

Geração de Isolinhas, com dados obtidos por levantamento GPS/L₁L₂, mediante a técnica de Redes Neurais Artificiais

Elaine Cristine Barros de Souza^{1*}, Selma Regina Aranha Ribeiro², Mosar Faria Botelho¹, Cláudia Pereira Krueger² e Jorge Antonio Silva Centeno²

¹Programa de Pós-graduação em Ciências Geodésicas, Universidade Federal do Paraná, Setor de Ciências da Terra, Cx. Postal 19001, 81531-990, Curitiba, Paraná, Brasil. ²Departamento de Geomática, Universidade Federal do Paraná, Curitiba, Paraná, Brasil. *Autor para correspondência. e-mail: elainechsouza@hotmail.com

RESUMO. O objetivo deste trabalho é mostrar uma alternativa para o processo de interpolação empregado em Modelagem Digital do Terreno. Utilizando-se dados de levantamentos GPS coletados por meio de posicionamento relativo cinemático realizou-se um processo de interpolação por meio de Redes Neurais Artificiais (RNA). Os resultados foram comparados com os dados obtidos usando-se o algoritmo de interpolação Inverso do Quadrado de uma Distância (IQD) para avaliar o comportamento das grades geradas por meio de análises qualitativas (isolinhas e MDT) e quantitativas (resíduos). Conclui-se que o método testado é viável se comparado com o algoritmo IQD e, portanto, o uso de RNA apresenta-se adequado para a interpolação de dados GPS provenientes do processamento de fase das portadoras L₁ e L₂.

Palavras-chave: Isolinhas, GPS, Redes Neurais Artificiais.

ABSTRACT. Generation of Isolines using GPS/L₁L₂ data and Artificial Neural Network technique. The objective of this work is to show an alternative for the interpolation process used in Digital Terrain Modeling. GPS surveying data of a kinematic relative positioning were interpolated by means of Artificial Neural Networks (ANN) algorithm. The performance of the generated gridding was compared to the Inverse Square Distance interpolation algorithm data by means of qualitative (isolines and DTM) and quantitative (residuals) analyses. In conclusion, the tested method is viable if compared to the algorithm Inverse of the Square of a Distance. Therefore, the use of ANN is suitable for the interpolation of GPS data obtained from the L₁ and L₂ carriers phase processing.

Key words: Isolines, GPS, Artificial Neural Networks.

Introdução

A partir do século XX com o advento das técnicas empregadas em Geodésia e Cartografia foi possível mapear e documentar a superfície da Terra com elevado grau de precisão. O *Global Positioning System* (GPS) é um exemplo de um componente eficaz para a formação de uma base geométrica uniforme, sendo possível gerar alguns produtos cartográficos a partir destes dados.

O GPS possibilita a determinação das coordenadas dos pontos em diferentes níveis de precisão dependendo da técnica de posicionamento utilizada, bem como do tipo de observável empregada. As estratégias de observação com o GPS podem ser classificadas inicialmente, em função do número de receptores envolvidos no levantamento. O posicionamento absoluto utiliza apenas um

receptor GPS, enquanto que o posicionamento relativo terá pelo menos dois receptores envolvidos (Krueger, 1996, p. 10). Nestas modalidades de posicionamento tem-se a técnica de posicionamento estática, quando o objeto a ser posicionado é estacionário, e a técnica de posicionamento cinemática, quando o objeto a ser posicionado está em movimento. Uma terceira modalidade refere-se ao método de posicionamento GPS Diferencial (DGPS) (Hoffmann *et al.*, 2001, p. 136). É possível obter precisão de décimos de milímetros para medida utilizando a fase das portadoras e atingindo o milímetro quando ocorre a resolução das ambiguidades.

A análise qualitativa e quantitativa da superfície física pode ser efetuada por meio de um Modelo Digital do Terreno (MDT). A representação mais

comum de um MDT, está associada a altimetria, embora possa representar outras grandezas que variam continuamente no espaço, como por exemplo, unidades geológicas ou teor de minerais (Burrough, 1986, p. 17). O MDT é fundamental para projetos relacionados a cartografia tridimensional, para cálculo de volumes em um projeto de estradas, apoio aos projetos de drenagens, base para projetos realizados em programas de Sistema de Informações Geográficas (SIG's), como por exemplo, estimação de distâncias na alocação de pontos de ônibus onde a inclinação do terreno tem grande importância, na geração de mapas de declividade, etc.

Os MDTs podem ser representados por grades irregulares ou grades regulares, similares às matrizes utilizadas para representar imagens digitais. Para a obtenção de uma representação contínua da superfície, a partir de observações esparsas resultantes do levantamento, técnicas de interpolação são necessárias. Para a interpolação, vários métodos encontram-se hoje disponíveis (estatísticos e geoestatísticos). Sua aplicação e sucesso dependem do tipo de relevo e dos dados disponíveis, sendo a escolha do interpolador a ser utilizado, de responsabilidade do profissional que o utilizará pela geração do modelo, conforme as suas necessidades.

Os procedimentos de interpolação de grades regulares a partir de amostras variam de acordo com a grandeza medida. No caso da altimetria, é comum o uso de funções de ponderação por Inverso do Quadrado de uma Distância (IQD). Já para variáveis geofísicas ou de natureza pedológica, procedimentos de filtragem ou geoestatísticos como Krigagem são utilizados (Câmara e Medeiros, 1998, p. 420).

O método de interpolação IQD assume que o valor médio a ser estimado para a variável em um ponto X qualquer é proporcional ao valor medido em "n" estações vizinhas (V_i) e inversamente proporcional ao quadrado da distância entre o ponto X e cada uma destas "n" estações (D_i^2). Portanto, quanto mais distantes o ponto estiver do ponto X, menor será seu peso ou, em outras palavras, menor sua influência sobre o valor a ser estimado (V_x) (Pellegrino *et al.*, 1998, p. 341).

Ressalta-se que apenas uma técnica de interpolação, baseada em análises estatísticas de erros que quantifiquem as irregularidades do terreno, não deve ser usada como o único meio de se avaliar a qualidade de um levantamento, na medida em que ela pode não prover estimativas confiáveis da precisão do MDT em todos os casos.

Uma alternativa para a geração de MDT é a

aplicação de Redes Neurais Artificiais (RNA). A RNA é um esforço matemático para simular, em parte, o funcionamento do cérebro humano por meio de uma rede de elementos de processamento unitários que juntos, e funcionando em paralelo, simulariam o fluxo de "informações" no cérebro humano. Como principais características das RNA, segundo Bittencourt (1998, p. 302), podem ser citadas: a capacidade de aprender (treinar) por exemplos e de generalizar este aprendizado, aplicando-o a situações antes não confrontadas ou não apresentadas previamente. Uma RNA se destaca por seu bom desempenho em tarefas mal definidas, nas quais falta o conhecimento explícito sobre como encontrar uma solução; e não requerem conhecimento a respeito de eventuais modelos matemáticos dos domínios da aplicação (processam informações espaço/temporais); são capazes de fazer armazenamento associativo de informações; possuem grande paralelismo, o que lhe confere rapidez de processamento.

Uma RNA é composta por vários neurônios interligados distribuídos em camadas. A primeira camada é chamada de camada de entrada e tem a função de armazenar as variáveis de entrada da rede. As camadas intermediárias denominadas de camadas escondidas são os "pensamentos", nos quais ocorrem os processamentos da rede. A última camada é definida como de saída, recebe os valores já processados pela rede. O arranjo destes neurônios pode assumir diferentes formas, variando na natureza da ligação entre camadas, o número de camadas e o número de neurônios por camadas, o que é denominado de arquitetura da RNA (Ito *et al.*, 2000, p. 157).

A propriedade mais importante da RNA é a habilidade de aprender seu ambiente e com isso melhorar seu desempenho. Este aprendizado é realizado por meio de processos iterativos de ajustes aplicados a seus pesos, o chamado treinamento. O aprendizado só ocorre quando a RNA atinge uma solução generalizada para uma classe de problemas. A maioria dos modelos de RNA possui uma regra de treinamento, na qual os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Isso é o mesmo que falar que elas aprendem por exemplos. A RNA passa pelo processo de treinamento a partir de um conjunto de dados reais diferindo da computação programada, a qual é necessário um conjunto de regras pré-fixadas e algoritmos.

Por isso, neste artigo, o principal objetivo está em utilizar a RNA como ferramenta para a interpolação de MDTs, partindo de levantamentos GPS (método relativo e técnica cinemática). Esta nova metodologia

é avaliada efetuando a comparação dos resultados da RNA com aqueles resultantes de métodos convencionais não estocásticos de interpolação, como o IQD.

Material e metodos

Área de estudo

A área escolhida para a realização do levantamento de campo (coleta dos dados GPS), localiza-se no Campus Centro Politécnico da Universidade Federal do Paraná (UFPR), Curitiba, Estado do Paraná, área cercada representada na Figura 1, que se encontra atrás do Laboratório de Geodésia Espacial (Lage), que possui as RRNN, com coordenadas *Universal Transverse Mercator* (UTM) no Sistema de Referência WGS-84, sendo as altitudes (H) geométricas: RN01 (N:7184247,916 m; E:677881,479 m; H:925,223 m), RN02 (N:7184210,177 m; E:677900,403 m; H:924,459 m), RN03 (N:7184210,009 m; E:677856,723 m; H:923,785 m) e a estação Para (N:7184223,247 m; E:677878,526 m; H:925,759 m), a qual faz parte da Rede Brasileira de Monitoramento Contínuo (RBMCM) de responsabilidade do Instituto Brasileiro de Geografia e Estatística (IBGE).




Figura 1. Área teste e disposição das RRNN.

Com a finalidade de se avaliar a qualidade das grades geradas usando a RNA, a metodologia foi dividida em etapas, que são: coleta de dados, geração de uma grade de referência pelo método convencional de interpolação (IQD), geração da grade pela técnica da RNA e avaliação da qualidade dos produtos.

Levantamentos de campo

O levantamento de campo foi realizado utilizando

o método de posicionamento relativo e a técnica cinemática com uma taxa de coleta dos dados igual a 1s. Realizou-se um caminhamento de forma a cobrir toda a área, utilizando um receptor *Ashtech Z-XII* (12 canais), com portadoras L_1L_2 e seus acessórios. A Figura 2 ilustra esse caminhamento e podem-se visualizar as RRNN (01, 02, 03 e Para) contidas na área levantada. O pós-processamento dos dados forneceram precisões relativas da ordem centimétrica (≈ 20 a 50 cm), e um total de 890 elementos amostrais.




Figura 2. Caminhamento percorrido com receptor de dupla frequência.

Geração do modelo de referência

Tendo as coordenadas planimétricas (E, N) e altitude (H) (em UTM e WGS-84), obtidas do pós-processamento dos dados GPS (posicionamento relativo e técnica cinemática - portadoras L_1L_2). A primeira etapa para a obtenção das isolinhas e do MDT e posterior análises, consistiu na geração de uma grade regular.

Utilizou-se uma resolução para a geração da grade, de 1 m x 1 m (E, N), respectivamente. Este valor foi estabelecido partindo-se da coleta dos dados GPS que foi realizada com uma taxa de 1s com o usuário se deslocando a uma velocidade média de 5 km s⁻¹, assumindo então, uma distância entre os pontos de aproximadamente 1 m.

A grade de referência foi interpolada no programa Surfer, com o algoritmo de interpolação IQD. A grade gerada foi neste caso, de 55 linhas por 47 colunas. As Figuras 3 e 4 ilustram o resultado do processamento, as isolinhas e o MDT.




Figura 3. Curvas de isolinhas delimitadas para o levantamento L_1L_2 .

Segundo estudos realizados por Souza (2002), esse método de interpolação é o que melhor representa e modela uma área quando são realizadas análises qualitativas e quantitativas, fazendo uso de dados pontuais oriundos de levantamentos GPS, pelo fato dele utilizar um critério de ponderação nas coordenadas.

Interpolação mediante a técnica de RNA

Para a interpolação dos modelos por RNA, utilizou-se o programa MatLab na versão 5.3, que possui um módulo de redes neurais, denominado de *Neural Network Toolbox for Use in MatLab*. A grande flexibilidade na manipulação e formatação de arquivos e diversidade de algoritmos implementados eficientemente (funções de ativação e transferência) justificam a escolha deste programa nesta pesquisa.

Treinamento

Um conjunto de elementos amostrais foram escolhidos para configurar as amostras de treinamento. Analisando os dados do receptor de dupla frequência (L_1L_2) bem como as RRNN existentes na área de estudo, verificou-se visualmente quais os pontos que representam as nuances mais significativas do relevo, ou seja, aqueles com cotas mais altas e mais baixas, bem como, as intermediárias. Assim estes pontos foram admitidos como as amostras de treinamento da RNA, perfazendo um total de 118 coordenadas para um total de 890 coordenadas coletadas. A quantidade de elementos amostrais de treinamento foi definida experimentalmente a partir de testes preliminares.




Figura 4. MDT delimitado para o levantamento L_1L_2 .

Com o objetivo de ter um maior controle sobre as amostras da superfície, os dados coletados como treinamento foram indexados de forma crescente considerando o valor das altitudes. Assim, para o treinamento das amostras, processadas com a técnica das RNA, tem-se a necessidade de que estas sejam intercaladas por coordenadas considerando o valor da altitude para que o processo de treinamento não se torne tendencioso, isto é, que a modelagem da rede só identifique as características de um conjunto amostral, ou seja, para que a rede não “decore” mas “aprenda” a identificar determinadas características do relevo. Para isso, as coordenadas foram alternadas. Por exemplo, para L_1L_2 (118 amostras), foram organizados em ≈ 13 vetores, intitulados de (V) com 9 elementos em cada vetor denominados de (A) ($V_n = [A_1, A_2, A_3 \dots A_9]$, sendo que $n = 1 \dots 13$).

Por meio da Tabela 1 verifica-se a situação de como as amostras seriam apresentadas a rede sem serem intercaladas e como são, na realidade, intercaladas no estudo. Uma rotina em MatLab foi desenvolvida para realizar esta alternância.

Tabela 1. Amostras sem alternância e alternadas.

Amostras sem alternância coord.	Amostras com alternância coord.
$A_1 V_1$	$A_1 V_1$
$A_2 V_1$	$A_1 V_2$
$A_3 V_1$	$A_1 V_3$
.....	
$A_9 V_1$	$A_1 V_{13}$
$A_1 V_2$	$A_2 V_1$
$A_2 V_2$	$A_2 V_2$
$A_3 V_2$	$A_2 V_3$
.....	
$A_9 V_2$	$A_2 V_{13}$
.....	
$A_1 V_3$	$A_9 V_1$
$A_2 V_3$	$A_9 V_2$
$A_3 V_3$	$A_9 V_3$
.....	
$A_9 V_3$	$A_9 V_{13}$
$A_1 V_{13}$	$A_9 V_{13} (2x) = 118$
.....	
$A_9 V_{13} (2x) = 118$	

Arquitetura e algoritmo de treinamento da RNA

Estruturar a arquitetura de uma RNA consiste em definir o número de camadas escondidas e a quantidade de neurônios por camada. Esta definição foi realizada por meio de uma série de experimentos, nos quais a arquitetura foi variada até que foi encontrada a arquitetura ideal, sendo o algoritmo de treinamento utilizado neste estudo o *Backpropagation*.

A rede foi treinada com duas e três camadas escondidas, com o intuito de se obter um Erro

Médio Quadrático (EMQ) aceitável ($\approx 0,001$). O mesmo foi adotado tendo em vista a precisão do levantamento, isto é, da ordem centimétrica. Para a maioria dos testes adotou-se um EMQ de 0,001, mas testes com 0,0001 também foram realizados e as épocas/iterações para convergência da rede foram ótimas, cerca de no máximo 1 minuto de processamento computacional.

Tendo-se definido a quantidade de camadas escondidas foi necessário determinar, experimentalmente, o número de neurônios (nós) por camada. Para tanto, se considera a regra de Hilton (1989), isto é, para definir o número de nós que as camadas intermediárias da rede devem ter. O autor afirma que, para o caso de duas camadas intermediárias, o número de nós da segunda camada não deve exceder um terço ($1/3$) do conjunto de nós da primeira.

Fixou-se à quantidade de neurônios da primeira camada intermediária em $1/3$ da quantidade de neurônios da primeira, testes foram realizados com 40 neurônios. Variou-se à quantidade de neurônios para a segunda camada, até obter-se uma quantidade de nós, nessa camada, que fornecesse o resultado esperado, em termos de iterações e do erro médio quadrático mínimo estipulado, a qual correspondeu a $1/4$ do total de neurônios da primeira camada intermediária, isto é, 10 neurônios.

Os experimentos realizados utilizando esta arquitetura convergiram com um número baixo de iterações, em torno de 26 épocas, e com um erro médio mínimo quadrático aceitável (performance/erro médio quadrático de 0,00099979 para o critério de parada de treinamento de 0,001). Ressalta-se que o algoritmo de treinamento utilizado foi o *Backpropagation* com a variação *Resilient Propagation* (RPROP), desenvolvido por (Reidmiller e Braun, 1993, p. 586-591).

Generalização

Após o treinamento é efetuada a generalização mediante a aplicação do modelo matemático a todos os dados originais, não apenas aqueles usados no treinamento. As Figuras 5 e 6 mostram os resultados qualitativos obtidos com relação às isolinhas e o MDT gerados com as saídas da RNA, bem como a plotagem dos dados originais (trajetória percorrida) sobre elas e, também, a disposição das RRNN.

Para visualização qualitativa dos resultados obtidos pela RNA utilizou-se o *software* Surfer,




Figura 6. MDT gerado para o levantamento L_1L_2 (saídas RNA).

fazendo uso do algoritmo do Vizinho mais Próximo para visualização da grade gerada pela RNA. Optou-se por esse algoritmo para gerar as isolinhas e o MDT, pelo fato que os resultados fornecidos pela RNA já são valores interpolados. O Vizinho mais Próximo é então o mais indicado, pois não interfere nos resultados interpolados pela rede, na etapa de geração da grade, pois o algoritmo parte do critério que a partir de um conjunto de amostras e dentro de um raio definido, ele medirá as distâncias e adotará a amostra mais próxima, sem efetuar qualquer ponderação nas coordenadas.




Figura 5. Isolinhas para o levantamento L_1L_2 (saídas RNA).

Resultado discussão

Com o intuito de uma análise quantitativa dos dados, computou-se a diferença entre as cotas (valores Z) dos dados de verificação e dos dados interpolados pela RNA. Com estes resultados é possível derivar medidas estatísticas que permitem a análise da qualidade da grade gerada com relação aos dados originais (verificação).

Segundo Gemael (1994, p. 87), a média aritmética é um estimador eficiente e um ótimo estimador da média populacional. Desta forma, escolhida a média aritmética como representativa da grandeza medida por meio de observações não correlacionadas de mesma confiança restou estimar o seu grau de precisão. Para tanto, é necessário adotar-se uma estimativa da precisão das observações, que neste trabalho foi o desvio padrão (medida de dispersão).

Verifica-se, na Tabela 2, os valores residuais obtidos para a grade gerada a partir dos levantamentos L_1L_2 . Estes resíduos são aceitos para a precisão esperada do levantamento executado com as duas portadoras.

Tabela 2. Análise comparativa da interpolação (IQD) e (RNA).

Método	Inverso do Quadrado de uma Distância	Redes Neurais Artificiais
Média das diferenças (m)	0,01172	0,00154
Desvio padrão das diferenças(m)	0,00140	0,000389

Assim como para a grade gerada com o interpolador do IQD, foram também calculados os resíduos (médias/desvios padrão) para a grade gerada com os valores de saída da RNA. Verifica-se, no Tabela 2, os valores residuais obtidos para as grades geradas a partir das coordenadas de saída da RNA.

Considerando o experimento realizado e os resultados obtidos, pode-se fazer um paralelo, avaliando-se às coordenadas precisas das RRNN, contidas na área levantada, com os valores de altitudes máximo, intermediário e mínimo obtidos após a geração das grades (dados interpolados), avaliando-se pontualmente as discrepâncias existentes entre os dados interpolados advindos do levantamento GPS usando a fase das portadoras L_1L_2 , por meio da RNA, com as coordenadas precisas das RRNN (01, 02, 03 e PARA). O critério adotado foi buscar as coordenadas máximas, intermediárias e mínimas desse levantamento (resultado da RNA) estando elas dentro de um raio de 1 m em torno de cada RRNN. A Tabela 3 ilustra as altitudes geométricas (H) precisas das RRNN e as coordenadas máximas, intermediárias e mínimas encontradas para o levantamento (após interpolação pela RNA), bem como as diferenças calculadas.

Tabela 3. Análise comparativa das RRNN de campo com as RRNN da RNA.

RRNN	L_1L_2	Diferenças Calculadas (m)
	Máxima Intermediária Mínima (m)	
RN 01 925,223m	925,992	0,769
	925,219	0,004
	925,014	0,209
RN 02 924,459m	924,953	0,494m
	924,457	0,002m
	924,001	0,458m
RN 03 923,785m	923,999	0,214m
	923,774	0,011m
	923,007	0,778m
PARA 925,759m	925,992	0,233m
	925,741	0,018m
	925,014	0,745m

Conclusão

Comparando-se os valores das colunas da Tabela 2, pode-se verificar que com a interpolação pelo método do IQD obteve-se um desvio padrão de 0,00140 m em relação à média dos valores, ao passo que para a RNA o desvio padrão foi de 0,000389 m, indicando o melhor desempenho da RNA, nesta análise quantitativa.

Se forem comparadas as isolinhas e o MDT gerado pelo interpolador IQD (Figuras 3 e 4) com o produto gerado pela RNA (Figuras 5 e 6), fica claro, visualmente, que as RNA modelaram melhor a região.

Verifica-se, também, pela plotagem das RRNN e das suas altitudes precisas sobre esses produtos gerados que, as nuances do relevo, bem como os valores das cotas nas curvas (depois de interpoladas com as saídas da RNA), se aproximaram da realidade fato não constatado de forma tão significativa quando interpolados pelo IQD.

Na Tabela 3, verifica-se que os melhores resultados foram para as coordenadas intermediárias, ou seja, aquelas mais próximas dos valores das RRNN, mas tendo em vista a precisão do levantamento (dados pós-processados e depois interpolados), essas diferenças não foram significativas, pois elas mostram que a interpolação foi muito boa, quando comparada com as coordenadas precisas das RRNN, todas as diferenças ficaram com valores da ordem centimétrica ou milimétrica.

Com essas análises fecham-se as discussões e verificações quanto às potencialidades das RNA como interpolador. A interpolação foi satisfatória, mostrando que se a rede for bem treinada, aprende mais sobre as características inerentes de cada entrada e conseqüentemente, consegue generalizar para todo o conjunto de dados, fornecendo uma saída precisa.

Devido aos resultados obtidos e aqui descritos, conclui-se que a técnica de RNA, comparativamente com o algoritmo Inverso do Quadrado de uma Distância, apresenta-se apta para a interpolação de dados GPS usando a fase das portadoras L_1L_2 . Desta forma, pode-se dizer que com a técnica de RNA torna-se possível gerar MDT com qualidade melhor que os algoritmos convencionais.

Referências

- BITTENCOURT, G. *Inteligência artificial*. Florianópolis: Editora UFSC, 1998.
- BURROUGH, P.A. *Principles of geographic information system for land resources assessment*. New York: Oxford University Press, 1986.
- CÂMARA, G.; MEDEIROS, J.S. Tendências na evolução do geoprocessamento. In: ASSAD, E.; SANO, E.E. (Ed.). *Sistema de Informações Geográficas*. Aplicações na Agricultura. Brasília: Embrapa, 1998. p. 411-424 (2. ed. revista e ampliada).
- GEMAEL, C. *Introdução ao ajustamento de observações*. Curitiba: Editora da UFPR, 1994.
- HILTON G.E. Connections learning procedures. *Artificial Intell.*, v. 40, n. 1-3, p. 185-234, 1989.
- HOFMANN, W.B. et al. *GPS: Theory and practice*. 5. ed. Wien: Springer-Verlag, 2001.
- ITO, Y. et al. Extraction of damaged regions using SAR data and neural networks. *Int. Arch. Photogram. Remote Sens.*, Amsterdam, v. 33, p. 156-163, 2000.

KRUEGER, C.P. Investigações sobre aplicações de alta precisão do GPS no âmbito marinho. 1996. Tese (Doutorado em Ciências Geodésicas)-Departamento de Geomática, Universidade Federal do Paraná, Curitiba, 1996.

PELLEGRINO, G.Q. *et al.* O uso de um sistema de informações geográficas no mapeamento de informações agrometeorológicas. *In: Embrapa. Sistema de informações geográficas – aplicações na agricultura.* 2. ed. 1998. p. 329–348.

REIDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: The RPROP Algorithm. *In: INTERNATIONAL CONFERENCE*

ON NEURAL NETWORK (ICNN), 1993. San Francisco, *Proceedings...* San Francisco, 1993. p. 586–591.

SOUZA, E.C.B. *Análises temporais de alta precisão utilizando GPS para avaliação das variações volumétricas ocorridas no istmo da Ilha do Mel.* 2002. Dissertação (Mestrado em Ciências Geodésicas)-Departamento de Geomática, Universidade Federal do Paraná, Curitiba, 2002.

Received on February 02, 2006.

Accepted on November 28, 2006.