

PERSPECTIVAS DA APLICAÇÃO DE REDES NEURAIS NA CLASSIFICAÇÃO DE DADOS MULTIESPECTRAIS DE SENSORIAMENTO REMOTO

ELISA TOMOE MORIYA SCHLÜNZEN^{*1}
MARIA DE LOURDES BUENO TRINDADE^{*2}
MILTON HIROKAZU SHIMABUKURO^{*3}
KLAUS SCHLÜNZEN JUNIOR^{*1}
MÁRCIO LUÍS ANDRADE NETO⁴

^{*}UNESP - Universidade Estadual Paulista - FCT
Caixa Postal 957
19060-900 Presidente Prudente - SP
ueppr@brfapesp.bitnet

¹Departamento de Matemática
²Departamento de Cartografia
³Polo Computacional

⁴UNICAMP - Universidade Estadual de Campinas - FEE
Departamento de Automação Industrial

Resumo. O presente trabalho tem o objetivo de avaliar a aplicabilidade de um algoritmo de Redes Neurais na classificação supervisionada de dados multiespectrais de Sensoriamento Remoto. Para isto foi implementada a Rede Neural de Perceptron multicamadas com o algoritmo de treinamento "Back-Propagation". Os resultados foram comparados com as classificações geradas pelo MAXVER, e mostraram-se bastante promissores.

Abstract. The aim of this work is to verify the potencial for the application of Neural Network to Remote Sensing multispectral data supervised classification. A Back-Propagation approach for multi-layer Perceptron Neural Network was implemented, and tested. The results have been compared with the conventional supervised maximum likelihood classification procedure. The preliminary results are promising.

INTRODUÇÃO

Tendo em vista as similaridades observadas no processo de reconhecimento de padrões em Redes Neurais e os procedimentos de classificação de imagens multiespectrais, nas quais identifica-se uma etapa de treinamento previamente à classificação, verificou-se a possibilidade de desenvolver um aplicativo em Redes Neurais para classificar dados multiespectrais de Sensoriamento Remoto.

Neste contexto, o objetivo do presente trabalho é desenvolver um sistema baseado na Rede de Perceptron de múltiplas camadas, utilizando um algoritmo de treinamento de "Back-

Propagation", adequado à classificação de imagens multiespectrais de Sensoriamento Remoto; relatar o processo de implementação do algoritmo, face as peculiaridades que estes dados apresentam; bem como, comparar os resultados experimentais obtidos da aplicação desta Rede Neural, com os resultados da utilização de classificadores convencionais, sobre uma mesma área teste.

REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais são modelos computacionais inspirados no sistema nervoso biológico, cujo funcionamento é semelhante a alguns procedimentos humanos, ou seja,

aprendem pela experiência, generalizam exemplos através de outros, abstraem características (Wasserman, 1989).

Do ponto de vista computacional, Lippmann (1987) ressalta que, ao invés de constituir-se em um programa formado por uma sequência de instruções, os modelos de Redes Neurais exploram muitas hipóteses simultaneamente, usando intensamente o paralelismo, e compondo-se de muitos elementos computacionais interligados através de pesos variáveis.

Apesar da grande diversidade de paradigmas de Redes Neurais Artificiais, todas são baseadas em uma configuração que engloba, essencialmente, um conjunto de entradas aplicadas a um neurônio, as quais são multiplicadas por um peso correspondente. Os produtos de entradas e pesos são então, somados para determinar o nível de ativação do neurônio.

Ainda de acordo com Wasserman (1989), as Redes Neurais Artificiais se organizam pelo número de camadas que compõe a topologia da rede. Desse modo, podem ser destacadas as Redes Neurais de camada Simples, formadas por um grupo de neurônios arranjados em apenas uma camada, e as multicamadas. Estas últimas, que podem ser entendidas como sendo a composição de várias redes de camadas simples, onde a saída de uma pode ser a entrada de outra, têm-se mostrados bastante adequadas no desenvolvimento de algoritmos de treinamento.

Em relação a aprendizagem / treinamento da rede, como um processo de ajuste dos pesos que possibilite a classificação de padrões, Lippmann (1987) categoriza-as como supervisionadas ou não-supervisionadas. A aprendizagem supervisionada requer um agente externo que direcione o comportamento do sistema e as modificações subsequentes, enquanto que na aprendizagem não-supervisionada a rede se auto organiza para produzir as trocas desejadas.

Existem, atualmente, vários modelos de Redes Neurais, desenvolvidas para as

mais diversas aplicações, as quais apresentam características específicas. Neste contexto está inserida a Rede Neural de Perceptron projetada tanto para o reconhecimento de padrões e bem como ferramenta de pesquisa para a modelagem de possíveis mecanismos cerebrais.

Perceptron contitue-se no precursor das Redes Neurais atuais e serviram para introduzir as estruturas básicas até hoje utilizadas, e cuja idealização é creditada a Rosembat, segundo Wasserman (1989), o teorema de aprendizagem de Rosembat afirma que o perceptron é capaz de aprender tudo o que ele pode representar, entendendo-se representação como a capacidade da rede simular uma função específica, enquanto que a aprendizagem requer um procedimento sistemático de ajuste de pesos para produzir esta função.

Lippmann (1987) ressalta que as regiões de decisão formadas por Perceptron são similares àquelas formadas por um classificador Gaussiano de Máxima Verossimilhança, a qual assume entradas não correlatas, e distribuições de classes diferentes.

Deste modo um classificador gaussiano para um número M de classes pode ser construído através de M estruturas do tipo Perceptron, desde que sejam usados algoritmos de treinamento para os classificadores.

O algoritmo de treinamento de Perceptron não faz suposições relacionadas a forma da distribuição básica para as classes, mas focaliza os erros que ocorrem quando estas distribuições se sobrepõe. Os classificadores gaussianos pressupõe a forma das distribuições básicas das classes, e são mais apropriados quando estas distribuições são conhecidas, Lippmann (1987).

Com o desenvolvimento de algoritmos de treinamento mais adequados, as estruturas de Perceptron evoluíram para o Perceptron de múltiplas camadas, as quais apresentaram uma ou mais camadas de nós entre as camadas de entrada e saída, sendo chamadas de camadas escondidas. A capacidade de Perceptron

de múltiplas camadas deve-se a não-linearidade entre os nós, de modo que tais redes formam novas regiões de decisão e resolvem o problema de regiões misturadas.

As Redes Neurais de Perceptron de múltiplas camadas podem ser treinadas com um algoritmo de treinamento iterativo chamado "Back-Propagation", o qual faz a adaptação dos pesos através de um algoritmo recursivo partindo dos nós de saída e trabalhando retroativamente nas primeiras camadas escondidas.

TRABALHOS PRÉVIOS SOBRE A APLICAÇÃO DE REDES NEURAI NA CLASSIFICAÇÃO DE IMAGENS MULTIESPECTRAIS

Em um trabalho recente, comparando a abordagem de Redes Neurais com os métodos estatísticos de classificação de dados de Sensoriamento Remoto adquiridos por diferentes fontes, Benediktsson (1990), relata uma série de trabalhos relacionados com esta aplicação. Assim este autor cita McClelland et. al. (1989), que utilizou uma Rede Neural de três camadas, treinadas através de um algoritmo "Back-Propagation", para classificar dados TM/LANDSAT. Segundo o mesmo enfoque, Decatur (1989), usando também um algoritmo "Back-Propagation" para treinamento de uma rede de Perceptron de três camadas, classificou dados de radar obtidos pelo SAR (Synthetic Aperture Radar).

Em relação ao trabalho de Benediktsson (1990), o autor concluiu que a principal vantagem das Redes Neurais comparada com os algoritmos estatísticos de classificação é que, no primeiro caso, não é necessário conhecer as funções de distribuição das classes de informação.

Key et. al. (1989) utilizou dados AVHRR e SMMR da região ártica, e classificou-os utilizando o procedimento de Máxima Verossimilhança, Redes Neurais e técnicas de interpretação visual. Os resultados indicaram que a abordagem de Redes Neurais oferecem vantagens em termos de

facilidade de uso, interpretabilidade e utilidade para classes espectrais indistinguíveis e temporalmente variáveis.

Avaliando o potencial da aplicação de Redes Neurais na classificação de dados de Sensoriamento Remoto, comparado com a classificação supervisionada convencional, através de um conjunto de treinamento mínimo, invariáveis nas duas situações, Hepner et. al. (1990) observou que a Rede Neural apresenta um desempenho superior que a classificação convencional.

Liu e Xiao (1991) relatam que, na classificação de dados de Sensoriamento Remoto, uma Rede Neural de múltiplas camadas, pode formar regiões de decisão complexas e, conseqüentemente, separar classes mescladas. No entanto, a convergência do algoritmo de treinamento de "Back-Propagation" é muito demorada, problema este que foi contornado utilizando um algoritmo "Back-Propagation" bloqueado, o que resultou em um aumento na performance da convergência e na acurácia da classificação.

Visando aumentar o desempenho da classificação de áreas cultivadas, Zhuang et. al. (1991), utilizaram dados sobre propriedades da terra incorporadas aos dados das sete bandas TM/LANDSAT, em um SIG-Sistema de Informações Geográficas. Os resultados obtidos mostraram que o classificador por Máxima Verossimilhança, não pode ser usado para os dados sobre propriedades da terra, inviabilizando a classificação conjunta, enquanto que o critério de Mínima Distância não apresentou bom desempenho nem mesmo na classificação das sete bandas TM/LANDSAT. Por outro lado, os resultados obtidos usando um classificador de Redes Neurais apresentaram uma melhor performance em relação aos métodos anteriores e um menor grau de confusão entre as classes de áreas cultivadas. Este aspecto evidencia o potencial da utilização de Redes Neurais em classificação de dados de Sensoriamento Remoto, quando são incorporadas outros tipos de dados, em

atuais concepções de SIG.

O ALGORÍTMO DE CLASSIFICAÇÃO POR REDES NEURAIS

AMBIENTE DE DESENVOLVIMENTO

Tendo em vista as limitações em termos de recursos materiais disponíveis para a implementação dos programas, optou-se por trabalhar com a seguinte configuração :

- . Micro computador PC-compatível, com monitor padrão EGA (resolução 640X350 pixels e 16 cores simultâneas). Nossa plataforma de hardware, baseada em um PC/AT 486, apesar de não ser a ideal, possui um poder de processamento acentuado, bem como coprocessador aritmético embutido no próprio microprocessador;

- . Linguagem Turbo Pascal 5.0

Esta linguagem de computação foi escolhida por apresentar facilidades de programação, implementar estruturas de dados adequadas e atender as necessidades de computação científica para a aplicação desenvolvida. Considerando o processo de treinamento da rede e de classificação de imagem, existe a necessidade de maior precisão e rapidez de cálculos em ponto flutuante, o que implica na utilização de um equipamento rápido dotado de coprocessador. A emulação do coprocessador por software, oferecida pelo Turbo Pascal, não apresenta a performance adequada ao processamento. Entretanto, avaliar o desempenho do algoritmo de Redes Neurais na classificação de dados multiespectrais, não é objeto do presente estudo.

ASPECTOS DE IMPLEMENTAÇÃO

Uma vez que não havia disponibilidade de um equipamento com uma configuração adequada para o processamento de dados multiespectrais e, face a necessidade de visualização dos dados originais, principalmente no procedimento de treinamento da rede, foi necessário gerar previamente as imagens, de modo que estas pudessem ser visualizadas no equipamento disponível.

Muito embora o equipamento utilizado disponha de 16 cores, uma imagem original não pode ser mostrada de modo direto, ou seja, um pixel na imagem gerada representando um ponto na imagem original, pois as imagens de Sensoriamento Remoto são representadas em 256 níveis de brilho.

Diante desta limitação utilizou-se de uma técnica de visualização de imagens denominada "Dithering", a qual consiste basicamente em agrupar várias cores para representar uma única cor. Em outras palavras, cada ponto da imagem é representada por vários pixels agrupados no monitor.

No presente caso, representou-se um ponto por uma matriz de 2X2 pixels, de modo a construir um conjunto de 13 tons de cinza a partir de 4 cores: preto, cinza, branco e branco brilhante; estas cores apresentam-se em ordem crescente de brilho.

A utilização deste artifício permitiu visualizar as imagens e foi imprescindível quando da seleção das amostras de treinamento para as classes.

REDE NEURAL DE PERCEPTRON COM ALGORÍTMO DE TREINAMENTO "BACK-PROPAGATION"

O desenvolvimento do trabalho foi baseado na implementação e aplicação experimental de uma Rede Neural de Perceptron de três camadas, para a classificação dos dados multiespectrais.

A Rede Neural de Perceptron, além de permitir a utilização de valores contínuos como entrada e de ser supervisionada, possui habilidade para aprender e reconhecer padrões. Sua estrutura é baseada em um conjunto de nós dispostos em camadas, onde um simples nó é conectado com todos os demais nós da camada superior. Cada nó processa a soma da multiplicação das suas entradas pelos pesos associados e passa o resultado ao nó de camada superior, através da aplicação de uma função sigmoide.

O processo de treinamento da rede utiliza o algoritmo de treinamento

"Back-Propagation", que consiste na apresentação de um conjunto de amostras que produz um resultado, o qual é comparado com um saída desejada.

O resultado da comparação desencadeia um processo de adaptação de pesos, retrocedendo de uma camada para a camada anterior, quando a diferença entre a saída obtida e a desejada não for inferior a um dado erro.

Desse modo, a configuração da Rede Neural desenvolvida refere-se a uma estrutura de nós interconectados, dispostos em três camadas. A primeira camada é composta de 27 nós, ou seja, de uma matriz de 3X3X3 nós (considerando a entrada simultânea de uma amostra de 3X3 pixels em 3 bandas espectrais), usada para o processamento dos dados de entrada. A segunda camada, ou camada "escondida", consta de 11 nós, número este definido com base em alguns testes preliminares. Finalmente, a terceira camada, ou camada de saídas, é composta de 4 nós, representando cada uma das quatro classes definidas previamente para a cena (saídas desejadas).

Hepner (1990) ressalta que, tanto o número de camadas escondidas quanto o número de nós em cada camada, serão variáveis com a aplicação, tipo e quantidade de informação disponível para a rede e que, estas variáveis estarão afetando substancialmente a performance da Rede Neural.

EXPERIMENTO REALIZADO

Para testar a aplicabilidade do algoritmo de Rede Neural na classificação de dados multiespectrais de Sensoriamento Remoto, foram utilizados um conjunto de três segmentos de uma imagem TM/LANDSAT de dimensões 100x120 pixels, referentes às bandas espectrais TM3, TM4 e TM5. A imagem em questão corresponde a uma área de reflorestamento na região de Itararé-SP, com órbita/ponto 221/57, quadrante B e data de passagem 09/08/88.

Esta área teste foi classificada usando o algoritmo de Rede Neural

implementado no PC/AT 486 e, para fins de comparação, o algoritmo MAXVER implementado no Sistema de Tratamento de Imagens - SITIM, desenvolvido pelo INPE e instalado no CEPAGRI-UNICAMP.

Tendo em vista a disponibilidade de dados de verdade terrestre sobre a área de estudos, foram estabelecidas 4 classes de cobertura da terra referentes a : reflorestamento adulto, reflorestamento jovem com mais de um ano; reflorestamento jovem com menos de um ano; e talhões cortados recentemente, e adotado um procedimento de treinamento supervisionado similar àquele apresentado por Hepner (1990).

Assim, em uma primeira aplicação do algoritmo de classificação MAXVER, foi definida para cada uma das 4 classes, uma área de treinamento de 10X10 pixels e feita uma primeira classificação.

Posteriormente, esta amostragem por classe, no caso do MAXVER, foi ampliada obtendo-se uma segunda classificação, e finalmente uma terceira classificação MAXVER, a partir de uma melhor distribuição da amostra de treinamento por classe, em relação à segunda classificação.

Para o treinamento da Rede Neural foram utilizadas as áreas de treinamento definidas para a primeira aplicação do algoritmo MAXVER, ou seja, amostras de 10X10 pixels para cada uma das classes, extraídas nas mesmas posições na cena.

Tendo em vista sua configuração, as entradas da rede consistiram de 9 valores referentes a uma janela de 3X3 pixels, a qual foi deslocada sobre a área de treinamento totalizando 64 entradas, desconsiderando-se a dimensionalidade das bandas.

Esta janela 3X3 pixels deslocando-se através da área de treinamento, assegura considerações simultâneas de textura e parâmetros de decisão específicos dos pixels adjacentes ao pixel central (Hepner, 1990).

Assim, as entradas da rede correspondem aos valores dos níveis de cinza para um pixel, em cada banda, e as saídas correspondem a cada uma das 4 classes de cobertura da terra

definidas anteriormente.

O processo de classificação pela rede, neste trabalho, leva em consideração uma janela de 3X3 pixels, onde apenas o pixel central é classificado. Tal abordagem permite que as características da vizinhança do pixel central possam ser analisadas pela rede.

RESULTADOS PRELIMINARES

O resultado da classificação utilizando o algoritmo de Rede Neural implementado foi surpreendente na medida que classificou um número muito maior de pixels, em comparação com as três aplicações do algoritmo MAXVER. Tal constatação pode ser feita através da análise da tabela 01 que relaciona o tamanho da amostra de treinamento utilizada, com o número de pixels não-classificados.

Comparando-se os resultados das classificações MAXVER-1 e da Rede Neural, ou seja, a partir da utilização das mesmas áreas de treinamento por classe (10X10 pixels), percebe-se que a Rede Neural é capaz de classificar um número maior de pixels. O mesmo ocorre quando a amostra de treinamento é ampliada para duas áreas de 10X10 pixels/classe, (MAXVER-2), ou ainda quando o conjunto amostral é dividido em três áreas de 7X7 pixels/classe.

Em relação à classificação obtida pelo algoritmo de Rede Neural percebe-se que, visualmente, ocorre uma certa confusão na definição das classes, principalmente, quanto à discriminação das áreas de reflorestamento jovem com mais de um ano daquelas com idade inferior a um ano. Isto pode ser decorrente da definição de duas classes informacionais distintas para feições espectralmente similares.

CONCLUSÃO

Os resultados preliminares mostraram o potencial de aplicação do algoritmo de Redes Neurais na classificação supervisionada de dados multiespectrais de Sensoriamento Remoto, no caso da Rede Neural de Perceptron multicamadas

com algoritmo de treinamento 'Back-Propagation'

Especialmente em relação à implementação da Rede Neural notou-se, que aparentemente, existe uma relação entre o número de neurônios (nós) de entrada, e os que compõe a primeira e a segunda camada. Isto significa que, variando o número de nós nas camadas, poderia se esperar uma maior ou menor eficiência da classificação, em termos de pixels não classificados. Além disso, percebeu-se a necessidade de um coprocessador aritmético para que houvesse a convergência do treinamento.

A comparação com a classificação MAXVER, a partir do experimento realizado, permitiu verificar que a fase de treinamento, principalmente na definição e posicionamento das amostras, não é tão crítico no caso de Redes Neurais. O treinamento da rede e a posterior classificação da cena levaram em consideração informações sobre a vizinhança do pixel.

AGRADECIMENTOS

Os autores agradecem a valiosa colaboração do Prof. Dr. Messias Menegette Junior e Prof. Nilton Nobuhiro Imai, da FCT/UNESP, bem como do analista de sistemas Jurandir Zullo Júnior da CEPAGRI/UNICAMP.

BIBLIOGRAFIA

- BENEDIKTSSON, J. A., SWAIN, P. H. & ERSOY, O. K.. Neural Network Approaches Versus Statistical Methods in Classification on Multisource Remote Sensing Data. *IEEE Transaction on Geoscience and Remote Sensing* 28(4) 540-552, 1990.
- HEPNER, G. H.. Artificial Neural Network Classification using a Minimal Training Set : Comparison of Conventional Supervised Classification. *Photogrammetric Engineering and Remote Sensing* 56(4) 469-473, 1990.

- KEY, J., MASLANIK, J.A. & SCHWEIGER, A. J.. Classification of Merged AVHRR and SMMR Arctic Data with Neural Networks. *Photogrametric Engineering and Remote Sensing* 55(9) 1331-1338, 1989.
- LIPPMANN, R. P.. An Introduction to Computing with Neural Nets. *IEEE ASSP Magazine* p. 4-19, 1987.
- LIU, Z. K. & XIAO, J.Y.. Classification of Remote Sensed Image Data Using Artificial Neural Networks. *International Journal of Remote Sensing* 12(11) 2433-2438, 1991.
- WASSERMAN, P.D.. Neural Computing Theory and Practice. Van Nostrand Reinhold, 1989.
- ZHUANG, X. & ENGEL, B. A.. Improving Classification of Crop Residues Using Digital Land Ownership Data and Landsat TM Imagery. *Photogrammetric Engineering and Remote Sensing* 57(11) 1487-1492, 1991.

TABELA 01. NÚMERO DE PIXELS NÃO-CLASSIFICADOS A PARTIR DA UTILIZAÇÃO DOS ALGORÍTMOS DE REDES NEURAIS E MAXVER

CLASSIFICADOR	TAMANHO DA AMOSTRA DE TREINAMENTO/CLASSE	NÚMERO DE PIXELS NÃO-CLASSIFICADOS
MAXVER-1	121 pixels/classe	7.793
MAXVER-2	242 pixels/classe	5.741
MAXVER-3	192 pixels/classe	5.161
REDE NEURAL	64 entradas/classe	3.032