



Inversão de dados de SEV utilizando uma rede multicamada

Emerson Araújo do Carmo
Teleson Neves Teles

CPGG/UFBA

Resumo

In this work we tested the application of the artificial neural networks (ANNs) to the inverse problem of eletroresistivity. The ANN used was multilayer perceptron (MLP) and the algorithm was Backpropagation with momentum.

Synthetic data were generated by FORTRAN programs for the training, validation and testing of the MLP. The results obtained for the inverse problem of eletroresistivity show be acceptable, eventhough with limited accuracy. Then we proposed a inversion procedure combining neural networks with linearized inversion. The use of this combined procedure resulted in a safe and fast convergence for the global solution for the models of the test group.

INTRODUÇÃO

O processamento de dados em geofísica é de fundamental importância, para que se possa interpretar o modelo de subsuperfície com base nas medidas de suas propriedades (problema inverso). Convencionalmente métodos de otimização baseados em algoritmos de busca local ou global são utilizados na solução do problema inverso, porém os métodos de busca local são fortemente dependentes de um bom modelo inicial para convergirem para a solução global enquanto que os métodos de busca global são onerosos computacionalmente. Contudo a aplicação de redes neurais artificiais vem sendo estudada como ferramenta opcional no processamento de dados geofísicos. Macias e Sen (1993) investigaram a aplicabilidade de redes neurais artificiais ao problema inverso de eletroresistividade, este trabalho motivou a pesquisa em torno deste assunto proporcionando o surgimento de outros trabalhos tanto no problema da inversão como em outros problemas geofísicos. Trabalhos como os de Teles e Ferreira (1997), Teles (1997), Lopes et al. (1997) e Pimentel e Teles (1997) mostraram o bom desempenho das redes em problemas geofísicos.

Neste trabalho testamos a aplicabilidade de uma rede multicamada no problema inverso de SEV's utilizando dados sintéticos para um modelo de três camadas. Os modelos gerados pela rede após o treinamento foram utilizados como modelos de partida para o algoritmo da inversão linearizada com o intuito de refinar a solução da rede.

MÉTODO DE ELETRORRESISTIVIDADE

O método de eletroresistividade utiliza fontes artificiais que geram correntes (contínua ou alternada de baixa frequência), as quais são introduzidas na terra através de eletrodos. O método se propõe, utilizando as medidas da

distribuição de potencial causado pelas correntes induzidas, extrair informações a respeito da distribuição de resistividade em subsuperfície.

A expressão que relaciona a resistividade aparente com o potencial elétrico, é:

$$\rho_a = \frac{\Delta V}{I} \cdot K \quad (1)$$

onde K é chamado fator geométrico e esta relacionado com a disposição dos eletrodos em campo. Geométricamente, a combinação entre os eletrodos de corrente e potencial chamamos de arranjo. Neste trabalho adotamos o arranjo Schlumberger de eletrodos devido a sua larga aplicação em trabalhos de campo.

As direção onde são efetuadas as medidas na superfície dão origem às técnicas de levantamento. Escolhemos a sondagem elétrica vertical também conhecida como SEV, e que consiste em efetuar as medidas na superfície com o objetivo de determinar a variação da resistividade com a profundidade.

O PROBLEMA INVERSO PARA DADOS DE SEV

O problema inverso em eletroresistividade consiste em através dos dados de resistividade aparente (ρ_a) e afastamento de eletrodos ($AB/2$) coletados em campo, se obter os parâmetros resistividade ρ_i e espessura h_j das camadas em subsuperfície, onde i e j variam da seguinte forma: $i=1,2,\dots,N$ e $j=1,2,\dots,(N-1)$, sendo N o número de camadas. Para se conseguir chegar ao vetor ótimo de parâmetros estimados que reproduza os dados de campo, é feita uma pesquisa no domínio ou espaço de parâmetros a fim de obter aqueles que forneçam o menor erro quadrático médio entre os dados observados e os dados calculados para o conjunto de parâmetros estimado.

Tradicionalmente o ajuste dos dados calculados e observados é feito através da *Inversão Linearizada*. Este método procura, a partir de um ponto de partida no espaço de modelos, encontrar o melhor vetor de parâmetros que minimize a função do erro quadrático entre os dados observados e calculados. A desvantagem deste método, está na dependência de um modelo de partida que esteja o mais próximo possível da solução global, em caso contrário o método poderá divergir ou convergir para um mínimo local. A expressão iterativa utilizada na inversão linearizada para a atualização do vetor de parâmetros no sentido dos mínimos quadrados é:

$$m^{k+1} = m^k + (G_k^t G_k)^{-1} G_k^t (d_{obs} - f(m_k)) \quad (2)$$

onde:

m^{k+1}	vetor de parâmetros da iteração k+1
m^k	vetor de parâmetros da iteração k
G	matriz sensibilidade
d_{obs}	vetor de dados observados
$f(m_k)$	vetor de dados calculados com os parâmetros da iteração k

REDES NEURAIS MULTICAMADAS (MLP)

Se entende por Rede Neural Artificial (ANN) um sistema de processamento de informações que possui certas características em comum com as redes neurais biológicas (Fausett, 1995). As redes neurais artificiais apresentam como principais características o aprendizado através de exemplos, a capacidade de generalização, adaptatividade e tolerância à falhas. A unidade de processamento de um rede neural é o neurônio fig(1)




Figura 1: Neurônio Artificial

onde x_p e y_k são respectivamente os sinais de entrada e saída, w_{kp} são os pesos, e θ_k e φ são respectivamente o bias e a função de ativação (que em geral é não linear). A capacidade da rede em solucionar um problema está diretamente ligado à sua topologia (número de camadas e neurônios, forma de conexão entre as camadas e entre os neurônios) e aos pesos (responsáveis por armazenar o conhecimento do problema em questão).

A rede MLP (Multilayer Perceptron) ou rede multicamada é formada por uma camada de entrada, uma ou mais camadas escondidas e a camada de saída. Este tipo de rede apresenta três características distintas:

- Cada neurônio na rede tem como função de ativação, uma função não linear diferenciável. A função utilizada nesta aplicação foi a função sigmóide.

$$y_j = \frac{1}{1 + e^{-u_j}} \quad (3)$$

onde u_j é chamado de nível de atividade interna e y_j é a saída do neurônio.

- A rede contém uma ou mais camadas escondidas de neurônios. Estes neurônios escondidos capacitam a rede a aprender problemas de maior complexidade extraíndo progressivamente mais características dos vetores de entrada.
- A rede exibe um alto grau de conectividade, determinado pela quantidade de pesos sinápticos.

As principais limitações desta topologia são a necessidade de um grande número de exemplos e a baixa taxa de convergência no treinamento da rede. O treinamento da rede consiste em apresentar à mesma um conjunto de treinamento formado por modelos representativos do problema (cada modelo sendo formado pelos dados de entrada

e suas respectivas saídas). A determinação dos pesos da rede se dá de forma a minimizar o erro quadrático médio entre a saída atual da rede e a saída esperada. Para a atualização dos pesos o método mais utilizado é o algoritmo de retropropagação do erro (neste trabalho utilizamos o algoritmo de retropropagação do erro com momentum). Neste método usa-se a informação do gradiente da função de erro quadrático na atualização dos pesos da rede, partindo da última em direção à primeira camada. A técnica do momentum é utilizada para acelerar a convergência do algoritmo. À medida que a rede vai sendo treinada o erro associado com a saída da rede e a saída esperada tende a diminuir. Dentre os critérios de parada do treinamento, a validação cruzada se destaca pela metodologia empregada. A aplicação desta, consiste em apresentar à rede além do conjunto de treinamento um conjunto de validação (diferente do anterior). A rede é treinada agora com a apresentação dos modelos de treinamento e os da validação, o ponto de parada para o treinamento se dá quando o erro referente aos modelos da validação crescer. A partir deste ponto a rede perde a capacidade de generalização.

Tanto os neurônios da camada escondida como os neurônios da camada de saída na MLP, realizam duas operações: A primeira diz respeito ao cálculo do estímulo de saída para cada neurônio, a segunda operação é o cálculo do gradiente do erro local com respeito aos pesos para cada neurônio. Um fato a ser destacado é que o estímulo de saída de um neurônio que não esteja na camada de saída será o sinal de entrada para o neurônio na camada seguinte. Desta forma o sinal se propaga no sentido entrada-saída da rede, por isso são conhecidas como redes não recorrentes ou *feedforward*. Enquanto que o sinal do erro, no algoritmo de retro-propagação do erro, se propaga na direção contrária (Haykin, 1994).

Na fig(2) apresentamos de forma esquemática a rede MLP utilizada neste trabalho.




Figura 2: Rede MLP com a topologia ótima alcançada mostrando a camada de entrada com 24 resistividades aparentes, a camada escondida com 40 neurônios, e a camada de saída com os 5 parâmetros do modelo de 3 camadas.

RESULTADOS NUMÉRICOS

O objetivo deste trabalho foi utilizar uma MLP para o problema de inversão de dados de SEVs. Foram adotados, para o treinamento da rede, dados sintéticos de SEV com arranjo

Schlumberger de eletrodos para modelos de três camadas. Todos os dados foram gerados por programa de modelagem direta em linguagem FORTRAN. De forma a se obter um conjunto de treinamento representativo do problema, os dados sintéticos de resistividade aparente foram gerados aleatoriamente utilizando parâmetros que variaram na seguinte faixa de valores: $10^0 \leq \rho_i \leq 10^3 \Omega$ e $1 \leq h_j \leq 250m$. Foram gerados conjuntos de treinamento de 500 e 1000 modelos, para a validação conjuntos de 150 modelos e para testar a rede após o treinamento, conjuntos de teste de 150 modelos.

Os dados antes de entrarem na rede sofreram um pré-processamento, onde lhes foram aplicados a função ln de forma a se trabalhar no domínio logarítmico. A utilização destes dados pré-processados melhorou a estabilidade do treinamento. Foram testadas várias topologias para os dois conjuntos de treinamento. A rede que alcançou melhor generalização no treinamento foi uma rede MLP com uma camada escondida contendo 40 neurônios treinada com um conjunto de 1000 modelos fig(2). Após o treinamento, a rede foi submetida ao conjunto de teste. A saída da rede foi utilizado num programa de modelamento direto para a construção de curvas de resistividade aparente as quais foram plotadas juntamente com as curvas de resistividades aparentes observadas. Analisaremos agora alguns resultados obtidos.

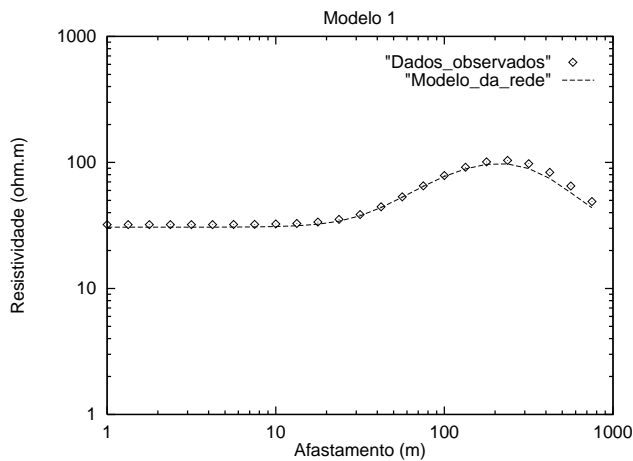


Figura 3: Plot contendo os dados observados e o modelo calculado pela rede

Na fig(3) apresentamos o gráfico com as curvas do modelo observado e do modelo calculado a partir da rede. Para estas duas curvas foi calculado o índice de ajuste f através da expressão:

$$f = \frac{2 \sum_{i=1}^n \rho_{a_{obs}} \rho_{a_{calc}}}{\sum_{i=1}^n \rho_{a_{obs}}^2 + \sum_{i=1}^n \rho_{a_{calc}}^2} \quad (4)$$

Na eq(4) o máximo índice de ajuste alcançado é 1,00. As curvas da fig(3) apresentaram um índice de ajuste de 0,99789. os dados referentes aos dois modelos se encontram na tabela(1). Nesta tabela apresentamos além do valor de cada parâmetro os modelos observado e calculado, e o erro entre os parâmetros observados e calculados. Dois parâmetro, ρ_2 e h_2 , apresentaram os maiores erros.

Na fig(4) apresentamos um segundo exemplo contendo a curva de dados observados e a curvas de dados calculados pelo modelamento direto utilizando a saída da rede. O

Fonte	ρ_1	ρ_2	ρ_3	h_1	h_2
Modelo real	32,14	338,02	30,31	29,41	62,98
Modelo da rede	30,65	330,46	29,29	27,79	56,01
$e = M_r - M_n $	1,49	7,56	1,02	1,62	6,97

Tabela 1: Tabela referente aos parâmetros do modelo real (M_r) e da rede (M_n) para o modelo1.

índice de ajuste entre as curvas para este segundo modelo foi de 0,99902.




Figura 4: Plot contendo os dados observados e o modelo calculado pela rede

Os dados referente a este modelo se encontram na tab(2). Dentre os erros calculados para os parâmetros, o maior corresponde ao da segunda resistividade.

Fonte	ρ_1	ρ_2	ρ_3	h_1	h_2
Modelo real	88,46	305,53	25,23	28,00	57,03
Modelo da rede	85,98	330,17	24,99	24,73	56,05
$e = M_r - M_n $	2,48	24,64	0,24	3,27	0,98

Tabela 2: Tabela referente aos parâmetros do modelo real (M_r) e da rede (M_n) para o modelo2.

Apesar da rede ter apresentado resultados aceitáveis, é notado que a solução dada pela rede nao corresponde ao modelo real. Para solucionar este problema adotamos um procedimento combinando a rede treinada com a inversão linearizada. Como a inversão depende fortemente de um modelo inicial, a nossa proposta é utilizar a saída da rede como tal modelo, mostraremos que estes modelos iniciais garantem a convergência para o mínimo global em todos os casos, fornecendo como resultado os parâmetros reais utilizados na geração dos dados sintéticos.

Na fig(6) o modelo invertido partindo do modelo inicial da rede, convergiu para a solução global em 3 iterações.

Para o modelo 2 a inversão partindo do modelo inicial da rede convergiu para a solução global em 4 iterações.




Figura 5: Plot do modelo 1 contendo: curva dos dados observados, modelo inicial dado pela rede, modelo calculados pela inversão linearizada

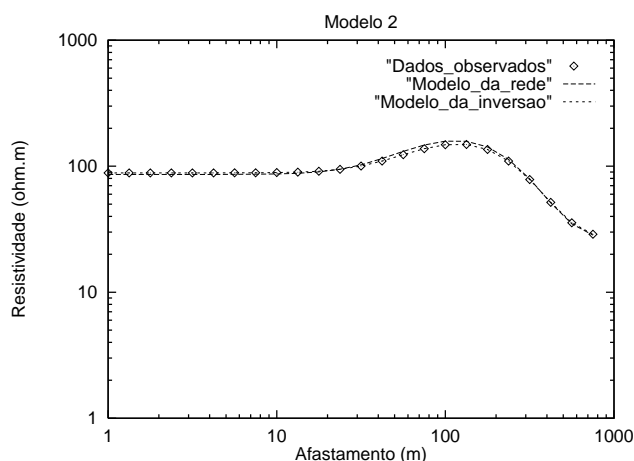


Figura 6: Plot do modelo 2 contendo: curva dos dados observados, modelo inicial dado pela rede, modelo calculados pela inversão linearizada

CONCLUSÕES

Neste trabalho testamos a aplicabilidade das redes neurais artificiais multicamadas na solução do problema inverso de eletrorresistividade para um modelo de três camadas.

Os resultados obtidos pela rede MLP com uma camada escondida contendo quarenta neurônios, mostraram-se satisfatórios. As curvas de resistividade aparente conseguidas pelo modelamento direto com dados de saída da rede referente ao conjunto de teste, apresentaram um bom ajuste quando comparadas com a curva observada dos dados sintéticos. Porém a solução obtida não correspondeu à solução global em nenhum dos modelos testados, necessitando da utilização do método de inversão linearizada para a obtenção da solução global.

A utilização dos modelos da rede como modelos iniciais para a inversão linearizada garantiu uma convergência segura e rápida, em todos os modelos testados, para a solução global mostrando a robustez do procedimento combinado.

REFERÊNCIAS

- Haykin, S. (1994) *Neural Networks - A Comprehensive Foundation*, Prentice-Hall.
- Fausett, L. (1995) *Fundamentals of Neural Networks - Architectures, Algorithms, and Applications*, Prentice Hall.
- Macias, C. C. e Sen, M. K. (1993) *Geophysical interpretation by artificial neural system: a feasibility study*, SEG annual meeting.
- Pimentel, A. L. e Teles, T. N. (1997) *Interpretação de Parâmetros Hidráulicos de Aquíferos Através de Redes Neural Artificial*, Resumos Expandidos - 5º Congresso Internacional da Sociedade Brasileira de Geofísica.
- Teles, T. N. (1997) *Cancelamento de Ruído Harmônico no Traço Sísmico*, Resumos Expandidos - 5º Congresso Internacional da Sociedade Brasileira de Geofísica.
- Teles, T. N. e Ferreira, N. R. (1997) *Aplicação das Redes Neurais Artificiais na Inversão de Sondagem Elétrica Vertical*, Resumos Expandidos - 5º Congresso Internacional da Sociedade Brasileira de Geofísica.
- Lopes, E. P., Lopes, Eliezer P., Barreto, L. M. e Barreto J. M. (1997) *Neural Georadar Probing of Stratified Media*, Resumos Expandidos - 5º Congresso Internacional da Sociedade Brasileira de Geofísica.

AGRADECIMENTOS

Emerson Araújo do Carmo agradece ao CNPq/PIBIC/UFBA pela bolsa de iniciação científica. Telessom N. Teles agradece ao CNPq pela bolsa de pesquisa. Os autores agradecem ao CPGG/UFBA pela apoio a este trabalho.