

INTEGRAÇÃO E INTERPOLAÇÃO DE DADOS DE ANOMALIAS AR LIVRE UTILIZANDO-SE A TÉCNICA DE RNA E KRIGAGEM¹

Integration and interpolation free air anomalies with basis in an ann and kriging

FRANCIELY ABATI MIRANDA
SÍLVIO ROGÉRIO CORREIA DE FREITAS
PEDRO LUIS FAGGION

Universidade Federal do Paraná - UFPR
Curso de Pós-Graduação em Ciências Geodésicas - CPGCG
Caixa Postal 19001, CEP 81531-970, Curitiba, Paraná, Brasil.
franciely.miranda@gmail.com; {sfreitas, faggion}@ufpr.br

RESUMO

Neste trabalho analisa-se a integração e interpolação de anomalias ar livre continentais e oceânicas, em área de $3^{\circ} \times 3^{\circ}$ em torno do Datum Vertical Brasileiro (DVB). Para tanto foram realizados novos levantamentos, bem como a compilação de dados e informações de modelos existentes. Foram reunidas informações (latitude, longitude, altitude ortométrica, gravidade real e anomalias ar livre) de 916 estações, distribuídas na região do DVB, além de empregar-se o modelo topográfico SAM_30s derivado do modelo digital SRTM, com resolução de $30''$ e o modelo global KMS2002 de anomalias da gravidade nos oceanos. Dispondo-se desses dados, as correções foram aplicadas e sua integração resultou num novo conjunto de anomalias ar livre. Posteriormente realizou-se a formação de grade regular de dados por interpolação utilizando-se a técnica de Rede Neural Artificial (RNA), através de 18 experimentos na busca da arquitetura da rede mais adequada à interpolação. Para avaliar a qualidade da grade RNA, comparou-se a mesma com a gerada obtida pelo interpolador Krigagem. Utilizou-se também um conjunto de dados independentes para avaliar o desempenho das duas grades geradas e aplicaram-se testes para determinar a qualidade dessas grades. A melhor grade de saída obtida pela técnica de RNA foi de um RMS de 5,59 mGal.

Palavras-chaves: Anomalias ar livre; Redes neurais artificiais.

¹ Uma versão prévia desse trabalho foi apresentada no II Simpósio Brasileiro de Geomática e V Colóquio Brasileiro de Ciências Geodésicas.

ABSTRACT

In this paper the integration and interpolation of Free Air anomalies coming from land and ocean in a $3^\circ \times 3^\circ$ area around the Brazilian Vertical Datum (BVD) are analysed. For this purpose new gravity surveys were carried out as well as data compilation and the use of existing models. They were collected information (latitude, longitude, ortometric height, gravity and free air anomalies) for 916 stations in the BVD region, and used the SAM_30s model from SRTM with $30''$ resolution, and the KMS2002 global free air ocean anomalies. With the collected information corrections were computed and the integration resulted in a new set of free air anomalies. From this new data set was formed a regular data grid by interpolating free air anomalies with basis in an Artificial Neural Network (ANN). The more adequate architecture was determined based on 18 experiments. The initial evaluation of the grid generated with ANN was realized by comparing it with a grid determined by Kriging. They were also used an independent data set for evaluating both grids. Numerical tests and statistical analysis of both grid were carried out in order to evaluate the grid quality. A 5,59 mGal RMS error was found for the better ANN generated grid.

Keywords: Free Air anomalies; Artificial Neural Network.

1. INTRODUÇÃO

Em julho de 2005 foi realizada uma campanha de densificação gravimétrica com apoio de gravímetros digitais associados com posicionamento de 83 estações (resultantes de dados coletados com a tecnologia GPS), pré-definidas de maneira a se obter uma cobertura homogênea em região de $3^\circ \times 3^\circ$ centrada aproximadamente no Porto de Imbituba – SC, visando corrigir a insuficiência de dados nesta região. Na mesma ocasião, foram reunidas informações acerca dos dados gravimétricos, altimétricos e topográficos existentes e disponíveis para a região em torno do DVB. Reuniram-se informações (latitude, longitude, altitude ortométrica, gravidade e anomalia ar livre) de 916 estações, distribuídas na área de interesse, um modelo topográfico derivado do modelo digital SRTM, SAM_30s, apresentando resolução de $30''$, bem como a aquisição do modelo de anomalias ar livre em áreas oceânicas derivadas da altimetria por radar a bordo de satélites (missões ERS-1 e GEOSAT), denominado KMS2002.

O modelo topográfico SAM_30s foi adotado por ser o modelo de maior qualidade dentre os modelos determinados por Matos (2005), justamente com a finalidade de ser utilizado em aplicações na área de Geodésia e Geofísica.

Visando a integração e interpolação dos dados das anomalias ar livre calculadas para o continente e das fornecidas para o oceano por meio do modelo KMS2002, utilizou-se a técnica de Rede Neural Artificial (RNA), sendo realizados 18 experimentos, com diferentes arquiteturas da rede.

Foram realizadas análises quantitativas (diferenças/resíduos) do comportamento das anomalias interpoladas com esta técnica, utilizando para tanto,

dados amostrais de verificação e as saídas interpoladas fornecidas pela RNA. Ressalta-se que 30% dos pontos utilizados para verificação da qualidade dos modelos gerados não fizeram parte da geração do modelo.

Com o objetivo de se avaliar a qualidade da grade RNA, comparou-se a mesma com a gerada por meio do interpolador Krigagem, pois segundo Matos (2005), Tierra (2003) dentre outras literaturas, é o que melhor representa dados de terreno, em particular, dados de anomalias gravimétricas. Cabe ressaltar que o interpolador exige o conhecimento a priori dos dados de entrada e a partir deles, determina os melhores parâmetros para modelagem.

Já a RNA apresenta como vantagem o fato dela não precisar do conhecimento prévio desses parâmetros. Ela necessita, no entanto, de um treinamento consistente, o que significa que as amostras de treinamento devem ser representativas, isto é, devem conter todas as nuances do relevo, além disso, a rede apresenta também como vantagem a possibilidade da integração de outras variáveis de entrada (HAYKIN, 2001).

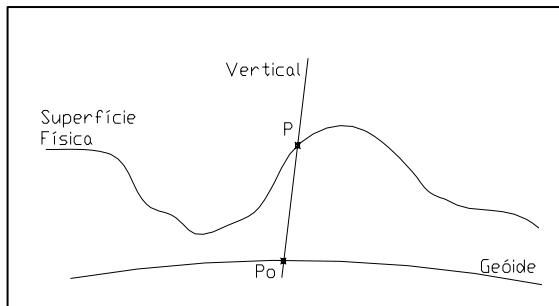
Neste trabalho será abordada a verificação da qualidade dos modelos bem como a comparação das grades geradas pelas técnicas de RNA e Krigagem.

2. CORREÇÃO ANOMALIA AR LIVRE

A correção anomalia ar livre consiste em reduzir para a superfície do geóide, ao longo da vertical, o valor da gravidade de um ponto observado na superfície topográfica da Terra, considerando o afastamento entre estas duas superfícies naquele ponto – altitude ortométrica, e o gradiente vertical real da gravidade, eliminando dessa forma o efeito das massas topográficas abaixo da estação gravimétrica (HOFMANN-WELLENHOF E MORITZ, 2005).

Para se determinar o valor da gravidade do ponto P_o no geóide (Figura 1), é necessário conhecer a lei de variação desta ao longo da vertical PP_o . Contudo esta variação não é conhecida, visto que pouco se sabe a respeito da distribuição interna das massas entre P e P_o .

Figura 1 - Redução Ar Livre



Adaptado de GEMAEL (1999).

Portanto, para efeitos práticos substitui-se o gradiente real pelo gradiente vertical normal da gravidade, onde o valor -0,3086 mGal é freqüentemente suficiente (TORGE, 1983), sendo a correção ar livre dada por (GEMAEL, 1999):

$$Cf = -\frac{\partial g}{\partial H} H \approx -\frac{\partial g}{\partial h} H \approx 0,3086H \quad (1)$$

e a anomalia ar livre por:

$$\Delta g_f = g_o + 0,3086H - \gamma_o \quad (2)$$

onde:

$$\frac{\partial g}{\partial H} = \text{gradiente vertical real da gravidade em miligal/metro;}$$

H = altitude ortométrica em metros;

$$\frac{\partial g}{\partial h} = \text{gradiente vertical normal da gravidade em miligal/metro, e sendo:}$$

g_o = gravidade real;

γ_o = gravidade normal.

A camada de massa não considerada entre P e P_o aumenta o valor da gravidade em P e, consequentemente, também da Δg_f , razão pela qual esta anomalia mantém uma correlação direta com a superfície topográfica e não é representativa para uma grande área. Esta dependência pode ser calculada e eliminada mediante uma regressão linear empírica, ou por uma redução topográfica, por exemplo, através da anomalia Bouguer (TORGE, 1983).

3. INTERPOLADOR KRIGAGEM

A Geoestatística é um ramo da estatística que lida com problemas associados ao espaço. Embora tradicionalmente desenvolvida na área da Geologia, particularmente em problemas relacionados com a estimativa das mudanças de concentração de minerais em minas, a Teoria da Geoestatística tem sido aplicada com sucesso em outras áreas científicas tais como Geodésia e Geofísica. O objetivo da interpolação Geoestatística, também conhecido como Krigagem, é criar uma superfície que minimize o erro dos valores avaliados e do modelo estatístico da superfície. Segundo Matos (2005), Krigagem é talvez o mais notável método de interpolação. Este estimador abrange um conjunto de métodos de estimação, sendo o mais usual a Krigagem normal, a qual assume que as médias locais não sejam necessariamente próximas da média da população. Neste caso, a estimativa é alizada utilizando apenas os pontos vizinhos. É o método mais apropriado para a

interpolação de dados de terreno (MAUNE² citado em MATOS, 2005).

A diferença entre a Krigagem e outros métodos de interpolação está na maneira como os pesos são atribuídos às diferentes amostras. No caso de interpolação linear simples, por exemplo, os pesos são todos iguais a 1/N (N é o número de amostras); na interpolação baseada no inverso do quadrado das distâncias, os pesos são definidos segundo esta alternativa através da distância que separa o valor interpolado dos valores observados. Na Krigagem, o procedimento é semelhante ao da interpolação por média ponderada, exceto que aqui os pesos são determinados a partir de uma análise espacial, baseada no semivariograma experimental. Além disso, a Krigagem fornece em média, estimativas não tendenciosas e com variância mínima.

4. REDES NEURAIS ARTIFICIAIS

A Rede Neural Artificial (RNA) é uma linha de pesquisa da Inteligência Artificial, dentro do conceito de conexionismo, que visa investigar a possibilidade de simulação de comportamentos inteligentes através de modelos inspirados no cérebro humano. É composta por unidades de processamento, operando em paralelo, inspiradas no sistema biológico dos neurônios (HAYKIN, 2001). Uma RNA consiste de um grande número de unidades de processamentos. Estes elementos são chamados de neurônios, unidades, células ou nodos. Cada neurônio é conectado a outro por meio de ligações, cada uma associada a pesos numéricos.

Segundo Rezende (2003) uma RNA é um modelo matemático que se assemelha às estruturas neurais biológicas e que tem capacidade computacional adquirida por meio de um aprendizado e de uma generalização. O aprendizado é atingido não pelas modificações dos neurônios mas pelas modificações dos pesos das interconexões. O aprendizado numa rede consiste em realizar mudanças sistemáticas a esses pesos a fim de levar os níveis de resposta da rede a valores aceitáveis. Logo, o conjunto de pesos das conexões pode ser visto como um sistema dinâmico, já que eles se adaptam para codificar o conhecimento que se deseja aprender. A generalização de uma RNA está ligada à capacidade de dar respostas coerentes para dados não apresentados a ela previamente na etapa de treinamento.

4.1 Características de uma Rede Neural Artificial

Conforme citações em Souza (2006), dentro do conexionismo (máquinas conexionistas) destacam-se as RNA, as quais têm se detido a estudar o cérebro e seu funcionamento. Existem vários modelos conexionistas dentre eles, pode-se citar: os Perceptrons - proposto por Rosenblatt em 1958, primeiro modelo de RNA envolvendo o conceito de aprendizado; os Perceptrons de multicamadas - proposto por Werbos em 1974; a Rede de Kohonen - proposta por Kohonen na década de 80

² MAUNE, D. F. Digital elevation model technologies and applications: the DEM users manual. ASPRS (The Imaging & Geospatial Information Society), 2001.

e a Rede de Hopfield - proposta por Hopfield em 1982. Também, uma RNA é um sistema de processamento de informações que apresenta certas características em comum com uma rede neural biológica. As RNAs são desenvolvidas como generalização de modelos matemáticos de neurônios biológicos com base no seguinte:

- o processamento das informações ocorre por intermédio de neurônios;
- os sinais são passados entre os neurônios por meio de conexões;
- cada conexão tem um peso associado;
- para determinar o sinal de saída, cada neurônio aplica na função de ativação à soma dos pesos dos sinais de entrada.

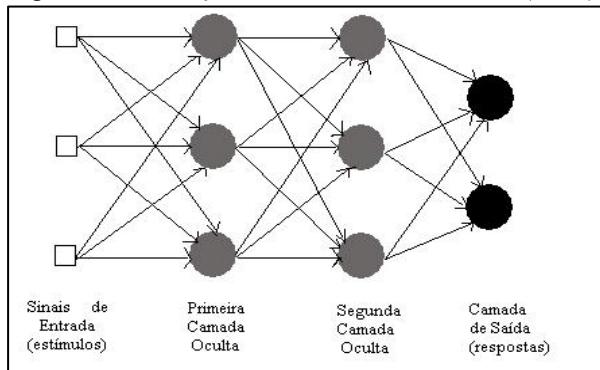
Assim sendo, as RNA baseiam-se na simulação dos neurônios biológicos, formados pelos dendritos, o corpo celular e o axônio que, junto com outros neurônios podem fazer muitas combinações, formando vários tipos de topologias.

4.2 Arquitetura de uma Rede Neural Artificial

Uma das maiores dificuldades no uso das RNA é a escolha da melhor arquitetura, pois este processo é experimental e por isso, demanda tempo de execução. Na prática o processo deve ser aplicado com o intuito de testar os vários métodos de aprendizado e as diferentes configurações que uma rede possa ter para a resolução do problema em questão.

Uma RNA pode ser composta por vários neurônios distribuídos em camadas. A primeira é chamada de camada de entrada e tem a função de armazenar os dados de entrada na rede. A camada intermediária, denominada também de camada escondida ou oculta, onde ocorre a maioria dos processamentos da rede. A última camada é definida como de saída, que recebe os valores já processados pela rede (Figura 2). A quantidade de neurônios por camadas e o número de camadas por rede é chamada de arquitetura da RNA (LOESCH E SARI, 1996; TIERRA, 2003).

Figura 2 – Ilustração da Rede Neural Artificial (RNA).



Adaptado de TIERRA (2003)

Os neurônios localizados nas camadas ocultas desempenham um papel importante durante o treinamento, porque agem como detectores de características. Conforme o processo de aprendizagem avança, os neurônios ocultos começam gradualmente a “descobrir” as características salientes que se referem os elementos amostrais de treinamento. Eles fazem isso realizando uma transformação não-linear dos dados de entrada para um novo espaço chamado de espaço oculto, ou espaço de características. Neste novo espaço, as variáveis de interesse podem ser mais facilmente detectadas e separadas entre si do que no espaço original de entrada (HAYKIN, 2001).

O número de nós (neurônios) da camada oculta é definido levando-se em consideração o funcionamento da rede, isto é, os neurônios da camada intermediária executam a separação do espaço das variáveis. Não existe uma regra geral que defina o número de camadas escondidas, esse número pode variar de 0 até n camadas (TAFNER et al., 1996). Alguns autores citam a regra de Hilton para definir o número de nós que as camadas intermediárias da rede devem ter. Essa regra afirma que o número de nós da segunda camada oculta não deve exceder a um terço ($1/3$) do valor da primeira camada oculta.

4.3 Treinamento Supervisionado

Para as redes com pesos, o aprendizado de uma RNA é realizado por meio de processos iterativos de ajustes aplicados aos pesos, o chamado treinamento. O aprendizado só ocorre quando a RNA atinge uma solução generalizada para um determinado problema.

Segundo Ribeiro (2003), treinar uma rede significa ajustar a sua matriz de pesos de forma que o vetor de saída coincida com um certo valor desejado para cada vetor de entrada.

No treinamento supervisionado, tanto vetores de entrada quanto de saída são fornecidos à rede. Desta forma, no treinamento é possível aplicar o vetor de entrada e a saída da rede é calculada. A saída obtida é comparada com um vetor de saída desejado (o qual foi inicialmente apresentado à rede) e um erro é calculado a partir dessa diferença. Os pesos atribuídos para cada entrada são atualizados conforme o algoritmo usado, para que este erro seja minimizado. Este processo é repetido para o conjunto amostral de treinamento até que o erro alcance um limite ou limiar (critério de parada ou tolerância) desejado e estipulado previamente (HAYKIN, 2001).

4.4 Generalização de uma Rede Neural Artificial

Após o treinamento da RNA, espera-se que a rede projetada seja capaz de generalizar. Diz-se que uma rede generaliza bem quando o mapeamento de entrada-saída computado pela rede for correto (ou aproximadamente correto) para o conjunto amostral não utilizado no processo de treinamento da rede. O processo de aprendizagem pode ser visto como um problema de “ajuste de curva”. A

própria rede pode ser considerada como um mapeamento não-linear de entrada-saída. Esse ponto de vista permite considerar a generalização de uma RNA como sendo o efeito de uma boa interpolação não-linear sobre os dados de entrada (HAYKIN, 2001). A rede realiza boa interpolação não-linear fundamentalmente porque redes multicamadas com funções de ativação contínuas produzem funções de saída que também são contínuas (SOUZA, 2006).

Uma RNA se for bem projetada para generalizar, produzirá um mapeamento de entrada-saída correto, mesmo quando a entrada for um pouco diferente dos exemplos usados para treinar a rede. Mas se uma RNA aprende um número excessivo de exemplos de entrada-saída, ela pode acabar memorizando os dados de treinamento. Ela pode fazer isso encontrando uma característica (devido ao “ruído”, por exemplo) que está presente nos elementos amostrais de treinamento, mas não na função subjacente que deve ser modelada. Este fenômeno é conhecido como excesso de ajuste ou excesso de treinamento e, quando treinada em excesso, ela perde a habilidade de generalizar entre padrões de entrada-saída similares (HAYKIN, 2001).

5 METODOLOGIA

5.1 Coleta dos Elementos de Treinamento/Verificação

Uma rotina em linguagem C++ foi desenvolvida para coletar os elementos amostrais de verificação. Utilizou-se para tanto a técnica de amostragem probabilística sistemática, assim, esta rotina foi concebida de forma a ler os dados do arquivo de entrada e reescrevê-lo, identificando seqüencialmente cada linha do mesmo, como um índice. Uma porcentagem desejada de coleta foi fornecida ao programa, bem como foram fornecidos os dados totais da área considerada. Desta forma, a rotina permitiu calcular o intervalo de coleta a partir dos pontos iniciais até os pontos finais (para a porcentagem desejada), fornecendo como saída, os elementos amostrais de treinamento. Em seguida, estes dados foram subtraídos do arquivo que continha o conjunto amostral total, fornecendo dessa forma os dados de verificação. Assim sendo, se uma porcentagem de 30% de amostras for requerida, aplicando a equação (3), tem-se que a cada intervalo de três (3) coordenadas uma (1) coordenada será coletada.

$$A = (T).(P) \quad (3)$$

$$\Delta I = \frac{T}{A} = \frac{T}{T.P} = \frac{1}{P}$$

onde:

T: total de elementos amostrais da área considerada;

P: porcentagem de coleta desejada;

A: número de elementos amostrais a serem coletados;

ΔI : intervalo de coleta para a percentagem estipulada.

Os dados de verificação são importantes, pois permitem a validação do modelo, quantificando mais precisamente o erro obtido, através do cálculo da diferença do desvio-padrão e da média entre a interpolação e a realidade dos dados coletados em campo, uma vez que os pontos de verificação não fizeram parte do processo de geração das grades.

Com o intuito de se realizar uma análise quantitativa do produto gerado, utilizou-se o módulo “grid/residuals” que o programa SURFER™ v7.0 oferece. Esta ferramenta permite computar a diferença entre os valores de Z dos dados de verificação com os valores de Z dos dados interpolados. Com estes resultados o programa fornece medidas estatísticas, como a média e o desvio-padrão, que permitem a análise da qualidade da grade gerada a partir dos dados originais.

5.2 Elementos Amostrais de Treinamento e de Verificação para a Rna

A etapa da coleta dos elementos amostrais de treinamento para a rede é fundamental para que a mesma realize a generalização dos dados totais e atinja a precisão desejada. Para tal, a amostra deve ser representativa da variação das anomalias que se está considerando. Isto é, deve ter a capacidade de representar todas as nuances do terreno na área a ser modelada (SOUZA, 2006).

Um subconjunto de dados foi escolhido para ser utilizado no treinamento da RNA. Este conjunto possui 70% de elementos do conjunto amostral total de dados.

Para a coleta do subconjunto amostral de verificação (conjunto de teste) utilizou-se o restante dos dados, que representam 30% do conjunto amostral. Ressalta-se que se utilizaram estas amostras para avaliar a qualidade das saídas interpoladas pela rede, auxiliando nas análises para fixar as melhores arquiteturas e posteriormente, para avaliar os valores residuais das grades geradas pela Krigagem e generalizadas pela RNA. Estes dados não fizeram parte do treinamento da rede e nem da generalização das grades.

5.3 Rna para Predição da Anomalia Ar Livre

Para a geração das malhas de anomalias ar livre, integrando continente-oceano, utilizou-se uma RNA multicamadas. Essa escolha se deu seguindo as recomendações de Tierra (2003) para o cálculo dessas anomalias.

A arquitetura geral da RNA multicamadas consiste de elementos de entrada, duas camadas ocultas e a camada de saída constituída por um neurônio que gera a anomalia ar livre. A escolha da arquitetura da rede é totalmente experimental e depende de testes com os algoritmos de aprendizagem e as diferentes configurações que uma rede pode ter (TIERRA E FREITAS, 2002). Porém, para iniciar o processo, adotou-se o critério da segunda camada oculta ser 1/3 da primeira oculta.

Souza (2006) comenta que a entrada e a saída da RNA são óbvias, porém as camadas ocultas (escondidas) da rede não é uma resposta óbvia, pois o número ótimo de camadas escondidas depende do problema e do número de variáveis envolvidas. Assim, deve-se proporcionar à rede o maior número possível de informações. Só que isso muitas vezes implica em construir uma arquitetura com grande quantidade de neurônios acarretando numa maior complexidade computacional, limitando o uso em relação ao tempo de processamento e espaço (tamanho dos arquivos).

Portanto, para se determinar a arquitetura final da RNA, com o objetivo de ser usada para a determinação da anomalia ar livre, foram utilizadas diferentes arquiteturas, e em consequência, vários testes no processo de treinamento e generalização.

Uma vez treinada a RNA e definidas as melhores arquiteturas, ela pôde ser usada para generalizar as anomalias ar livre em função dos elementos de entrada.

Por exemplo, numa modelagem onde as variáveis de entrada foram três (Latitude, Longitude e Altitude), treina-se a rede e armazena-se o resultado da arquitetura dessa modelagem, bem como os pesos. Depois se executa a generalização para uma mesma arquitetura da rede já treinada, utilizando as coordenadas (latitude, longitude) dos nós da grade obtida pela Krigagem acrescida de sua respectiva altitude, obtendo-se como saída, a grade RNA dos valores das anomalias nas mesmas posições da grade obtida pela Krigagem. Desta forma, ter-se-á duas grades idênticas em posição (latitude, longitude), uma grade com atributo das anomalias ar livre interpoladas pela Krigagem e a outra grade com atributo das anomalias ar livre interpoladas pela RNA (MIRANDA, 2006).

6. RESULTADOS E ANÁLISES

Utilizou-se um conjunto de dados para avaliar o desempenho da RNA e da grade gerada pela Krigagem para as anomalias. Esses dados representam 30% das amostras, ressaltando-se que os mesmos não foram utilizados tanto no treinamento quanto na geração do modelo digital final das anomalias. Estes pontos foram escolhidos de forma a estarem distribuídos em toda a área de estudo e também com variações na topografia.

Realizaram-se testes quantitativos a fim de determinar numericamente, por meio de análises estatísticas, quanto foi a precisão da grade gerada. Para tanto, calculou-se as diferenças entre os elementos amostrais de verificação (medidos em campo) e a grade gerada (valores das anomalias interpolados), sendo estas diferenças quantificadas mediante o cálculo da média e do desvio-padrão.

Os resultados destes testes mostram que a grade Krigagem difere dos dados originais nos pontos de verificação (valores medidos em campo), sendo o valor do desvio-padrão um indicador da precisão da grade gerada em relação aos pontos de verificação.

Vale ressaltar que o método de interpolação apresenta vantagens e desvantagens que dependem de vários fatores, tais como: quantidade de dados disponíveis, regularidade da distribuição espacial e fidelidade aos pontos observados (solução exata ou suavizada). Por mais eficiente que seja o método de interpolação, caso a distribuição dos dados observados não seja favorável, os resultados podem ser insatisfatórios, exigindo-se até a realização de novos levantamentos.

Cabe salientar que o interpolador exige o conhecimento a priori dos dados de entrada e a partir deles determina os melhores parâmetros para modelagem. Portanto, devem ser os mais representativos possíveis da região a ser modelada.

Já a RNA não precisa do conhecimento prévio desses parâmetros, ela necessita sim de um treinamento consistente, o que significa, no caso do método supervisionado, que as amostras de treinamento devem ser representativas, isto é, devem conter todas as nuances do relevo. Para tal, uma sistemática (método) coerente na delimitação e coleta dos elementos amostrais de treinamento precisa ser empregada, conforme apresentada e sugerida na metodologia. A rede apresenta também como vantagem a possibilidade da integração de outras variáveis de entrada (SOUZA, 2006).

Portanto, no decorrer deste trabalho, foi testada a técnica de RNA para predizer anomalias ar livre, a partir da integração dos dados calculados para o continente e dos fornecidos para o oceano por meio do modelo KMS2002.

A fim de definir a arquitetura da RNA, iniciou-se uma série de testes, realizados em ambiente Matlab, definindo as entradas e as saídas, as camadas ocultas e o número de neurônios por camada. Realizaram-se vários experimentos na busca da arquitetura da rede mais adequada para à resolução do problema em questão, totalizando 18 experimentos (Tabela 1).

As iterações foram limitadas em um número de 10.000 e o critério de parada do treinamento foi experimental. A rede foi alterada para treinar com 2 e 3 elementos de entrada e o treinamento foi encerrado após o RMS atingir o limiar de 0,001mGal e em alguns casos de 0,0001 mGal, conforme síntese das análises na Tabela 2. Nesta tabela pode-se verificar que os experimentos 1, 11, 13, 15, 17 e 18 não atingiram o limiar proposto pra seu treinamento. Em relação ao experimento 1, isso se deve provavelmente ao número de elementos da camada de entrada (2) não ser suficiente, apenas a latitude e longitude para predizer a anomalia ar livre.

Variou-se o número de dados para treinamento da rede buscando testar dessa maneira, se o número de dados de anomalias sob os oceanos influenciava a predição das anomalias para o continente, visto que se tinha 5000 dados para o oceano e 899 para o continente.

Tabela 1 – Experimentos realizados no treinamento e generalização da RNA.

Exp.	Entrada	Arquit.	Treino Conv.?	Verif. %	Treino %	Função de Transf.	Média (mGal)	Desvio Padrão (mGal)	RMS	Limiar
01	φ, λ	[30 10 1]	Não	30	70	Logsig, Trainrp	-		-	0,001
02	φ, λ, H	[30 10 1]	Sim	30	70	Logsig, Trainrp	-0,454	$\pm 0,144$	9,27	0,001
03	φ, λ, H	[30 10 1]	Sim	30	*	Logsig, Trainrp	-0,276	$\pm 0,195$	6,75	0,001
04	φ, λ, H	[45 15 1]	Sim	30	70	Logsig, Trainrp	-0,072	$\pm 0,096$	6,20	0,001
05	φ, λ, H	[18 6 1]	Sim	30	70	Logsig, Trainrp	-0,206	$\pm 0,100$	6,45	0,001
06	φ, λ, H	[45 15 1]	Sim	30	*	Logsig, Trainrp	-0,291	$\pm 0,193$	6,67	0,001
07	φ, λ, H	[18 6 1]	Sim	30	*	Logsig, Trainrp	-0,231	$\pm 0,201$	6,98	0,001
08	φ, λ, H	[60 20 1]	Sim	30	70	Logsig, Trainrp	-0,082	$\pm 0,100$	6,45	0,001
09	φ, λ, H	[60 20 1]	Sim	30	70	Logsig, Trainrp	-0,070	$\pm 0,092$	5,92	0,001
10	φ, λ, H	[60 20 1]	Sim	30	70	Tansig, Tainln	-0,482	$\pm 0,087$	5,59	0,001
11	φ, λ, H	[18 6 1]	Não	30	70	Tansig, Tainln	-		-	0,001
12	φ, λ, H	[30 10 1]	Sim	30	70	Tansig, Tainln	-0,223	$\pm 0,091$	5,86	0,001
13	φ, λ, H	[45 15 1]	Não	30	70	Tansig, Tainln	-0,222	$\pm 0,156$	10,02	0,001
14	φ, λ, H	[90 30 1]	Sim	30	70	Tansig, Tainln	1,029	$\pm 0,113$	7,23	0,001
15	φ, λ, H	[18 1 1]	Não	30	70	Tansig, Tainln	-		-	0,001
16	φ, λ, H	[90 30 1]	Sim	30	70	Tansig, Tainln	-		-	0,001
17	φ, λ, H	[18 1 1]	Não	30	70	Tansig, Tainln	-		-	0,0001
18	φ, λ, H	[60 20 1]	Não	30	70	Tansig, Tainln	-		-	0,0001

* Proporcional

Tabela 2 – Comparação quantitativa das grades obtidas pela técnica de RNA e Krigagem – mGal.

Processo	Média	Desvio Padrão	RMS	Valor mín.	Valor máx.
Anomalias ar livre - krigagem	0,031	$\pm 0,060$	4,59	-49,090	60,489
Anomalias ar livre RNA – Experimento 10	-0,482	$\pm 0,087$	5,59	-70,663	51,884

Realizou-se nos experimentos 3, 6 e 7, um treinamento com quantidades proporcionais destes dados (70% para dados do continente, com 600 pontos, e 12% para dados do oceano, com 600 pontos), porém a alteração nos resultados não foi significativa como mostra a Tabela 1.

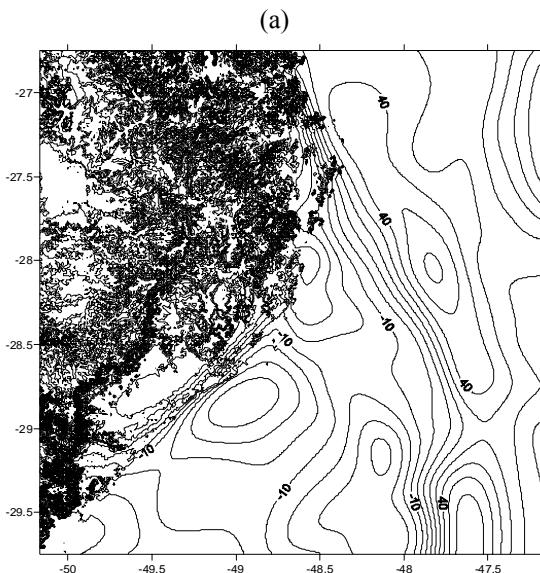
O tempo de processamento de treinamento variou entre 5min e 53min. O número de neurônios por camadas foi obtido de forma experimental até se obter o número de neurônios em cada camada que forneça a precisão esperada, a qual foi tomada baseada no modelo obtido pela Krigagem, com RMS de 4,59 mGal.

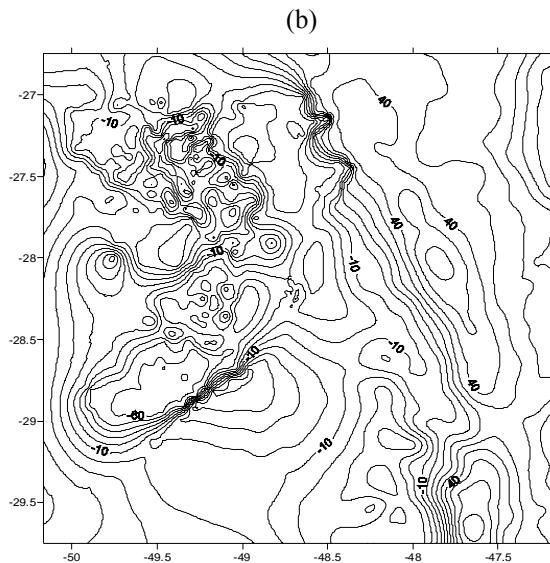
Uma vez treinada a RNA, e definidas as melhores arquiteturas, a mesma pode ser usada para generalizar as anomalias ar livre em função dos elementos de entrada.

As análises de comparação de desempenho entre as arquiteturas testadas foram feitas mediante o cálculo da média e do desvio padrão das diferenças entre as anomalias ar livre conhecidas nos pontos de verificação, as quais não fizeram parte do treinamento da rede, e as saídas (anomalias interpoladas).

Com estes resultados foi possível comparar a qualidade da grade de saída de melhor desempenho obtida pela técnica de RNA (Figura 3), em relação à grade obtida pela Krigagem conforme Tabela 2.

Figura 3 – Comparaçao qualitativa das grades obtidas pela técnica de RNA (a) e Krigagem (b) em mGal.





Nota-se, ao analisar a Figura 3, que a grade gerada pelo processo de interpolação Krigagem difere da obtida pela técnica de RNA. Isso deve-se ao fato de que Krigagem suaviza tanto a superfície continental quanto oceânica durante o processo de interpolação a partir dos dados amostrais, pois realiza uma média dos valores das amostras, ocultando dessa forma valores de máximo e mínimo, deixando a superfície mais homogênea.

A RNA apresenta uma melhor variabilidade para o terreno (Figura 3) devido ao uso do SRTM_30s na generalização da grade, porém a inclusão da variável altitude fez com que as isoanômalas apresentassem “ruídos” na parte continental, ou seja, a RNA teve maior oscilação e tornou-se mais instável.

A Tabela 2 mostra os valores residuais obtidos entre a grade gerada e os elementos amostrais de verificação, objetivando avaliar a grade gerada pelo interpolador Krigagem e técnica RNA.

A RNA apresenta um RMS superior ao método de interpolação Krigagem (Tabela 2), isso devido a falta de reconhecimento do contexto onde estão inserido os pontos de anomalias ar livre. Portanto a inserção de novas variáveis poderá contribuir para a caracterização do contexto do ambiente onde estão os pontos com as anomalias.

7. CONCLUSÕES E RECOMENDAÇÕES

Em relação a RNA, esta teve o seu uso indicado em função da capacidade de treinamento e generalização no que se refere a interpolação e integração de diferentes variáveis para caracterização das anomalias ar livre continente-oceano.

A definição da arquitetura da rede, por ser experimental, foi sem dúvida a etapa de maior dificuldade na modelagem, pois sua definição resultou da aplicação de 18 testes, realizados em ambiente Matlab.

A etapa da coleta dos elementos amostrais de treinamento para a RNA é fundamental para que a rede forneça resultados coerentes, pois existe uma dependência direta do erro alcançado no treinamento e o desempenho da RNA na etapa de generalização. Foi implementado um programa em C++ para realizar a coleta dos mesmos. Optou-se por uma amostragem probabilística, utilizando-se a técnica de amostragem sistemática, o que garante que todos os elementos têm probabilidade conhecida e diferente de zero de pertencer a amostra.

O resultado da RNA com o uso de duas variáveis (latitude e longitude) não discretizou bem a área representada, indicando a necessidade da inclusão de mais uma variável de entrada, a altitude ortométrica. Com a inclusão desta variável, a RNA apresentou os primeiros resultados, e para alguns casos, o da RMS da anomalia ar livre obtida foi na ordem de 10,92 mGal. Com a mudança da arquitetura da rede (foram testadas 18 diferentes configurações), o melhor resultado obtido foi de 5,59 mGal, referente ao experimento 10, cuja arquitetura é [60 20 1]. Quando se utilizou o interpolador Krigagem para o mesmo conjunto de dados, chegou-se a um RMS de 4,59 mGal.

O uso do SRTM SAM_30s na generalização da RNA fez com que a rede tivesse um maior nível de detalhamento sobre as características complexas da área, entretanto, a inclusão da variável altitude fez com que as isoanômalas apresentassem comportamento menos suave na parte continental, porém os testes demonstraram que mesmo com o uso desta variável pode-se obter melhorias nos resultados finais da RNA.

Para a geração do modelo digital foi utilizado o interpolador Krigagem, visto que neste contexto apresentou resultados mais coerentes (Tabela 2) que os testes realizados com a RNA na predição de anomalias ar livre.

Recomenda-se analisar a possibilidade da inclusão de outras variáveis de entrada para o treinamento da RNA para predição de anomalias ar livre, como: gravidade normal e correção ar livre, buscando melhores resultados no cálculo desta; analisando dessa forma a influência dessas variáveis sobre a modelagem dessa anomalia.

AGRADECIMENTOS

Os autores agradecem ao CNPq via Projeto Conexão de Redes Geodésicas Verticais – Parte 2, processo nº 479838/2006-2 e bolsa nº 303942/2005-3.

REFERÊNCIAS BIBLIOGRÁFICAS

GEMAEL, C. *Introdução à Geodésia Física*. Curitiba: Editora da UFPR, 1999. 302pp.

- HAYKIN, S. *Redes neurais – princípios e prática*. Trad. Paulo Martins Engel. Porto Alegre: Bookman, 2001. 891 pp.
- HOFMANN-WELLENHOF, B. E MORITZ, H. *Physical Geodesy*. Wien, New York: Springer, 2005, 403pp.
- LOESCH, C.; SARI, S. *Redes Neurais Artificiais. Fundamentos e Modelos*. Blumenau: FURB, 1996.
- MATOS, A. C. O. C de. *Implementação de modelos digitais de terreno para aplicações na área de Geodésia e geofísica na América do Sul*. 2005. 355pp. Tese - Depto. de Engenharia de Transportes – USP, São Paulo.
- MIRANDA, F. A. *Contribuição para análise do campo da gravidade na região do Datum Vertical Brasileiro*. 2006. 120 pp. Dissertação (Mestrado em Ciências Geodésicas) – Curso de Pós-Graduação em Ciências Geodésicas, UFPR, Curitiba.
- REZENDE, S. O. *Sistemas inteligentes - fundamentos e aplicações*. São Paulo: Editora Manole, 2003. 525 pp.
- RIBEIRO, S. R. A. *Integração de imagens LANDSAT TM e dados auxiliares para a delimitação automática de unidades fisionômicas usando Redes Neurais Artificiais*. 2003, 160 pp. Tese (Doutorado em Ciências Geodésicas) – Curso de Pós-Graduação em Ciências Geodésicas, UFPR, Curitiba.
- SOUZA, E. C. B de. *Modelagem do relevo oceânico usando RNA*. 2006, 223pp. Tese (Doutorado em Ciências Geodésicas) – Curso de Pós-Graduação em Ciências Geodésicas, UFPR, Curitiba.
- TAFNER, M. A. et al. *Redes Neurais Artificiais – Introdução e princípios de neurocomputação*. Blumenau: EKO, 1996.
- TIERRA, A; FREITAS, S.R.C. *Predicting Free-Air Gravity Anomaly Using Artificial Neural Network*. International Association of Geodesy Symposia: Vertical Reference Systems. Springer, v. 124, 2002, p 215-218.
- TIERRA, A. R. T. *Metodologia para a geração da malha de anomalias gravimétricas para obtenção de geóide gravimétrico local a partir de dados esparsos*. 2003. 140pp. Tese (Doutorado em Ciências Geodésicas) – Curso de Pós-Graduação em Ciências Geodésicas, UFPR, Curitiba.
- TORGE, W. *Geodésia*. México: Ed. Diana, 1983.

(Recebido em novembro / 2008. Aceito em junho / 2009.)