

MÉTODO PARA MODELAGEM DO RELEVO OCEÂNICO USANDO REDES NEURAS ARTIFICIAIS

*Method to the oceanic bottom relief modelling
using Artificial Neural Network*

ELAINE CRISTINE BARROS DE SOUZA¹
CLÁUDIA PEREIRA KRUEGER²
SELMA REGINA ARANHA RIBEIRO²
CLAUDIA ROBBI SLUTER²

Curso de Pós-Graduação em Ciências Geodésicas
Departamento de Geomática - Setor de Ciências da Terra
Universidade Federal do Paraná

Caixa Postal 19011 – Centro Politécnico – Jardim das Américas
CEP: 81531-990 – Curitiba – PR – Brasil

¹elaineCBSouza@brturbo.com.br; ²{[ckrueger](mailto:ckrueger@ufpr.br), [selmar](mailto:selmar@ufpr.br), [robbi](mailto:robbi@ufpr.br)}@ufpr.br

RESUMO

Este trabalho propõe um método para modelagem do relevo oceânico a partir de dados batimétricos usando Redes Neurais Artificiais (RNA). Os dados utilizados foram coletados pelo navio *Polarstern* (AWI-Alemanha) com o sistema *multibeam Hydrosweep DS-2*. A área situa-se entre a Irlanda e o Reino Unido (Província de Pelágia). Na primeira etapa dos processamentos, como variáveis de entrada para o treinamento da RNA, foram adotadas as posições planimétricas das profundidades (coordenadas E, N); outra variável foi o peso atribuído aos ângulos de incidência dos feixes. Numa segunda etapa foram utilizadas as coordenadas E, N de uma grade gerada pelo interpolador Inverso do Quadrado da Distância (IQD), para que as grades generalizadas pela rede tivessem as mesmas posições da grade IQD (modelo de referência). As verificações foram realizadas mediante o comportamento das profundidades interpoladas e das grades generalizadas pela rede, fazendo uso de elementos amostrais de verificação. O método proposto gerou resultados que atenderam a precisão do equipamento, conforme o fabricante e a Organização Internacional de Hidrografia que preconizam 1% da lâmina d' água para a categoria de profundidades em questão, sendo o erro máximo permitido neste caso de 17 m. A RNA forneceu resultados cujo erro máximo foi de 14 m.

Palavras-chaves: Batimetria, Rede Neural Artificial, Modelo Digital do Terreno.

ABSTRACT

The main purpose of this investigation is to generate a three-dimensional model of the ocean relief from bathymetric data, based on the concept of Artificial Neural Networks (ANN). The data used in the investigation were collected by “Polarstern” ship (AWI-Germany) with the multibeam system Hydrosweep DS-2. The area is located between Ireland and United Kingdom (Pelagia Province). In this first stage of the processings, as entrance variables for the training of the net, it was adopted the horizontal positions of the depths (coordinates E, N); and also linear weights were attributed to the angles of incidence of the beams. In a second stage it was also used the horizontal coordinates E, N of a grid generated by the interpolation algorithm, the Inverse Distance to a Power. This way, the grids were to be generalized by the net in the same positions of the grid Inverse Distance to a Power which was adopted as being the reference model “field truth”, aiming at obtaining the RNA grid in the same positions of the Inverse Distance to a Power grid. The processing verifications were made by qualitative and quantitative analyses, of the behavior of the interpolated depths and of the generalized grids by the net. For such analyses it was used verification elements. The study shows that the proposed method is able to produce results that satisfy the precision of the equipment (multibeam), according to the manufacturer and also according to specifications of the International Organization of Hydrographic that indicates an acceptable error of being 17 m the maximum error allowed for this case. The ANN showed results with a maximum error of 14 m.

Key-words: Bathymetry, Artificial Neural Networks, Digital Terrain Model

1 INTRODUÇÃO

A qualidade dos produtos cartográficos gerados a partir de levantamentos ecobatimétricos, depende essencialmente dos métodos empregados, da qualidade e precisão dos equipamentos utilizados. A precisão na obtenção das profundidades está vinculada a alguns parâmetros externos ao equipamento, dentre eles: a intensidade de retorno do “pulso”, a qual depende das características do solo oceânico e da propagação do som na água.

As análises qualitativas e quantitativas da superfície física, incluindo o fundo oceânico, podem ser efetuadas por meio de um Modelo Digital do Terreno (MDT). Pesquisas mais recentes têm utilizado as técnicas da Inteligência Artificial (IA), mais precisamente as RNA's para modelar a superfície.

Atualmente existem diversas pesquisas que abordam sob os mais variados aspectos tanto da técnica dos MDT's quanto das RNA's. Há uma corrente de pesquisadores no segmento da Geodésia Marinha que se ocupa com estudos e modelagem da superfície oceânica, visando a representação e investigações relativas das características geomorfológicas do fundo. Dentre os trabalhos já desenvolvidos, pode-se citar: análises do sistema *multibeam* para caracterização do fundo oceânico CLARKE (2002); métodos para os processamentos e a

representação digital de dados hidrográficos LENK e KRUSE (2000); JACOBS (2002); classificação dos sedimentos do fundo oceânico, utilizando intensidades de *backscatter* advindos de um sistema *multibeam*, usando modelos *Self Organization Map* CHAKRABORTY et al. (2001); um estudo 3D do comportamento sísmico e distribuição de formações de corais em águas categorizadas como profundas HUVENNE et al. (2003); uma proposta para visualização do relevo marinho BUZIEK et al., (1992), entre outras investigações sempre enfatizando a interpolação de dados advindos de levantamentos batimétricos e investigações sobre o comportamento dessas superfícies e características do fundo oceânico.

A investigação apresentada neste artigo, consiste em gerar um modelo tridimensional do relevo oceânico, a partir de dados batimétricos (profundidades) coletados pelo *Hydrosweep DS-2 (HYDROgraphic multibeam SWEEPing)*. Empregou-se a técnica da RNA, método de treinamento supervisionado e o algoritmo para redes muticamadas *back-propagation*, em águas categorizadas como profundas (400 a 1700 m).

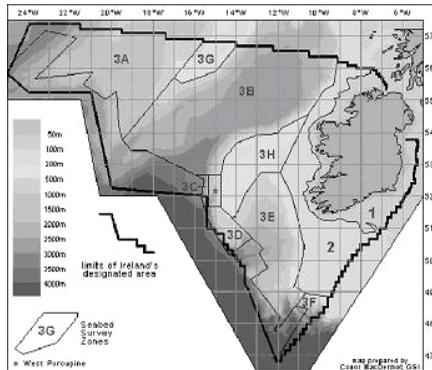
Buscou-se ainda realizar análises qualitativas (curvas isobatimétricas) e quantitativas (resíduos) do comportamento das profundidades interpoladas e das grades generalizadas com o método proposto, utilizando elementos amostrais de verificação os quais não fizeram parte do aprendizado da rede e as saídas interpoladas fornecidas pela RNA (análise pontual); analisar a qualidade das grades RNA, comparando-as com a grade gerada por meio do interpolador IQD; discriminar o desempenho da RNA, como interpolador na estimativa de diferentes precisões de profundidades, e na integração com diferentes variáveis de entrada para o treinamento na modelagem de dados batimétricos em águas categorizadas como profundas.

2 MATERIAIS E MÉTODOS

Os dados utilizados nesta pesquisa foram coletados em levantamentos executados dentro de um projeto de pesquisa para investigações em ecossistemas marinhos, chamado *Geological Evolution of Carbonate Processing (GEOMOUND)* EUROPEAN COMMUNITIES (2005); (GEOMOUND, 2004).

As águas territoriais Irlandesas, estendem-se principalmente do lado oeste da Irlanda, os limites envolvidos no mapeamento da área, podem ser visualizados na Figura 1. As águas irlandesas tem uma cobertura de aproximadamente 1400 km². É possível separá-las em 3 zonas. A primeira zona (1), representa a costa (litoral), a segunda (2) é o continente e a terceira (3A até 3H), inclui os bancos e a bacia de *Porcupine* (área deste estudo), bem como o canal de *Rockall*.

Figura 1 - Zonas das águas irlandesas envolvidadas no mapeamento da área de estudo
 Fonte: INSS (2005)



2.1 Materiais

Amostras de profundidades: Profundidades com limites de 400 m até 1700 m; Foram utilizadas 414.866 coordenadas com uma área plana de aproximadamente 398 km² com localização geográfica em 50° 42' N a 50° 53' N e 11° 15' O a 11° 31' O.

Número e valores angulares de incidência dos feixes: Sequência numérica dos feixes 59 *Pre-formed beams* (PFB's) e seus valores angulares de incidência, os quais foram utilizados como variável complementar de entrada nos treinamentos da RNA, a qual foi denominada de “peso linear”.

Equipamentos: Os levantamentos, foram realizados utilizando o sistema *multibeam Hydrosweep DS-2*. Permite medir 59 PFB's de profundidades simultâneas com um único pulso; tem cobertura angular de varredura de 90°; opera a uma frequência de 15,5 kHz; a precisão da batimetria é de 1% conforme a altura da lâmina d' água para os modelos gerados. Tem um espaçamento entre feixes de 2,3°; os limites de profundidades atingidas são de 10 até 11.000 m; possui estabilização em todos os eixos; duração do pulso de +/- 1 a 10 ms; largura da banda de 0,3 – 2 kHz. Mais detalhes ver KRUPP ATLAS (2004); AWI (2004); (SCHENKE, 1990); SURFER e GUTBERLET e SCHENKE (1989).

Programas: **Surfer 7.0.:** interpolação e geração das curvas isobatimétricas; **MatLab 5.3:** processamento com a RNA; **C++:** coleta dos elementos amostrais de treinamento e verificação, utilizado para eliminar pontos comum entre os arquivos; distribuir os pesos conforme a geometria do sistema *Hydrosweep DS-2*. Mais detalhes ver SOUZA (2006).

2.1.1 Levantamentos de Campo – Sistemática para Obtenção dos Dados

O levantamento de campo que originou os dados aqui empregados consistiu de 14 perfis completos, com cerca de 130 km de comprimento. Ao todo foram

levantados 2500 km² em 4 dias e meio (11 a 16 de junho de 2000). As linhas do levantamento foram planejadas utilizando como base as curvas isobatimétricas extraídas da *General Bathymetric Chart of the Oceans* (GEBCO) Digital Atlas 1997 - GDA 97 (GEBCO, 2004). Para assegurar precisão e obter a cobertura total da área, uma superposição entre os perfis adjacentes de pelo menos 10% foi executada durante a varredura do *multibeam*. Mais detalhes ver AWI (BEYER et al., 2003, p. 28).

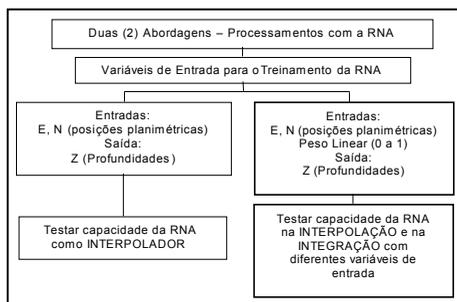
O princípio operacional do *Hydrosweep* é enviar um sinal do emissor, instalado na embarcação, este sinal atinge o fundo submerso, e mede os 59 PFB's com um único pulso. O eco retorna a superfície, onde o pulso é detectado por um receptor. A recepção do eco refletido do fundo submerso é convertido em profundidades. O princípio básico deste *multibeam*, baseia-se nas medidas do feixe central, o de número trinta (30), o qual é considerado o mais preciso, pois dele, a verdadeira profundidade ou, o melhor perfil de profundidade ao longo da trajetória do navio é determinada. Próximos dele, são registrados os menores valores dos ângulos de incidência do pulso. Mais detalhes ver AWI (2005 (b)); ATLAS (2004); SCHENKE (1990); KRUPP ATLAS (1998); (SCHENKE, 1987); SCHENKE e ULRICH (1986).

2.2 Métodos

2.2.1 Síntese dos Processamentos a serem Executados com o IQD e com a RNA

A geração dos modelos tridimensionais do fundo oceânico, por meio da RNA, foi executada utilizando amostras de profundidades (seção 2.1), para tal, duas abordagens foram utilizadas nos processamentos RNA, como mostra o fluxograma da Figura 2, a fim de avaliar a capacidade da rede na interpolação e na integração de diferentes variáveis de entrada (E, N) e (E, N, peso linear).

Figura 2 – Fluxograma das abordagens com RNA



Na seção 3.1 estão descritas as informações referentes ao relevo, através da representação a partir da grade regular, gerada com o interpolador IQD da área fornecida pelo AWI – “modelo adotado como referência” apresentado na seção

3.1.1. A seção 3.1 visa apresentar as características da área e dos dados em estudo, mediante análises qualitativas e quantitativas, etapa importante pois a grade IQD serviu como base para a generalização da grade por meio da RNA (seção 3.1.2) e as diferenças entre essas grades, possibilitaram avaliar a proximidade da grade RNA à superfície do fundo oceânico representada com a grade IQD (seções 3.1.1 e 3.1.2.). Para melhor entendimento do método proposto e das fases que foram executadas, o diagrama de blocos na Figura 3 apresenta uma síntese dos processamentos executados com o IQD e a Figura 4 com a RNA, desde os processamentos executados, até os produtos gerados e as análises.

Figura 3 – Diagrama de blocos – sequência das fases executadas com o IQD

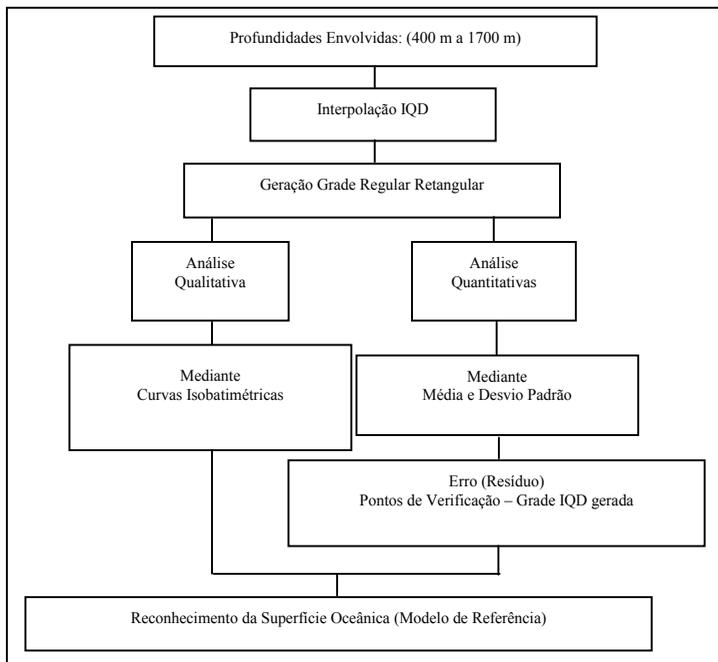
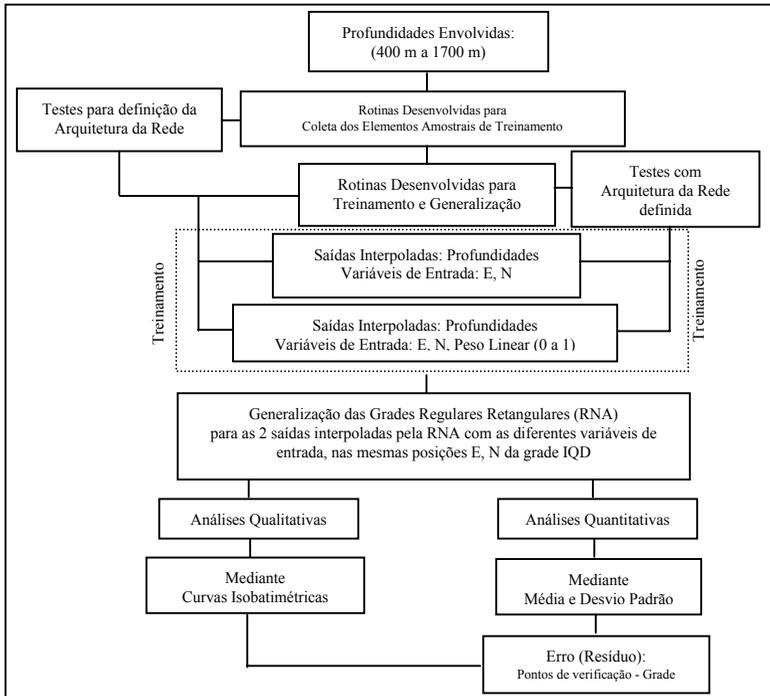


Figura 4 – Diagrama de blocos – sequência das fases executadas com a RNA



2.2.2 Método para Coleta dos Elementos Amostrais de Treinamento e de Verificação

Dois subconjuntos amostrais com 5% de elementos (20.743 coordenadas) e outro com 30% de elementos (124.461 coordenadas), foram selecionados a partir do conjunto amostral total de dados e foram utilizados para o treinamento da rede (5%) e para a verificação do modelo (30% conjunto de teste). Os 30% de elementos amostrais, pontos de verificação, não fizeram parte do processo de treinamento e nem na generalização das grades e foram utilizados para avaliar a qualidade das saídas interpoladas pela rede (análise pontual), auxiliando nas análises para fixar as melhores arquiteturas e posteriormente, quantificando mais precisamente de quanto foi o erro com base no cálculo das diferenças do desvio padrão e da média entre a interpolação e a verdade de campo (modelo IQD).

O método desenvolvido, denominado de “coleta sistemática” dos elementos amostrais foi executado em linguagem C++. A estrutura da rotina teve como base, os perfis transversais e longitudinais percorridos durante a trajetória do navio na coleta dos dados. Esta rotina foi indexada de forma a ler todos os dados do levantamento, na sequência do perfilamento percorrido pelo navio (ida e volta), isto

é, de Sul para Norte e vice - versa.

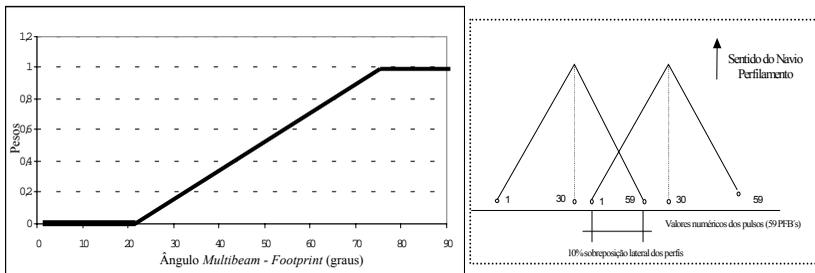
Uma porcentagem desejada de coleta foi fornecida ao programa, bem como, foram fornecidos os dados totais da área considerada. Desta forma, a rotina implementada permitiu calcular o intervalo de coleta a partir dos pontos iniciais até os pontos finais (para a porcentagem desejada), fornecendo como saída, os elementos amostrais de treinamento e os de verificação. Mais detalhes ver SOUZA (2006).

2.2.3 Método para Atribuição dos Pesos para as Variáveis de Entrada da RNA

Na atribuição dos pesos para as coordenadas, nas quais foram medidas as profundidades, considerou-se que para cada coordenada E, N, Z, existe relacionado um valor numérico do feixe, o qual varia de 1 a 59 (seção 2.1.1), finalizado este intervalo, inicia-se uma nova varredura do fundo oceânico. O feixe de número 30 é o feixe central (situado sempre no nadir) sendo as profundidades neste feixe e nas suas proximidades as mais precisas de acordo com o princípio básico do *multibeam*, conforme citado na seção 2.1.1.

O método linear adotado para a atribuição dos pesos, foram baseados em investigações realizadas por GOURLEY et al. (2000) que afirmam que um peso, atribuído a um pulso numa determinada posição, dependerá do seu ângulo de incidência, o qual também está correlacionado aos valores numéricos do feixe. Em uma área com superposição entre linhas (neste caso 10%), a aplicação de um peso com relação ao ângulo de incidência, garante que a maior prioridade seja dada aos feixes situados na parte mais interna da varredura. Feixes próximos do nadir têm maior realce e precisão, e os pesos menores são sempre atribuídos para os feixes na parte mais externa da varredura. A Figura 5, mostra como é o modelo linear de pesos utilizando os ângulos de incidência e respectivos valores numéricos.

Figura 5 – Modelo de atribuição dos pesos para o *multibeam* e varredura do sistema
Fonte: adaptado de GOURLEY et al. (2000)



3 EXPERIMENTOS RESULTADOS E DISCUSSÕES

3.1 Geração do Modelo de Referência – Grade IQD

A consistência dos dados e o reconhecimento da área, foram avaliados por meio de uma superfície matemática que retratasse a geomorfologia marinha (grade regular). A superfície (grade) foi gerada por meio do algoritmo de interpolação IQD, utilizando a base de dados fornecida pelo instituto AWI, a qual consistiu de um arquivo sob a forma de linhas e colunas com coordenadas no sistema de projeção UTM, localizadas no Meridiano Central 9° Oeste, no sistema de referência WGS-84. Os dados foram fornecidos na sequência conforme mostra a Tabela 1.

Tabela 1 – Sequência dos dados fornecidos pelo AWI

Contador do arquivo	E (m)	N (m)	Z Profundidades (m)	Número dos feixes (1 a 59)	Ângulos de incidência dos feixes
30	330442	5595671	-1302	29	5,2
31	330477	5595669	-1300	30	4,7

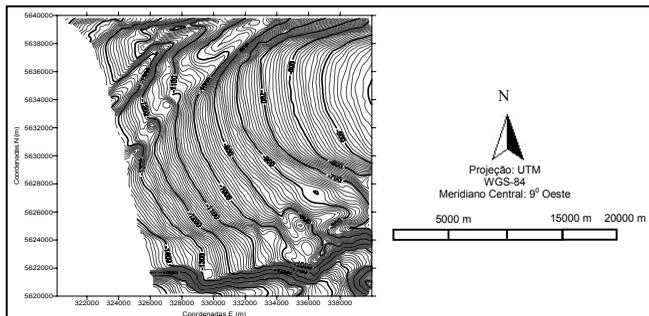
Depois de executada a interpolação e da grade gerada, procedeu-se a visualização das curvas isobatimétricas, bem como, ao cálculo e análise das diferenças entre os elementos amostrais de verificação (30%) e a grade obtida com a interpolação. Analisando-se os resultados qualitativos e quantitativos obtidos após interpolação com o IQD, pôde-se constatar que tanto o tamanho do conjunto amostral (290.406 pares de coordenadas), bem como a distribuição espacial dos elementos amostrais, permitiram inferir que as informações disponíveis foram suficientes para atender as necessidades apresentadas (geração da grade e a representação do fundo oceânico), uma vez que o interpolador IQD mostrou-se satisfatório em termos da precisão exigida, para a geração da grade servindo como “modelo de referência”. A satisfatoriedade em termos de precisão da grade obtida com o IQD se deve a investigações realizadas anteriormente a fim de encontrar os parâmetros necessários para a execução da etapa de interpolação por meio do algoritmo IQD. Dentre os experimentos realizados, pode-se enumerar: a) busca com raio variável na grade; b) testes com classes de declividades; c) análises do desvio padrão em cada célula da grade, com relação a precisão do equipamento que é de 1% conforme a altura da lâmina d’água.

Estas investigações mostraram um ganho significativo em precisão quando se utiliza um raio de busca por quadrante com 75 m e uma resolução da grade de 50 m, permitindo cobertura total da área. Esses dois parâmetros mantêm todas as informações contidas nos pulsos desde as profundidades mais rasas até as mais profundas. Desta forma, as estruturas geomorfológicas do fundo puderam ser representadas com confiabilidade. Mais detalhes ver BEYER et al. (2003, p. 28).

Um primeiro controle da qualidade dos resultados obtidos pelo IQD, foi uma comparação visual (qualitativa) das curvas isobatimétricas dada na Figura 6 para as

profundidades interpoladas. Essa análise possibilitou identificar que não existem irregularidades “ruídos” nas formas das isóbatas e nem a presença de tendências nas mesmas em toda a área modelada.

Figura 6 – Curvas isobatimétricas interpoladas pelo IQD



Os resultados quantitativos mostraram que a grade IQD difere dos dados originais, nos pontos de verificação (valores medidos em campo) em 0,63 m. Os valores residuais das diferenças em desvio padrão (grade e os 30% de elementos amostrais de verificação) atenderam a precisão do equipamento que é de 1% conforme a altura da lâmina d' água.

3.2 Definição da Arquitetura da RNA e Algoritmo de Treinamento

As variáveis de entrada para o treinamento da RNA foram: (a) coordenadas planimétricas (E, N); (b) E, N, peso linear (0 a 1). O critério de parada do treinamento foi experimental, pois nos testes executados pôde-se perceber que muitas vezes, um limiar adotando-se um Erro Médio Quadrático (EMQ) próximo da precisão desejada, por exemplo, 0,1 ou muito pequeno, menor que 0,0001, não implica necessariamente numa boa generalização. Existe um “ótimo” para a convergência da RNA e este, é definido experimentalmente partindo-se da precisão que se deseja obter. A rede foi definida para treinar com 2 e 3 camadas de entrada e o treinamento foi encerrado após o EMQ atingir um limiar de aproximadamente 0,00099957 para o limiar estipulado de 0,0001. O número de vezes que o conjunto de treinamento é apresentado a rede (o número de ciclos) foi mantida em até no máximo 500 vezes, para as diferentes arquiteturas testadas.

Definida a quantidade de camadas escondidas, duas, foi determinado experimentalmente o número de neurônios por camada. Após a definição experimental dos neurônios da primeira camada escondida, definiu-se então, os neurônios da segunda camada escondida que corresponderam na maioria dos casos, a 1/3 ou 1/4 dos neurônios da primeira camada escondida, critério este adotado segundo a regra de HILTON (1989) In: FITZGERALD et al. (1996, p. 984).

Também foram testadas, arquiteturas mais “quadradas”, ou seja, quantidades de neurônios na primeira e segunda camadas escondidas com valores próximos, para verificar como responde a RNA nestes casos com relação as saídas interpoladas.

Em resumo, a quantidade de entradas da primeira camada, denominada de “camada de entrada”, foi igual ao número de variáveis de entrada para o treinamento da RNA, ou seja, duas (experimento a) e três (experimento b) entradas. O número de neurônios da “camada de saída” foi uma, que correspondem as profundidades (coordenadas Z). As camadas escondidas foram duas (2) e o número de neurônios em cada camada escondida possuem diferentes valores para as arquiteturas testadas, conforme mostra a Tabela 2.

Tabela 2 – Número de neurônios nas duas camadas escondidas para as arquiteturas testadas

Arquiteturas testadas	1	2	3	4	5	6	7
nº neurônios nas camadas escondidas	24 e 6	28 e 7	30 e 26	30 e 26	30 e 10	48 e 12	96 e 32

Arquitetura que apresentou os melhores resultados

O algoritmo de treinamento utilizado foi o *back-propagation* e sua variação *Resilient*, desenvolvido por REIDMILLER et al. (1993). As taxas de aprendizado utilizadas foram 0,2 e 0,3. Os processamentos com termo *Momentum* utilizaram 0,2 e 0,3. Uma vez treinada a RNA e definidas as melhores arquiteturas, ela pôde ser usada para generalizar as profundidades em função dos vetores de entrada, dos casos (a) e (b).

3.3 Resultados e Discussões – Redes Neurais Artificiais

3.3.1 Interpolação Usando Diferentes Variáveis de Entrada para o Treinamento da RNA

Foi adotada a arquitetura 5 com um critério de parada de treinamento (limiar) igual a 0,0001 para os processamentos a qual foi escolhida devido ter apresentado o melhor resultado dentre as 7 arquiteturas testadas. Mais detalhes ver SOUZA (2006). Os resultados e discussões se baseam na verificação quantitativa e qualitativa da interpolação mediante o uso da RNA, mediante os resultados da média e do desvio padrão, os quais foram calculados fazendo a diferença entre os elementos amostrais de verificação e as saídas da rede de forma pontual (interpolada).

Os dois grupos de variáveis de entrada testadas no processo de treinamento da RNA foram: (a) E, N; (b) E, N, peso linear, sendo a arquitetura da rede definida com: duas e três variáveis de entrada; duas camadas escondidas com 30 e 10 neurônios; e uma camada de saída sendo a profundidade (Z).

A Tabela 3 mostra os resultados obtidos com os processamentos referentes à

interpolação fornecida pela RNA (arquitetura 5).

Tabela 3 – Diferenças pontuais entre os 30% de pontos de verificação e da interpolação RNA

nº de neurônios camadas escondidas (30,10) variáveis de entrada	Treinamento limiar 0,0001 (EMQ)	Diferença pontos de verificação – RNA	
		Média (m)	Desvio Padrão (m)
(a)	0,000099995 (5%)	0,0022	14,89
(b)	0,000099996 (5%)	-0,0559	13,89

Os resultados mostram que a qualidade da grade gerada com 5% de elementos amostrais de treinamento e com a utilização de duas ou três variáveis de entrada no treinamento foi compatível com a precisão do equipamento utilizado nos levantamentos, 1% conforme a altura da lâmina d'água (seção 2.2.2).

3.3.2 Generalização da Grade RNA – Resultados e Discussões

As posições planimétricas (E, N) da grade IQD foram usadas na etapa de generalização da grade RNA, com isso, foi possível gerar uma grade para cada saída interpolada fornecida pela rede, mediante o treinamento executado (seção 3.3.1) com as variáveis de entrada consideradas (a) e (b). Alocando-se as profundidades geradas pelas RNA na grade (E, N do IQD) foi possível analisar às médias e os desvios padrão das diferenças calculadas em relação aos elementos amostrais de verificação e as saídas da rede na forma de uma grade (análise pontual). A Tabela 4, mostra os resultados obtidos com os processamentos para a generalização das grades RNA, considerando-se os experimentos (a) e (b).

Tabela 4 – Resultados da generalização das grades em relação aos pontos de verificação

nº de neurônios camadas escondidas (30,10) variáveis de entrada	Diferença pontos de verificação – RNA limiar 0,0001	
	Média (m)	Desvio Padrão (m)
(a)	-0,0353	14,12
(b)	-0,0309	13,81

Mediante análise dos desvios padrão (Tabela 4), verifica-se que a precisão da grade generalizada nas mesmas posições da grade IQD e com as variáveis (a) e (b) foi de aproximadamente 14 m, houve pouca modificação do resultado, quando do experimento (b), introduzindo-se a variável pesos como dados de entrada.

Uma outra análise foi executada para avaliar o comportamento das profundidades interpoladas pela rede com o uso das diferentes variáveis de entrada para o treinamento, com relação aos valores medidos em campo, conforme mostram os gráficos das Figuras 7 e 8. Foi adotada uma amostra com 224 elementos para esta representação gráfica, onde no eixo X estão indicados o número de elementos

representados (coordenadas) e no eixo Y (lado esquerdo) estão os valores de profundidades e neste mesmo eixo (lado direito) verificam-se as diferenças (resíduos) calculadas entre os valores interpolados e os valores medidos em campo. A Figura 8, mostra o comportamento das profundidades interpoladas pelo IQD para os mesmos elementos amostrais e as diferenças com relação aos valores medidos. Tanto as grades RNA quanto a IQD estão sendo comparadas com os valores medidos em campo.

Figura 7 – Comportamento das profundidades na grade RNA com valores medidos (entradas: (E, N), (E, N, peso linear) e diferenças residuais

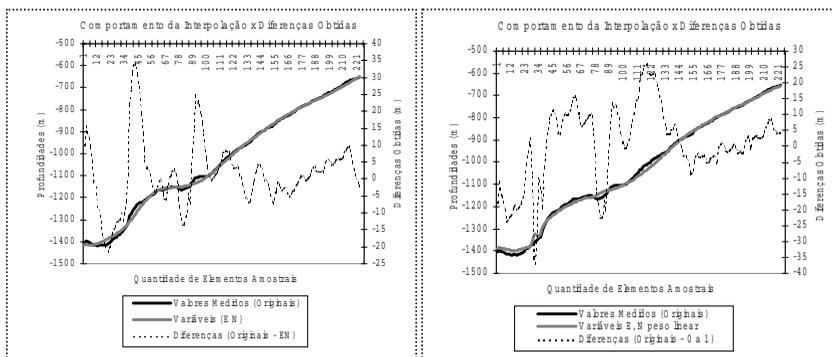
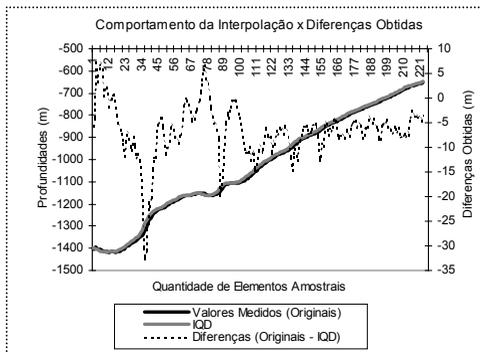


Figura 8 – Profundidades interpoladas pelo IQD e valores medidos



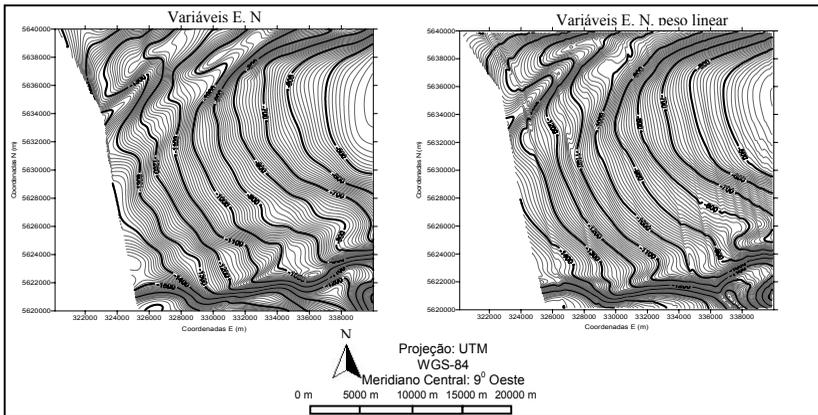
As Figuras 7 e 8, mostram que o comportamento das profundidades interpoladas nos experimentos usando a combinação entre as variáveis de entrada para o treinamento da RNA, foi aceitável levando em consideração a precisão desejada para o modelo (17 m). As profundidades estimadas pelo interpolador IQD (modelo de referência) mostraram resultados superiores quanto a modelagem

comparativamente com a RNA, para o subconjunto amostral analisado.

Mediante uma análise dos valores pontuais de todas as saídas fornecidas pela RNA, verifica-se que as oscilações na rede começam a acontecer a partir das profundidades em torno de 900 a 1000 m. Isso indica que a RNA apresentou uma diferença residual menor entre a interpolação e os valores medidos para as profundidades até aproximadamente 900 m. Com o aumento das profundidades, a rede apresentou valores de Z interpolados que possuem uma maior oscilação com relação aos valores medidos em campo. Estes resultados podem indicar que a rede é influenciada pelo aumento das profundidades. Porém mesmo ocorrendo esta oscilação, os resultados quantitativos estão atendendo a precisão desejada em relação ao equipamento utilizado na coleta dos dados, mediante análises das diferenças residuais entre a RNA e os valores medidos em campo. Foi verificado que com o uso da variável (a), 89% das diferenças residuais estão dentro da precisão permitida (17 m); para a variável (b) tem-se 79% respectivamente e para o IQD obteve-se 94% de acerto.

O resultado qualitativo obtido com o uso da RNA pode ser visualizado nas curvas isobatimétricas na Figura 9.

Figura 9 – Curvas isobatimétricas – Análise qualitativa (Variáveis: E, N – (a)) e (Variáveis: E, N, peso linear – (b))



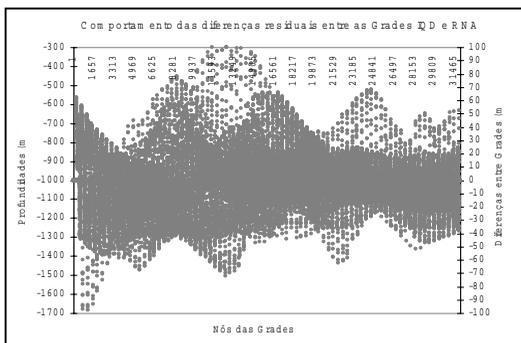
Qualitativamente por meio da Figura 9 foi verificado que com o uso da variável peso linear, experimento (b), as isóbatas apresentaram “ruídos”(o delineamento dos perfis podem ser visualizados nas curvas). Esse problema pode ser justificado pela não utilização das coordenadas mais afastadas do feixe central (30), nas quais foram atribuídos peso com valor zero (0). Desta forma qualitativamente, os melhores resultados (análise subjetiva), foram obtidos com a utilização das variáveis de entrada E, N. Isso pode ser justificado pelo fato de que

quando não se integra nenhuma informação às posições planimétricas E, N, as quais são pontuais, o comportamento das curvas é mais suave, ou seja, a saída da RNA é mais estável. O resultado qualitativo com o uso da variável E, N, mostra que os elementos amostrais coletados para o treinamento da rede, foram suficientes e discretizaram todas as características do relevo.

3.3.3 Comparação entre as Grades Generalizadas pela RNA e a Grade IQD – Resultados e Discussões

Serão apresentados os resultados e discussões baseados na verificação quantitativa e qualitativa das diferenças residuais entre as grades RNA e à superfície do fundo oceânico representada com a grade IQD. As diferenças entre as grades indicam a proximidade das grades RNA à superfície do fundo oceânico representada com a grade IQD. Para a representação gráfica das diferenças, foi utilizado os resultados obtidos com as variáveis de entrada E, N (arquitetura 5). A Figura 10 mostra as diferenças calculadas entre as grades as quais possuem 156.999 nós, mas para facilitar a visualização, foram considerados 53.334 nós da grade. No eixo (X) estão representados os nós das grades, no eixo Y (lado esquerdo), estão as profundidades interpoladas e neste mesmo eixo do lado direito, estão representadas as diferenças residuais entre as grades.

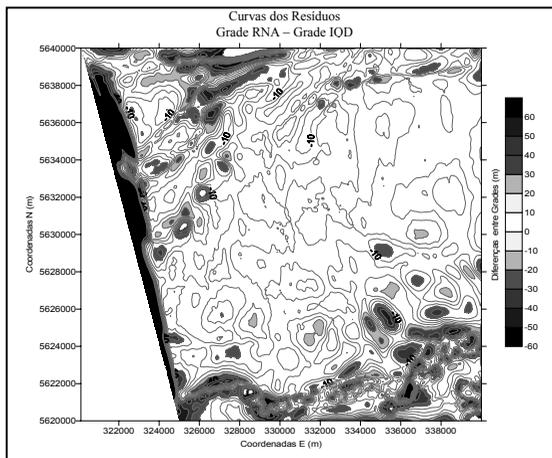
Figura 10 – Comportamento das diferenças residuais entre a grade IQD e a grade RNA



Verifica-se que os resíduos entre as grades IQD e RNA, concentram-se em torno dos 16 m (valor absoluto) para 89% dos valores. Para a grade RNA utilizando o treinamento executado com as variáveis de entrada E, N e generalizada nas mesmas posições dos nós da grade IQD (Figura 10), a grade IQD e a grade generalizada pela RNA diferiram em termos das diferenças residuais entre superfícies com um desvio padrão de 15,22 m.

Na Figura 11 pode-se visualizar o comportamento dos resíduos entre as grades para o caso da variável E, N e o modelo de referência IQD. Esses resultados confirmam as análises e discussões das seções 3.3.1 e 3.3.2, onde na RNA as maiores variações observadas acontecem a medida que aumentam as profundidades e também conforme a declividade do terreno. Com o aumento das profundidades e maior variação do relevo, a rede apresentou regiões que possuem uma maior oscilação com relação ao modelo de referência.

Figura 11 – Curva das diferenças entre as grades IQD e RNA



Quantitativamente as diferenças obtidas entre a grade IQD e as grades RNA, mostram que elas divergiram pouco em termos de desvios. Para a variável de entrada E, N experimento (a) a diferença entre a grade IQD e RNA foi a menor, da ordem de 15,22 m e para o experimento (b) foi de 15,30 m.

4 CONSIDERAÇÕES FINAIS

Os resultados obtidos com a interpolação e com as grades generalizadas usando a RNA, atingiram as precisões desejadas para as profundidades consideradas, com base na precisão estipulada pelo fabricante do sistema *multibeam Hydrosweep DS-2*. Os dois experimentos executados utilizando diferentes variáveis para o treinamento da rede, forneceram resultados residuais em termos de desvio padrão menores que o erro máximo permitido (17 m), a RNA forneceu resultados cujo erro máximo foi de 14 m.

O método desenvolvido para a coleta dos elementos amostrais de treinamento de forma sistemática, foi importante, pois o processo adotado nessa coleta, influenciou na etapa de generalização.

Com a inserção dos pesos linear (0 a 1), foi verificado uma tendência nas curvas indicando um possível problema com a definição dos pesos. Esta variável

não contribuiu na modelagem, pelo fato de se ter atribuído valores numéricos de 0 a 1, fazendo com que os feixes mais afastados do central, fossem eliminados. Mas os resultados mostraram que apesar destes feixes serem considerados menos precisos, eles devem ser utilizados, pois contribuem na precisão da modelagem.

As variáveis E, N contribuíram mais no processo de interpolação, pelo fato de que o terreno está sendo representado com uma cobertura total (pontos distribuídos em todo o terreno), isto é, não sendo atribuídos pesos aos feixes localizados na faixa de 20% de recobrimento, sendo assim, todos os pontos possuem um mesmo peso para o treinamento da rede. O que mostra a alta qualidade dos dados de profundidades coletados pelo sistema *multibeam Hydrosweep DS-2*, que não necessitam de mais informações para caracterizar com mais precisão o relevo e discriminar as classes de profundidades.

Verificou-se que a integração dos dados de profundidades e dos pesos, foi possível. Os testes comprovam que se deve ter o cuidado na utilização da variável peso, pois os resultados mostraram que o comportamento dos mesmos devem ser analisados, permitindo assim, uma representação qualitativa mais condizente com a superfície verdadeira, tendo em vista o “ruído” detectado em algumas isóbatas.

Quanto a comparação entre as superfícies (modelo de referência e modelo RNA), conclui-se mediante os desvios padrão das diferenças entre grades, que utilizando a variável que teve o melhor desempenho (experimento (a)) obteve-se uma diferença entre grades de 15,22 m.

Apesar das diferenças entre as grades RNA com a superfície do fundo oceânico representada com a grade IQD, os resultados apontaram uma proximidade (mesma tendência) entre as superfícies, mas não se pode afirmar qual dos métodos é o melhor para a modelagem tridimensional do relevo oceânico. O que se pode concluir é que ambos algoritmos possuem vantagens e desvantagens inerentes a cada método e a utilização deles dependerá do que se deseja obter com os produtos qualitativos gerados e a precisão que se deseja atingir. Dentre as vantagens e desvantagens observadas tem-se: O algoritmo IQD faz uma interpolação local e a RNA faz uma interpolação global; A RNA não necessita de nenhum conhecimento previo da área em estudo (relevo). O IQD precisa conhecer características do levantamento de campo (espaçamento da coleta), do equipamento que executou a varredura (geometria), para que sejam encontrados quais os parâmetros mais adequados para executar uma interpolação que atinja a precisão desejada, como por exemplo, o tamanho do raio de busca, a dimensão da grade; Uma vez definida a arquitetura da rede que melhor se adaptou para as diferentes profundidades envolvidas, não é necessário se preocupar mais com essa etapa. Se esta arquitetura for usada novamente para modelar qualquer região com os mesmos limites de profundidades testados anteriormente, ela terá bom desempenho, uma vez que a arquitetura foi definida e as variáveis de entrada para o treinamento também. Desta forma, o interpolador RNA terá bom desempenho para qualquer dimensão de área; A RNA permite a integração de diferentes variáveis para o processo de interpolação

o que não é possível usando o interpolador IQD. Acredita-se que esta seja a maior vantagem da RNA em relação ao IQD, uma vez que a rede permite que diferentes informações possam ser tratadas e referenciadas no processo da modelagem, juntamente com a variável profundidade, de uma única vez, e com isso, poder-se-á avaliar a influência de variáveis complementares de diferentes formatos na modelagem tridimensional do relevo oceânico; Outra vantagem da RNA comparativamente com o algoritmo de interpolação IQD, é que a rede conseguiu bom desempenho na generalização da grade, utilizando apenas 5% de elementos amostrais no treinamento.

5. AGRADECIMENTOS:

Ao Instituto de pesquisas alemão *Alfred Wegener Institut für Polar und Meeresforschung* (AWI) - *Polarstern* pela disponibilização de dados e materiais relevantes ao desenvolvimento da pesquisa;

Ao *Institut für Erdmessung* (IfE) – Universidade de Hannover, pelo uso de suas instalações e laboratórios e aos pesquisadores deste instituto pela atenção dispensada;

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), ao *Deutscher Akademischer Austausch Dienst* (DAAD) pela concessão de uma bolsa de estudos (cooperação internacional Brasil/Alemanha).

5 – REFERÊNCIAS BIBLIOGRÁFICAS

ATLAS Hydrographic (2004). *Specifications and performance data*. Disponível em: <<http://www.atlashydro.com>>. Acessado em: setembro de 2004.

AWI (2004). *Alfred Wegener Institut für Polar und Meeresforschung – Polarstern*. Disponível em: <<http://www.awi-bremerhaven.de/>> Acessado em: constantemente no ano 2004.

AWI (2005 (b)). *Alfred Wegener Institut für Polar und Meeresforschung – Polarstern. Informação obtida em comunicação pessoal*. Contato com: Herr SCHULTE, D.; Herr KROCKER, R.; Herr BEYER, A.; Herr SCHENKE, H. W., em agosto de 2005.

BEYER, A.; SCHENKE, H. W.; KLENKE, M.; NIEDERJASPER, F. (2003). *High resolution bathymetry of the eastern slope of the Porcupine seabight*. Marine Geology, 198, pp. 27 - 54.

BUZIEK, G., GRÜNREICH, D., KRUSE, I. (1992). *Stand und Entwicklung der digitalen Landschaftsmodellierung mit dem Topographischen Auswertesystem der Universität Hannover (TASH)*. Vermessung, Photogrammetrie und Kulturtechnik, pp. 87- 88, Februar 1992.

CHAKRABORTY, B.; SCHENKE, H. W.; KODAGALI, V.; HAGEN, R. (2001). *Analysis of multibeam-Hydrosweep echo peaks for seabed characterization*, Geo-Marine Letters, v. 20, n. 3, pp. 174-181.

CLARKE, J. E. H. (2002). *The Challenge of Technology: Improving Sea-Floor Mapping Methodologies- Visualizing the sea Floor: Mapping Submarine Landscapes*. Symposium

- on: Visualizing and Looking Beyond Earth-American Association for the Advancement of Science. Boston, Feveireiro.
- EUROPEAN COMMUNITIES (2004). *Environment and sustainable development: 165 new research projects to be launched*. (1995 – 2003). Disponível em: <<http://europa.eu.int/comm/research/press/2000/pr1602en-annex.html>> Acessado em: agosto de 2004.
- FITZGERALD, R. W.; LEES, B. G. (1996). *Temporal context in floristic classification*. Computers Geosciences, v. 22, n. 9, pp. 981 – 994.
- GEBCO (2004). *General Bathymetric Chart of the Oceans (Data from GEBCO Digital Atlas)*. Disponível em: < <http://www.ngdc.noaa.gov/gebco/gebco.html>> Acessado em: junho de 2004.
- GEOMOUND (2004). *The internal mound factory. The Geomound webserver*. The Department of Geology University College Dublin. Disponível em: <<http://geomound.ucd.ie/>>. Acessado em: junho de 2004.
- GOURLEY, M.; HUGHES, C. J. E. (2000). *Integration time and spatial domains during multibeam data cleaning*. 15 th Hydrographer's Conference. German Hydrographic Society.
- GUTBERLET, M.; SCHENKE, H. W. (1989). HIDROSWEEP: New era in high precision bathymetric surveying in deep and shallow water. Marine Geodesy 13, pp. 1 – 23.
- HILTON G. E. (1989). *Connections learning procedures*. Artificial Intell, v. 40, n. 1 - 3, pp. 185 – 234.
- HUVENNE, V. A. I.; De MOL, B.; HENRIET, J. P. (2003). *A 3D Seismic Study of the Morphology and Spatial Distribution of Buried Coral Banks in the Porcupine Basin, SW of Ireland*. Marine Geology, 198, pp. 5 - 25.
- INSS (2005). *Irish National Seabed Survey*. Disponível em: <http://www.gsiseabed.ie/>. Acessado em: maio de 2005.
- JACOBS, M. (2002). *Analyses of High Resolution Bathymetric Data in Eltanin Impact Area*. Master's Thesis, Bremerhaven, Germany.
- KRUPP ATLAS ELEKTRONIK (2004). *Atlas Hydrosweep Equipment, Hydrographic Multibeam Sweeping Survey Echosounder*. Operating Instructions, Edition 04.88 Order-N.: ED 6015 G 012, Krupp Atlas elektronik GmbH, 2005.
- KRUPP ATLAS ELEKTRONIK (1998). *Atlas Hydrosweep, hydrographic multi-beam deep sea sweeping echosounder system*. System Deskription, Bremen 9. Edition 04.88 order-n.: ED 6015 G 012, Krupp Atlas elektronik GmbH.
- LENK, U; KRUSE, I. (2000). *Digitale Geländemodellierung: Grundlagen, Methoden und ihre kritische Bewertung*. In: Bundesanstalt für Geowäerkunde, Reihe Veranstaltungen 3/2000: Modellierung von Höhendaten für hydrologische Fragestellungen. Koblenz, Berlim, 2000.
- REIDMILLER, M.; BRAUN, H. (1993). *A direct adaptive method for faster backpropagation learning: the RPROP algorithm*. In: Proceedings of the IEEE, International Conference on Neural Network (ICNN), 1993, San Francisco – USA., pp. 586 – 591.
- SCHENKE, H. W.; J. ULRICH. (1986). *Flächenhafte Kartierung des Meeresbodens*. Geowissenschaften - AWI - Zeit, 4, pp. 122 - 130.
- SCHENKE, H. W. (1987). *Ergebnisse und Analysen bathymetrischer Vermessung mit Fachersonarsystemen*. Beitrage zum 3. Hydrographie Symposium der DhyG in

Bremerhaven 23 - 24. April.

SCHENKE, H. W. (1990). *Die Fächersonaranlage Hydrosweep - Ein neues System zur flächenhaften Vermessung des Meeresbodens*. Die Geowissenschaften 6: pp. 161 – 169.

SOUZA, E., C., B. (2006). *Modelagem tridimensional do relevo oceânico usando Redes Neurais Artificiais*. Tese (Doutorado em Ciências Geodésicas). Departamento de Geomática. Universidade Federal do Paraná, Curitiba, 181 p.

(Recebido em junho de 2006. Aceito em novembro de 2006)