

Comparação de uma Arquitetura Neural com o Algoritmo de Máxima Verossimilhança na Classificação de uma Cena LANDSAT/TM

MÁRCIO L. GONÇALVES¹
MÁRCIO L. DE ANDRADE NETTO²
JURANDIR ZULLO JÚNIOR³

¹ PUC • MINAS – Av. Padre Francis Cletus Cox, 1661 Cep 37701-355
Poços de Caldas - MG - Brasil

Email: marcio@pcaldas.pucminas.br

² DCA/FEEC/UNICAMP Email: marcio@dca.fee.unicamp.br

³ CEPAGRI/UNICAMP Email: jurandir@cpa.unicamp.br

Abstract. This work presents a comparison between the performances of a Modular Neural Architecture and the Maximum Likelihood algorithm in the classification of a LANDSAT/TM scene. The Neural Architecture is constituted of two processing modules: a module for feature extraction of the image using Kohonen's Self-Organizing Map and other module for classification using a Multi-Layer Perceptron network. The experimental results show that the Neural Architecture presented a superior performance to the Maximum Likelihood algorithm.

1. Introdução

Tendo em vista as similaridades observadas no processo de reconhecimento de padrões em Redes Neurais Artificiais (RNA) e alguns procedimentos de classificação de imagens, sucessivas aplicações na classificação de imagens de Sensoriamento Remoto (SR) têm sido registradas na literatura, mostrando que as RNA são capazes de alcançar resultados comparáveis ou até mesmo superiores aos das abordagens estatísticas convencionais.

Entre as vantagens das RNA sobre os métodos estatísticos convencionais está a não necessidade de um conhecimento a priori da distribuição de probabilidade dos dados, uma vez que as RNA têm a habilidade de aprender as propriedades de distribuição dos dados durante a fase de treinamento, bem como a habilidade de generalizar e incorporar informações e conhecimentos não-estatísticos que podem ser potencialmente valiosos.

Embora os trabalhos já desenvolvidos, que aplicam as RNA na classificação de imagens de SR, apresentem resultados superiores em relação aos métodos convencionais, a maioria desses trabalhos, além de abordarem muito superficialmente o processo de classificação em si, não exploram todo o potencial que as RNA podem oferecer (Gonçalves (1997)). Redes neurais do tipo Perceptron Multicamadas com o algoritmo de treinamento *backpropagation* são utilizadas como se fossem a única alternativa para os classificadores estatísticos convencionais. Além disso, o longo tempo de treinamento apresentado pelos algoritmos de aprendizagem é sempre apontado como empecilho para a utilização mais ampla das RNA na classificação de imagens de SR (Foody (1995), Gonçalves (1996a)).

Nesse sentido, observa-se a necessidade de analisar, desenvolver e validar novas arquiteturas e metodologias destinadas à classificação de imagens de SR, utilizando as RNA como paradigma de processamento básico durante as fases de processamento das imagens.

O presente trabalho tem como objetivo testar a aplicabilidade de uma Arquitetura Neural Modular na classificação de uma cena TM/LANDSAT comparando o seu desempenho com a de um classificador de Máxima Verossimilhança.

2. A Arquitetura Neural

Conforme mostra a **figura 1**, a Arquitetura Neural proposta neste trabalho é composta por dois módulos de processamento: um módulo para extração de atributos da imagem utilizando o Mapa Auto-Organizável de Kohonen (Self-Organizing Map – SOM) e outro módulo para a classificação, utilizando uma rede neural de Perceptrons Multicamadas (Multi-Layer Perceptron – MLP).




Figura 1: A Arquitetura Neural de classificação

Assim como todo sistema de reconhecimento de padrões convencional, a arquitetura divide o problema de reconhecimento em duas fases: extração de atributos e classificação.

Em geral, quando se utiliza as RNA para realizar o reconhecimento de padrões, a fase de extração de atributos é freqüentemente integrada dentro de uma rede global, que é então treinada com algoritmos de aprendizagem supervisionada (Oja (1994)). De fato, a maioria dos trabalhos que aplicam as RNA no reconhecimento de padrões de imagens de SR utilizam apenas uma única rede para realizar essa tarefa. Embora esta abordagem pareça ser mais simples para resolver o problema de reconhecimento, ela pode ser inadequada para problemas complexos como o de análise de imagens, uma vez que a rede neural utilizada pode exigir uma grande quantidade de neurônios e de amostras de treinamento. A tarefa de seleção de amostras neste caso pode se tornar muito trabalhosa, uma vez que ela é realizada manualmente. Portanto, em um sistema de reconhecimento de padrões de imagens, uma fase separada de extração de atributos é essencial. Os resultados obtidos com a extração de atributos podem revelar propriedades sobre a estrutura dos dados que facilitam o processo de classificação dos padrões. As amostras de treinamento podem ser selecionadas de forma que sejam mais representativas, proporcionando a utilização de redes de classificação mais simples e com maior habilidade de generalização (Jain (1994)).

2.1 O Módulo de Extração de Atributos

O módulo de extração de atributos na arquitetura neural de classificação tem como objetivo obter uma melhor representação dos padrões originais da imagem, de modo que as seguintes tarefas dentro do processo de classificação possam ser realizadas com maior facilidade: i-) identificação das classes espectrais presentes na imagem; ii-) definição do conjunto de classes de informação desejadas e, iii-) definição de um conjunto de amostras para cada uma das classes de informação escolhidas (essas amostras são utilizadas posteriormente no módulo de classificação).

Em Mao (1995), verifica-se que um grande número de RNA e algoritmos de aprendizagem têm sido propostos como novas ferramentas ou como abordagens suplementares para a extração de atributos.

Na arquitetura de classificação proposta foi empregado o SOM no módulo de extração de atributos. O SOM possui algumas propriedades que são interessantes para a extração de atributos de imagens de SR. Foi possível construir a partir dele uma ferramenta de auxílio visual, denominada Mapa de Agrupamentos de Kohonen (MAK). A **figura 2** ilustra o processo de construção do MAK.




Figura 2: Construção do Mapa de Agrupamentos de Kohonen (MAK).

Na abordagem proposta foram utilizadas janelas de pixels da imagem original como padrões de treinamento para o SOM. Esses padrões são coletados de maneira aleatória e uniforme sobre toda a região da imagem e fornecidos como vetores de entrada para o SOM. Uma vez que o SOM possui a particularidade de distribuir seus neurônios na forma de um *array* retangular e, levando-se em conta que os vetores de pesos de cada neurônio possuem as mesmas dimensões que os vetores de entrada, torna-se possível gerar uma imagem do *array* de pesos do SOM

(Kohonen (1988)). A imagem do *array* resultante, após o treinamento não-supervisionado pelo SOM é o MAK.

O MAK constitui-se numa ferramenta de auxílio visual tornando possível identificar as classes espectrais da imagem, definir as classes de informação e selecionar suas respectivas amostras de treinamento, que serão utilizadas posteriormente no módulo de classificação. Ele possui algumas características “herdadas” do SOM que facilitam a realização dessas tarefas, tais como:

- Como o SOM efetua um agrupamento (*clustering*) dos padrões de treinamento, é possível visualizar no MAK as classes espectrais presentes na imagem original através dos agrupamentos obtidos;
- A propriedade do SOM, de preservar as relações topológicas entre os vetores de dados de entrada, reflete-se na propriedade do MAK de preservar estas relações em termos da distância entre os agrupamentos, isto é, agrupamentos que são vizinhos no MAK representam classes de cobertura terrestre que possuem características espectrais semelhantes;
- Outra propriedade importante do SOM é preservar as distribuições de probabilidade encontradas nos dados de entrada. Esta propriedade pode ser verificada no MAK, onde classes espectrais com maior frequência de ocorrência nos dados de entrada serão mapeadas em regiões maiores no MAK.

Portanto, na abordagem proposta, as classes de informação e suas amostras, que serão utilizadas no módulo de classificação, são selecionadas por um analista de imagens a partir do próprio MAK e não através da imagem original, como é feito usualmente. O analista escolhe através dos agrupamentos formados no MAK as classes de informação desejadas para realizar a classificação e depois seleciona um conjunto de amostras de treinamento delimitando áreas sobre os agrupamentos que correspondem às classes escolhidas.

2.2 O Módulo de Classificação

Uma vez definidas as classes de informação desejadas e suas respectivas amostras no módulo de extração de atributos através do MAK, o objetivo do segundo módulo da arquitetura proposta é realizar a classificação final da imagem utilizando uma rede neural MLP.

A rede MLP utilizada na arquitetura de classificação possui apenas uma camada escondida de neurônios. O número de entradas da rede depende do tamanho das amostras das classes de informação que são selecionadas no MAK. Na camada escondida, não existe uma regra definida para o número de neurônios. Uma configuração satisfatória é procurada de modo iterativo apenas levando-se em conta que quanto maior o número de classes de informação e de amostras de treinamento, maior deve ser o número de neurônios. Na camada de saída da rede, o número de neurônios é igual a quantidade de classes de informação desejadas para realizar a classificação da imagem.

No processo de treinamento da rede MLP, cada uma das amostras adquiridas através do MAK são apresentadas à rede, que terá seus pesos ajustados até produzir um resultado que satisfaça uma medida de erro pré-definida.

Terminando o processo de treinamento da rede MLP, ao invés de se classificar imediatamente todos os pixels da imagem original, a rede pode ser utilizada para classificar os pixels do próprio MAK. Através do MAK classificado é possível visualizar a separação dos

agrupamentos que correspondem às classes de informação, permitindo verificar se as amostras que foram selecionadas através dele são realmente representativas. Caso a separação das classes no MAK não esteja boa, novas amostras podem ser selecionadas e a rede MLP é treinada novamente. Caso, contrário ou seja, se a separação das classes no MAK é satisfatória, a rede MLP pode então ser utilizada para classificar todos os pixels da imagem, produzindo assim um mapa temático da cena.

Na busca de alternativas para o baixo desempenho do algoritmo *Backpropagation* padrão, normalmente apontado como o principal empecilho para uma utilização mais ampla na classificação de imagens de SR, a arquitetura neural de classificação utiliza um algoritmo de treinamento avançado para a rede MLP. O algoritmo utiliza informação de segunda ordem calculada de maneira exata para minimizar a função erro da rede MLP. Maiores detalhes sobre o algoritmo podem ser encontrados em Gonçalves (1996b) e Gonçalves (1997).

2.3 Um Resumo do Processo de Classificação

Apresentada então a arquitetura neural de classificação, o processo de classificação das imagens pode ser resumido como segue:

1. Várias janelas de pixels são coletadas de maneira aleatória e uniforme sobre toda região da imagem e fornecidas como padrões de entrada para o SOM.
2. O treinamento não supervisionado do SOM é efetuado.
3. A imagem do *array* de pesos do SOM é gerada, obtendo assim o MAK.
4. Um analista de imagens escolhe através do MAK as classes de informação desejadas e seleciona um conjunto de amostras de treinamento para essas classes.
5. O treinamento supervisionado da rede MLP é realizado utilizando as amostras selecionadas através do MAK.
6. O MAK é classificado pela rede MLP. Se a separação das classes no MAK não estiver satisfatória, novas amostras são selecionadas e a rede MLP é treinada novamente.
7. Todos os pixels da imagem original são classificados através da rede MLP, produzindo assim um mapa temático da cena.

A **figura 3** ilustra o processo de classificação da imagem pela arquitetura neural.




Figura 3: Ilustração do processo de classificação da imagem pela arquitetura neural.

3. Comparação entre a Arquitetura Neural e o Classificador de Máxima Verossimilhança

Para comparar o desempenho da Arquitetura Neural proposta com o de um classificador de Máxima Verossimilhança, adotou-se uma metodologia cujo desenvolvimento constou, inicialmente, da seleção de uma área teste. Uma vez que se dispunha das seis bandas LANDSAT/TM, referentes ao espectro refletido de radiação eletromagnética, optou-se por utilizar um procedimento para reduzir o número de bandas espectrais a serem usados na classificação. No caso, o algoritmo utilizado define o melhor subconjunto de três bandas, de um total de seis bandas disponíveis que deverão fornecer um bom compromisso entre precisão da classificação e tempo computacional.

Posteriormente, com o objetivo de facilitar a interpretação da imagem, uma composição colorida das três bandas selecionadas foi feita associando as cores vermelho, verde e azul a cada uma delas, sintetizando numa única imagem as informações contidas nas três bandas espectrais.

Concluindo o processamento inicial das três bandas espectrais da área teste foi feita então a classificação da imagem pela Arquitetura Neural proposta e pelo algoritmo de Máxima Verossimilhança, e então uma análise comparativa entre as imagens classificadas foi realizada.

3.1. A área teste

A área teste selecionada refere-se a um segmento de imagem de 512x512 pixels extraído de uma cena LANDSAT/TM. A área corresponde à região de cruzamento dos rios Pardo e Mogi Guaçu localizados na região nordeste do estado de São Paulo (longitude de 48° oeste e latitude 21° sul) e foi registrada no dia 8 de agosto de 1990.

A **figura 4** mostra a imagem resultante da composição colorida das bandas espectrais 7, 4 e 5 selecionadas para os testes, associadas, respectivamente, às cores vermelho, verde e azul.



Figura 4: Composição colorida das bandas espectrais.

3.2 Classificação pela Arquitetura neural

Conforme foi apresentado anteriormente, a Arquitetura Neural é composta por dois módulos de processamento: um módulo para extração de atributos da imagem e outro módulo para a classificação.

A etapa principal do módulo de extração de atributos é a obtenção do MAK, pois é através dele que deverão ser escolhidas as classes de informação desejadas e suas respectivas amostras de treinamento, que serão utilizadas posteriormente no módulo de classificação.

Uma vez que as dimensões do MAK dependem diretamente do número de neurônios utilizados no SOM e das dimensões das janelas de pixels que são coletadas da imagem original, foi necessário definir esses parâmetros antes de gerar a sua imagem. A definição foi feita com base em alguns testes experimentais. A **figura 5** mostra quatro exemplos de MAK's de diferentes dimensões gerados para a imagem teste da **figura 4**.




Figura 5: Diferentes MAK's gerados para a imagem teste: (a) 100x120 neurônios; janelas 3x3 (b) 250x300 neurônios; pixel-a-pixel (c) 60x80 neurônios; janelas 5x5 (d) 60 x80 neurônios; janelas 3x3.

Pode-se observar em cada um dos MAK's da **figura 5** as características “herdadas” das propriedades do SOM, como:

- a formação de agrupamentos correspondentes às classes espectrais presentes na imagem (*clustering*);
- a preservação das relações topológicas entre os padrões de entrada em termos da distância entre os agrupamentos, isto é, agrupamentos que são vizinhos no MAK representam classes de cobertura terrestre que possuem características espectrais semelhantes. Por exemplo, os agrupamentos próximos ao agrupamento correspondente à água, que aparece com a cor preta, podem indicar classes de cobertura terrestre que

apresentam uma porcentagem maior de umidade que outras localizadas em agrupamentos mais distantes (essa característica fica evidente quando são observados os níveis de intensidade dos pixels);

- a preservação das distribuições de probabilidade encontradas nos dados de entrada, ou seja as classes espectrais com maior frequência de ocorrência na imagem a ser classificada aparecem em regiões maiores no MAK, como por exemplo, é o caso da vegetação que aparece com a cor verde.

Dentre os MAK's gerados o da **figura 5 (d)** foi escolhido para realizar a seleção das classes de informação desejadas para classificar a imagem, bem como, de suas respectivas amostras de treinamento. Esta escolha foi feita com a ajuda de um analista de imagens que considerou o MAK adequado para tal procedimento. Além disso, o MAK escolhido apresenta dimensões menores que as dos outros e foi gerado com janelas (3x3) de pixels as quais podem incorporar informações de textura, o que não acontece por exemplo com o MAK da figura 5 (b), que foi gerado pixel-a-pixel.

A etapa seguinte no módulo de extração de atributos consistiu em definir as classes de informação e as suas respectivas amostras de treinamento através do MAK.

Devido a inexistência de dados de verdade terrestre para a área teste escolhida, a definição das classes de informação foi feita com a ajuda de um especialista do CEPAGRI/UNICAMP que tinha um conhecimento prévio da cena e portanto selecionou as classes de cobertura terrestre presentes na imagem.

Conforme mostra a **figura 6**, através do MAK gerado foram escolhidas 5 classes de informação: água, solo nu, solo úmido, vegetação e cultura agrícola.



Figura 6: Localização das Classes de Informação no MAK

Foram selecionadas diretamente sobre o MAK 15 amostras de treinamento para as 5 classes de informação. Cada amostra foi composta por uma janela 3x3 de pixels, resultando portanto um total de 135 pixels selecionados.

Após a definição das classes de informação desejadas e de suas amostras, foi realizado então o processo de treinamento da rede MLP. A rede MLP foi composta por 27 entradas, 14 neurônios na camada escondida e 5 neurônios na camada de saída. As 27 entradas correspondem à janelas 3x3 de pixels selecionadas no MAK (o que indica a incorporação de informações de textura - contexto do pixel).

Terminado o processo de treinamento, antes de realizar a classificação da imagem teste, a rede foi utilizada para classificar os pixels do próprio MAK. A **figura 7** mostra o MAK classificado, onde pode-se verificar a separação das classes de informação, construindo regiões de decisão para a classificação. As regiões não-classificadas, em preto, podem indicar a presença de classes distintas, que podem ser iterativamente incorporadas em seleções mais abrangentes e refinadas de classes.



Figura 7: MAK Classificado.

A separação adequada das classes de informação no MAK classificado, pode ser uma boa indicação de que as amostras selecionadas para realizar o treinamento da rede MLP foram representativas, permitindo realizar a classificação dos pixels da imagem teste com maior confiança nos dados de treinamento.

A **figura 8** mostra a imagem classificada pela arquitetura neural.




Figura 8: Imagem teste classificada pela arquitetura neural.

A **tabela 1** mostra a área ocupada por cada classe de informação e também a área não classificada (em número de pixels e Km²).

<i>Classes de Informação</i>	<i>Número de Pixels</i>	<i>Km²</i>
Água	4576	4,1184
Vegetação	105720	95,148
Solo úmido	26829	24,146
Solo nu	58005	52,204
Cultura agrícola	29373	26,435
<i>Sem classificação</i>	<i>37641</i>	<i>33,876</i>

Tabela 1: Área ocupada por cada classe e área não classificada na imagem pela arquitetura neural.

3.3 Classificação pelo Algoritmo de Máxima Verossimilhança

A classificação da imagem teste utilizando o algoritmo de Máxima Verossimilhança foi feita através da função específica chamada MAXVER, que está implementada no SITIM (Sistema de Tratamento de Imagens) instalado no CEPAGRI/UNICAMP.

Apesar dos bons recursos oferecidos pelo SITIM para realizar a seleção de amostras, foi requisitada também nesta abordagem a ajuda de um especialista do CEPAGRI.

Foram selecionadas 17 amostras de treinamento para as 5 classes de informação, sendo que cada amostra foi composta por uma janela 5x5 de pixels da imagem teste. Depois de ter realizado alguns testes experimentais, verificou-se que este número de amostras foi o menor possível para que fosse efetuada uma boa estimativa dos parâmetros exigidos pelo algoritmo de classificação.

A **figura 9** mostra a imagem classificada pelo algoritmo de Máxima Verossimilhança.




Figura 9: Imagem teste classificada pelo algoritmo de Máxima Verossimilhança.

A **tabela 2** mostra a área ocupada por cada classe de informação e também a área não classificada.

<i>Classes de Informação</i>	<i>Número de Pixels</i>	<i>Km²</i>
Água	2203	1,982
Vegetação	127070	114,363
Solo úmido	3827	3,444
Solo nu	58176	52,358
Cultura agrícola	22006	19,805
Sem classificação	48862	43,975

Tabela 2: Área ocupada por cada classe e área não classificada na imagem pelo Algoritmo de Máxima Verossimilhança.

3.4 Análise Comparativa das classificações

Devido a inexistência de dados de verdade terrestre, os seguintes critérios foram adotados para realizar uma comparação entre as classificações resultantes da Arquitetura Neural e do algoritmo de Máxima Verossimilhança: i-) número de pixels não-classificados, ii-) número de pixels utilizados no treinamento, iii-) Variância Relativa, iv-) Coeficiente Kappa e vi-) aspecto visual.

O coeficiente Kappa foi utilizado neste contexto para comparar as duas imagens classificadas, sendo que os pixels de uma delas formaram o conjunto de padrões de referência, enquanto que os pixels da outra formaram o conjunto de padrões-teste.

Os valores dos parâmetros utilizados como critério de comparação são mostrados na **Tabela 3**.

Parâmetros de comparação	Arquitetura Neural	Máxima Verossimilhança
Número de pixels não classificados	37641	48862
Número de pixels para treinamento	135	425
Variância Relativa	0.5214	0.3747
Coeficiente Kappa	59	

Tabela 3: Valores dos parâmetros utilizados na comparação das classificações.

Quanto ao aspecto visual, o desempenho da Arquitetura Neural é significativamente superior. A classificação pelo Algoritmo de Máxima Verossimilhança apresentou uma aparência salpicada, o que não ocorreu na classificação pela Arquitetura Neural, que mostrou uma boa definição das classes de informação com regiões classificadas bastante uniformes. Obviamente, a abordagem utilizada na Arquitetura Neural, na qual os pixels vizinhos são considerados influencia na aparência homogênea das classes.

4. Conclusões

Os números indicam que a classificação pela arquitetura neural apresentou resultados superiores aos da classificação pelo Algoritmo de Máxima Verossimilhança. De acordo com o número de pixels não classificados observa-se que a abordagem neural tolera maiores variações espectrais dos pixels a serem classificados, o que é confirmado pelo fato da Arquitetura Neural ter classificado a maior parte dos pixels que se referem a áreas de solo úmido, o que não ocorreu na classificação pelo algoritmo de Máxima Verossimilhança. A classificação pela Arquitetura Neural exigiu um número muito menor de pixels no conjunto de amostras de treinamento. Isto

indica que o processo de seleção de amostras através do MAK foi satisfatório. O MAK proporcionou uma boa representação para as classes espectrais presentes na imagem.

As vantagens da Arquitetura Neural podem ser melhor entendidas levando-se ainda em conta que a classificação em sistemas neurais normalmente é feita por uma única rede MLP, onde a extração de atributos, isto é, a seleção de classes e amostras é feita diretamente a partir da imagem original por um especialista. Com a modularização do sistema, a tarefa de extração de atributos foi realizada pelo SOM, gerando uma ferramenta prática, o MAK, que fornece informações úteis quanto à representatividade, distribuição e semelhança das classes espectrais. Isso torna possível, identificar e selecionar, por inspeção visual, as classes espectrais e suas respectivas amostras de treinamento que serão usadas na fase de classificação. Essas vantagens do MAK podem ser enfatizadas nos casos em que a imagem apresenta uma variabilidade muito complexa de padrões espectrais, onde pode tornar-se difícil a tarefa de seleção das classes, bem como de suas amostras, diretamente da imagem original.

Finalmente, vale ressaltar que as comparações realizadas referem-se à classificações obtidas por algoritmos com princípios e características, em geral, bastante diferenciadas e não cabe aqui decidir qual o melhor método, porém testar e analisar a aplicabilidade de uma Arquitetura Neural na classificação do segmento de imagem, correspondente à área teste, tendo em vista que ainda há uma gama de arquiteturas, métodos de aprendizagens, e classes de redes neurais que ainda não foram exploradas neste tipo de aplicação.

Referências

- Foody, G. M.; McCulloch, M. B.; Yates, W. B.. *Classification of Remotely Sensed Data by an Artificial Neural Network: issues related to training data characteristics*. In: Photogrammetric Engineering and Remote Sensing, v. 61, n. 4, pp. 391- 401, 1995.
- Gonçalves, M. L.; Netto, M. L. A.; Zullo Jr, J.. *Um Sistema Neural Modular para Classificação de Imagens utilizando Mapas de Kohonen*. In: Anais do VIII Simpósio Brasileiro de Sensoriamento Remoto. Salvador, Brasil. Abril, 1996a.
- Gonçalves, M. L.; Netto, M. L. A.; Zullo Jr, J.. *A Modular Neural Architecture for Image Classification using Kohonen Feature Extraction*. In: Proceedings of XVIII International Congress for Photogrammetry and Remote Sensing, pp. 117-122. Viena, Austria, 1996b.
- Gonçalves, M. L.. *Uma Arquitetura Neural Modular para Classificação de Imagens Multiespectrais de Sensoriamento Remoto*. Tese de Mestrado. Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, 1997.
- Jacobs, R. A., Jordan, M. I., Barto, A. G. *Task Decomposition through Competition in a Modular Connectionist Architecture: The what and where vision tasks*. Cognitive Science, vol. 15, pp. 219-250, 1991.
- Jain, A. K.; Mao, J.. *Neural Networks and Pattern Recognition*. In: Computational Intelligence: Imitating Life, pp. 194-212. IEEE Publication, 1994.
- Kohonen, T.. *Self-Organization and Associative Memory*. New York: Springer-Verlag, 1988.
- Mao, J.; Jain, A. K.. *Artificial Neural Networks For Feature Extraction and Multivariate Data Projection*. IEEE Transactions on Neural Networks, v. 6, n. 2, pp. 296-317, 1995.
- Oja, E.; Lampinen, J.. *Unsupervised Learning for Feature Extraction*. In: Computational Intelligence: Imitating Life, pp. 13-22. IEEE Publication, 1994.