

A INFLUÊNCIA DA ALTERNÂNCIA ENTRE CLASSES E AMOSTRAS NA ENTRADA DA REDE NEURAL NA CLASSIFICAÇÃO DE IMAGEM DIGITAL.

Mosar Faria Botelho¹
Jorge Silva Centeno²

1 Pós Graduação em Ciências Geodésicas - UFPR – mfbotelho@yahoo.com.br

2 Depto. De Geomática - UFPR centeno@geoc.ufpr.br

RESUMO

O presente trabalho investigou a influência da alternância de classes e amostras na entrada da Rede Neural, na classificação de imagens digitais oriundas do sensoriamento remoto. Este trabalho envolve a análise da eficiência do software de simulação, MULTIBACK, que modela as RNAs para identificação de feições utilizando o modelo de retro-propagação.

Palavras-chave: Sensoriamento Remoto; Redes Neurais; Classificação de Imagens

ABSTRACT

The present work investigates the influence of the alternation of classes and samples in Neural Network input in the classification of remote sensing digital images. This work involves the analysis of the efficiency of the simulation software, MULTIBACK, that models RNAs for identification of features using the back-propagation model.

Keywords : Remote sensing; Neural NetWork; Image Classification

1. INTRODUÇÃO

As redes neurais pertencem a um dos ramos da Inteligência Artificial que busca inspiração no funcionamento do cérebro para construir algoritmos computacionais inteligentes os quais serão capazes de aprender e desenvolver suas representações internas do conhecimento. A habilidade das redes em extrair complicadas relações lineares (e não lineares) a partir dos dados de entrada ruidosos de imagens digitais, oriundas do sensoriamento remoto, tem produzido resultados surpreendentes (HAYKIN, 2001).

A utilização de Redes Neurais Artificiais emerge como uma alternativa vantajosa aos classificadores baseados em conceitos estatísticos, uma vez que nenhuma hipótese prévia sobre a distribuição dos dados a serem classificados é exigida, e os dados de entrada podem ter origens e escalas diferentes (RIBEIRO, S. R. A.; BÁHR, H. P. e CENTENO, J. S., 2002). As Redes Neurais artificiais tem considerável potencial para a classificação de dados advindos de Sensoriamento Remoto. A classificação através de um conjunto de treinamento mostra que as Redes Neurais apresentam capacidade para classificar classes melhor que o método da análise discriminante (FOODY; MCCULLOCH E YATES, 1995).

No presente artigo são apresentados os resultados de um experimento que investigou a influência da alternância de classes e amostras na entrada da Rede Neural na classificação de imagens digitais oriundas do sensoriamento remoto. Este trabalho envolve verificar a influência da variação da quantidade de amostras para cada classe, quando as classes na entrada da rede para a classificação final forem intercaladas. Também pretende-se analisar a eficiência do algoritmo do modelo de retro-propagação, para classificação de imagens digitais, adaptado para possibilitar a variação da camada intermediária, a normalização dos padrões de entrada, assim como a classificação da imagem implementado no software MULTBACK.

2. REVISÃO DE LITERATURA

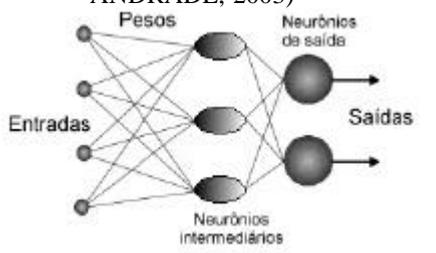
2.1. REDES NEURAIAS

As Redes Neurais vêm sendo utilizadas com sucesso nas mais diversas áreas de pesquisas, principalmente como ferramenta de classificação de imagens digitais. Pode-se citar: na detecção de focos de incêndio (TORINO E BARRETO, 2002); na classificação de áreas agrícolas, na separação de culturas (VIEIRA, 2000); na medicina para a detecção de câncer em Mamogramas Digitalizados (KINOSHITA, MARQUES E FRERE 2000); no desenvolvimento de métodos para a detecção de movimentos de objetos, através de seqüência de imagens digitais (FERNANDEZ – CABALLERO E AL, 2003) e outras. Neste mesmo incentivo, outros pesquisadores têm se empenhado para melhorar a arquitetura ou a classificação na saída da rede,

fazendo com que fique mais rápida no seu processamento, aprendizado e treinamento como visto em JI (2000), TONDER E EJIMA (2000), OLIVEIRA E BAUCHSPIESS (2001), MARTINS, GUIMARÃES E FONSECA (2002), YILMAZ E AKIN (2002), BAKKER E HESKES (2003).

Conforme DYMINSKI (2000), uma rede neural é constituída por diversos neurônios dispostos em camadas, como é mostrado na figura 1. Usualmente as camadas são classificadas em três grupos: camada de entrada: onde os padrões são apresentados à rede; camadas escondidas: onde é feito o processamento; camada de saída: onde o resultado final é concluído e apresentado. O número de neurônios de entrada é função do número de variáveis considerados para a classificação.

FIGURA 1 – ARQUITETURA DE UMA REDE NEURAL (ADAPTADO DE ANDRADE, 2003)



Em cada neurônio (i) de cada uma das camadas (j), os valores das entradas (x_i) são multiplicados por um peso (W_{ij}), que simula a sinapse biológica, gerando entradas ponderadas, como é mostrado na equação 1. A soma ponderada das entradas resulta num único valor (NET) que será comparado com o valor limite para ativação do neurônio. Se este valor alcançar o limite de ativação do neurônio, ele será excitatório, e será repassado aos neurônios seguintes, caso contrário ficará inativo (VIEIRA, 2000).

$$\text{NET} = \sum W_{ij} * x_i \quad (1)$$

A função de ativação do neurônio é quem controla as suas saídas, ou seja, processa o valor NET e gera a saída, que será aplicada a outro neurônio. Os valores da ativação resultantes serão modulados por uma função de transferência (não linear - sigmóide, lógica, linear, etc...). Geralmente, adota-se funções não lineares, devido ao fato de simularem mais precisamente os neurônios biológicos (ABELÉM, 1994).

2.2. TREINAMENTO POR MEIO DO ALGORITMO DA RETROPROPAGAÇÃO

A Rede Neural pode ser treinada para resolver problemas de classificação multispectral. Treinar uma Rede Neural significa ajustar a sua matriz de pesos (W) de forma que o vetor de saída coincida com um certo valor desejado para cada vetor de entrada (RIBEIRO, E CENTENO, 2001).

O algoritmo de retro-propagação é o algoritmo mais utilizado para o treinamento de Redes Neurais, sendo em parte, responsável pelo ressurgimento do interesse dessa área da Inteligência Artificial. Este é um algoritmo supervisionado que consiste em fornecer padrões de classes conhecidas, de forma a ajustar os pesos das conexões entre neurônios, objetivando minimizar o erro na saída, o que caracteriza o aprendizado. O algoritmo baseia no método do gradiente decrescente (RIBEIRO E CENTENO, 2001).

As funções mais utilizadas no modelo de retro-propagação são as funções não lineares (ABELÉM, 1994; VIEIRA, 2000). Foi adotada, para este trabalho a função sigmóide, onde os pontos de saturação estão entre 0 e 1.

3. MATERIAIS E MÉTODOS

3.1. IMAGEM

Utilizou-se parte da imagem de satélite, Spot HRV de 28 de junho, com 3 bandas, figura 2, que representa uma área de estudo localizada próxima à cidade de Littleport no município de Cambridge, leste da Inglaterra, fornecido gentilmente pela Universidade Federal de Viçosa. Esta área está aproximadamente ao nível do mar com topografia levemente ondulada. A agricultura da região é caracterizada por técnicas de plantação de colheita rotativa, contendo culturas agrícolas como: Batata, batata doce, trigo, Terra improdutiva, cebola, Pêra, Cebola, Parnips, cenoura. A imagem cobre uma área de 200 x 200 pixels, correspondente a 16 km².

Para esta imagem, dispõe-se de uma classificação de referência, ou seja, a verdade de campo detalhada, cobrindo toda a imagem. Esta atividade foi executada durante a tese de doutorado de VIEIRA(2000). Esta classificação ideal, mostrada na figura 3, será usada para avaliar o desempenho da classificação.

FIGURA 2 – IMAGEM SPOT HRV DE 28 DE JUNHO 1999

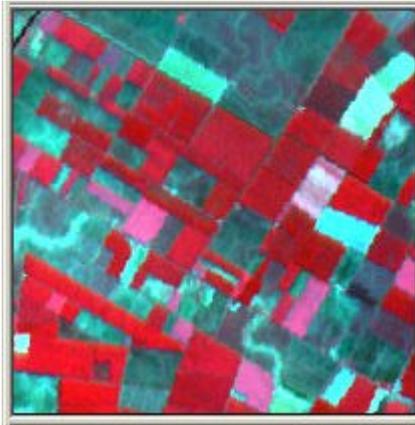
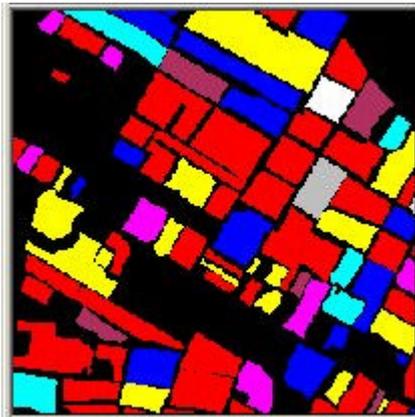


FIGURA 3 – IMAGEM DE REFERÊNCIA



| | |
|--|-------------------|
|  | Batata |
|  | Batata Doce |
|  | Trigo |
|  | Terra improdutiva |
|  | Cebola A |
|  | Pêra |
|  | Cebola B |
|  | Parsnips |
|  | Cenoura |

3.2. EQUIPAMENTOS UTILIZADOS

Foi necessário para a execução deste trabalho:

- um computador DURON 850, HD 10.0 GB, 128 MB RAM, monitor LG SVGA
- O algoritmo de retro-propagação implementado no programa MULTIBACK.

3.3. MODELO DE APRENDIZADO DA REDE NEURAL

Implementou-se um algoritmo do modelo de retro-propagação do erro para classificação de imagens digitais, o qual foi originalmente implementado por VIEIRA (2000) na linguagem C ++, ambiente MS-DOS, para a identificação de feições. Neste estudo por meio do software BUILDER 3, converteu-se esse modelo para o ambiente Windows, em linguagem C++, possibilitando assim a variação dos neurônios da camada intermediária, Taxa de Aprendizado e Momento. Este produto foi intitulado como MULTIBACK.

Para este trabalho foi utilizado apenas uma camada intermediária na rede (a única disponível pelo software). No algoritmo de treinamento da retro-propagação do erro o cálculo da variação dos pesos e do erro estão expressos pelas Equações 2 e 3.

$$\Delta W_{ij} = \mathbf{hd} \mathbf{q} \quad (2)$$

$$\mathbf{d} = (A - \mathbf{q})$$

Onde:

A : saída esperada

\mathbf{q} : saída da rede

\mathbf{d} : representa a diferença entre a saída esperada (A), e a saída da rede

ΔW_{ij} : variação dos pesos

Foi adotada, para este trabalho a função sigmóide, onde os pontos de saturação estão entre 0 e 1 (Equação 4).

$$\mathbf{a}_i(t+1) = \frac{1}{1 + e^{-NET_i}} \quad (4)$$

Já para se fazer o ajuste dos pesos para as camadas intermediárias, não existe padrão específico, logo substituí o erro local apresentado na Equação 3, pelo somatório dos produtos entre os pesos que ligam o neurônio em questão com os neurônios da camada de saída (i) e os deltas (\mathbf{d}) dos respectivos neurônios dessa camada.

Para iniciar o processo de treinamento das Redes Neurais, é necessário que todos os pesos sejam inicializados aleatoriamente com valores pequenos, garantindo desta forma que a rede não fique saturada com grandes valores. No treinamento são realizados os seguintes passos:

1. Selecionar um conjunto de treinamento e aplicar estes padrões individualmente à rede.
2. Calcular a saída da rede.
3. Calcular a diferença entre a saída da rede e a saída desejada (erro).
4. Ajustar os pesos da rede de maneira a minimizar o erro.
5. Repetir o passo 1 até o passo 4 para cada padrão do conjunto de treinamento, até o erro se tornar aceitável para o conjunto total de padrões.

4. EXPERIMENTOS

Da imagem original, foram escolhidas várias amostras de culturas diferentes (720 amostras totais, sendo que 120 para cada classe sendo um total de 6 classes). Estas amostras foram utilizadas em dois experimentos: No primeiro, as amostras foram organizadas e ordenadas por classe. Isto significa que todas as amostras de uma mesma classe eram apresentadas à rede uma atrás da outra, para só então ser apresnetadas as amostras de uma classe diferente. Na segunda série de experimentos, as amostras foram intercaladas, variando-se também o número de amostras e a quantidade de amostras intercaladas.

Os dados foram normalizados, devido tratar-se de uma imagem de satélite (a normalização é necessária para não saturar a função de transferência - sigmoideal) onde os dados precisam variar entre 0 e 1, considerando o fator de normalização igual a 255, que é o maior valor de um nível de cinza.

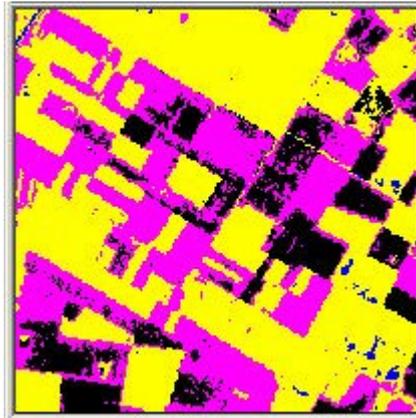
Na determinação da arquitetura da rede, considerou-se 30 neurônios na camada escondida. Neste experimento, foi utilizada uma taxa de aprendizado igual a 0,2 e o momento igual a 0,9.

5. RESULTADOS E DISCUSSÃO

5.1. VERIFICAÇÃO DA EFICIÊNCIA DO ALGORITMO SEM ALTERNÂNCIA ENTRE AMOSTRAS

O processo de aprendizado foi detido depois de 21.141 ciclos de treino quando a rede encontrou o mínimo geral na superfície de erro, com 0,19697 de erro relativo. Após verificar esta convergência, fez-se a classificação de toda a imagem utilizando a mesma arquitetura de rede e os pesos determinados na fase de aprendizado. O resultado é mostrado na figura 4. Comparando este produto com a imagem de referência (Figura 3), nesta classificação foi constatado que 51% dos pixels encontram-se corretamente classificados.

FIGURA 4 - CLASSIFICAÇÃO SEM VARIAÇÃO DAS CLASSES NA ENTRADA DA REDE



5.2. A INFLUÊNCIA DA ALTERNÂNCIA DE AMOSTRAS NAS CLASSES.

Realizaram-se testes variando a quantidade de amostras para cada classe e intercalando as mesmas, gerando assim suas frequências ou séries. Na entrada da rede foram colocadas seqüências de séries de classes. Na Tabela 1 encontra-se um resumo dos testes realizados com as amostras na entrada da rede. Por exemplo, no primeiro experimento desta série (teste 1, na tabela 1), 120 amostras foram escolhidas para cada classe, sendo elas intercaladas por classe. No segundo experimento, apenas 60 amostras foram escolhidas para cada classe e elas foram intercaladas em pares.

Comparando os resultados dos testes da Tabela 1, observa-se que o teste 4 foi aquele que gerou a maior melhora na classificação, visto que o erro na imagem de referência foi de 28%, ou seja, a imagem gerada teve uma classificação de 72% de acertos (Figura 5). Também observa-se, para o experimento 4, que o número de ciclos foi menor que o número de ciclos que gerou a imagem sem a alternância de classes, isto justifica-se não só a alternância entre classes mas também devido a quantidade de amostras necessária para o aprendizado da rede ser menor.

Como exemplo, no teste 3, o total de amostra é de 120. Sendo 10 amostras por classe, como no caso em estudo temos 6 classes, tendo um total de 60. As Classes

foram repetidas (séries ou freqüência) 2 vezes perfazendo um total de 120 amostras a serem processadas pela Rede Neural.

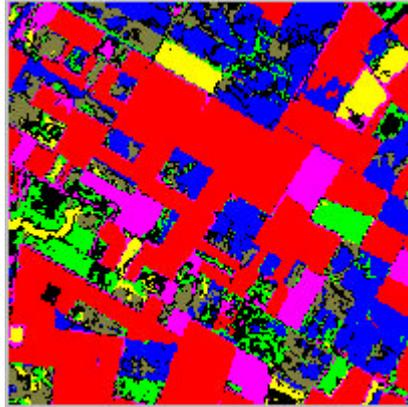
TABELA 1 – TABELA REFERENTE AOS TESTES EXECUTADOS VARIANDO O NÚMERO DE AMOSTRAS E INTERCALANDO AS AMOSTRAS.

| Testes | Total de amostras | Amostra/ Classe | Séries ou Freqüências | Erro na Imagem referência (%) | Total de Ciclos |
|--------|-------------------|-----------------|-----------------------|-------------------------------|-----------------|
| 1 | 720 | 120 | 1 | 49 | 21000 |
| 2 | 720 | 60 | 2 | 49 | 3000 |
| 3 | 120 | 10 | 2 | 31 | 3000 |
| 4 | 120 | 5 | 4 | 28 | 13000 |
| 5 | 90 | 5 | 3 | 29 | 10000 |
| 6 | 96 | 4 | 4 | 29 | 9000 |
| 7 | 72 | 3 | 4 | 31 | 23000 |
| 8 | 72 | 12 | 1 | 67 | 15000 |

Observa-se, na Tabela 1, que quando fixamos o número de amostra, para o teste 1 e 2 (um valor relativamente alto de amostras), notamos a irrelevância no resultado final da classificação tendo um erro na imagem de referência igual a 49%. Quando diminuimos a quantidade de amostra, para o teste 3, e mantivemos o número de séries, observa-se uma melhoria significativa no resultado final. Notamos que ao aumentar a quantidade de séries, a quantidade de amostras por classe diminui (testes 4, 5 e 6), tendo assim uma melhoria no aprendizado da rede. Porém quando, diminuimos novamente o número de amostras para o teste 7, percebemos que o erro na imagem de referência aumentou, igualando-se ao erro encontrado no teste de número 3 apesar da diferença na quantidade de amostras e séries. Observa-se, para o teste 8, que para um número de amostras pequeno e a não alternância das classes, resultaram em um erro na imagem de referência de 67%. Logo concluímos que a convergência na classificação final está relacionada com o número de séries impostas para a rede. Portanto conclui-se que:

- Quando se tem muita amostra na entrada da rede, satura-se o aprendizado, além de deixá-la muito lenta.
- Quanto menor o número de amostras melhor o resultado da classificação final, isto acompanhado das respectivas séries. Porém temos que observar que 1 amostra equivale a 1 pixel e portanto necessitamos de um mínimo, neste caso, de 5 pixel para ter uma área representativa na imagem.

FIGURA 5 - IMAGEM GERADA COM A VARIAÇÃO DAS CLASSES NA ENTRADA DA REDE.



6. CONCLUSÃO

Conclui-se que a alternância entre classes na entrada da rede é recomendada, sendo ela responsável por uma melhoria de até 20% na classificação final da imagem digital oriunda do sensoriamento remoto e também que a alternância de classes na entrada da rede leva a otimizar o aprendizado da rede assim como diminuir a quantidades de amostras para seu treinamento.

O algoritmo da retropropagação, implementado (nesse estudo) por meio do programa intitulado MULTIBACK, para a classificação de imagens digitais é eficiente devido a possibilidade de se poder variar os neurônios da camada intermediária, bem como a variação das taxas de aprendizado e do termo “Momento” e ainda o usuário poder interferir na alternância das amostras.

7. REFERÊNCIAS

ABELÉM, A. J. G., **Redes Neurais Artificiais Na Previsão De Séries Temporais**, publicação Dissertação de Mestrado pela Universidade Católica do Rio de Janeiro, RJ, Brasil, p.157, 1994.

ANDRADE, F. A. **Integração de variáveis espectrais e forma na classificação de imagens de alta resolução utilizando redes neurais artificiais**. Dissertação de mestrado pela Universidade Federal do Paraná, Curitiba, p.120, 2003.

BAKKER, B. e HESKES, T. **Clustering ensembles of neural network models.** Neural Networks, v.16, p.261-269, 2003.

DYMINSKI, A.S. **Análise de Problemas Geotécnicos Através de Redes Neurais.** Rio de Janeiro. (Tese) - Universidade Federal do Rio de Janeiro, p.196, 2000.

FERNÁNDEZ – CABALLERO et al. **On Motion Detection Through a Multi-Layer Neural Network Architecture.** Neural Networks, v.13, p.291-303, 2000.

FOODY, C.M. ; MCCULLOCH, M. B. ; YATES, W.B. **Classification of remote sensed data by an artificial neural network: issues related to training data characteristics.** Photogrametric Engineering & Remote Sensing, v.61, n.4, p.391–401, 1995.

HAYKIN, S. **Redes Neurais. princípios e prática.** Porto Alegre: Bookman, p. 900, 2001.

JI, C.Y. **Land-Use Classification of Remotely Sensed Data Using Kohonen Self-Organizing Feature Map Neural Networks.** Photogrametric Engineering & Remote Sensing, v.66, n.12, p.1451– 1460, 2000.

KINOSHITA, S.K.; MARQUES, P.M.A. e FRÈRE, A.F. **Utilização da Análise de Componentes Principais e Redes Neurais Artificiais para a Classificação de Nódulos em Mamogramas Digitalizados.** Anais do CBEB'2000, p.1214-1216, 2000.

MARTINS, M. P. GUIMARÃES, L. N. F. E FONSECA, L. M. G. **Classificador de Texturas por Redes Neurais.** II Congresso Brasileiro de Computação, p.6, 2002.

OLIVEIRA, K. C. e BAUCHSPIESS A. **Classificação de Imagens Codificadas por Cadeias Direcionais Utilizando Redes Neurais Artificiais.** V Congresso Brasileiro de Redes Neurais, PUC, Rio de Janeiro – RJ –Brasil, p. 73-78, 2001.

RIBEIRO, S. R. A. e CENTENO, J.A.S. **Classificação do uso do solo utilizando redes neurais e o algoritmo maxver,** in INPE/SELPER (Ed.), Anais do XX Simpósio brasileiro de sensoriamento remoto, p. CD, Foz do Iguaçu, INPE, 2001.

RIBEIRO, S. R. A.; BÄHR, H. P. e CENTENO, J. S. **Integração de imagens de satélite e dados complementares para a delimitação de unidades de paisagens usando uma abordagem baseada em regiões.** Boletim de Ciências Geodésicas, Curitiba, v.8, nº1, p.47-57, 2002.

TONDER, G. J. e EJIMA, Y. **The patchwork engine: imagem segmentation from shape symmetries.** Computers & Geosciences, v.13, p.291-303, 2000.

TORINO, C. V. e BARRETO, D. T. Detecção de Fumaça Através do Processamento de Imagem Utilizando Redes Neurais em um Sistema Híbrido. XIV Congresso Brasileiro de Automática, Natal – RN, p.1434-1439, 2002.

VIEIRA, C. A. O. Accuracy Of Remotely Sensing Classification Of Agricultural Crops: A Comparative Study. Thesis Submitted to the University of Nottingham for the Degree of Doctor of Philosophy, p.396, 2000.

YILMAZ, S.; DEMIRCIOGLU, C. E AKIN, S. Application de artificial neural networks to optimum bit selection. Computers & Geosciences, v.28, p.261-269, 2002.