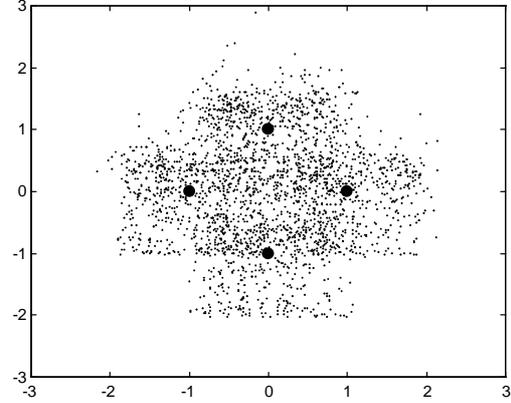


Figura 5: Ilustração dos conjuntos de treinamento para o caso de um ruído não-gaussiano em um sistema 4-PSK (● = sinal, . = sinal+ruído).

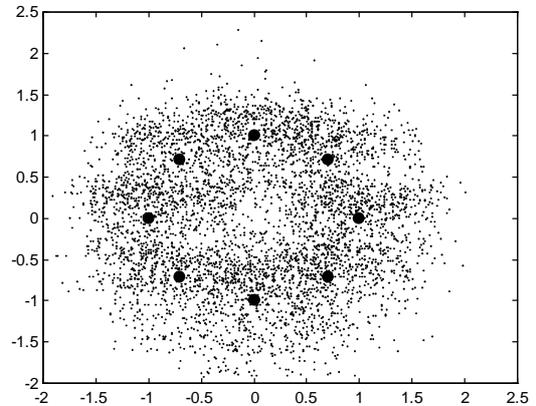


Figura 6: Ilustração dos conjuntos de treinamento para o caso de um ruído não-gaussiano em um sistema 8-PSK (● = sinal, . = sinal+ruído).

Tendo por base essas modificações, são utilizados como conjuntos de treinamento os próprios centros, ou seja, cada i –ésimo conjunto é formado apenas por um único ponto. Assim, pode-se observar que o conjunto de treinamento é bem reduzido quando comparado com os detetores propostos em [3][4] que utilizam vários pontos para o i –ésimo conjunto. Dessa forma, pode-se acelerar significativamente o processo de treinamento, contornando assim o problema apresentado pelo modelo do detetor baseado no MLP [4].

5. Resultados e Testes

No intuito de validar o uso do modelo de detetor RBF como substituto dos modelos propostos em [3] [4], que apresentaram alguns problemas, foram realizadas as mesmas simulações. Isto é, foram construídas, através de simulações com um ruído gaussiano e também com um ruído não gaussiano, as curvas de probabilidade de erro de símbolo para os sistemas M -PSK e M -QAM. No caso do ruído gaussiano as curvas foram comparadas com os modelos teóricos e para o ruído não gaussiano as curvas foram comparadas com as que foram geradas para o ruído gaussiano. No caso do sistema CPFSK binário também foi realizada uma simulação utilizando o processador de Viterbi. Os resultados destas simulações, estão apresentadas nas Figs. 7–12.

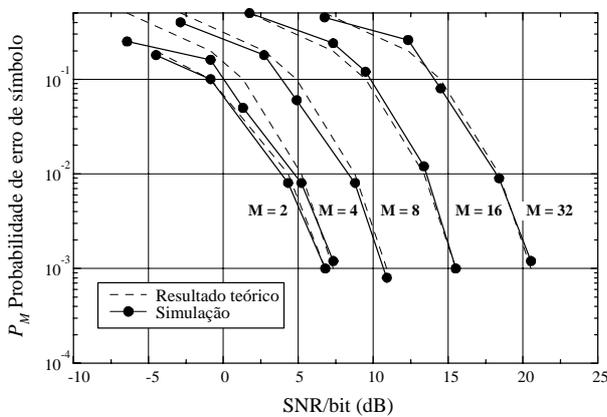


Figura 7: Resultados da simulação do detetor RBF implementando um sistema M -PSK.

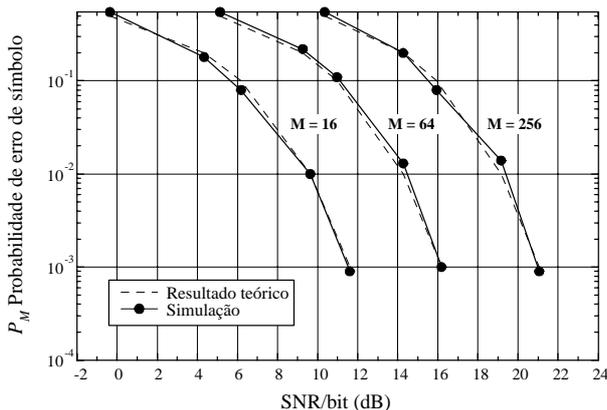


Figura 8: Resultados da simulação do detetor RBF implementando um sistema M -QAM.

6. Conclusões

Este trabalho apresentou um modelo de detetor baseado nas redes RBF, chamado de detetor RBF, aplicado

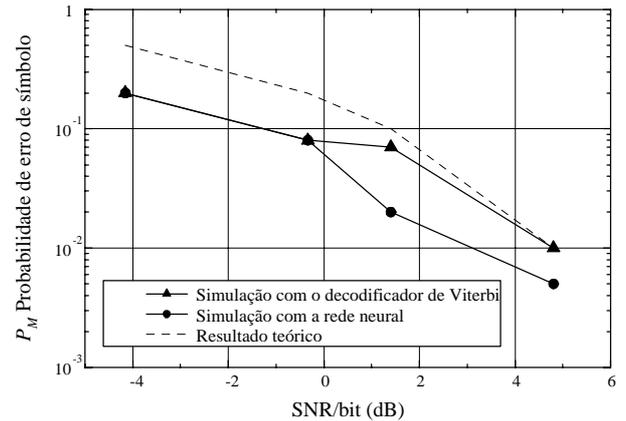


Figura 9: Resultados da simulação do detetor RBF para um sistema CPFSK binário de resposta completa e $h = 0,7143$.

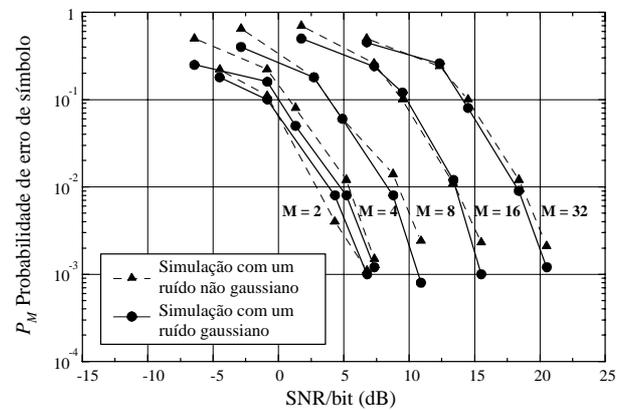


Figura 10: Resultados da simulação do detetor RBF implementando um sistema M -PSK contaminado por um ruído aditivo não gaussiano.

a sistemas de comunicação digital cujo o esquema de modulação pode ser caracterizado em um espaço N -dimensional de sinais. Os resultados apresentados se mostraram bastante atrativos no que diz respeito à comparação das curvas teóricas da probabilidade de erro de símbolo para os sistemas M -PSK, M -QAM e CPFSK binário. Com relação a simulação com o ruído de natureza não gaussiana os resultados se mostram também bastantes atrativos, mostrando assim que os detetores baseado em RNA não tem restrições quanto ao modelo de ruído.

A grande vantagem da utilização da RBF está na velocidade do processo de treinamento. As redes RBF, como descrito em [12], são, usualmente mais rápidas no processo de treinamento que o MLP. Entretanto, têm a desvantagem de uma maior exigência de memória. Todavia, as alterações introduzidas na proposta de treinamento possibilitam uma redução acentuada no conjunto de treinamento contrabalançando a maior exigência de

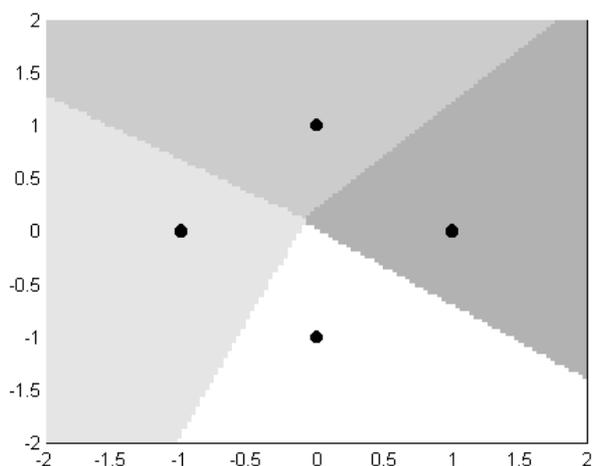


Figura 11: Contornos de classificação do detetor RBF implementando um sistema 4-PSK contaminado por um ruído aditivo não-gaussiano.

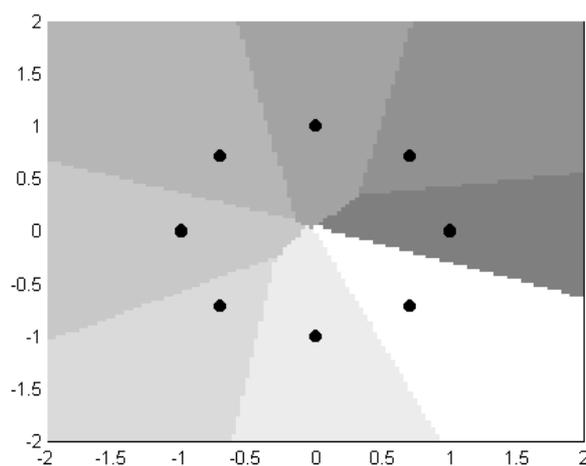


Figura 12: Contornos de classificação do detetor RBF implementando um sistema 8-PSK contaminado por um ruído aditivo não-gaussiano.

memória do algoritmo de treinamento original. Apesar dessa vantagem, é preciso salientar que as redes RBF têm um processamento em tempo real mais lento. Isto deve-se ao fato da utilização das funções radiais de base da camada escondida. Assim, pode-se concluir que o detetor RBF pode ser um bom substituto dos detetores baseados no perceptron de uma cada e no MLP. Finalizando, é interessante observar que o detetor RBF treinado para um sistema com M sinais na constelação pode ser usado em distintos sistemas M -ários, exceto pelo treinamento, que especifica cada esquema de sinalização em particular.

Referências

- [1] J. W. Watterson. An optimum multilayer perceptron neural receiver for signal detection. *IEEE Trans. Neural Networks*, 1:298–300, 1990.
- [2] A. Bernardini and D. S. Fina. Optimal decision boundaries for M-QAM signal formats using neural classifiers. *IEEE Trans. Neural Networks*, 9:241–246, 1998.
- [3] M. A. Fernandes, A. D. Neto e J. B. Bezerra. Um neuroreceptor aplicado a sistemas de modulação digital. No *III Congresso Brasileiro de Redes Neurais, Santa Catarina*, páginas 432–436, 1997.
- [4] M. A. Fernandes, A. D. Neto e J. B. Bezerra. A neural network model applied to the detection of digital signals. No *IEEE/SBT International Telecommunications Symposium, São Paulo*, páginas 279–283, 1998.
- [5] M. A. Fernandes, A. D. Neto e J. B. Bezerra. *Redes Neurais Artificiais Aplicadas à Detecção Inteligente de Sinais*. Dissertação de Mestrado, LECA-DEE-UFRN, RN, 1999.
- [6] S. Haykin. *Communication Systems*. John Wiley, New York, 1983.
- [7] J. G. Proakis. *Digital Communications*. McGraw-Hill, New York, 1989.
- [8] J. B. Bezerra. Modelamento de sistemas cpm como uma máquina de mealy. No *13^o Simpósio Brasileiro de Telecomunicações, São Paulo*, páginas 667–672, 1995.
- [9] J. E. Moody and C. J. Darken. Fast learning in networks of locally-tuned processing units. *Neural Computation*, 1:281–294, 1989.
- [10] T. Poggio and F. Girosi. Networks for approximation and learning. *Proceedings of the IEEE*, 78:1481–1497, 1990.
- [11] T. Poggio and F. Girosi. Regularization algorithms for learning that are equivalent to multilayer networks. *Science*, 247:978–982, 1990.
- [12] S. Haykin. *Neural Networks: A Comprehensive Foundation*. Englewood Cliffs, New Jersey, 1994.