



## Busca por modelo de prisma vertical do Campo Magnético utilizando rede neural.

Antonio Nuno de Castro Santa Rosa, IG/UnB  
Nilton Correia da Silva, MSTM/ UniEVANGÉLICA

### Resumo

Neste estudo apresentamos os resultados da modelagem teórica do campo geomagnético para prisma vertical infinito e foram simuladas diferentes fontes com comprimento, largura e profundidade do topo. Os campos são os dados de entrada para o Mapa Auto-Organizável (rede neural de Kohonen), ou seja, servem de dados de treinamento desta rede. A rede neural treinada submetido uma imagem de um campo magnético anômalo, em seguida a rede realiza a busca em seu Mapa auto-organizável do modelo e que apresenta a menor distância Euclidiana do dado de entrada. Os resultados obtidos foram animadores para a continuação da pesquisa.

### Introdução

Neste estudo determinamos diferentes campos magnéticos gerados pelas anomalias de fontes com diferentes parâmetros que são: profundidade, largura e comprimento do prisma vertical, então podem ser geradas diferentes anomalias. Veja que aqui estamos interessados em determinar o campo total das anomalias e com objetivo de treinamento para uma rede neural.

As anomalias geradas diretamente pela soma dos campos apresentam resultados que diferem da situação de uma modelo real convolutivo, ou seja, fonte e ruído. Para minimizar este erro utilizamos o filtro gammap [4], que minimizar os erros na borda de cada campo de um prisma. No passo seguinte calculamos diferentes modelos e que vão servir de entrada para o treinamento da rede neural, após o treinamento da rede entramos com os dados reais. Os resultados são bons e indicam um grande potencial neste algoritmo de busca.

### Metodologia

#### Sistemas Auto-Organizáveis

Uma importante característica das redes neurais artificiais é sua habilidade em aprender a partir de seu ambiente e, por meio desse aprendizado, prover algum tipo de funcionalidade. Existem duas classes distintas de algoritmos para promover este aprendizado em redes neurais: os algoritmos com aprendizado supervisionado, para os quais um conjunto de saídas desejadas é fornecido por um supervisor externo - desta maneira a rede deve ser capaz de mapear as entradas fornecidas nas saídas desejadas e o aprendizado não

supervisionado ou sistemas auto-organizáveis. O propósito de um algoritmo dessa natureza é descobrir padrões ou características significantes nos dados de entrada sem o auxílio de um supervisor. Para tanto, o algoritmo é alimentado com um conjunto de regras de natureza *local*, o que lhe permite aprender a computar um mapeamento da entrada em uma saída com propriedades específicas desejadas. O termo "local" significa que a mudança aplicada ao peso sináptico de um neurônio é limitado ao vizinho imediato deste neurônio ver na figura 1, [7], [8].

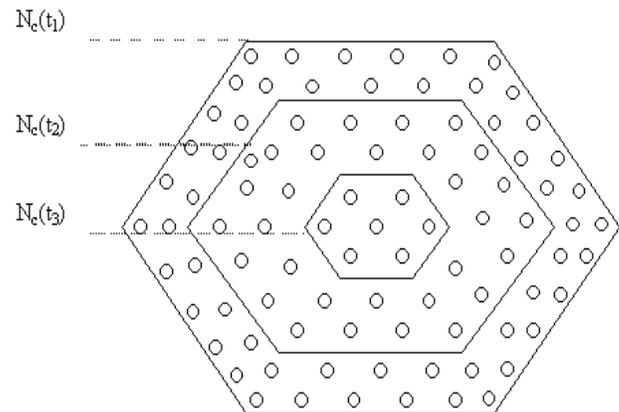


Figura 1. Definição do conjunto de vizinhança  $N_c(t)$  ( $t_1 < t_2 < t_3$ ).

O aprendizado não supervisionado (auto-organizável) consiste em se modificar, repetitivamente, os pesos sinápticos de uma rede neural em resposta aos padrões de ativação (entradas) e de acordo com as regras prescritas até uma configuração final acontecer [9]. Inicialmente considere uma matriz de unidades de neurônios, um vetor de pesos  $m_i(t) \in R^n \{t = 1, 2, 3, \dots\}$  associado a cada unidade  $i$

e um padrão de entrada  $x(t) \in R^n$  a ser comparado a todas unidades. As duas regras a seguir definem um processo no qual um mapeamento de padrões é formado por auto-organização quando um número suficiente de vetores de entradas é recebido pela rede [6]:

Regra 1: Encontrar a unidade  $c$  cujo vetor de pesos é mais similar ao padrão de entrada  $x(t)$ :

$$\|x(t) - m_c(t)\| = \min_i \{ \|x(t) - m_i(t)\| \} \quad (3)$$

A unidade  $c$  é considerada a unidade que responde ao padrão  $x(t)$ .

Regra 2: Modificar os vetores de pesos da unidade  $c$  e de seus vizinhos topológicos:

$$\left. \begin{aligned} m_i(t+1) &= m_i(t) + \alpha(t)[x(t) - m_i(t)] \forall i \in N_c \\ m_i(t+1) &= m_i(t) \forall i \notin N_c \end{aligned} \right\} \quad (4)$$

A vizinhança topológica  $N_c$  é uma função dependente do tempo (figura 1).  $\alpha(t)$  é um escalar que representa a intensidade de ganho de adaptação do neurônio vencedor ( $0 < \alpha(t) < 1$ ). Este parâmetro possui um decremento suave dependente do tempo durante o processo de aprendizagem da rede [5].

### Aplicação

Geramos os campos para diferentes fontes, os campos são calculados em uma malha regular representando o mais próximo possível da realidade de campo, ou seja, diferentes fontes. Na figura 2, mostramos o campo gerado por dois corpos com: profundidade, largura e comprimentos diferentes. O resultado é um único campo, porém com bordas devido ao efeito da adição dos campos. Então minimizamos este efeito utilizando filtragem no domínio do tempo.



Figura 2 – Campo magnético de dois corpos em profundidades de topo e tamanho de largura e comprimento diferentes.

Na figura 3, mostramos o efeito do campo magnético filtrado e com menor ruído de borda. Abaixa flutuação do ruído de bordo em tons de cinza não pode ser tratada com filtros lineares. Então utilizamos o filtro gamamap [4], então esses resultados possibilitaram utilizarmos os

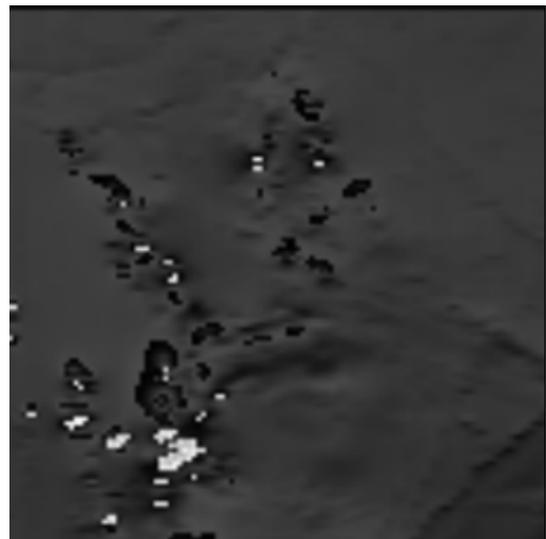
diferentes campos como dados de entrada para o treinamento da rede neural.



Figura 3 – Campo magnético de dois corpos em diferentes profundidades do topo, largura e comprimento após filtragem utilizando gamamap.

### Resultados

Os resultados da busca pela rede de rede neural, atende a uma identificação de anomalias causadas por feições sintéticas geradas. O mapeamento procura as melhores soluções possíveis em termos da mínima distância de Euclídes ver figura 4. Veja que nesta figura podemos identificar muitas anomalias, porém este efeito é devido ao número de iteração que ainda não atendeu a convergência matemática do problema [1]. Existe a necessidade de o algoritmo realizar um número mínimo de iterações para atingir a convergência do problema matemático aqui proposto.



*Figura 4 – Campo magnético classificado após algumas iterações da rede neural.*

Na figura 5, mostramos o campo do dado observado filtro pela rede neural, veja que as duas anomalias gerada pelo modelo teórico (pontos escuros na imagem) estão bem ajustado as anomalias do campo observado (pontos claros). A identificação do modelo utilizado se deu em uma grade de 125 x 125 cada deslocamento nos eixos x e y de foi de 100 metros. As profundidades dos prismas foram de 250 e 300 metros respectivamente. A localização do primeiro prisma foi de x igual 350 e y igual a 390 metros, o segundo foi de x em 925 e y em 965 metros. Na grade os primas foram espaçados em x e y de forma que o efeito de borda dos campos fosse perceptivo para trabalharmos a utilização da filtragem no domínio do tempo para este problema que aparece quando os corpos são simulados em pequenas distâncias entre si.



*Figura 5 – Resultado da busca do campo sintético magnético gerado com o treinamento de diversos corpos de prima vertical em uma anomalia observada em campo.*

### **Discussão e Conclusões**

Todos os resultados encontrados são sintéticos e com isto ainda possibilitam diferentes tipos de experimentos a serem realizados como: diferentes fontes, diferentes redes e dados observados de outras regiões.

A metodologia não depende da natureza da anomalia em si, porém do conjunto de treinamento utilizado na rede neural [3]. O Mapa Auto-Organizável, que é a rede possibilita diversas outras formas de análise ao problema abrindo assim grandes perspectivas de usa da mesma.

### **Agradecimentos**

Agradecimento ao Instituto de Geociências da Universidade de Brasília, laboratório de Geofísica Aplicada. Por fornecer os dados e o ambiente computacional. Os dados estão sob contrato e não podem ser divulgada a fonte.

### **Referências**

- [1] SILVA, N. C. ; ROSA, A. N. C. S. ; CARVALHO JUNIOR, O. A. ; Santos Junior, William Pereira dos . Classificadores Neurais Não Supervisionados. In: Genilda D'arc Bernardes; Roberto Prado de Moraes. (Org.). Políticas Públicas: Meio Ambiente e Tecnologia. 1 ed. Goiânia: Vieira, 2010, v. 1, p. 207-217, ISBN: 9788589779722.
- [2] SANTA ROSA, A. N. C. ; WEIGANG, L. ; SILVA, N. C. ; MENESES, P.R. . Filtering and Classification of SAR images using Parallel Som. In: SPIE's 14th Annual International Symposium Applications and Science of Computational Intelligence III, 2000, Orlando, Florida, U.S.A.. SPIE's 14th Annual International Symposium Applications and Science of Computational Intelligence III. Orlando, Florida, U.S.A. : SPIE, 2000. v. 4055. p. 469-475.
- [3] SILVA, N. C. ; SANTA ROSA, A. N. C. . Estimative of SOM Learning Parameters Using Genetic Algoritms. In: 6th World Multiconference on Systemics, Cybernetics and Informatics (SCI 2002), 2002, Orlando, FL USA. 6th World Multiconference on Systemics, Cybernetics and Informatics (SCI 2002). Orlando , FL USA : SCI 2002, 2002. v. XX. p. 31-36.
- [4] SANTA ROSA, A. N. C. ; MENESES, P.R. . Performance of Map filters to Reduce Speckle in Radasat imagens. In: Simposio Final GlobeSAR2, 1999, Bueno Aires. Simposio Final GlobeSAR2. Bueno Aires : GlobeSAR, 1999. v. 1. p. 876-880.
- [5] Kohonen, T., Self-Organizing Maps, New York : Springer-Verlag, 1997.
- [6] Kohonen, T., "Speech recognition based on topology-preserving neural maps ", (1990). "Neural Computings Architectures: The Design of Brain-Like Machines" - Aleksander, I., pp. 26-40. MIT Press, Cambridge, Massachusetts, USA.
- [7] Ritter H.; Schulten K.. "Convergence properties of Kohonen's topology conserving maps: Fluctuations, stability and dimension selection". Biol. Cybernetics, 60, pp. 59--71, 1988.
- [8] Malsburg C. von der, "Network self-organization", In: An introduction to neural and electronic networks (S.F. Zornetzer, J.L. Davis, C. Lau, eds.), pp. 421-432. San Diego, CA: Academic Press, 1990.
- [9] Haykin, S., "Neural Networks – A comprehensive foundation", Macmillan College Publishing Company, (1994), 352-354.