

Solução do Problema Inverso para Obtenção de Perfis Verticais de Temperatura da Atmosfera utilizando Redes de Elman

Elcio H. Shiguemori José Demisio S. da Silva Haroldo F. de Campos Velho
Laboratório de Computação e Matemática Aplicada - LAC
Instituto Nacional de Pesquisas Espaciais - INPE
[elcio, demisio, haroldo]@lac.inpe.br

Resumo

Perfis verticais de temperatura da atmosfera são inferidos por uma rede neural artificial a partir de dados de satélite. Os perfis verticais são uma peça chave para os modelos numéricos de previsão do tempo, principalmente no hemisfério sul, onde há grandes áreas não cobertas por estações de coleta de dados terrestres. Neste artigo, a rede neural de Elman é utilizada no processo de inversão. A rede tem uma arquitetura considerada parcialmente recorrente, visando adicionar memória ao modelo. Por ter seu processo de aprendizagem supervisionado ela é treinada com dados providos pelo modelo direto caracterizado pela equação de transferência radiativa. Além disso, dados reais de radiação medidos no HIRS-2 - High Resolution Infrared Radiation Sounder - são usados como entrada para a rede neural como teste de validação, os resultados da inversão são comparados com perfis de temperatura medidos por uma radiossonda. Uma análise dos resultados obtidos mostra que a rede neural apresenta resultados próximos aos obtidos por métodos de regularização de alta ordem, de Tikhonov e Máxima Entropia.

***Palavras-chave:** problemas inversos, redes neurais artificiais, perfis verticais de temperatura, redes de elman.*

1. Introdução

A estrutura vertical de temperatura e vapor d'água representa uma importante informação para processos meteorológicos da atmosfera. Entretanto, devido a problemas logísticos e econômicos, há uma grande deficiência de observações da Terra. Nesse sentido, a recuperação de perfis verticais de temperatura e umidade da atmosfera a partir de dados de radiancias de satélites tornam-se importante para

aplicações como análise de tempo e assimilação de dados em previsão numérica de tempo.

Interpretação de radiancias de satélites em termos de parâmetros meteorológicos requer a inversão da Equação de Transferência Radiativa (ETR) onde medidas de radiação realizadas em diferentes frequências são relacionadas à energia de diferentes regiões da atmosfera. O grau de indeterminação do problema está associado com a resolução espectral e o número de canais espectrais. Entretanto, a solução é muito instável com relação a ruídos nos processos de medidas (Carvalho et al. 1999; Ramos et al. 1999). Outras metodologias e modelos também têm sido empregadas para melhorar o processamento de dados de satélites. Devido à dificuldade de obter soluções corretas, várias aproximações e métodos têm sido desenvolvidos para extrair informações de dados de satélites (Chahine, 1970; Liou 1982; Smith, 1985).

Neste artigo, uma rede neural artificial (RNA) proposta por Elman (1990) é usada para resolver a inversão de dados de sensoriamento remoto. Outros modelos têm sido utilizados para o processo de inversão (Shiguemori et al., 2004-a, 2004-b; Viterbo et al., 2004). Os perfis verticais de temperatura obtidos pela técnica são comparados como os obtidos por Carvalho et al. (1999) e Ramos et al. (1999), que utilizaram técnicas de regularização de Tikhonov e princípio da máxima entropia de alta ordem.

A rede neural utilizada tem o aprendizado supervisionado, onde os conjuntos de treinamento são formados por pares de entrada e saída. As entradas são medidas de radiancias obtidas por diferentes canais do satélite e as saídas desejadas são os perfis verticais de temperatura nas diferentes camadas da atmosfera. O conjunto de treinamento é formado pela solução do problema direto, a partir de perfis de temperatura sintéticos e perfis verticais reais medidos por radiossonda.

Primeiramente, na Seção 2 é apresentado o modelo direto da equação de transferência

radiativa. Na seção 3 é apresentada a arquitetura da rede neural utilizada. Na seção seguinte são apresentados os resultados de generalização da rede apresentando 324 padrões não utilizados na fase de treinamento e em seguida o resultado obtido pela rede quando apresentados reais obtidos pelo HIRS/2. Finalmente, as conclusões são apresentadas na seção 5.

2. Problema Direto

O problema direto pode ser expresso como:

$$I_\lambda(0) = B_\lambda(T_s)\mathfrak{S}_\lambda(p_s) + \int_{p_s}^0 B_\lambda[T(p)] \frac{\partial \mathfrak{S}_\lambda(p)}{\partial p} dp \quad (1)$$

onde I_λ é a radiância espectral, λ é a frequência do canal, \mathfrak{S} é a camada da função de transmitância atmosférica, s é a superfície [chahine] e B é a função de Planck que é função da temperatura T e pressão p :

$$B_\lambda(T) = \frac{2hc^2 / \lambda^5}{[e^{hc/\lambda k_B T} - 1]} \quad (2)$$

sendo h é a constante de Planck, c a velocidade da luz e k_B é a constante de Boltzmann.

Por propósitos práticos, a equação (1) é discretizada usando diferenças finitas centrais (Carvalho et al. 1999 e Ramos et al. 1999):

$$I_i = B_{i,s}(T_s)\mathfrak{S}_{i,s} + \sum_{j=1}^{N_p} \left(\frac{B_{i,j} + B_{i,j-1}}{2} \right) [\mathfrak{S}_{i,j} - \mathfrak{S}_{i,j-1}] \quad (3)$$

onde $i=1, \dots, N_\lambda$, com $I_i \equiv I_{\lambda_i}(0)$, N_λ é o número de canais no satélite e N_p é o número de camadas atmosféricas consideradas.

A solução do problema direto é utilizada para gerar os conjuntos de treinamento. Este procedimento nem sempre é necessário, pois o conjunto de treinamento poderia ser formado somente por radiâncias medidas por satélite e perfis de temperatura obtidos por radiossondagem.

3. Arquitetura da rede neural

RNAs são compostas de elementos simples de processamento (neurônios). Um modelo de neurônio artificial consiste basicamente de uma

combinação linear seguida de uma função de ativação.

Arranjos destas unidades formam as RNA caracterizadas por:

1. elementos de processamento muito simples;
2. pesos sinápticos entre os elementos de processamento;
3. processamento paralelo e controle distribuído;
4. aprendizagem automática de representações internas.

RNAs exploraram o intrínseco processamento paralelo e a tolerância à falhas; propriedades que tornam as RNAs apropriadas para aplicação em reconhecimento de padrões, processamento de sinais, processamento de imagens, mercados financeiros, visão computacional, engenharia, etc. (Haykin, 1994; Lin e Lee, 1996; Nadler e Smith, 1993; Tsoukalas e Uhrig, 1997).

O mais simples modelo de RNA é o Perceptron de uma única camada com uma função de ativação degrau, que é apropriada, somente, para resolver problemas lineares. Essa de deficiência contribuiu para um período de pouca pesquisa sobre redes neurais na década de 70 (Haykin, 1994). Na década de 80 as redes ressurgiram com a publicação do artigo de Hopfield (1982) em redes recorrentes e a publicação de dois volumes de processamento paralelo por Rumelhart e McClelland (Haykin, 1994).

Existem diferentes arquiteturas de redes neurais artificiais que são dependentes da estratégia de aprendizagem adotada. Esse artigo descreve a rede neural utilizada na simulação: a rede recorrente de Elman – ver Figura 1. A rede recorrente de Elman (1994) recebe sinais de realimentação da primeira camada escondida. Os pesos das unidades escondidas são treinados da mesma forma como os pesos da camada de saída.

Na figura 1 x é a entrada da rede neural, $i=1 \dots n$ é a dimensão do vetor de entrada, y_{mk} é o k -ésimo neurônio da m -ésima camada e X_{1k} é a k -ésima entrada recorrente da rede neural.

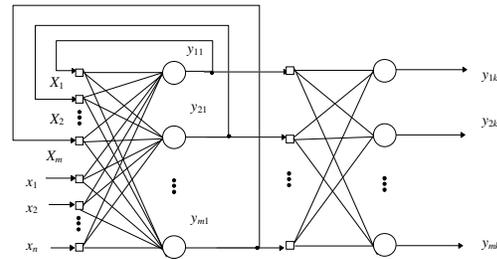


Figura 1 - Arquitetura de uma rede recorrente simples.

Na fase de aprendizagem, o algoritmo utilizado para o treinamento foi o da retropropagação do erro, discutido detalhadamente em Haykin (1994). Deve-se observar que num dado instante a rede não só recebe a entrada externa, mas também a realimentação da saída da primeira camada oculta da rede.

4. Solução do problema inverso

As redes neurais artificiais têm dois estágios em sua aplicação. Durante a fase de aprendizagem, os pesos e limiares da rede correspondentes a cada conexão são ajustados. Para a ativação, a saída é obtida baseada nos pesos e limiares calculados durante a fase de treinamento.

4.1 Treinamento

Os dados experimentais que intrinsecamente contêm erros no mundo real, é simulado adicionando ruído gaussiano à solução exata do problema direto:

$$\tilde{I} = I_{\text{exato}} + \sigma \mu \quad (4)$$

onde σ é o desvio padrão do ruído e μ é uma variável aleatória com distribuição Gaussiana, com média zero e variância unitária. Neste artigo, os experimentos foram corrompidos com 5% de ruído.

A rede foi treinada com um conjunto de treinamento formado com 101 perfis de temperatura sintéticos e 324 escolhidos aleatoriamente de um conjunto de temperatura do banco de dados TIGR (Chédin et al., 1985).

4.2 Ativação

Para análise dos resultados, o erro entre a temperatura obtida pela rede neural e pela temperatura desejada é calculado em 3 diferentes camadas. As camadas 1 e 2, que são as áreas de maior interesse para os meteorologistas compreendem, respectivamente, entre 1000-500 hPa e 475-250 hPa. As camadas 3 e 4 compreendem, respectivamente, entre 200-85 hPa e 70-20 hPa.

A média dos erros dos resultados da inversão, para cada camada atmosférica, obtida com a rede neural de Elman é descrita na tabela 1 e obtida por:

$$\text{Erro} = \frac{1}{Np} \sum_{i=p_a}^{p_b} (T_i^{\text{Radiosonda}} - T_i^{\text{Rede Neural}}) \quad (5)$$

onde Np é o número de pontos em cada camada, p_a e p_b são, respectivamente, pressão inicial e final em cada camada.

Tabela 1 - Resultados dos testes de generalização, utilizando a rede de Elman.

Neurônios escondidos	Camada 4	Camada 3	Camada 2	Camada 1
1	3.2546	3.6673	2.2253	2.4813
2	2.0222	2.4679	2.0208	1.4305
3	2.0172	2.5542	2.0840	1.2403
4	2.0685	2.5711	2.0605	1.2616
5	1.8740	2.3128	2.0796	1.3760
6	1.8715	2.2003	1.8518	1.3273
7	1.8641	2.1751	1.7601	1.2668
8	1.9157	2.2488	1.9060	1.4143
9	1.9033	2.3149	2.1434	1.2825

5. Solução utilizando dados reais de radiancias de satélites

Simulações utilizando dados reais de radiancias de satélites – High Resolution Radiation Sounder (HIRS-2) do NOAA-14, foram realizadas para avaliar a precisão da rede de Elman, sendo o HIRS-2 um dos três instrumentos de medida do TIROS Operational Vertical Sounder (TOVS). O resultado obtido pela RNA é comparado com as medidas de temperatura da atmosfera obtida com uma radiosonda e com os resultados obtidos por Carvalho et al. (1999) e Ramos et al. (1999), que usaram o princípio da máxima entropia e regularização de Tikhonov de alta ordem na solução.

O número de observações correspondentes é uma fração do número de temperatura que deseja-se estimar: deseja-se estimar o perfil de temperatura em 40 camadas a partir de radiancias medidas em 7 canais do satélite.

Similarmente aos resultados apresentados no exemplo de generalização, os erros da simulação são apresentados em 4 diferentes camadas e são apresentados na tabela 2.

Comparando-se os resultados obtidos pela rede de Elman pelos obtidos pela Rede Perceptron de Múltiplas Camadas (RPMC) apresentados em Shiguemori et al. (2004), pode-se observar que o uso da rede de Elman na solução do problema inverso não melhora a qualidade do perfil vertical de temperatura na atmosfera. No entanto, observa-se que bons resultados (inversões) podem

ser obtidos utilizando uma quantidade menor de neurônios na camada escondida. Mesmo considerando que o número de conexões aumenta ao utilizar entradas recorrentes entre os neurônios na camada escondida, como a última camada deseja-se calcular a temperatura em 40 pontos diferentes, o número de conexões da rede neural diminui. Esta característica pode ser útil em algumas aplicações, pois o custo computacional é menor. A necessidade de uma quantidade menor de neurônios na camada escondida pode ser observada nos testes de generalização utilizando 324 padrões, bem como no teste de generalização utilizando dados reais medidos pelo satélite.

9	1.4401	3.2534	2.1625	0.5787
---	--------	--------	--------	--------

Dois exemplos de perfis verticais de temperatura obtidos pela rede de Elman, utilizando 2 e 3 neurônios na camada escondida são apresentados, respectivamente, nas Figuras 2 e 3. O perfil vertical de temperatura medido pela radiossonda é apresentado em preto; o resultado da inversão obtido pela rede neural de Elman é apresentado em azul e as soluções obtidas pelos métodos de regularização de Tikhonov de ordem 1 em vermelho e obtidas pelo método de regularização pelo princípio da máxima entropia de ordem 2 são representadas em verde.

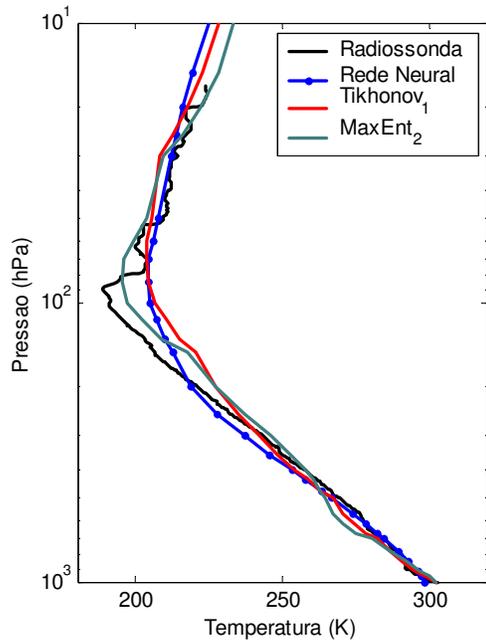


Figura 2 - Inversão obtida pela rede de Elman utilizando 2 neurônios na camada escondida.

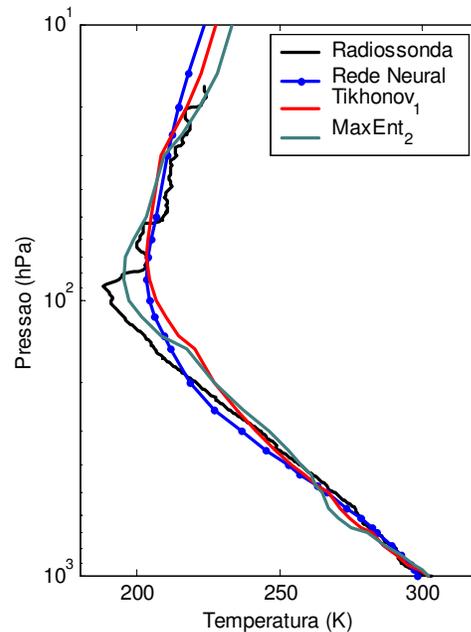


Figura 3 - Inversão obtida pela rede de Elman utilizando 3 neurônios na camada escondida.

Tabela 2 - Resultados do teste de Generalização, utilizando a rede de Elman.

Neurônios escondidos	Camada 4	Camada 3	Camada 2	Camada 1
1	5.5722	8.6230	2.3809	3.6574
2	1.2737	3.8398	1.8219	0.5294
3	1.4819	3.6493	1.9991	0.5585
4	1.5825	3.4847	1.9785	0.5786
5	1.3829	3.2676	1.9183	0.5553
6	1.4842	3.5895	1.9395	0.5835
7	1.3712	3.4206	2.2913	0.7608
8	1.7342	3.2084	1.6709	0.5693

5. Conclusões

A formulação matemática do problema de recuperação de perfis verticais de temperatura a partir de dados de sensoriamento remoto é dada pela inversão da equação integral de transferência radiativa, e que conduz à solução da equação integral de Fredholm mal-condicionada. Os resultados mostram boas aproximações entre recuperações da rede neural de Elman e das medidas de radiossonda.

A rede mostrou-se eficiente para resolver o problema inverso, e as reconstruções são comparáveis com os métodos de regularização apresentados em (Carvalho et al., 1999 e Ramos et al. 1999). Foi observado que a rede neural de Elman resolve o problema inverso para obtenção dos perfis verticais de temperatura na atmosfera, tal como os resultados apresentados em (Shiguemori et al. 2004-a e 2004-b; Viterbo et al. 2004). Apesar de não terem sido recuperados melhores resultados comparando-se com os resultados obtidos pela rede neural Perceptron de Múltiplas Camadas (Shiguemori et al. 2004) a rede apresentou bons resultados utilizando uma quantidade menor de neurônios na camada escondida, deste modo seu uso pode apresentar vantagens em aplicações, pois o uso de uma quantidade menor de pesos e limiares diminui o custo computacional.

Na prática, algoritmos de inversão operacionais reduzem o risco de caírem num mínimo local inicializando o processo de busca iterativo de uma estimativa inicial suficientemente próxima ao perfil verdadeiro, particularmente em regiões onde pelo menos uma informação *a priori* é conhecida (Chédin, 1985). RNAs podem relaxar essa restrição incorporando mais dados na fase de aprendizagem.

Algumas vantagens podem ser listadas com o uso de RNA: após da fase de treinamento, a inversão com redes neurais artificiais é muito mais rápida que métodos de regularização; RNAs podem ser implementadas em hardware, os neurocomputadores, se tornando um método de inversão mais rápido que as RNA emuladas em software.

Agradecimentos

Este trabalho teve apoio do CNPq - Brasil e FAPESP - São Paulo.

Referências bibliográficas

Carvalho, J. C.; Ramos, F. M.; Ferreira, N. J.; Campos Velho, H. F. Retrieval of Vertical Temperature Profiles in the Atmosphere, *3rd International Conference on Inverse Problems in Engineering (3ICIPE)*, Proceedings in CD-ROM, paper code HT02, 1999, 235-238.

Chahine, M. T. Inverse Problem in Radiative Transfer: determination of atmospheric parameters, *Jour. Atmos. Sci.*, 1970, 27, 960.

Chédin, A.; Scott, N. A.; Wahiche, C.; Moulini, P.; The improved initialization inversion method: A high resolution physical method for temperature retrievals from TIROS-N series. *Climate Appl. Meteor.*, 1985, 24, 128-143.

Elman, J. L. Finding Structure in Time, *Cognitive Science*, 1990, 14, 179-211.

Haykin, S. *Neural Networks: A Comprehensive Foundation*, Macmillan. New York, 1994.

Hopfield, J. J. Neural Networks and physical systems with emergent collective computational abilities, *Proceedings of the National Academy of Sciences*, 1982, 79, p. 2554.

Lin, C-T; Lee, G. *Neural Fuzzy System: A Neuro-Fuzzy Synergism to Intelligent System*, Prentice Hall, New Jersey, 1996.

Liou, K. N. *An introduction to atmospheric radiation*, academic press, Orlando, 1982.

Nadler, M.; Smith, E. P. *Pattern Recognition Engineering*, John Wiley & Sons, New York, 1993.

Ramos, F. M.; Campos Velho, H. F.; Carvalho, J. C.; Ferreira, N. J. Novel Approaches on Entropic Regularization, *Inverse Problems*, 1999, 15(5), 1139-1148.

Shiguemori, E. H.; Campos Velho, H. F.; Silva, J. D. S.; Carvalho, J. C. Neural Network based Models in the Inversion of Temperature Vertical Profiles from Radiation Data, *Inverse Problems, Design and Optimization Symposium - IPDO*, 17-19 Março de 2004, Rio de Janeiro (RJ), Brasil - Proc. in CD-ROM: código do artigo IPDO-077.

Shiguemori, E. H. ; Silva, J. D. S. ; Campos Velho, H. F.; Carvalho, J. C. Radial Basis Function Neural Network in the Inversion of Temperature Vertical Profiles from Satellite Data, *Simpósio Brasileiro de Redes Neurais - SBRN*, 28-01 Outubro 2004, São Luis (MA), Brasil.

Smith, W. L.; Woolf, H. M.; Schriener, A. J. Simultaneous retrieval of surface and atmospheric parameters: a physical analytical direct approach, *Adv. in Rem. Sens.*, 1985, 7.

Tsoukalas, L. H.; Uhrig, R. E. *Fuzzy and Neural Approaches in Engineering*, John Wiley & Sons, New York. 1997.

Viterbo V. C.; Braga J. P.; Shiguemori, E. H. ; Silva, J. D. S.; Campos Velho, H. F. Atmospheric temperature retrieval using non-linear Hopfield neural network, *Inverse Problems, Design and Optimization Symposium - IPDO*, 17-19 Março de 2004, Rio de Janeiro (RJ), Brasil.