

CAROLINE BERGAMO GONÇALVES

REDES NEURAS ARTIFICIAIS NA MODELAGEM DIGITAL: INTERFACE ENTRE
OCEANO E CONTINENTE

CURITIBA

2010

CAROLINE BERGAMO GONÇALVES

REDES NEURAS ARTIFICIAIS NA MODELAGEM DIGITAL: INTERFACE ENTRE OCEANO E
CONTINENTE

Dissertação de mestrado apresentada ao
Curso de Pós-Graduação em Ciências
Geodésicas, Universidade Federal do Paraná,
como requisito parcial à obtenção do título de
Mestre em Ciências Geodésicas.

Orientador: Prof. Dr. Jorge Antonio
Centeno
Co-orientadora: Prof(a). Dra. Claudia
Pereira Krueger

CURITIBA

2010

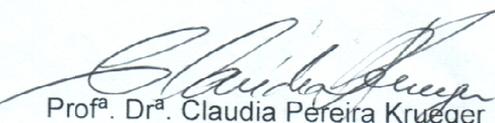
TERMO DE APROVAÇÃO

CAROLINE BERGAMO GONÇALVES

"REDES NEURAIS ARTIFICIAIS NA MODELAGEM DIGITAL NA INTERFACE
ENTRE OCEANO E CONTINENTE"

Dissertação nº 234 aprovada como requisito parcial do grau de Mestre no Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra da Universidade Federal do Paraná, pela seguinte banca examinadora:

Co-Orientadora:



Profª. Drª. Claudia Pereira Krueger
Departamento de Geomática, UFPR



Profª. Drª. Selma Regina Aranha Ribeiro
Universidade Estadual de Ponta Grossa, UEPG



Prof. Dr. Hideo Araki
Departamento de Geomática, UFPR



Prof. Dr. Romualdo Wandresen
Departamento de Geomática, UFPR

Curitiba, 28 de maio de 2010.

LISTA DE FIGURAS

FIGURA 1 - Geometria para a determinação da posição do sistema GPS.....	16
FIGURA 2 - Método de Posicionamento DGPS. Fonte: Adaptada de SEEBER, 1993.....	18
FIGURA 3 - Princípio de funcionamento do ecobatímetro.....	23
FIGURA 4 - Níveis de referência altimétricos. Fonte: Adaptado de IHO ,2009.	24
FIGURA 5 - Representação real da Terra, representação geométrica (elipsóide), representação física (geóide). Fonte: FRACZEK, 2003.....	26
FIGURA 6 - O geóide e outras superfícies equipotenciais com as linhas de prumo perpendiculares a cada superfície equipotencial. Fonte: TORGE, 1991.	26
FIGURA 7 - Alturas entre a forma real da Terra, o geóide e o elipsóide. Fonte: FRACZEK,2003.	27
FIGURA 8 - Régua da estação maregráfica indicando a altura do NR em relação ao elipsóide de referência.	28
FIGURA 9 - Superfícies de tendência. Fonte: Schulzer et. al., 1990.	32
FIGURA 10 - Neurônio biológico.	33
FIGURA 11 - Estrutura de um neurônio artificial de McCulloch e Pitts (1943). Adaptado de HAYKIN, 2001.	35
FIGURA 12 - Funções de ativação: (a) linear, (b) rampa, (c) degrau e (d) sigmoidal. Fonte: Adaptado de BRAGA <i>et al.</i> , 2000.....	36
FIGURA 13 – Exemplos de topologia de rede.(a) Rede alimentada adiante ou acíclica com uma única camada de neurônios. (b) Rede alimentada adiante ou acíclica totalmente conectada com uma camada oculta e uma camada de saída. (c) rede recorrente sem laços de auto-realimentação e sem neurônios ocultos. (d) Rede recorrente com neurônios ocultos. Fonte: HAYKIN, 2001.	37
FIGURA 14 - Método de aprendizado supervisionado. Fonte: Adaptado de BRAGA <i>et al.</i> , 2000.	38
FIGURA 15- Localização e acesso ao Saco do Limoeiro, Ilha do Mel, Paraná. Fonte: Adaptado de ARAÚJO, 2001.	41
FIGURA 16 - Linhas de verificação e de sondagem na tela do programa Hypack. Linhas de sondagem com menor distância entre si e linhas de verificação mais distantes umas das outras.	43
FIGURA 17 - Estação base, estação de referência e antena de rádio no istmo da Ilha do Mel ..	44
FIGURA 18 – Pontos coletados pelo levantamento GPS mostrados na tela do ArcGis.	45
FIGURA 19 - Divisão dos dados em 80% para testes e 20% para verificação.	47
FIGURA 20 - Divisão dos dados em 60% (a), 40% (b), 20% (c), 10% (d) e 5% (e).	47
FIGURA 21 - Representação espacial do método do vizinho natural aplicado a 5% dos dados.	53
FIGURA 22 - Representação espacial do método do vizinho natural aplicado a 10% dos dados.	53
FIGURA 23 - Representação espacial do método do vizinho natural aplicado a 20% dos dados.	54
FIGURA 24 - Representação espacial do método do vizinho natural aplicado a 40% dos dados.	54
FIGURA 25 - Representação espacial do método do vizinho natural aplicado a 60% dos dados.	55

FIGURA 26 - Representação espacial do método do vizinho natural aplicado a 80% dos dados.	55
FIGURA 27 - Representação espacial do método de krigagem aplicado a 5% dos dados.	58
FIGURA 28 - Representação espacial do método de krigagem aplicado a 10% dos dados.	58
FIGURA 29 - Representação espacial do método de krigagem aplicado a 20% dos dados.	59
FIGURA 30 - Representação espacial do método de krigagem aplicado a 40% dos dados.	59
FIGURA 31 - Representação espacial do método de krigagem aplicado a 60% dos dados.	60
FIGURA 32 - Representação espacial do método de krigagem aplicado a 80% dos dados.	60
FIGURA 33 - Representação espacial do método de triangulação aplicado a 5% dos dados.	62
FIGURA 34 - Representação espacial do método de triangulação aplicado a 10% dos dados.	62
FIGURA 35 - Representação espacial do método de triangulação aplicado a 20% dos dados.	63
FIGURA 36 - Representação espacial do método de triangulação aplicado a 40% dos dados.	63
FIGURA 37 - Representação espacial do método de triangulação aplicado a 60% dos dados.	64
FIGURA 38 - Representação espacial do método de triangulação aplicado a 80% dos dados.	64
FIGURA 39 - Representação espacial do método de aproximação polinomial aplicando a função biquadrática a 5% dos dados.	67
Figura 40 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado LM com taxa de aprendizagem de 0.01 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda.	70
Figura 41 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado LM com taxa de aprendizagem de 0.1 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda.	71
Figura 42 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado LM com taxa de aprendizagem de 0.3 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda.	71
Figura 43 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.025 e topologia de 24 neurônios na primeira camada escondida e 6 na segunda.	72
Figura 44 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.1 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda.	72
Figura 45 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda.	73
Figura 46 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda e foi treinada com 5% dos dados.	75
Figura 47 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda e foi treinada com 10% dos dados.	75
Figura 48 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda e foi treinada com 20% dos dados.	76

Figura 49 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda e foi treinada com 40% dos dados	76
Figura 50 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda e foi treinada com 60% dos dados.	77
Figura 51 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda e foi treinada com 80% dos dados.	77
FIGURA 52 - Caixas demonstrando os métodos e densidades (caixa 2) que foram comparadas as redes neurais (caixa 1).	79
FIGURA 53 - Divisão dos pontos que foram utilizados nos testes da área de difícil acesso.	80
FIGURA 54- Representação espacial do método de vizinho natural aplicado aos dados do teste na área de possível escassez de informação.....	81
FIGURA 55 - Representação espacial do método de krigagem aplicado aos dados do teste na área de possível escassez de informação.....	82
FIGURA 56 - Representação espacial do método de triangulação aplicado aos dados do teste na área de possível escassez de informação.....	83
Figura 57 - Representação espacial do resultado da rede LM com taxa de aprendizagem 0.01 e topologia de duas camadas escondidas sendo que a primeira contém 30 neurônios e a segunda 10 neurônios.	84
FIGURA 58 - Representação espacial do resultado da rede LM com taxa de aprendizagem 0.3 e topologia de duas camadas escondidas sendo que a primeira contém 30 neurônios e a segunda 10 neurônios.	85
Figura 59 - Representação espacial do resultado da rede RP com taxa de aprendizagem 0.025 e topologia de duas camadas escondidas sendo que a primeira contém 30 neurônios e a segunda 10 neurônios.	85
Figura 60 - Representação espacial do resultado da rede RP com taxa de aprendizagem 0.8 e topologia de duas camadas escondidas sendo que a primeira contém 30 neurônios e a segunda 10 neurônios.	86

LISTA DE TABELAS

TABELA 1- Precisão atingida por diferentes métodos de posicionamento GPS relativo.	19
TABELA 2 - Padrões para levantamentos hidrográficos.....	21
TABELA 3 - Coeficientes de correlação encontrados pela comparação do resultado alcançado pelo método de vizinho natural aplicado as diferentes densidades e a verdade de campo, desvio padrão e variância dos erros obtidos pelo método de vizinho natural.....	52
TABELA 4 - Coeficientes de correlação encontrados pela comparação do resultado alcançado pelo método de krigagem aplicado as diferentes densidades e a verdade de campo, desvio padrão e variância dos erros obtidos pelo método de krigagem.	57
TABELA 5 - Coeficientes de correlação encontrados pela comparação do resultado alcançado pelo método de triangulação aplicado as diferentes densidades e a verdade de campo, desvio padrão e variância dos erros obtidos pelo método de triangulação.	61
TABELA 6 - Coeficientes das funções polinomiais biquadráticas ajustadas com 5%, 10%, 20%, 30%, 40%, 60% e 80%.....	65
TABELA 7 - Coeficientes das funções polinomiais bicúbicas ajustadas com 5%, 10%, 20%, 30%, 40%, 60% e 80%.	65
TABELA 8 - Coeficientes das funções polinomiais biquárticas ajustadas com 5%, 10%, 20%, 30%, 40%, 60% e 80%.	66
TABELA 9 - Coeficientes de correlação encontrados pela comparação do resultado atingido pelo método de aproximação polinomial com função biquadrática ajustando 5%, 10%, 20%, 30%, 40%, 60% e 80% e a verdade de campo.....	66
TABELA 10 - Coeficientes de correlação encontrados pela comparação do resultado atingido pelo método de aproximação polinomial com função bicúbica ajustando 5%, 10%, 20%, 30%, 40%, 60% e 80% e a verdade de campo.....	66
TABELA 11 - Coeficientes de correlação encontrados pela comparação do resultado atingido pelo método de aproximação polinomial com função biquártica ajustando 5%, 10%, 20%, 30%, 40%, 60% e 80% e a verdade de campo.....	66
TABELA 12 - Coeficientes de correlação obtidos pela aplicação de diferentes topologias de rede e métodos de aprendizado utilizando a função de transferencia Purelin.	68
TABELA 13 - Coeficientes de correlação obtidos pela aplicação de diferentes topologias de rede e métodos de aprendizado utilizando a função de transferencia Logsig.	68
TABELA 14 - Coeficientes de correlação obtidos pela aplicação de diferentes topologias de rede e métodos de aprendizado utilizando a função de transferencia Tansig.....	68
TABELA 15 - Coeficientes de correlação obtidos pela aplicação de RNA com método de aprendizado LM e diferentes taxas de aprendizagem.	69
TABELA 16 - Coeficientes de correlação obtidos pela aplicação de RNA com método de aprendizado LM e diferentes taxas de aprendizagem.	69
Tabela 17 - Coeficientes de correlação obtidos pela aplicação de diferentes métodos de aprendizado e taxas de aprendizagem.	74
Tabela 18 - Desvio padrão e variâncias dos testes com redes neurais artificiais que apresentaram maior coeficiente de correlação para as redes treinadas com diferentes densidade de dados de entrada.....	78

TABELA 19 - Coeficientes de correlação encontrados pela comparação dos resultados obtidos com os métodos de redes neurais que foram utilizados no teste da área de possível escassez de informação e a verdade de campo.....	84
--	----

SUMÁRIO

1 INTRODUÇÃO	11
2 OBJETIVO GERAL E ESPECÍFICO	14
2.1 OBJETIVO GERAL.	14
2.2 OBJETIVO ESPECÍFICO	14
3 REVISÃO DA LITERATURA	15
3.1 LEVANTAMENTOS GEODÉSICOS.....	15
3.1.1 Sistema de Posicionamento Global.....	15
3.1.2 Métodos de posicionamento	17
3.2 LEVANTAMENTOS HIDROGRÁFICOS	19
3.2.1 Padrões mínimos de qualidade	20
3.2.2 Equipamentos e obtenção de profundidades.....	21
3.2.3 Datum altimétrico, redução batimétrica e níveis de referência	23
3.3 INTEGRAÇÃO CONTINENTE – OCEANO	25
3.4 MODELOS DIGITAIS DE TERRENO.....	28
3.5 MÉTODOS DE INTERPOLAÇÃO	29
3.5.1 Triangulação e vizinho natural	29
3.5.2 Krigagem.....	30
3.5.3 Superfície de aproximação polinomial.....	31
3.6 REDES NEURAIIS ARTIFICIAIS.....	32
3.6.1 O neurônio artificial	35
3.6.2 Topologias da rede	36
3.6.3 Aprendizado	38
4 MATERIAIS E MÉTODOS	41
4.1 ÁREA DE ESTUDO	41
4.2 MATERIAIS.....	42
4.3 MÉTODOS.....	42
4.3.1 Levantamentos.....	42
4.3.2 Métodos de interpolação, redes neurais artificiais e avaliação.....	48
4.3.3 Aplicação dos métodos de estimativa de altitude para área de possível escassez de informação	51
5 RESULTADOS E DISCUSSÃO	52
5.1 VIZINHO NATURAL	52
5.2 KRIGAGEM	56
5.3 TRIANGULAÇÃO.....	61

5.4 SUPERFICIE DE APROXIMAÇÃO POLINOMIAL	65
5.5 REDES NEURAS ARTIFICIAIS.....	67
5.6 COMPORAÇÃO DOS MÉTODOS DE ESTIMATIVA.....	79
5.7 APLICAÇÃO DOS MÉTODOS DE ESTIMATIVA DE ALTITUDE PARA ÁREA DE POSSÍVEL ESCASSEZ DE INFORMAÇÃO	80
6 CONCLUSÃO	87
REFERÊNCIAS	89

1 INTRODUÇÃO

O constante desenvolvimento econômico das regiões costeiras cada vez mais é alvo de estudos espaciais que envolvem a coleta de dados em campo e a elaboração de produtos cartográficos. Os produtos cartográficos são utilizados em diversos estudos, sejam eles ambientais, geofísicos, oceanográficos, entre outros, e ainda em obras costeiras como na construção de portos ou instalações portuárias, marinas, pontes, molhes, dutos submarinos, alimentação de praias dentre outras obras de engenharia costeira. Seja qual for o objetivo ou a natureza do produto cartográfico que se deseja elaborar, o relevo normalmente é parte indispensável deste.

Na representação cartográfica, o relevo pode ser ilustrado por uma reprodução digital: os modelos digitais de terreno (MDT). A geração do MDT é feita aplicando métodos de interpolação sobre dados tridimensionais (latitude, longitude e altitude) amostrados no terreno. Os métodos de interpolação estimam valores de altitude em locais não amostrados a partir de medições tridimensionais feitas em pontos na mesma região. Sendo assim, é comum que os trabalhos tenham início com o levantamento dessas informações tridimensionais na área de estudo. No caso da representação da região que faz interface entre o oceano e o continente, se faz necessária a coleta das informações nessas duas porções e estas informações provêm de diferentes métodos de levantamentos. Na porção emersa usam-se níveis topográficos, estações totais ou o Sistema de Posicionamento Global (GPS). Na parte submersa, é comum o uso de ecobatímetros acoplados a embarcações; neste caso é comum a utilização de um GPS associado ao ecobatímetro para fornecer as coordenadas geodésicas planimétricas do ponto amostrado.

O sucesso da representação cartográfica de uma região costeira poderia então ser garantido de posse de todos os equipamentos adequados para a coleta de informações tridimensionais, não fosse a dificuldade na observação de informações na área de interface entre oceano e continente. A dificuldade de coleta de informações nessas regiões se deve ao acesso restrito ou ainda a ação da hidrodinâmica local. Em praias, por exemplo, as regiões de difícil acesso normalmente se localizam numa porção da praia denominada antepraia, mesma região onde ocorre o processo de empolamento da onda até sua quebra, compreendendo assim as chamadas zonas de surfe e arrebentação. Muehe (2004) aponta em seu trabalho problemas de coleta de informação afirmando que a intensa atividade hidrodinâmica na antepraia associada à dissipação de energia das ondas faz dessa zona um objeto de estudo complexo e de difícil observação devido ao risco para embarcação e, na zona de surfe, ao portador da mira, exigindo prudência, habilidade e disponibilidade de tempo e embarcação para realização dos trabalhos no momento em que as condições oceanográficas se tornarem propícias.

Levantou-se a hipótese que os métodos capazes de estimar valores de altitude podem contribuir para a solução do problema de coleta de informações nas regiões de difícil acesso. Poder-se-ia utilizar métodos conhecidos de interpolação, como os métodos de vizinho natural, krigagem, triangulação, regressão polinomial, entre outros. Esses métodos já foram por diversas vezes estudados e suas limitações são conhecidas. Como por exemplo, em áreas de relevo acidentado não se deve utilizar modelos de interpolação que tende a suavização, como é o caso das superfícies de aproximação por regressão polinomial. Este método tende a suavização pois modela a variação espacial em larga escala, negligenciando a variabilidade local e podendo por isso criar um modelo não realista da área de estudo. Em contrapartida, os modelos que se baseiam restritamente nas variabilidades locais podem não ser eficientes para generalizar informações nas regiões onde estas são escassas, como é o caso.

Diante disso, pensou-se em um método que fosse capaz de estimar valores de altitude superando os problemas encontrados pelos métodos de interpolação consagrados. Seria interessante a escolha de um método de estimativa que pudesse se adaptar à diferenças abruptas de densidade, pois este trabalho pretende trabalhar com a escassez de informações em um região específica, as demais regiões provavelmente terão abundância de dados. Seria pertinente que o método de estimativa reconhecesse as características de um determinado local e os padrões de uma determinada região, como a declividade por exemplo, e conseguisse transferir esse conhecimento para a área de escassez de informação.

Por isso se pensou nas redes neurais artificiais (RNA). Este método é capaz de reconhecer padrões e talvez seja capaz de estimar valores de altitude numa região de escassez de informações, baseando-se em duas regiões adjacentes com abundância delas. As redes neurais artificiais podem ser capazes de fornecer um modelo que defina forma da área de estudo e que, quando se deseja obter um valor da cota em diferentes pontos, basta entrar com as coordenadas geodésicas do ponto nas entradas da RNA e sua saída fornecerá o valor. Espera-se uma resposta mais realista quando se deseja saber o valor da grandeza em pontos não levantados.

Porém, para verificar se os métodos produzem estimativas realistas é necessária a coleta de informações nas regiões críticas no que tange aos levantamentos. Por esse motivo se faz necessária a escolha por uma região de águas calmas e profundidades rasas, além disso, é importante que os levantamentos sejam programados para acontecer seguindo os períodos de maré de sizígia e livre de ação das ondas. Por isso, a área escolhida foi o Saco do Limoeiro, um depósito sedimentar subaquático que foi interpretado por Angulo (1999) como sendo um hemi-delta de maré enchente. Deltas de maré enchente (*flood-tidal deltas*) são formados por sedimentos depositados por correntes de maré enchente junto a desembocaduras no interior de estuários (ARAÚJO, 2001).

Este trabalho organiza-se em Introdução, Revisão da Literatura, Materiais e Métodos, Resultados e Discussão, Conclusão e Referências. Na Introdução o problema central do trabalho é apresentado e algumas hipóteses são levantadas com o intuito de solucionar esse problema. Na Revisão da Literatura são explicados os fundamentos que embasaram as hipóteses levantadas no capítulo da Introdução e que tornaram a realização desse trabalho possível. No capítulo de Materiais e Métodos estão apresentados os materiais utilizados durante a execução do trabalho bem como a sequência de eventos efetuados. Esta sequência de eventos produziram resultados que foram apresentados e discutidos no capítulo Resultados e Discussão. As conclusões desse trabalho são apresentadas ao final, no capítulo Conclusão. Este ainda é seguido por um capítulo Referência que apresenta a bibliografia das fontes utilizadas nesse documento.

2 OBJETIVO GERAL E ESPECÍFICO

2.1 OBJETIVO GERAL

- Modelar matematicamente a variação do fundo na região de interface oceano e continente, no caso da porção emersa não estar unida ou sobreposta a porção submersa em decorrência da escassez de informação nessas regiões.

2.2 OBJETIVO ESPECÍFICO

- Analisar métodos de estimativa aplicados a previsão de valores de altitude.
- Analisar se os métodos de estimativa podem ser utilizados na previsão de valores de altitude na região de escassez de informação.
- Analisar se as redes neurais artificiais apresentam estimativas mais realistas em comparação com os demais métodos.

3 REVISÃO DA LITERATURA

3.1 LEVANTAMENTOS GEODÉSICOS

3.1.1 Sistema de Posicionamento Global

O Sistema de Posicionamento Global (GPS), desenvolvido pelo Departamento de Defesa dos Estados Unidos da América – DoD (*Department of Defense*), é um sistema de rádio-navegação que visa não só a determinação de coordenadas tridimensionais, mas também do tempo, da velocidade e da direção num sistema de referência.

O sistema de referência utilizado no posicionamento GPS é um sistema global, geométrico, geocêntrico (com origem no centro de massa da Terra) e equipotencial (potencial gravítico é o mesmo em qualquer ponto da superfície), denominado WGS-84 (*World Geodetic System 1984*). Neste sistema todos os eixos passam pelo centro da terra e o eixo Z positivo está orientado para o pólo Norte e o eixo X positivo passa pelo ponto vernal, ou primeiro ponto da constelação Áries, que coincide com a linha do equador. O eixo Y, que também passa pela linha do equador, completa o sistema seguindo a regra da mão direita (SEEBER, 2003). Este sistema está associado a um elipsóide de revolução geocêntrico GRS-80, cujos parâmetros que o definem são o semi-eixo maior e o achatamento.

O princípio fundamental de funcionamento do GPS é baseado na triangulação, para isso se determinam as distâncias do receptor aos satélites, as chamadas pseudodistâncias. Os satélites enviam sinais eletromagnéticos na frequência das ondas de rádio, que são captados pelo receptor. Pelo tempo de propagação do sinal e pela sua velocidade é possível determinar as pseudodistâncias.

A Figura 1 apresenta a geometria para a determinação da posição de um Ponto R situado na superfície da Terra em relação a um sistema de referência euclidiano. As coordenadas dos satélites envolvidos na determinação das pseudodistâncias são conhecidas e estas são enviadas ao receptor do usuário pelo próprio satélite através das efemérides transmitidas. A partir das coordenadas de um satélite n é possível determinar as distâncias \overline{SnO} do satélite até a origem O do sistema de referência.

Mediante as observações que o receptor instalado no ponto R realiza pode-se determinar as pseudodistâncias \overline{SnR} . A distância desconhecida é a distância \overline{OR} da origem O do sistema ao receptor e a partir dela é possível calcular a coordenada geodésica do Ponto R .

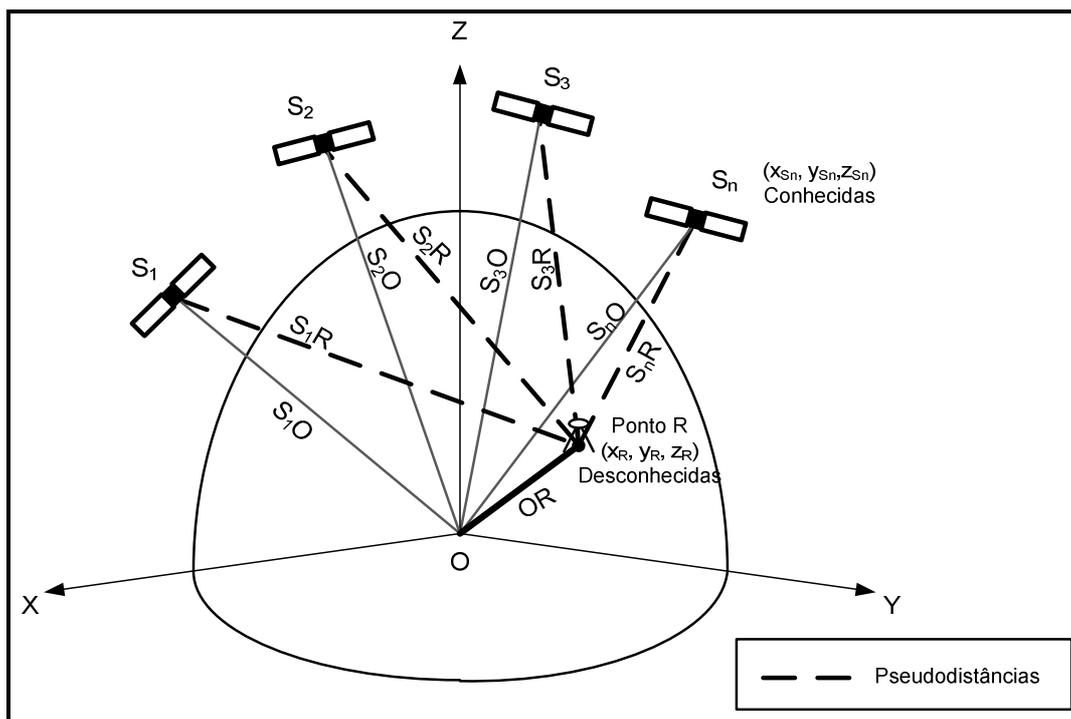


FIGURA 1 - Geometria para a determinação da posição do sistema GPS.

A coordenada geodésica do ponto R (latitude, longitude, altitude geométrica) é determinada mediante três equações de distância que estabelecem uma relação entre as observações de pseudodistâncias $\overline{S_n R}$, os parâmetros descritos pela posição dos satélites e a localização da estação de observação R. A relação entre eles é dada pela equação fundamental apresentada na Equação 1.1:

$$\overline{S_n O} = \overline{S_n R} + \overline{R O} \quad (1)$$

Do ponto de vista geométrico, apenas três medidas de distância seriam necessárias para a resolução do sistema de equações. Porém, uma quarta observação é indispensável porque o GPS realiza a determinação de distância por um caminho, sendo que o relógio do receptor não é sincronizado com o relógio do satélite. As informações do sistema de tempo dos satélites são enviadas ao receptor, juntamente com a posição dos satélites, pelas efemérides transmitidas. Esse erro de sincronização entre os relógios é a razão principal para o uso do termo pseudodistância. Com a aplicação do método dos mínimos quadrados (MMQ), é possível resolver o sistema com três incógnitas e quatro equações.

O rastreamento simultâneo de no mínimo quatro satélites acima do horizonte é disponibilizado pelo sistema GPS 24 horas por dia, em qualquer parte do mundo, independente das condições meteorológicas. O sistema é composto por uma constelação básica de 24 satélites dispostos em 6 planos orbitais quase circulares com uma inclinação orbital de 55° (SEEBER, 2003), contendo 4 satélites em cada plano defasados em 90° , a altura orbital média é de 20.200km e o período de 12 horas.

A constelação de satélites corresponde ao segmento espacial, além deste, o sistema GPS é constituído também pelos segmentos de controle e do usuário. O segmento de controle é composto por uma estação de controle central – MCS (Master Control Station), estações de monitoramento em todo o mundo – MS (Monitor Station) com antenas que enviam dados aos satélites – GA (Ground Antennas) (SEEBER, 2003; HOFMANN-WELLNHOF et. al., 1994). As funções desse segmento são (SEEBER, 2003):

- Monitorar e controlar o sistema continuamente,
- Determinar o sistema de tempo GPS,
- Predizer as efemérides e o comportamento dos relógios dos satélites,
- Atualizar periodicamente as mensagens de navegação para cada satélite,
- Comandar pequenas manobras para manter a órbita do satélite ou realocá-lo para substituir por outro.

O segmento de usuários é constituído por todos aqueles que utilizam o sistema, civis ou militares, incluindo muitos tipos de receptores (HOFMANN-WELLNHOF et. al., 1994).

3.1.2 Métodos de posicionamento

Os métodos de posicionamento se dividem classicamente em absoluto, relativo e diferencial.

O método absoluto caracteriza-se pela adoção de apenas um receptor para determinação das coordenadas geodésicas de um ponto sobre a superfície terrestre. Este posicionamento pode ser realizado por meio das técnicas estáticas, com a antena GPS parada em um ponto, ou cinemática, com a antena GPS em movimento.

O posicionamento relativo caracteriza-se pela observação simultânea dos sinais de pelo menos 4 satélites em pelo menos duas estações distintas, tomando uma como ponto base de coordenadas conhecidas e outra como estação itinerante ou incógnita. Nesta situação os erros referentes ao relógio serão minimizados podendo chegar a serem eliminados se a linha de base for curta (menor que 1km). O método relativo subdivide-se em: estático, estático rápido com uma ocupação, estático rápido com reocupação, cinemático, stop and go, e pseudocinemático. Nos métodos estático, estático rápido com uma ocupação, estático rápido com reocupação onde a antena se encontra estacionária e nos métodos cinemático, stop and go, e pseudocinemático no qual a antena está em movimento.

O posicionamento diferencial é muito semelhante ao relativo. Consiste no posicionamento de uma estação móvel através das correções diferenciais geradas na

estação de referência. Porém, as correções geradas na estação de referência são enviadas em tempo real por meio de um sistema de comunicação que pode ser rádio de transmissão, linha telefônica ou satélites de comunicação no formato RTCM (FIGURA 2).

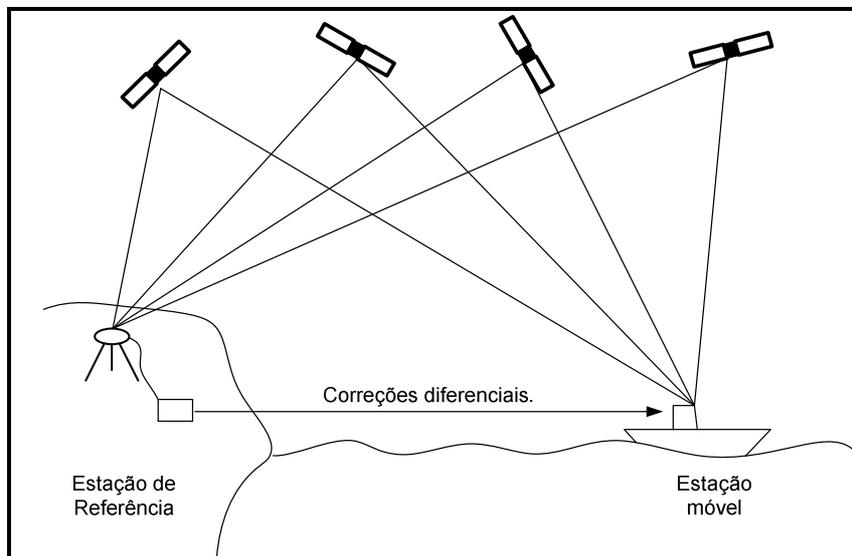


FIGURA 2 - Método de Posicionamento DGPS. Fonte: Adaptada de SEEBER, 1993.

A precisão do posicionamento varia de acordo com o método empregado. O método absoluto subdivide-se de acordo com a precisão em: absoluto convencional, absoluto preciso e de alta precisão. No convencional tem-se precisão de 13 a 25m. Essa precisão pode ser melhorada com o método absoluto preciso. Este método utiliza as efemérides precisas e correções dos relógios dos satélites, obtendo assim coordenadas pós-processadas com precisão de 1 m, ou melhor. No posicionamento absoluto de alta precisão é imprescindível a utilização de receptores de dupla frequência. No posicionamento absoluto em geral, o tempo de permanência sobre um ponto não ocasiona uma melhora significativa na qualidade dos resultados como acontece no posicionamento relativo.

No posicionamento relativo, o tempo de permanência varia de acordo com a distância em que se encontram a estação base e a estação itinerante, essa distância é chamada de linha de base. A precisão do método relativo, bem como o tempo de permanência em cada ponto para determinados comprimentos de linhas de base, depende de qual técnica do método relativo foi utilizada. Estas informações podem ser observadas na tabela 1.

TABELA 1- Precisão atingida por diferentes métodos de posicionamento GPS relativo.

Técnicas	Período de ocupação	Precisão
Estático: Linha de base menor que 10km. Linha de base maior que 10km. (com L1 e L2)	Mínimo 1h. 6 – 24 hrs.	1,5 – 5 mm + (0,01 – 1 ppm) 1,5 – 5 mm + (0,01 – 1 ppm)
Estático rápido: Linha de base menor que 5 km. Linha de base menor que 15 km (com L1 e L2).	5 – 8 min. 5 – 20 min.	5 – 20 mm + (1 ppm) 5 – 20 mm + (1 ppm)
Pseudocinemático	1 – 5min.	Poucos centímetros.
Cinemático contínuo	Contínuo.	10 cm – 1m.
Stop and GO	Aproximadamente 1 min.	Poucos centímetros.

No método diferencial, as precisões encontradas variam de 10m a centímetros. Porém, nesse método, além da linha de base, das observáveis empregadas e do cálculo das correções diferenciais, irão influenciar também na precisão a qualidade do sistema de comunicação e a taxa de atualização e transferência de dados (KRUEGER, 1996).

3.2 LEVANTAMENTOS HIDROGRÁFICOS

De acordo com a Portaria 121/MB/2003 por Levantamento Hidrográfico (LH) se entende o conjunto de atividades executadas na obtenção de dados batimétricos, geológicos, maregráficos, fluviométricos, topo-geodésicos, oceanográficos e geofísicos, em áreas marítimas, fluviais, lacustres e em canais naturais ou artificiais, navegáveis ou não, que não tenham como finalidade a pesquisa e a investigação científica, de que trata o Decreto nº 96.000, de 2 de maio de 1988.

Os levantamentos hidrográficos realizados no território nacional ou em Águas Jurisdicionais Brasileiras, por entidades extra Marinha, devem obedecer às instruções determinadas pela Marinha do Brasil. Tais instruções tem por finalidade estabelecer normas para a execução de levantamento hidrográficos por órgãos públicos da Administração Central, ou pelas autarquias e entidades paraestatais e federais. A intenção de execução de levantamentos hidrográficos por algum desses órgãos deve ser levada ao conhecimento do Ministério da Marinha para que esta possa autorizar os levantamentos e controlá-los.

3.2.1 Padrões mínimos de qualidade

A Diretoria de Hidrografia e Navegação (DHN), órgão da Marinha do Brasil incumbido de exercer o controle de sobre qualquer levantamento hidrográfico em Águas Jurisdicionais Brasileiras, adota padrões de qualidade recomendados pela IHO (International Hydrographic Organization).

De acordo com a precisão requerida o IHO (2008) subdivide os levantamentos hidrográficos em quatro tipos:

- Ordem Especial: Esta é a mais rigorosa das ordens. Sua utilização destina-se apenas para regiões onde a separação entre a quilha da embarcação e o fundo marinho é mínima. Por isso se faz necessário uma investigação completa do fundo e as feições a serem detectadas por esse levantamento devem ser pequenas. Por destinar-se apenas para regiões onde a folga sob a quilha é mínima, é improvável que levantamentos de Ordem Especial serão conduzidos em águas mais profundas do que 40 m. Exemplos de áreas que se justifica um levantamento de Ordem Especial: áreas de atracação, portos e áreas críticas em canais de transporte marítimo.
- Ordem 1a: Esta Ordem destina-se as regiões onde o mar é suficientemente raso para permitir que feições naturais ou antrópicas no fundo do mar possa ser uma preocupação para o tráfego marinho, mas onde a separação quilha-fundo é maior comparada a Ordem Especial. Nessas regiões se faz necessário uma investigação completa do fundo, porém o tamanho da característica a ser detectada nesta Ordem é maior que as detectadas na Ordem Especial. Estes levantamentos devem ser realizados em áreas com menos de 100 m de profundidade.
- Ordem 1b: Esta ordem é apropriada para áreas menos profundas que 100m, onde uma descrição geral do fundo marinho é adequada para o tipo de embarcação que se espera transitar por tal região. Não se requer uma busca completa do fundo marinho, o que significa que algumas feições podem ser perdidas. Esta Ordem é recomendada somente onde a separação quilha-fundo não é considerada problema. Um exemplo seria uma área onde as feições características do fundo apresentem baixa probabilidade de perigo para a navegação.
- Ordem 2: Esta é a menos rígida das Ordens e se destina para áreas onde a profundidade é somente uma descrição geral do fundo. Não se requer uma busca completa do fundo marinho. Recomenda-se que estes levantamentos se limitem a áreas mais profundas que 100m. Admite-se que se a profundidade excede os 100m é improvável a existência de feições suficientemente grandes para afetar a navegação.

Cada classe tem seus padrões especificados de acordo com a tabela 2. Isso garante que os dados coletados seguindo esses padrões são suficientemente precisos e tem suas incertezas quantificadas, possibilitando seu uso seguro na navegação.

TABELA 2 - Padrões para levantamentos hidrográficos.

Ordem	Especial	1ª	1b	2
Acurácia horizontal.	2m	5m + 5% da profundidade	5m + 5% da profundidade	20m + 10% da profundidade
Acurácia para Profundidades Reduzidas	a= 0,25m b= 0,0075	a= 0,5m b= 0,013	a= 0,5m b= 0,013	a= 1,00m b= 0,023
Pesquisa completa do fundo.	Requerida.	Requerida.	Não requerida.	Não requerida.
Detecção de feições.	Feições cúbicas maiores que 1m.	Feições cúbicas maiores que 2m em profundidades acima de 40m; 10% da profundidade abaixo de 40m.	Não aplicável.	Não aplicável.

Fonte: Adaptado de IHO, 2008.

3.2.2 Equipamentos e obtenção de profundidades

Os equipamentos e métodos utilizados para a medição de profundidades são função da ordem do levantamento (exatidão e profundidade média) e da obrigatoriedade da cobertura total do fundo (MARREIROS & ARTILHEIRO, 1999). Para a medição de profundidades utiliza-se o ecobatímetro (sonar acústico), que pode ser de feixe simples ou multifeixe, ou ainda o sonar de varredura lateral.

O ecobatímetro de feixe simples efetua medição contínua de profundidades em perfis. A superfície coberta por este equipamento é uma função da abertura angular do feixe acústico (normalmente os sondadores acústicos apresentam aberturas de feixe entre 6º e 14º).

O ecobatímetro multifeixe obtém as profundidades sobre uma faixa e não somente ao longo da linha de sondagem, obtendo uma grande quantidade de profundidades, cobrindo o leito submarino e garantindo que todos os perigos sejam encontrados e delimitados, melhorando a qualidade das informações representadas na carta náutica (site dhn). A largura da faixa sondada varia de equipamento para equipamento, mas a abertura angular do feixe pode ultrapassar os 90°. O sondador multifeixe permite efetuar a

cobertura total do fundo desde que seja garantida a sobreposição entre faixas adjacentes.

A sondagem por varredura lateral é realizada por meio de um equipamento rebocado (peixe), em conjunto com o ecobatímetro multifeixe, instalado no casco ou na borda de uma embarcação. Este equipamento efetua o registro de intensidade do sinal acústico e gera uma imagem de elevada resolução, permitindo a realização de Levantamentos Hidrográficos de Ordem Especial, onde é garantida a cobertura total do fundo (100 %). No entanto, as posições das informações contidas na imagem sonar não estão geometricamente corrigidas, ao contrário dos dados adquiridos com o ecobatímetro multifeixe, que produz dados geometricamente corretos.

Genericamente, o princípio de funcionamento consiste na medição do intervalo de tempo entre a transmissão de um impulso acústico e a sua detecção após reflexão no fundo (FIGURA 3). Para o cálculo da profundidade é necessário o conhecimento da velocidade de propagação do impulso na água, que pode variar aproximadamente de 1.420m/s a 1.580m/s, dependendo da temperatura, salinidade e, em baixas temperaturas, da pressão (EBERLE, 1994, *apud* TEDESCO, 2003). Conhecendo a velocidade média a profundidade é obtida através de:

$$d = c_m * \frac{\Delta t}{2} \quad (2)$$

Onde d é a profundidade, c_m a velocidade média de propagação do som na água e Δt o intervalo de tempo do duplo trajeto do impulso acústico entre o transdutor e o fundo. O transdutor é o equipamento básico de um ecobatímetro que transforma energia elétrica em energia sonora, que é transmitida através da água, e converte o eco recebido em energia elétrica.

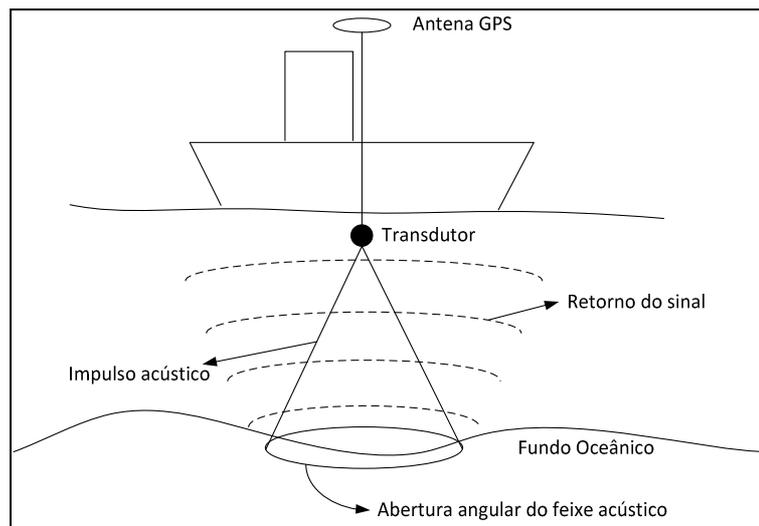


FIGURA 3 - Princípio de funcionamento do ecobatímetro.

Antes de cada levantamento, faz-se necessária a calibração do ecobatímetro visando à obtenção de medidas acuradas de profundidades. Para tal, utiliza-se um disco de calibração, que pode ser um disco de 30 a 40cm de diâmetro, suspenso por um cabo/corda graduado. Deve-se abaixar o disco em linha reta, alinhado com o centro do transdutor, em várias profundidades, observando a profundidade no cabo graduado e a profundidade detectada pelo aparelho. A calibração deve ser realizada, no mínimo, até 70% da profundidade máxima. Através desta pode-se então ajustar os parâmetros de velocidade do som e sensibilidade do fundo (TEDESCO, 2003).

3.2.3 Datum altimétrico, redução batimétrica e níveis de referência.

Os levantamentos batimétricos utilizam como datum altimétrico, ou vertical, o Nível Médio dos Mares (NM ou MSL do inglês Mean Sea Level), diferente do sistema GPS que utiliza o elipsóide. Isso porque a coleta dos dados batimétricos está relacionada ao nível do mar. O NM corresponde à altura média da superfície do mar considerando todos os estágios de oscilação da maré, baseado em observações de séries temporais de alturas de marés, tomadas em uma Estação Maregráfica, por um período de 19 anos, em uma determinada região.

Os instrumentos utilizados para registro das alturas do nível do mar instantâneas são os marégrafos. Este instrumento registra analógica ou digitalmente as oscilações do nível do mar em um determinado ponto da costa. Os marégrafos podem ser acústicos, de pressão e de radar (IOC, 2006). O registro produzido, sob a forma de gráfico, denomina-se maregrama.

O NM corresponde à elevação zero e essa pode variar de local para local, isso porque a medição dos níveis do mar esta sujeita aos padrões de maré característicos de uma determinada área. As marés se alteram em resposta as mudanças nas forças

gravitacionais, que são decorrentes da mudança na posição do sol e da lua em relação à Terra. As marés geradas pelas forças resultante do alinhamento sol, lua e Terra são chamadas de marés astronômicas, que provocam variações periódicas nos níveis dos mares. Existe ainda a maré meteorológica, que é gerada pela ação dos ventos, temperatura e pressão atmosférica, e provoca efeitos de maré associados a eventos meteorológicos.

Com a determinação do datum vertical local é possível referenciar os levantamentos batimétricos a ele. Porém, como o nível de maré no instante da coleta de dados é considerado, é necessário conhecer qual a altura da maré nesse instante, para que esse seja corrigido. Essa correção corresponde à redução batimétrica que elimina os efeitos da maré instantânea, permitindo que as profundidades obtidas sejam referenciadas ao nível médio do mar, ou a outros níveis relacionados a ele.

Existem outros níveis de referência associados ao nível do mar além do NM, como pode ser observado na figura 4. Todos esses níveis são deduzidos a partir de observações do nível do mar ao longo de vários anos. A escolha por um nível de referência mais adequado depende da finalidade.

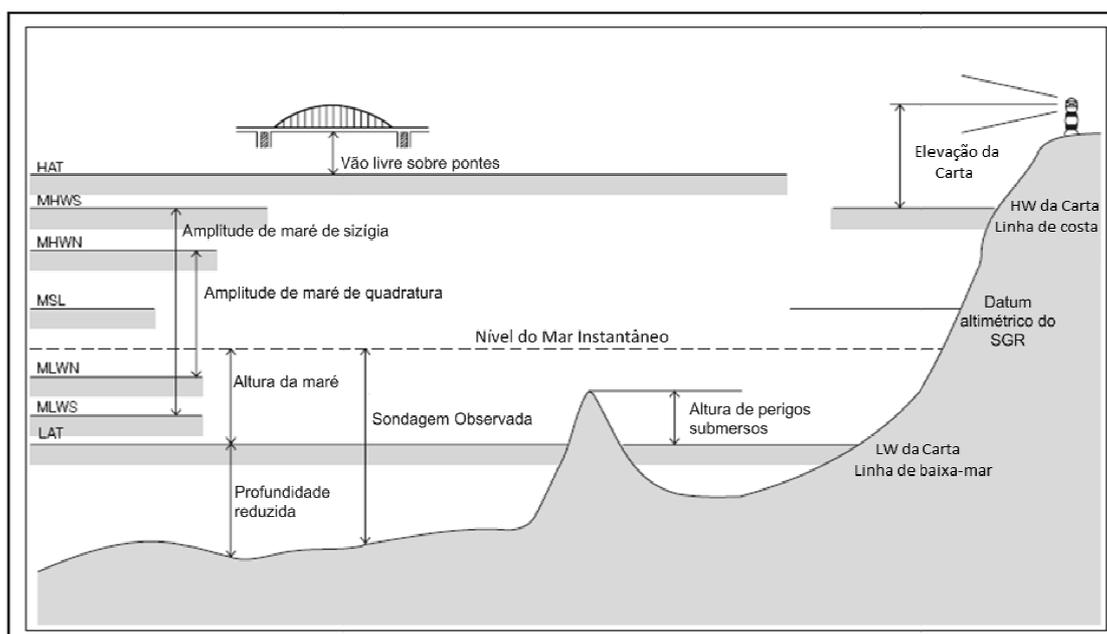


FIGURA 4 - Níveis de referência altimétricos. Fonte: Adaptado de IHO ,2009.

O HAT (Highest Astronomical Tide) e o LAT (Lowest Astronomical Tide) são definidos como o nível de maré mais alto e mais baixo, respectivamente, previstos para ocorrer sob condições meteorológicas médias e quaisquer combinações de condições astronômicas. HAT e LAT não são níveis extremos, certas condições meteorológicas podem causar um maior ou menor nível, respectivamente. O LAT e o HAT foram adotados pelo IHO como planos de referência padrão internacional,

visando à padronização mundial. O HAT pode ser utilizado para a determinação de altura de pontes e linhas de transmissão, garantindo que estes não fiquem submersos durante períodos de maré cheia. O LAT pode ser utilizado como Nível de Redução (NR) de cartas náuticas. O NR corresponde a um plano abaixo do NM, a adoção desse nível permite que profundidades mínimas encontradas na região sejam representadas nas cartas náuticas, garantindo que profundidades menores que as representadas na carta não serão encontradas no local durante a navegação, somente profundidades maiores, devido os efeitos de maré.

MHWN (*Mean High Water Neaps*) e MLWN (*Mean Low Water Neaps*) correspondem, respectivamente, as médias de preamar e baixa-mar de quadratura, deduzidas de uma longa série de observações, das alturas de preamar e baixa-mar de quadratura. MHWS (*Mean High Water Springs*) e MLWS (*Mean Low Water Springs*) correspondem às médias de preamar e baixa-mar de sizígia, deduzidas de uma longa série de observações das alturas de preamar e baixa-mar de sizígia. As marés de sizígia acontecem durante as luas nova e cheia, quando o sol e a lua estão do mesmo lado em relação à Terra, ou diametralmente opostos, e têm somados seus efeitos de atração gerando as mais altas e mais baixas marés. MLWS é o nível adotado pela DHN como NR nas Cartas Náuticas brasileiras.

3.3 INTEGRAÇÃO CONTINENTE – OCEANO

Os métodos de levantamentos topográficos e de posicionamento global, como o GPS, estão associados a um elipsóide de revolução e a altitude é medida a partir desse elipsóide. Já os levantamentos batimétricos utilizam o nível médio dos mares como referencial altimétrico.

A superfície dos oceanos, que cobre 70% da superfície terrestre, descreve outro modelo da Terra, o modelo físico (e não geométrico) denominado de geóide. Diferente do elipsóide de referência, o geóide tem a superfície irregular, que se aproxima da superfície topográfica da Terra. Tanto o geóide como o elipsóide não coincidem com a real superfície da Terra (FIGURA 5), mas o geóide está mais próximo desta que o elipsóide porque a força da gravidade atua de maneira diferente ao longo da superfície terrestre, devido principalmente a distribuição irregular de massas do planeta.

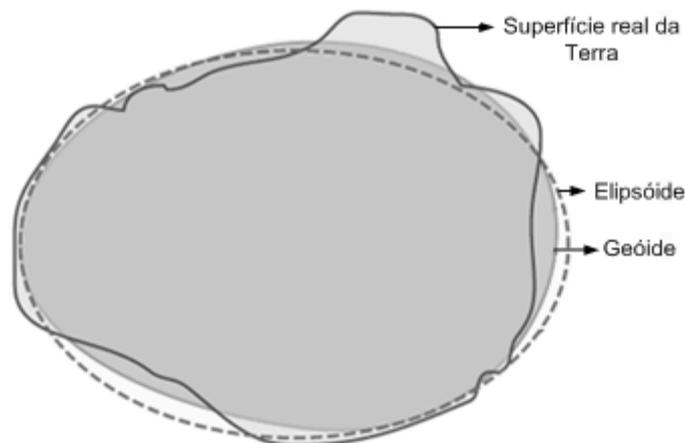


FIGURA 5 - Representação real da Terra, representação geométrica (elipsóide), representação física (geóide). Fonte: FRACZEK, 2003.

A força gravitacional que atua ao redor de qualquer corpo de massa gera um campo gravitacional em torno dele, sendo assim, a força gravitacional que atua ao redor da Terra gera o campo gravitacional terrestre. Um campo gravitacional só é percebido se grandes aglomerações de matéria são consideradas, como o sol, a Terra e a lua. Quando se considera corpos de pouca massa seu campo gravitacional não é percebido porque a força da gravidade é pequena.

O campo gravitacional terrestre pode ser subdividido em diversas camadas ou superfícies contínuas, sendo estas formadas por pontos no espaço que possuem o mesmo valor de força gravitacional. Estas superfícies são chamadas de superfícies equipotenciais ou geopotenciais (FIGURA 6). Estas superfícies são intersectadas perpendicularmente por linhas de prumo que descrevem a direção da gravidade em um determinado ponto da superfície equipotencial.

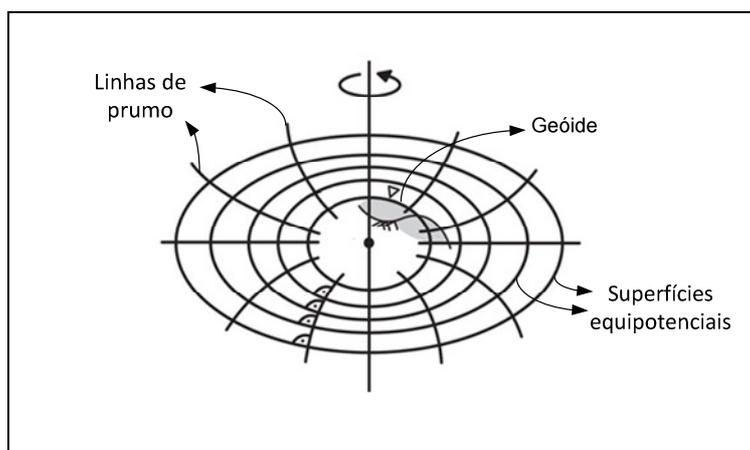


FIGURA 6 - O geóide e outras superfícies equipotenciais com as linhas de prumo perpendiculares a cada superfície equipotencial. Fonte: TORGE, 1991.

Assim, o geóide é uma superfície equipotencial do campo gravitacional terrestre que coincide, em média, com o NM e se estende também pelos continentes. Essa definição negligencia perturbações que acontecem na superfície oceânica (TORGE, 2001, p.3). As perturbações são resultado das mudanças no campo gravitacional terrestre. Estas mudanças acontecem porque as forças gravitacionais da lua, do sol e da Terra mudam de acordo com a posição que estes se encontram. Essas perturbações podem ocorrer periodicamente, como no caso das marés, ou associado a algum evento, de tempestade por exemplo, e podem acontecer a nível global, regional ou local.

O geóide é utilizado como sistema de referência vertical para os levantamentos batimétricos, enquanto que o GPS utiliza o elipsóide. Quando áreas adjacentes, de interface continente-oceano, são levantadas utilizando ambos os métodos é necessária a padronização dos dados para que estes sejam apresentados em uma única representação cartográfica.

Para que os dados sejam padronizados em um único sistema de referência se faz necessária a transformação de um sistema para o outro. Porém, nem sempre os parâmetros de transformação são conhecidos. Nos sistemas de referência verticais é necessário conhecer a diferença de altura entre o geóide e o elipsóide (FIGURA 7), essa altura é denominada altura geoidal N . Conhecendo-se essa altura é possível adotar um único sistema de referência, empregando a seguinte fórmula no conjunto de dados que se deseja transformar:

$$h = H + N \quad (3)$$

A altura entre o geóide e a superfície da Terra é conhecida por altitude ortométrica H , a altitude entre o elipsóide e a superfície da terra é a altitude elipsoidal h . É possível transformar os dados referenciados no elipsóide para o geóide e vice versa.

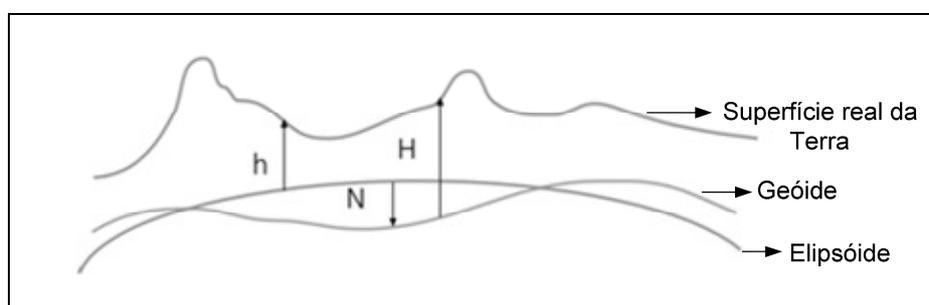


FIGURA 7 - Alturas entre a forma real da Terra, o geóide e o elipsóide. Fonte: FRACZEK,2003.

A altura entre o NR e o elipsóide de referência pode ser determinada quando as relações entre os parâmetros apresentados na figura 8 são estabelecidas. Onde β é a altura do NR em relação ao elipsóide de referência, h é a altitude elipsoidal da RN

conectada ao datum altimétrico, r o comprimento da régua, d o desnível da régua em relação a RN, S a altura do nível médio do mar na estação maregráfica e Z a altura do NR abaixo do NM.

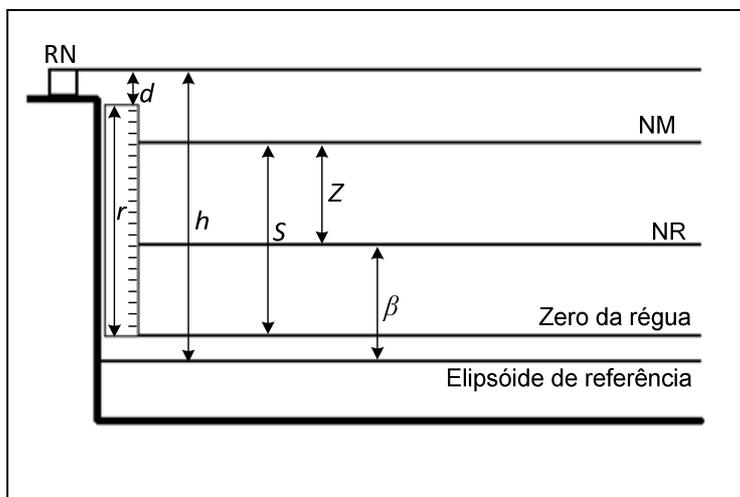


FIGURA 8 - Régua da estação maregráfica indicando a altura do NR em relação ao elipsóide de referência.

3.4 MODELOS DIGITAIS DE TERRENO

Um Modelo Digital de Terreno (MDT) pode ser entendido por uma representação digital de uma porção da superfície da Terra. MDTs têm sido usados em aplicações de geociências desde 1950. Desde então eles se tornaram o principal constituindo no processamento de dados geográficos e servem de base para um grande número de aplicações em estudos da terra e engenharia (WEIBEL & HELLER, 1991).

A representação dos MDTs pode acontecer em duas estruturas: uma rede irregular triangular (TIN, do inglês *triangulated irregular network*) ou uma matriz regular. A representação TIN é composta pelos pontos originais amostrados, ligados três a três, formando triângulos irregulares. Nesta representação os valores planimétricos e altimétricos observados são mantidos sem nenhuma transformação para estruturas intermediárias. Nesta representação a rede de pontos se adapta naturalmente à variação de complexidade do terreno. Onde houver pouca variação na superfície somente uma pequena quantidade de pontos é amostrada e onde houver muita variação, mais dados são coletados (MAUNE *et. al.*, 2001). Desta forma, feições geomorfológicas descontínuas como topos de morros, linhas de cumeada e de drenagem são facilmente incorporadas em um TIN aumentando a quantidade de pontos observados nessas regiões.

A manutenção dos dados planimétricos e altimétricos amostrados não acontece com as matrizes regulares, estas têm um conjunto de pontos regularmente espaçados, e os valores altimétricos são estimados para cada ponto da malha a partir dos valores observados, que dificilmente são espaçados regularmente como a matriz. Nesta representação a densidade de pontos de amostragem não pode ser adaptada a complexidade do terreno. Assim, um grande número de pontos é necessário para representar o terreno de acordo com a acurácia requerida (WEIBEL & HELLER, 1991). Além disso, pode ocorrer redundância de dados em regiões de pouca variabilidade e perda de informações em regiões de descontinuidade. Apesar disso as grades regulares são muito utilizadas por apresentarem mais rapidez na leitura computacional e maior eficiência na geração de outros produtos como: curvas de nível, ângulos de declividade e orientação, mapas de sombra, entre outros.

Na geração de grades, tanto regulares como as irregulares, é comum que as informações coletadas na região de interesse passem por um procedimento, denominado interpolação, para que valores do mesmo atributo sejam estimados em locais onde não existe esta informação.

É em decorrência do processo de interpolação que ocorre a perda de informações nas regiões de relevo acidentado durante a geração das grades regulares, pois a interpolação causa a suavização das áreas de mudança de declividade. Grades regulares podem ser geradas por métodos de interpolação como a krigagem, enquanto que os métodos que envolvem triangulação produzem grades irregulares.

3.5 MÉTODOS DE INTERPOLAÇÃO

Interpolação é o nome dado ao procedimento de predição de valores de atributos em locais não amostrados a partir de medições feitas em pontos na mesma região (Burrough,1998).

Segundo Watson (1992) os métodos de interpolação baseados na distância, na vizinhança, em triângulos e em funções de ajuste são os mais amplamente utilizados para fins cartográficos.

3.5.1 Triangulação e vizinho natural

O método baseado em triangulações calcula o valor a ser interpolado no centro do triângulo, pela média ponderada aritmética dos três pontos que formam o triângulo. Os métodos geralmente se baseiam na triangulação de Delaunay. Os três pontos de cota conhecida que formam o triângulo que contém o ponto a ser interpolado são identificados e caracterizam sua vizinhança. Estes três pontos formam um círculo vazio, sem que outros pontos estejam contidos no seu interior. Como fator

de ponderação existem duas possibilidades: usar o critério de distância ou da área de influência.

No método de interpolação ponderada pela distância, calcula-se o valor interpolado como a média ponderada dos três pontos, usando como ponderador a distância entre o ponto desconhecido e os três vértices do triângulo.

O método do vizinho natural também se baseia na triangulação de Delaunay. As retas perpendiculares às arestas do triângulo formado pelos pontos vizinhos formam polígonos de Thiessen ou Voronoi, esses polígonos definem as áreas individuais de influência de cada ponto no triângulo. Assim sendo, a cota do ponto interior é calculada como a soma ponderada das cotas destes três vizinhos, usando a área de influência como fator ponderador, ou seja, os pesos são proporcionais às áreas (MATOS, 2005).

A superfície formada pelo método dos triângulos tem mudança de declividade nas arestas entre os triângulos. Esse método, que produz curvas com aparência angular, é útil para investigações iniciais e quando linhas suaves não são importantes. É apropriado quando os dados são conhecidos por conter formações morfológicas importantes, como as descontinuidades representadas por feições lineares de relevo (cristas) e drenagem (vales), porque esse método expressa padrões de erosão e drenagem (WATSON, 1982; FELGUEIRAS E CÂMARA, 2001).

3.5.2 Krigagem

O método krigagem, baseado em geoestatística, assume que as médias locais não são necessariamente próximas da média da população, utilizando para isso uma ponderação baseada no semivariograma. Neste método o primeiro passo consiste em criar o semivariograma e as funções de covariância para estimar a dependência estatística (ou correlação espacial) entre os dados. Então, busca-se o modelo que tenha tal correlação espacial como seu dependente, sendo esse o modelo que ajusta todos os dados. O segundo passo consiste em fazer a predição estatística da superfície. A krigagem pretende criar uma superfície que minimize o erro dos valores avaliados e do modelo estatístico da superfície, fornecendo estimativas não tendenciosas e com variância mínima (MATOS, 2005). Segundo Maune (2001, *apud* MATOS, 2005) a krigagem é o método mais apropriado para interpolação de dados de terreno.

3.5.3 Superfície de aproximação polinomial

A superfície de aproximação por regressão polinomial, também conhecidas como superfície de tendência, usa funções polinomiais para representar uma superfície que se ajusta aos dados amostrados.

As funções polinomiais recebem classificações de acordo com o grau e a quantidade de dimensões. As funções que formam superfícies são as bidimensionais. As funções bidimensionais podem ser classificadas quanto ao grau: função bilinear é a função que tem duas variáveis e seu maior expoente é o número 1. Aumentando o número do expoente para 2, a função passa a ser biquadrática, e para 3 a função passa a ser bicúbica e assim por diante, formando ainda as funções biquárticas e biquinticas.

Função biquadrática:

$$z = a + bx + cy + dx^2 + exy + fy^2 \quad (4)$$

Função bicúbica:

$$z = a + bx + cy + dx^2 + exy + fy^2 + gx^3 + hx^2y + ixy^2 + jy^3 \quad (5)$$

Função biquártica:

$$z = a + bx + cy + dx^2 + exy + fy^2 + gx^3 + hx^2y + ixy^2 + jy^3 + kx^4 + lx^3y + mx^2y^2 + nxy^3 + oy^4 \quad (6)$$

Esse método é aplicado em dois estágios: primeiro os parâmetros da função são determinados e então a interpolação é realizada utilizando esses parâmetros (WATSON, 1992). A determinação dos parâmetros acontece por meio da utilização do método de regressão por mínimos quadrados.

As superfícies de aproximação por regressão polinomial, que podem também ser chamadas de superfícies de tendência, buscam modelar a variação espacial em larga escala. A grande vantagem é a simplicidade de cálculo. No entanto, a suposição implícita do modelo, em negligenciar a variabilidade local não é realista para a maior parte dos dados (FELGUEIRAS E CÂMARA, 2001).

Na figura 9 pode-se observar exemplos de superfícies, onde (a) refere-se a uma superfície bilinear, (b) uma superfície biquadrática e (c) e (d) um superfície bicúbica vista de dois ângulos distintos.

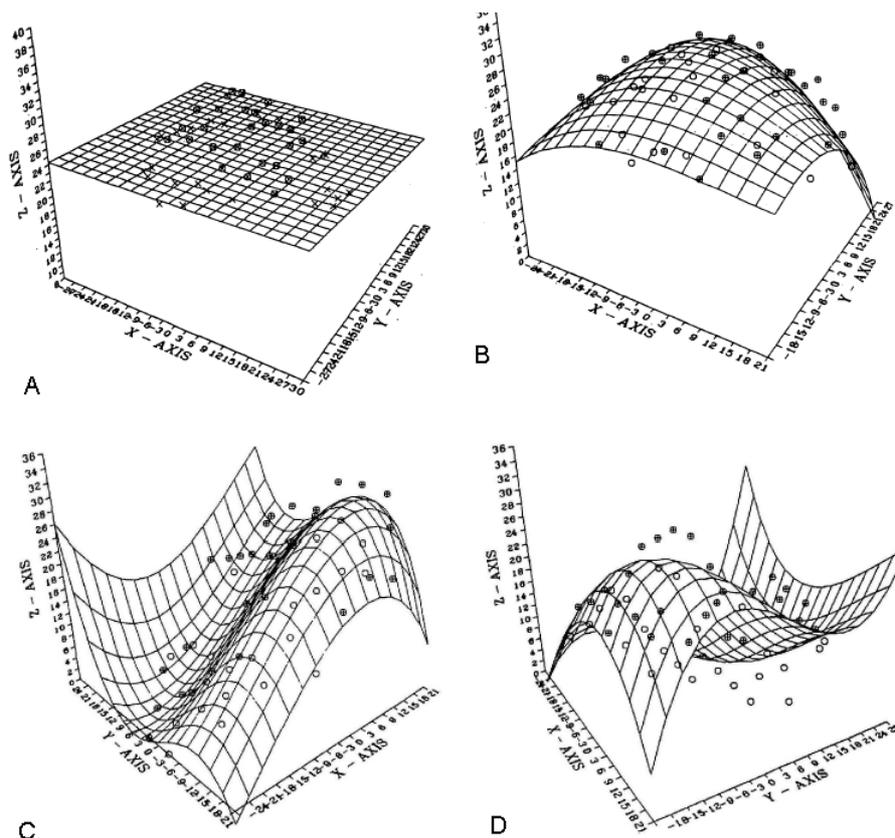


FIGURA 9 - Superfícies de tendência. Fonte: Schulzer et. al., 1990.

3.6 REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) fazem parte de uma das áreas da ciência da computação denominada computação natural. A computação natural se dedica ao estudo de abordagens computacionais que se inspiram em técnicas existentes na natureza. Essa ciência busca trazer para o meio computacional o processo de extração de idéias provenientes da natureza possibilitando o desenvolvimento de sistemas artificiais.

As RNAs buscam se estruturar de maneira que, de algum modo, relembram a estrutura do cérebro humano. Os trabalhos com redes neurais artificiais foram motivados pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador convencional (Haykin, 2001. Pg 27). Os computadores convencionais usam a computação algorítmica para processar informações, enquanto que as RNAs usam uma forma de computação não-algorítmica.

Para entender as redes neurais artificiais, uma breve apresentação do funcionamento dos neurônios biológicos é apresentada a seguir.

O cérebro humano é constituído por unidades de processamento, os neurônios. Um esquema simplificado do neurônio é mostrado na figura 10. Estes são formados

por dendritos, corpo celular e axônio. Os dendritos têm por função receber informações, ou impulsos nervosos, oriundas de outros neurônios e conduzi-los até o corpo celular. O corpo celular é onde as informações recebidas são processadas e novos impulsos são gerados. O axônio é responsável pela condução do novo impulso nervoso para o dendrito do próximo neurônio. Os neurônios são maciçamente interconectados por uma rede de sinapses.

Sinapses são os locais onde as extremidades de neurônios vizinhos se encontram e o impulso passa de um neurônio para o outro. Quando um impulso elétrico gerado no corpo celular de um neurônio chega a uma das terminações sinápticas do seu axônio, modificações químicas são provocadas na membrana destas terminações, liberando moléculas chamadas genericamente de neurotransmissores, que se difundem através da junção sináptica entre dois neurônios. Essas moléculas se aderem então ao dendrito do neurônio receptor provocando uma modificação na membrana desta que acaba, algumas vezes, provocando a geração de um novo impulso elétrico (excitação), outras vezes, dificultando seu aparecimento (inibição). Este impulso elétrico, se criado, se propaga até o corpo celular do neurônio que recebeu o sinal. Se a intensidade do sinal for suficiente o corpo celular pode disparar, ou ativar, sua função de processamento. A intensidade com que o impulso é transmitido de um neurônio para o outro depende, portanto, do tipo de neurotransmissor, de sua abundância no terminal sináptico e da sensibilidade da membrana dendrítica a excitações. Mudando valores de intensidades destas conexões muda-se o comportamento da rede e estas mudanças representam um processo de aprendizagem.

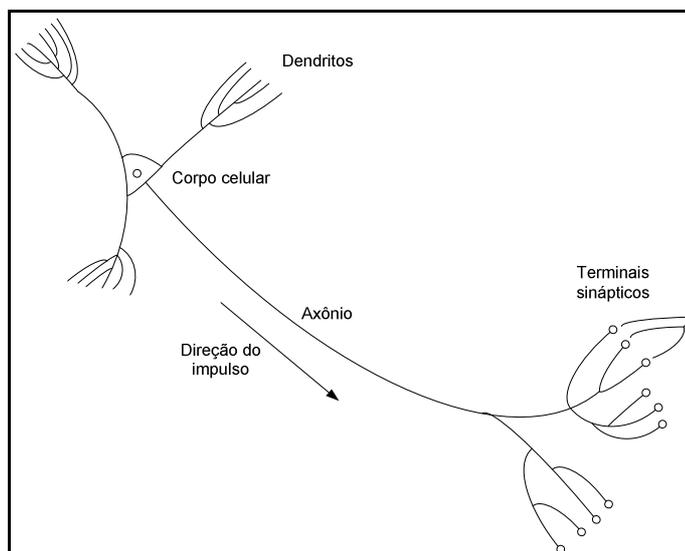


FIGURA 10 - Neurônio biológico.

Por aprendizagem entende-se o modo como os seres adquirem novos conhecimentos a partir do meio ambiente, desenvolvem competências, melhoram o desempenho e mudam o comportamento. Diante de um problema o cérebro humano

processa informações em busca de uma resposta adequada. As intensidades de transmissão sináptica são ajustadas para que resposta seja capaz de resolver tal problema. Quando a resposta for apropriada o aprendizado foi adquirido e pode ser utilizado futuramente.

As redes neurais artificiais também passam pelo processo de aprendizagem para desenvolver conhecimento, habilidade e experiência. O conhecimento adquirido durante o processo de aprendizagem é também armazenado nas conexões entre os neurônios, sobre a forma de pesos sinápticos. Cada interconexão recebe um peso, ou uma força, que vai sendo ajustado durante o processo de aprendizado. Quanto mais uma sinapse é estimulada, mais força ela recebe, podendo estas ser positivas ou negativas, dependendo se as sinapses são inibitórias ou excitatórias.

Para Haykin (2001. pg 27), o cérebro humano é um computador (sistema de processamento de informação) altamente complexo, não-linear e paralelo. A complexidade cerebral se deve a forma com que os bilhões de neurônios se organizam. Esta organização cerebral confere ao cérebro a habilidade de operar de forma paralela e distribuída, onde os impulsos podem passar por diversos caminhos diferentes, processando então diversas informações ao mesmo tempo. Esse sistema é capaz de processar complexas funções, que normalmente não respondem de forma linear. São capazes de conduzir a solução desejada de vários tipos de problemas de elevada complexidade. Contudo, esses sistemas não permitem interpretar adequadamente os resultados ou entender a evolução do processo adaptativo que levou a obtenção da solução. Por isso as RNAs são caracterizadas como modelos de processamento do tipo “caixa preta”.

De acordo com o que foi apresentado anteriormente, uma RNA pode ser definida, segundo Haykin (2001. pg 28), como um processador maciçamente paralelamente distribuído constituído por unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

- ✓ O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;
- ✓ Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

3.6.1 O neurônio artificial

O funcionamento de um neurônio biológico pode ser modelado matematicamente, de forma simplificada, por neuronios artificiais. O primeiro modelo artificial de um neurônio biológico foi proposto por McCulloch e Pitts (FIGURA 11) em 1943 e é uma simplificação do que se sabia então a respeito do neurônio biológico. Sua descrição matemática resultou num modelo com n terminais de entrada x_1, x_2, x_n (que representam os dendritos) e apenas um terminal de saída y (representando o axônio). Para simular o comportamento das sinapses, os terminais de entrada do neurônio têm pesos acoplados w_1, w_2, w_n cujos valores podem ser positivos ou negativos, dependendo das sinapses correspondentes serem inibitórias ou excitatórias. O efeito de uma sinapse particular i no neurônio pós-sináptico é dado por $x_i w_i$ (BRAGA *et al.*, 2000, p. 8).

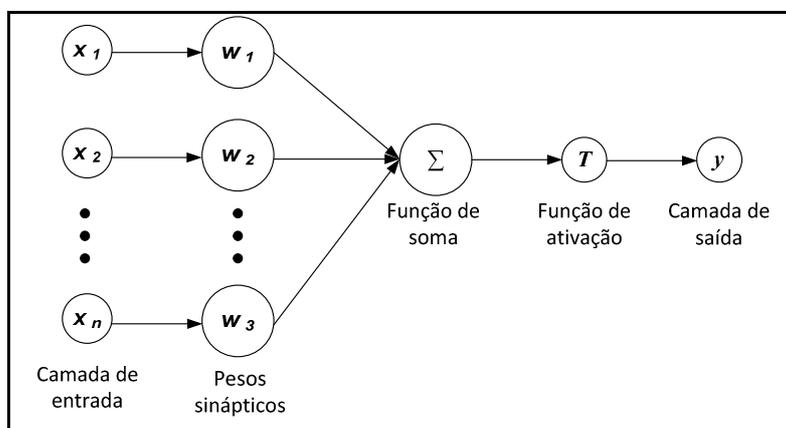


FIGURA 11 - Estrutura de um neurônio artificial de McCulloch e Pitts (1943). Adaptado de HAYKIN, 2001.

As intensidades $x_i w_i$ correspondem aos sinais de entrada ponderados pelos pesos sinápticos. Estes são somados pela função de soma Σ , gerando um novo sinal. Se este novo sinal exceder certo limite pré-estabelecido (*threshold*) a unidade produz uma determinada resposta de saída. O limite é definido por uma função denominada função de ativação T . A função de ativação tem por atribuição decidir por ativar (disparar) uma saída, ou não, dependendo do valor da soma ponderada das suas entradas. As mais comuns funções de ativação são a função linear, a função rampa, função degrau e função sigmoideal. Estas funções podem ser observadas na figura 12.

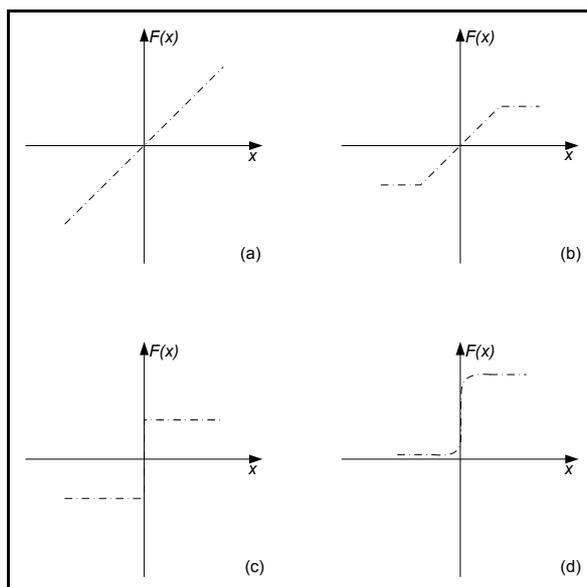


FIGURA 12 - Funções de ativação: (a) linear, (b) rampa, (c) degrau e (d) sigmoideal. Fonte: Adaptado de BRAGA *et al.*, 2000.

3.6.2 Topologias da rede

Os neurônios de uma rede neural artificial podem se conectar de diversas maneiras, formando diferentes tipos de estruturas. Os parâmetros que definem a arquitetura de uma rede são:

- ✓ O número de camadas da rede: que pode ser uma única camada ou múltiplas camadas
- ✓ O número de neurônios em cada camada
- ✓ O tipo de conexão entre os neurônios: que pode ser do tipo acíclico (feedforward) onde a saída de um neurônio em qualquer camada da rede nunca é utilizada como entrada de neurônios de camadas anteriores, e do tipo cíclica (*feedback*) onde a saída de algum neurônio de uma camada da rede é utilizada como entrada de um neurônio de alguma camada anterior

A maneira pela qual os neurônios de uma rede neural são estruturados esta intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede. Sendo assim, cada arquitetura confere uma característica diferente à rede neural artificial. Em geral, pode-se identificar três classes de arquiteturas (HAYKIN, 2001. pg 46):

- ✓ Redes alimentadas adiante com camada única
- ✓ Redes alimentadas diretamente com múltiplas camadas
- ✓ Redes recorrentes

As redes alimentadas adiante com camada única se caracterizam por serem acíclicas e pelos neurônios estarem dispostos em uma única camada como na figura 13(a). As redes alimentadas diretamente com múltiplas camadas se distinguem pela presença de uma ou mais camadas ocultas, intermediárias ou escondidas (figura 13(b)). A função dos neurônios das camadas ocultas é intervir entre a entrada externa e a saída da rede. Com a adição de uma ou mais camadas ocultas a rede torna-se capaz de extrair estatísticas de ordem elevada, esta característica é especialmente valiosa quando o tamanho da camada de entrada é grande.

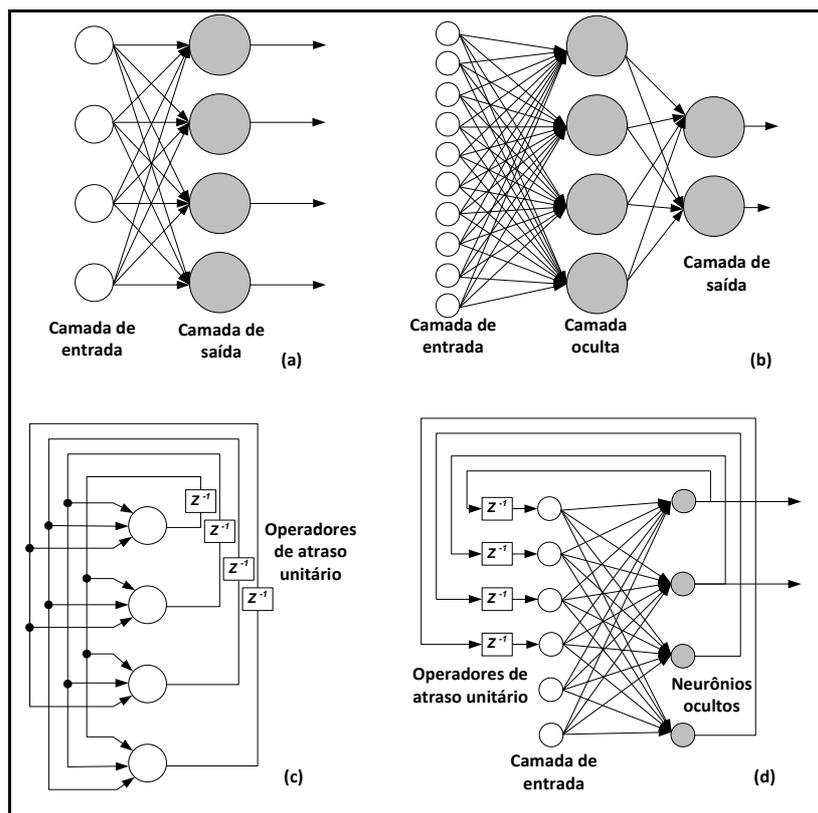


FIGURA 13 – Exemplos de topologia de rede. (a) Rede alimentada adiante ou acíclica com uma única camada de neurônios. (b) Rede alimentada adiante ou acíclica totalmente conectada com uma camada oculta e uma camada de saída. (c) rede recorrente sem laços de auto-realimentação e sem neurônios ocultos. (d) Rede recorrente com neurônios ocultos. Fonte: HAYKIN, 2001.

As redes recorrentes se diferenciam das demais por ter pelo menos um laço de realimentação. Na figura 13(c) pode-se observar uma rede recorrente sem neurônios ocultos e sem laços de auto-realimentação, em que cada neurônio alimenta seu sinal de saída de volta para a entrada de todos os outros neurônios, mas não para o próprio neurônio. Uma rede recorrente com neurônios ocultos pode ser vista na figura 13(d), em que as conexões de realimentação se originam dos neurônios ocultos e dos neurônios de saída. A presença de laços de realimentação envolve o uso de ramos

particulares compostos de elementos de atraso unitário z^{-1} que resulta num comportamento dinâmico não-linear.

3.6.3 Aprendizado

A propriedade que é de importância primordial para uma rede neural é a habilidade de aprender a partir de seu ambiente e de melhorar o seu desempenho mediante a aprendizagem. Uma rede neural artificial aprende acerca do seu ambiente através de um processo de aprendizagem que implica a seguinte seqüência de eventos: a rede neural é estimulada por um ambiente e sofre modificações nos seus parâmetros como resultado da estimulação, então a rede neural responde de uma maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura interna. As modificações na estrutura interna da rede ocorrem por meio de um processo iterativo que aplica ajustes aos parâmetros da rede, tornando-a mais instruída.

Um conjunto pré-estabelecido de regras bem definidas para a solução de um problema de aprendizagem é denominado um algoritmo de aprendizagem. Não há um algoritmo único de aprendizagem para um projeto de redes neurais, tem-se um conjunto de regras representadas por expressões matemáticas, cada qual com suas vantagens e desvantagens.

Os algoritmos diferem entre si pela maneira como é feita os ajustes nos parâmetros da rede. Estes métodos podem ser agrupados em dois paradigmas principais: aprendizado supervisionado e não supervisionado.

O método de aprendizado supervisionado, também denominado de aprendizagem com um professor, caracteriza-se pela presença de um supervisor, o professor. Este professor possui o conhecimento sobre o ambiente (representado por um conjunto de exemplos de entrada e saída) e por isso tem condições de indicar explicitamente um comportamento bom ou ruim para a rede, visando direcionar o processo de treinamento.

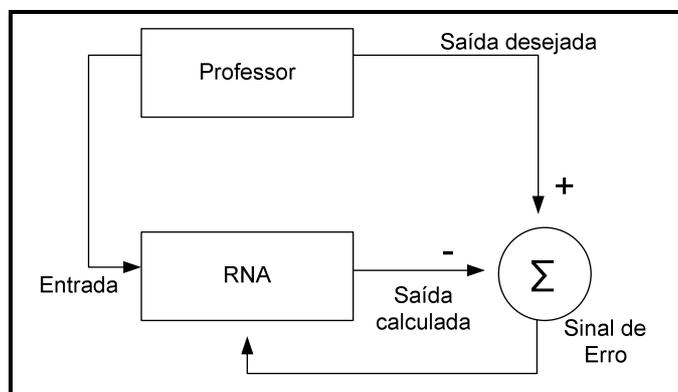


FIGURA 14 - Método de aprendizado supervisionado. Fonte: Adaptado de BRAGA *et al.*, 2000.

Quando entradas são apresentadas a rede (FIGURA 14), ela fornece uma saída calculada. O professor compara a saída calculada com a saída desejada, e informa a rede sobre o erro da resposta atual. A cada padrão de entrada submetido, a resposta desejada é comparada a calculada e os pesos das conexões são ajustados para minimizar o erro. A cada etapa de treinamento pequenos ajustes são feitos nos pesos sinápticos e níveis de *bias* de um neurônio para que a diferença entre a resposta calculada e desejada seja minimizada. Estes ajustes são realizados passo a passo, iterativamente, até que a rede consiga reproduzir os exemplos do professor. O conhecimento do ambiente disponível ao professor foi transferido para a rede neural pelo treinamento, o professor pode então ser dispensado e deixar a rede neural lidar com o ambiente inteiramente por si mesma.

O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre (HAYKIN, 2001. pg 75).

O software Matlab dispõe de alguns algoritmos de aprendizagem que permitem trabalhar com diversos tipos de RNAs de maneira fácil e rápida, diminuindo o custo na produção destas. O algoritmo de *Backpropagation* gradiente descendente – GD é um algoritmo que atualiza os pesos e *bias* de acordo com um gradiente descendente. O algoritmo Levenberg-Marquardt – LM – atualiza os pesos sinápticos e valores de *bias* seguindo o modelo de otimização de Levenberg-Marquardt. O algoritmo *Backpropagation* gradiente descendente com taxa de aprendizado adaptativa – GDA atualiza os pesos e *bias* durante o treinamento também de acordo com um gradiente descendente, mas levando em consideração ainda uma taxa de aprendizado adaptativa. O algoritmo de *Backpropagation* gradiente descendente com momento – GDM - atualiza os pesos e *bias* durante o treinamento também de acordo com um gradiente descendente e uma constante denominada momento. O *Backpropagation* gradiente descendente com momento e taxa de aprendizado adaptativa – GDX – leva em consideração o gradiente descendente, a taxa de aprendizado adaptativa e a constante momento durante o processo de treinamento e atualização dos pesos e *bias*. E por fim o algoritmo *Backpropagation* Resilient – RP atualiza o peso e valores de *bias* seguindo o algoritmo *backpropagation* resilient. O termo *Backpropagation* ou retropropagação se refere aos métodos de aprendizado supervisionado que atualiza seus pesos e valores de *bias* pelo método de correção dos erros obtidos como resultados da rede treinada. O termo momento se refere a uma constante que, quando incluída no algoritmo, tem efeito de estabilizar a rede. Para obter mais informações sobre o funcionamento do método *backpropagation* e parâmetros da rede consulte HAYKIN (2001).

O aprendizado não supervisionado não requer um professor, isso porque não há saída desejada, ou seja, não há exemplos rotulados da função a ser aprendida pela

RNA. Para estes algoritmos somente padrões de entradas estão disponíveis para a RNA.

Para exemplificar este método podemos usar os sistemas classificadores. Uma vez que a RNA tenha se ajustado as regularidades estatísticas dos dados de entrada, ela desenvolve a habilidade de formar representações internas para codificar as características da entrada e, desse modo, de criar automaticamente novas classes (BECKER, 1991 apud HAYKIN, 2001). Em outras palavras, quando a RNA recebe padrões de entrada, ela organiza arbitrariamente os padrões em categorias. Quando uma entrada é fornecida à RNA, esta fornece uma resposta de saída indicando a classe que a entrada pertence. Se uma classe não pode ser encontrada para o padrão de entrada, uma nova classe é gerada. Este tipo de aprendizado só se torna possível quando existe redundância nos dados de entrada. Sem a redundância seria impossível encontrar quaisquer padrões ou características dos dados de entrada (BRAGA *et al.*, 2000).

4 MATERIAIS E MÉTODOS

4.1 ÁREA DE ESTUDO

A Ilha do Mel se localiza na desembocadura da Baía de Paranaguá no litoral do estado do Paraná – BR (FIGURA 16). Na sua porção sudoeste se situa o Saco do Limoeiro, com águas calmas e vista para o continente, onde se encontra a praia de Pontal. O canal compreendido entre a Ilha do Mel e a praia de Pontal é denominado canal da Galheta e dá acesso ao porto de Paranaguá.

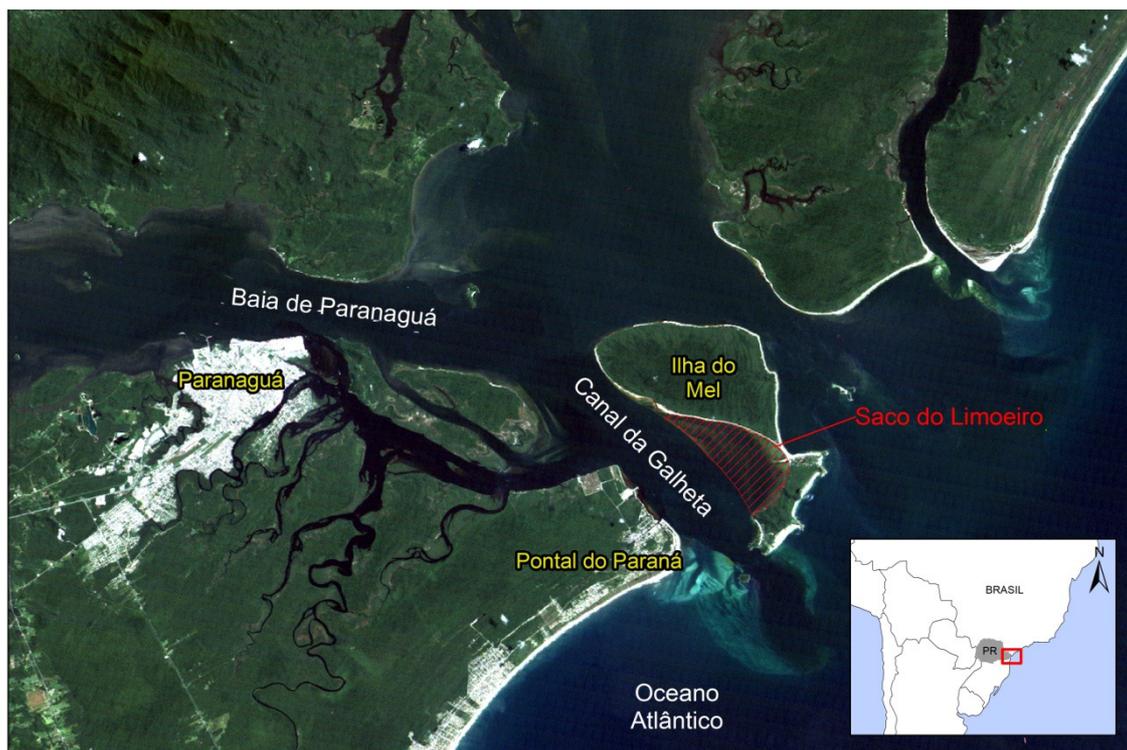


FIGURA 15- Localização e acesso ao Saco do Limoeiro, Ilha do Mel, Paraná. Fonte: Adaptado de ARAÚJO, 2001.

O Saco do Limoeiro é um depósito sedimentar subaquático que foi interpretado por Angulo (1999) como sendo um hemi-delta de maré enchente. Deltas de maré enchente (*flood-tidal deltas*) são formados por sedimentos depositados por correntes de maré enchente junto a desembocaduras no interior de estuários (ARAÚJO, 2001).

O Saco do Limoeiro foi escolhido como área de estudo por ser uma região de interface continente-oceano calma, sem ondas ou correntes fortes e de profundidade relativamente rasa, garantindo a união dos dados batimétricos e geodésicos.

4.2 MATERIAIS

Os equipamentos utilizados na elaboração deste trabalho são:

- Dois receptores DGPS de dupla frequência, 12 canais, Ashtech ZXII;
- Dois receptores GPS de dupla frequência com até 120 canais, sendo 16 para L1 e 16 para L2, Leica GPS1200;
- Quatro receptores GPS de dupla frequência com até 72 canais, sendo 14 para L1 e 14 para L2, Leica GPS900;
- Sistema de comunicação (par de rádios Pacific Crest com potências de 35W e 2W, e antenas onidirecionais);
- Ecobatímetro de feixe único modelo SDH-13A da Odom Hydrographic Systems, Inc., que opera numa frequência de 208kHz, com capacidade para realizar medidas para profundidades entre 0,35m e 123m e um transdutor;
- Embarcação;
- Nível digital para o nivelamento geométrico;
- Programa HYPACK para planejamento, execução e processamento dos dados do levantamento hidrográfico;
- Programa LEICA Geo Office para pós-processamento das informações geodésicas;
- Programa Microsoft Excel para reduções maregráficas;
- Programa MatLab para execução das estimativas de cota e implementação das RNAs;
- Programa ArcGis para elaboração dos MDTs.
- Programa Statgraphics Centurium para análises estatísticas.

4.3 MÉTODOS

O método proposto neste estudo pretende estimar a profundidade de um ponto a partir da coordenada planimétrica desse ponto por meio dos métodos de interpolação.

A metodologia foi organizada em duas etapas. A primeira, levantamentos, descreve as fases que englobam a coleta de dados em campo. A segunda inclui a análise dos métodos de interpolação.

4.3.1 Levantamentos

a) Planejamento dos levantamentos batimétricos de acordo com as normas da DHN.

A DHN regulamenta os levantamentos hidrográficos pela portaria 121/MB/2003. Nesta portaria encontra-se anexada a instrução técnica A-06A que estabelece os procedimentos para levantamentos hidrográficos executados por entidades extra marinha.

Nesta etapa foram planejadas as linhas de sondagem dispostas, aproximadamente, de modo perpendicular as isóbatas da área (FIGURA 17). Também foram planejadas as linhas de verificação, perpendiculares às linhas de sondagem.

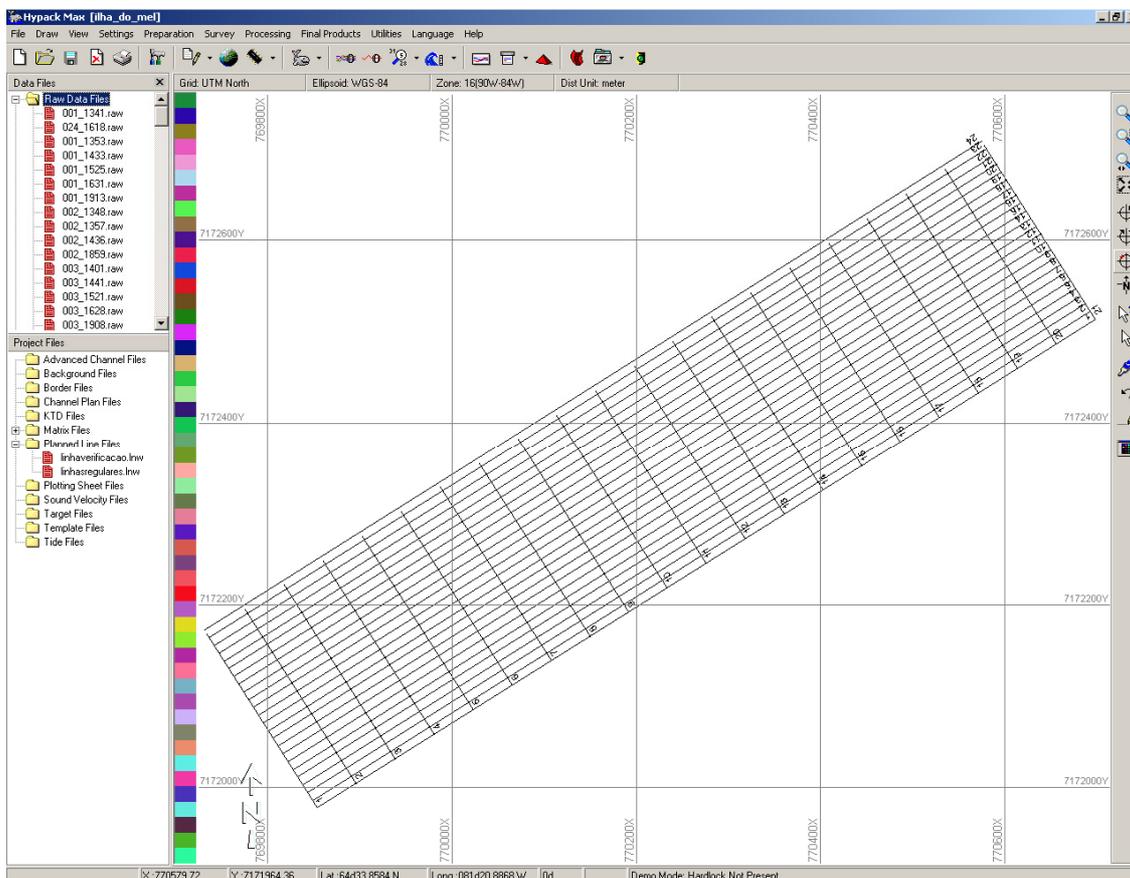


FIGURA 16 - Linhas de verificação e de sondagem na tela do programa Hypack. Linhas de sondagem com menor distância entre si e linhas de verificação mais distantes umas das outras.

b) Nivelamento geométrico da estação maregráfica e levantamento geodésico da RN associada ao marégrafo.

A instrução técnica A-06A estabelece que antes do início da batimetria, deve-se realizar o nivelamento geométrico das estações maregráficas a serem utilizadas na redução das sondagens. Tal procedimento tem por finalidade verificar se a régua da estação está na mesma posição que a indicada pela ficha de descrição (F-41) disponível. Caso se constatem discrepâncias superiores a 2 mm, entre os desníveis das RN oriundos das F-41 e os oriundos dos nivelamentos, e superiores a 5 cm entre os desníveis RN-régua oriundos das F-41 e os oriundos dos nivelamentos, deve-se confeccionar um desenho esquemático apresentando os novos desníveis, os quais deverão ser considerados para efeito da redução das sondagens.

A ficha F- 41- 60135 – 1821 – 001/08 descreve a estação maregráfica Barra de Paranaguá – Canal da Galheta, que foi utilizada neste trabalho. No dia 8 de maio de 2009 realizou-se o nivelamento geométrico do marégrafo descrito nessa ficha e não

foram verificadas discrepâncias entre os níveis da ficha e do nivelamento realizado. O desenho esquemático do marégrafo desta ficha foi então utilizado na redução dos levantamentos batimétricos.

A determinação da coordenada geográfica da RN1 (referência de nível – RN - conectada ao marégrafo presente na ficha F- 41- 60135 – 1821 – 001/08) por levantamento geodésico aconteceu no dia 18 de fevereiro de 2006. A altitude elipsoidal desta RN precisa ser conhecida para determinação da altura entre o NR e o elipsóide de referência.

c) Escolha e implantação de uma estação de referência e determinação das suas coordenadas geodésicas precisas.

Dois pontos foram escolhidos para a implantação de uma estação de referência e uma estação base (FIGURA 18). Ambas as estações tiveram suas coordenadas geodésicas precisas determinadas pelo método de posicionamento relativo estático no dia 21 de maio de 2009. O local da estação de referência foi escolhido observando que o envio das correções diferenciais fosse possível.

Em um dos pontos foi alocada a estação de referência do sistema DGPS. Este sistema manda as correções diferenciais pela antena de comunicação para a estação móvel, colocada junto do ecobatímetro, durante a realização dos levantamentos batimétricos. Após o envio as correções são perdidas porque tais dados não são salvos pelo sistema.



FIGURA 17 - Estação base, estação de referência e antena de rádio no istmo da Ilha do Mel

No outro ponto foi implantada a estação base. Esta estação coletou e salvou os dados do rastreamento para que esses pudessem ser utilizados no pós-processamento dos dados coletados pelo método relativo cinemático que foram realizados na parte emersa da área de estudo.

d) Calibração do ecobatímetro

Durante os dias de sondagem efetuou-se a aferição do ecobatímetro por meio do uso de uma placa de aferição, para a cota referente à profundidade média da área de sondagem.

e) Levantamentos geodésicos, batimétricos e maregráficos.

Durante os dias 22 a 24 de maio de 2009 foram realizados levantamentos hidrográficos e geodésicos no Saco do Limoeiro. As datas foram escolhidas por apresentarem marés de sizígia.

Foram realizados levantamentos batimétricos durante os períodos de maré cheia. Nos períodos de maré baixa foram levantados, com GPS, pontos da região que fica submersa nos períodos de maré cheia, utilizando o método relativo cinemático. Coordenadas geodésicas de pontos permanentemente emersos foram coletados durante todo o período de levantamentos.

Os pontos dos levantamentos batimétricos e geodésicos podem ser observados na figura 19.

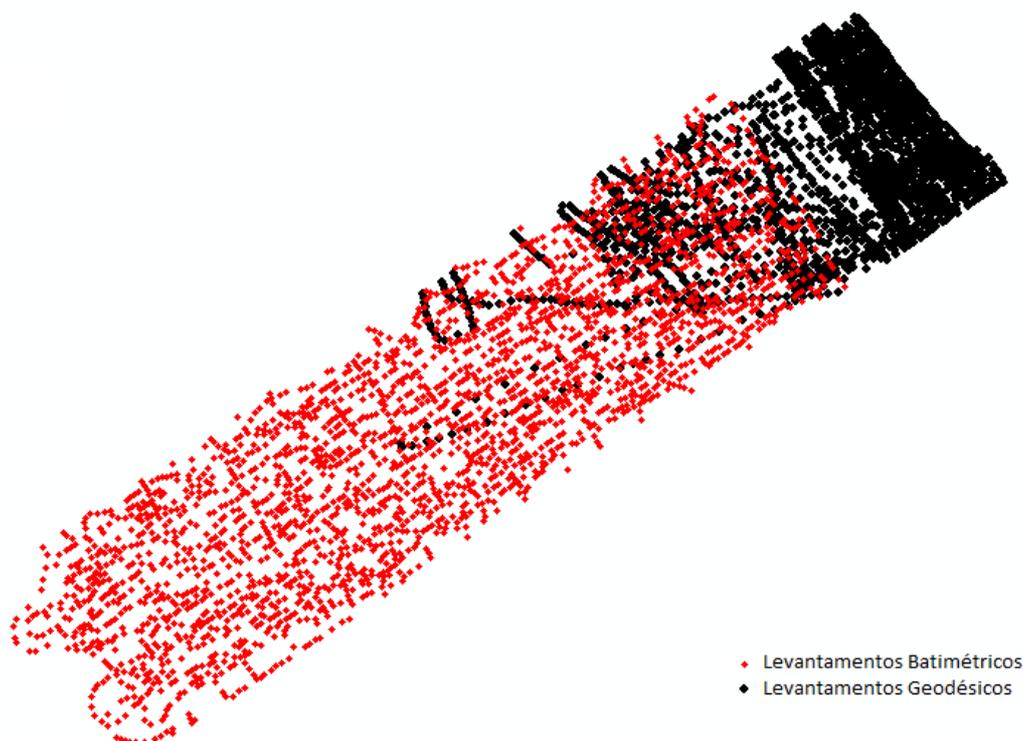


FIGURA 18 – Pontos coletados pelo levantamento GPS mostrados na tela do ArcGis.

As informações maregráficas para a realização deste trabalho foram disponibilizadas pela empresa responsável pela praticagem do Porto de Paranaguá.

f) Análise dos resultados obtidos

A análise dos dados batimétricos foi feita sobre os pontos onde as linhas de sondagem coincidem com as linhas de verificação. Pôde-se assim determinar se existem diferenças na obtenção de profundidades para um mesmo ponto.

As diferenças encontradas não ultrapassaram a precisão do equipamento que é de 10 cm.

Para a análise dos dados GPS foram considerados dois parâmetros criados durante o pós-processamento dos dados pelo programa Leica GeoOffice: a qualidade do posicionamento, *PosnQty*, e qualidade de altitude, *HgtQty*.

Sendo o pós processamento desses dados realizado com as efemérides precisas, obtidas no site do *International GNSS Service* (IGS): http://igsb.jpl.nasa.gov/components/prods_cb.html, os parâmetros de qualidade para o posicionamento e altitude foram, respectivamente, de 0,0022138m e 0,003982m.

g) Redução dos dados batimétricos ao NR

Foram feitas as correções de maré com auxílio do maregrama e os dados foram reduzidos ao nível de redução. Esse processo aconteceu no *software* Excel.

h) Processamento das informações coletadas pelo método relativo estático e cinemático.

O pós-processamento das informações geodésicas coletadas foi feito utilizando o *software* LEICA Geo Office. Inicialmente foi realizado o pós-processamento do levantamento relativo estático, utilizando a estação de Cananéia da Rede Brasileira de Monitoramento Contínuo (RBMC) como base de coordenada precisa conhecida. Este processamento determinou a coordenada precisa da estação locada na Ilha do Mel que foi utilizada como base nos levantamentos cinemáticos posteriores.

Com a determinação da coordenada precisa da estação base na Ilha do Mel foi possível pós-processar os levantamentos cinemáticos realizados.

Todos os pós-processamentos foram realizados utilizando as efemérides precisas que foram obtidas no *site* do *International GNSS Service* (IGS).

i) Padronizar as informações verticais obtidos pelo ecobatímetro e pelo GPS num mesmo sistema de referência

Com o desenho esquemático contido na ficha F- 41- 60135 – 1821 – 001/08 (FIGURA 8) e com a altitude elipsoidal da RN01 foi possível determinar a altura entre o NR e o elipsóide de referência. Com essa altura os dados batimétricos foram convertidos em altitudes elipsoidais e estão agora associados ao mesmo sistema de referência dos dados geodésicos. Essa conversão foi feita no programa Microsoft Excel.

j) Organização dos dados

Após a união dos dados geodésicos e batimétricos, estes foram divididos em 20% para verificação e 80% para testes (FIGURA 20), essa escolha se deu aleatoriamente utilizando um algoritmo criado no programa MatLab.

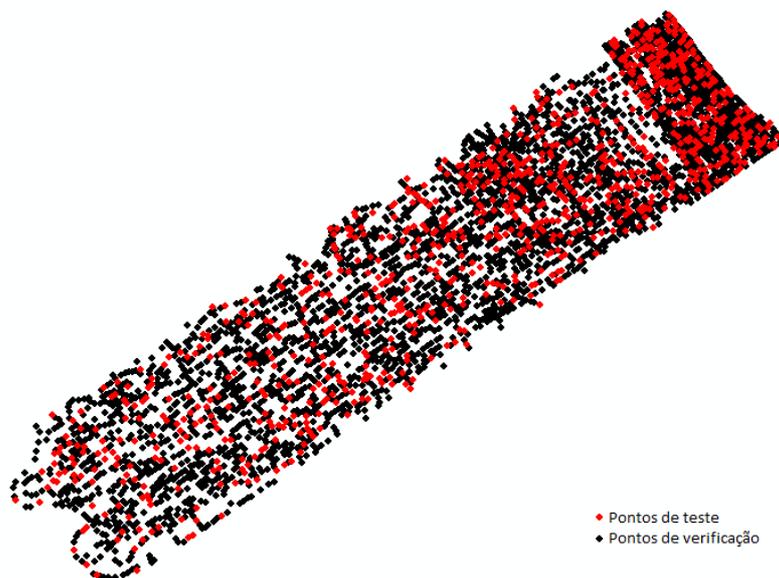


FIGURA 19 - Divisão dos dados em 80% para testes e 20% para verificação.

Posteriormente empregou-se o mesmo algoritmo para que dos 80% dos dados de teste fossem selecionados aleatoriamente conjuntos menores de 60%, 40%, 20%, 10% e 5% do total de dados (FIGURA 21).

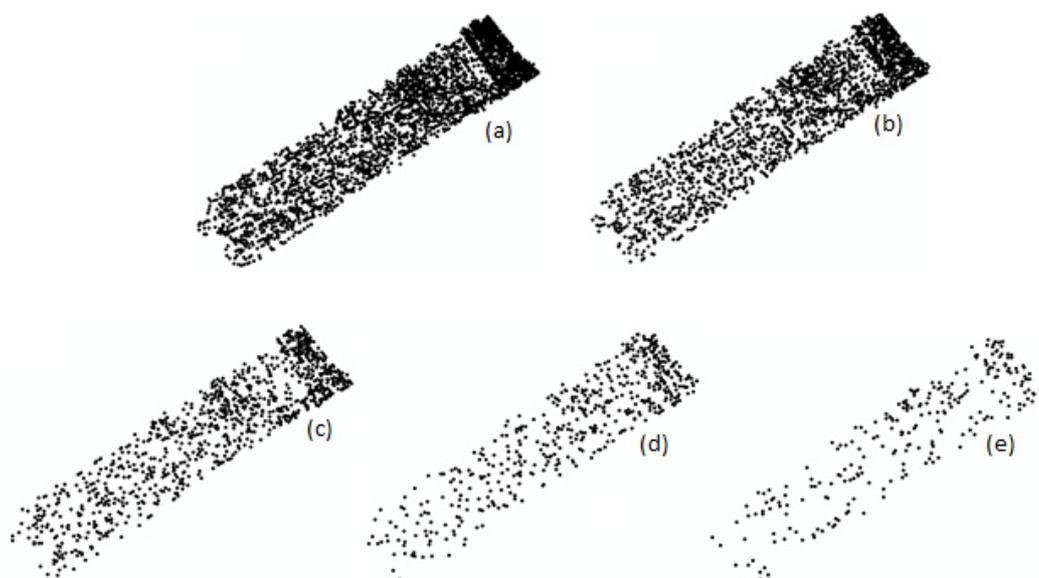


FIGURA 20 - Divisão dos dados em 60% (a), 40% (b), 20% (c), 10% (d) e 5% (e).

Quando se utiliza 80% dos dados a quantidade média aproximada de pontos numa área de 10.000m^2 ($100\text{m} \times 100\text{m}$) é de 114 pontos. Para 60% a quantidade é de 85 pontos para mesma área. Para 40%, 20%, 10% e 5% dos dados, a quantidade média

aproximada de pontos para a área de 10.000 m² é de 57, 28, 14 e 7 pontos, respectivamente.

4.3.2 Métodos de interpolação, redes neurais artificiais e avaliação

Nesta fase, diferentes métodos de interpolação da cota foram comparados, são eles: vizinho natural, krigagem, triangulação, superfície de aproximação polinomial e redes neurais artificiais. Os métodos do vizinho natural, krigagem e triangulação foram aplicados dentro do ambiente ArcGis, usando a ferramenta 3D analyst. O método que usa as redes neurais foi desenvolvido dentro do ambiente Matlab, assim como o método da Superfície de Aproximação Polinomial.

Os métodos de interpolação executados no ArcGis geram superfícies durante o processamento. Porém, os métodos executados no MatLab precisam passar por um outro procedimento para a geração das superfícies. Para representação espacial dos métodos de superfície de aproximação polinomial e das redes neurais artificiais foi preciso extrair os pontos centrais da superfície criada pelo método de krigagem. Esses pontos tiveram suas coordenadas planimétricas, distantes entre si em 1 m, aplicadas aos modelos criados pelas funções polinomiais e pelas redes neurais artificiais criando assim uma altitude para cada um desses pontos permitindo assim a visualização espacial.

Todos os métodos foram testados com diferentes volumes de dados. As proporções de 80%, 60%, 40%, 20%, 10% e 5% dos dados organizados aleatoriamente (FIGURAS 20(b) E 21) foram utilizados para treinamento da rede neural. Para verificação foram utilizados outros 20% dos dados que foram descartados nos testes, estes estão representados na figura 20(a).

Para verificação dos testes vizinho natural, krigagem e triangulação os dados de verificação tiveram o atributo estimado lido diretamente na superfície criada. Assim o atributo lido pode ser comparado ao atributo observado em campo.

No caso dos testes de aproximação polinomial e redes neurais artificiais, os dados de verificação foram empregados aos modelos criados por estes testes para que a comparação entre o valor estimado e o observado em campo pudesse acontecer.

Em todos os casos, para cada ponto de verificação tem-se uma altitude medida em campo e uma altitude estimada. Assim, cada um desses testes resulta em uma matriz com as altitudes medidas em campo e outra com as estimativas. Essas matrizes foram então comparadas resultando em uma matriz de erro e em um coeficiente de correlação entre as matrizes.

O coeficiente de correlação descreve a medida ou o nível de relação entre duas variáveis. Se o coeficiente for igual a 1 a correlação é dita como perfeita e indica que as variáveis crescem ou decrescem juntas, na mesma proporção. Se o coeficiente for -1 indica que quando uma das variáveis cresce a outra decresce na mesma proporção,

ou vice e versa. E quanto mais próximo a zero for o valor do coeficiente de correlação menor será a indicação de que as variáveis estão correlacionadas entre si.

Com o objetivo de testar se diferentes densidades e testes produzem resultados estatisticamente semelhantes às matrizes de erros dos testes que se deseja comparar passaram por uma análise estatística.

As análises estáticas empregadas foram os testes de hipótese de Student, também chamado de teste t e o teste de Fisher, também chamado de teste f. Estes testes são aplicados para verificar se diferentes amostras pertencem a uma mesma população, ou seja, se são amostras homogêneas. Os testes f e t comparam as variâncias σ^2 e médias μ , respectivamente. Se as variâncias e as médias não apresentarem diferenças significativas então as amostras pertencem a mesma população.

O teste f examina se as variâncias de populações são estatisticamente semelhantes. Para verificar se as variâncias populacionais são similares ou diferentes, através do teste F, as seguintes hipóteses são verificadas:

$$\begin{aligned} H_0: \sigma_1^2 &= \sigma_2^2 \\ H_1: \sigma_1^2 &\neq \sigma_2^2 \end{aligned}$$

A variável de teste do teste F é razão entre a maior variância e a menor variância expressa por:

$$F_{n_1-1, n_2-2} = \frac{S_1^2}{S_2^2} \quad (11)$$

Onde S_1^2 e S_2^2 representam a estimativa da variância das amostras 1 e 2, já que a variância da população não é conhecida.

Se a hipótese nula H_0 for rejeitada e as variâncias forem diferentes com certeza as amostras são heterogêneas e não é necessário proceder o teste t. Se as variâncias não forem estatisticamente diferentes, continua-se efetuando a comparação entre duas médias.

O teste t verifica se as duas médias são estatisticamente semelhantes levantando a hipótese nula H_0 de que as amostras possuem médias iguais, ou a hipótese H_1 de que são diferentes:

$$\begin{aligned} H_0: \mu_1 &= \mu_2 \\ H_1: \mu_1 &\neq \mu_2 \end{aligned}$$

Para isso, assumindo que os dois conjuntos de dados são duas populações normais independentes $N(\mu_1, \sigma_1^2)$ e $N(\mu_2, \sigma_2^2)$ e que se dispõe de amostras de tamanho n_1 e n_2 de cada população, cujas médias amostrais são m_1 e m_2 e as respectivas variâncias amostrais S_1^2 e S_2^2 , a estatística de teste t para verificar a hipótese nula é:

$$z = (m_1 - m_2) / \left(\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2} \right)^{\frac{1}{2}} \quad (12)$$

Se a hipótese constatar que não há diferença significativa entre as médias das amostras, considerando um nível de significância de $\alpha=0,05$, então as médias são estatisticamente semelhantes as amostras são homogêneas.

Os testes estatísticos foram realizados no ambiente Statgraphics Centurium.

Outros procedimentos e características são específicos de cada método, estes são descritos a seguir:

a) Vizinho Natural

Pelo método do vizinho natural foram geradas 6 superfícies de grade regular com tamanho de célula de 1m. Apesar de este método se basear na técnica de triangulação como explicado no item 3.5.1, a grade gerada é uma grade regular.

b) Krigagem

O resultado dessa interpolação também são 6 grades regulares com tamanho de célula de 1m.

c) Triangulação

Por este método foram geradas 6 malhas irregulares. Neste tipo de grade o ArcMap realiza uma classificação para que a representação não seja feita por pontos interligados por linhas e sim por diferentes cores, que facilitam a visualização.

d) Superfície de aproximação polinomial

Foram criados 3 algoritmos que determinaram os coeficientes das funções polinomiais biquadrática, bicúbica e biquártica, pelo método paramétrico dos mínimos quadrados, que ajustam as observações num modelo matemático.

As funções obtidas foram empregadas aos pontos de verificação para que a altitude calculada fosse comparada estatisticamente à verdade de campo, gerando matrizes de erros e coeficientes de correlação como nos demais testes.

e) Redes Neurais Artificiais

O programa MatLab possui uma biblioteca denominada *Neural Network Toolbox*. Esta biblioteca possui algoritmos utilizadas na construção, execução, visualização e simulação das redes neurais artificiais. Os diversos algoritmos que constituem o *Neural Network Toolbox* permitem trabalhar com diversos tipos de RNAs de maneira fácil e rápida, diminuindo o custo na produção destas.

Sendo assim, os testes utilizaram os métodos de aprendizado e as funções de transferência contidas neste sistema. Os métodos de aprendizado utilizados neste trabalho são:

- *Backpropagation* Levenberg-Marquardt - LM
- *Backpropagation* gradiente descendente - GD

- *Backpropagation* gradiente descendente com taxa de aprendizado adaptativa - GDA
- *Backpropagation* gradiente descendente com momento – GDM
- *Backpropagation* gradiente descendente com momento e taxa de aprendizado adaptativa - GDx
- *Backpropagation* Resilient - RP

Cada método de aprendizado foi testado com cada uma das funções de transferência disponibilizadas pelo Matlab, são elas: *logsig*, *purelin* e *tansig*.

Foram atribuídos dois critérios de parada de treinamento. Aquilo que fosse atingido primeiro parava o treinamento da rede. Os critérios são:

- Erro médio quadrático: 0.01.
- Número de iterações: 1000.

Além disso diferentes topologias de redes foram utilizadas, todas com duas camadas escondidas e com o número de neurônios na segunda camada não excedendo a 1/3 da quantidade da primeira camada, como estabelece a regra de Hilton. Foram testadas as seguintes topologias de rede:

- 24 neurônios na primeira camada e 6 na segunda.
- 30 neurônios na primeira camada e 10 na segunda.
- 96 neurônios na primeira camada e 32 na segunda.

A escolha por estas topologias aconteceu baseada nos trabalhos de Souza (2006).

Após esses testes, escolheu-se algumas das melhores redes que foram utilizadas para avaliar seus resultados com diferentes taxas de aprendizagem e diversos volumes de dados. Foram utilizadas ainda para comparação com os métodos de vizinho natural, krigagem, triangulação e aproximação polinomial.

4.3.3 Aplicação dos métodos de estimativa de altitude para área de possível escassez de informação

Os dados foram separados de modo a testar os métodos de estimativa na área de difícil acesso. Os dados contidos nessa área foram usados para verificação. Os dados aleatoriamente distribuídos - 5%, 10%, 20%, 40%, 60%, 80% - tiveram os dados da área de interesse removidos.

Tanto no ambiente ArcGis, como no Matlab, os dados dispostos de maneira a verificar a estimativa na área de interesse passam pelos mesmos processos já executados anteriormente, assim como os dados de verificação, que agora estão dispostos na área que em muitos casos existe a escassez de informação.

5 RESULTADOS E DISCUSSÃO

5.1 VIZINHO NATURAL

A aplicação do método de estimativa por vizinho natural utilizando diferentes densidades de pontos resultou nos modelos de terreno que podem ser observados nas figuras compreendidas entre os números 22 e 27. Os modelos que utilizaram maior quantidade de pontos foram os que apresentaram mais detalhes, enquanto que os modelos que utilizaram menos pontos negligenciaram algumas feições, como os bancos de areia formados pela ação das correntes em destaque na figura 22.

Os pontos de verificação (FIGURA 20 (a)) foram sobrepostos aos modelos e nesses pontos o valor de altitude estimado pelo modelo foi extraído.

As leituras nos pontos de verificação resultaram em uma matriz de altitudes estimadas, que foi comparada com a matriz das altitudes observadas em campo. A partir dessas duas matrizes foi possível calcular o coeficiente de correlação entre elas e pela diferença das duas obter o erro da estimativa, ou seja, o erro é igual ao valor calculado subtraído do valor observado em campo.

Todos os modelos apresentaram coeficiente de correlação próximos a 1, principalmente aqueles que utilizaram maior quantidade de dados, para esses as estimativas foram mais semelhantes à verdade de campo que para os demais. Nota-se que os coeficientes de correlação obtidos dos modelos que utilizaram 40% e 60% não apresentaram diferenças significativas. O mesmo aconteceu com os coeficientes de correlação obtidos dos modelos que utilizaram 60 e 80% dos dados, como pode ser observado na tabela 3.

TABELA 3 - Coeficientes de correlação encontrados pela comparação do resultado alcançado pelo método de vizinho natural aplicado as diferentes densidades e a verdade de campo, desvio padrão e variância dos erros obtidos pelo método de vizinho natural.

	Vizinho Natural 5%	Vizinho Natural 10%	Vizinho Natural 20%	Vizinho Natural 40%	Vizinho Natural 60%	Vizinho Natural 80%
Coeficiente de Correlação	0,948111	0,963613	0,969081	0,979201	0,97993	0,981786
Desvio Padrão	0,29565	0,249247	0,229156	0,188833	0,184881	0,176373
Variância	0,087409	0,062124	0,052512	0,035658	0,034181	0,031107

Para confirmar se diferentes densidades produzem resultados estatisticamente semelhantes, como sugerem os coeficientes de correlação, foram utilizados testes de hipótese de Fisher e de Student.

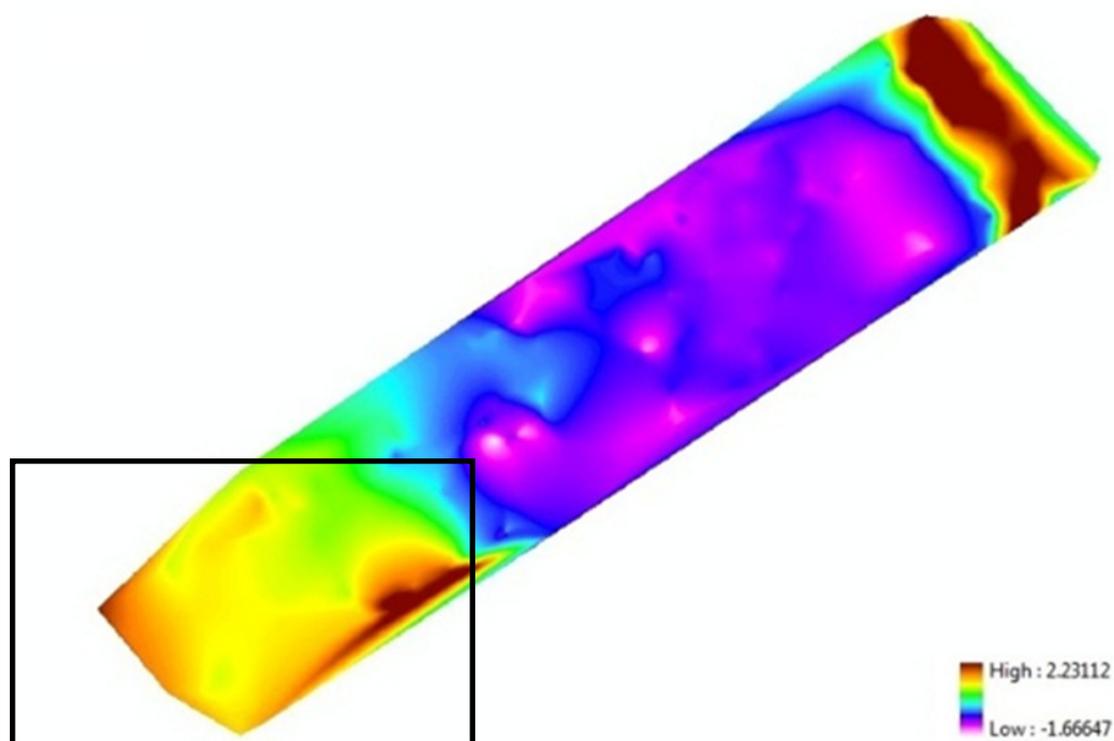


FIGURA 21 - Representação espacial do método do vizinho natural aplicado a 5% dos dados.

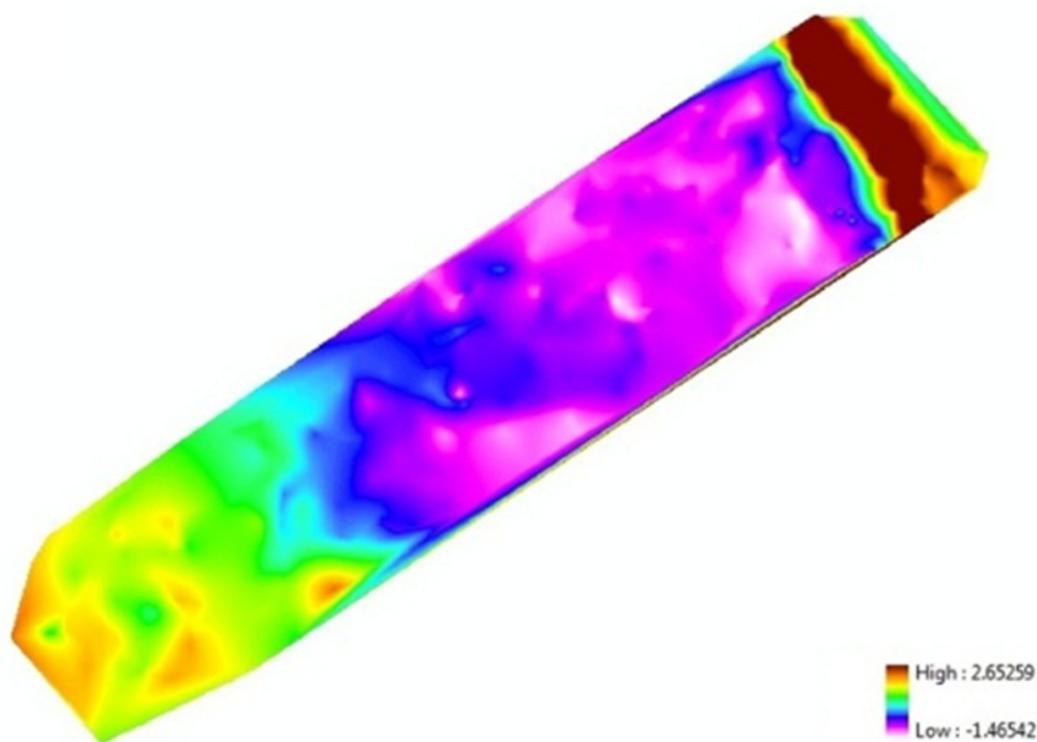


FIGURA 22 - Representação espacial do método do vizinho natural aplicado a 10% dos dados.

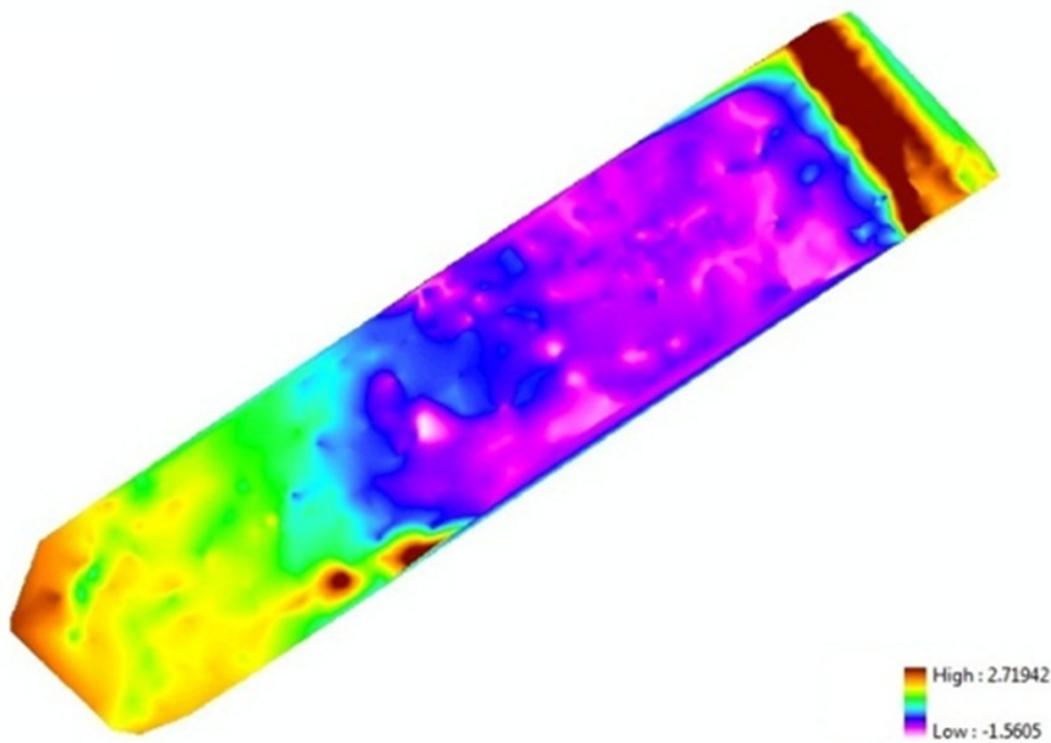


FIGURA 23 - Representação espacial do método do vizinho natural aplicado a 20% dos dados.

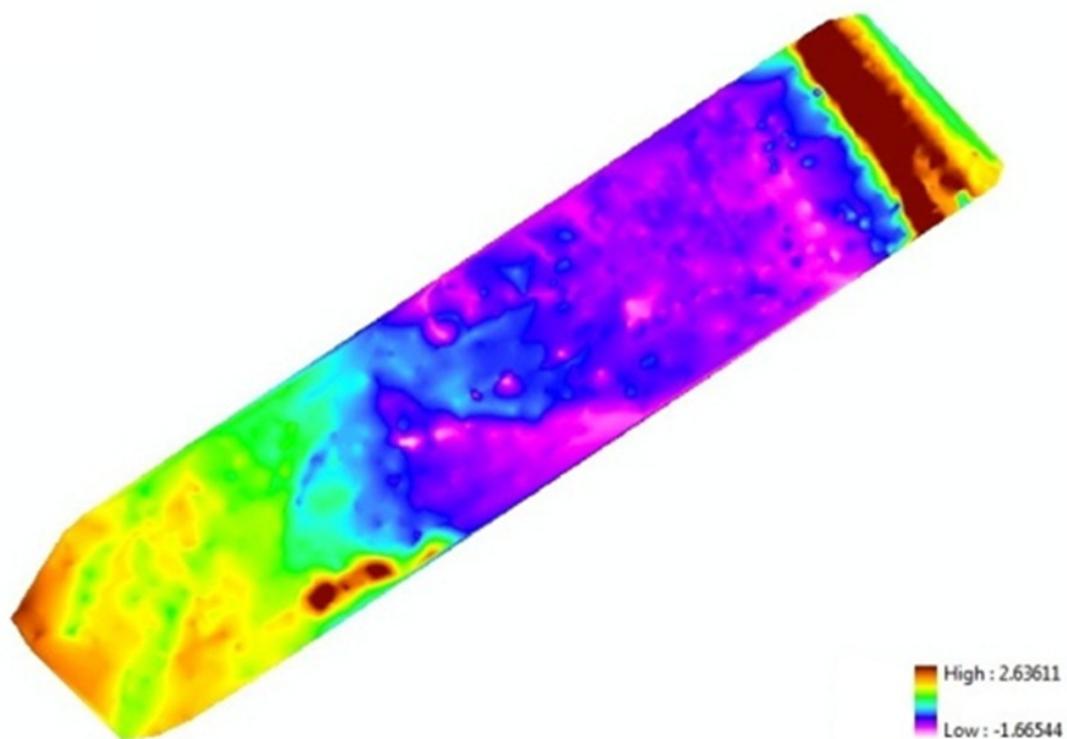


FIGURA 24 - Representação espacial do método do vizinho natural aplicado a 40% dos dados.

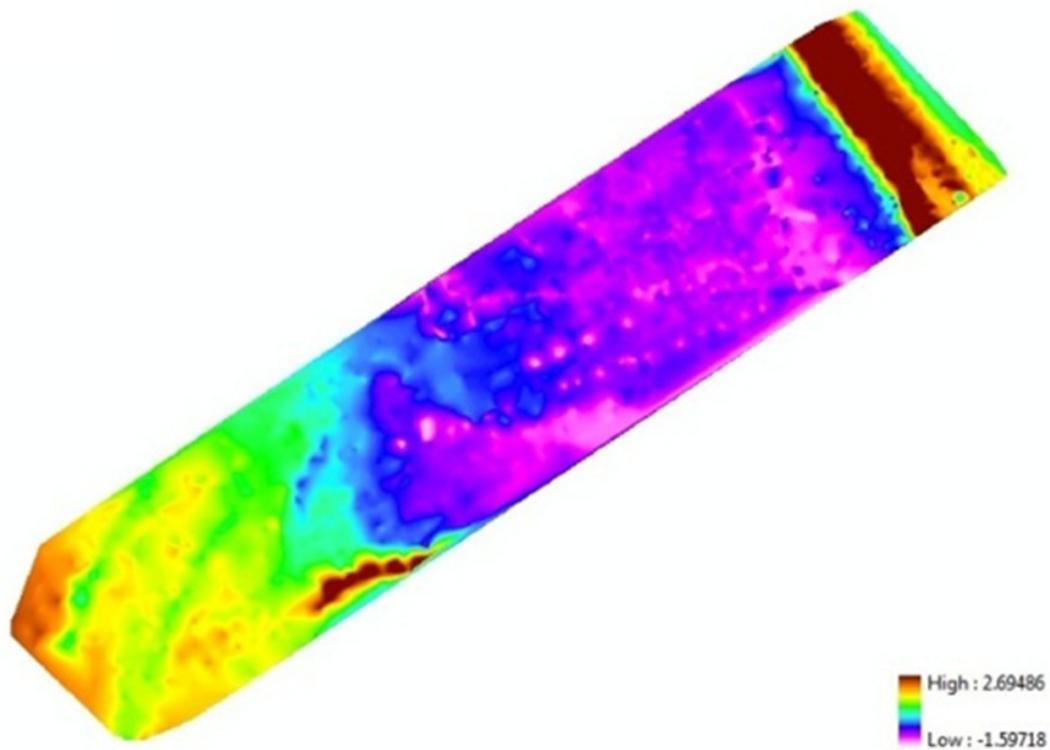


FIGURA 25 - Representação espacial do método do vizinho natural aplicado a 60% dos dados.

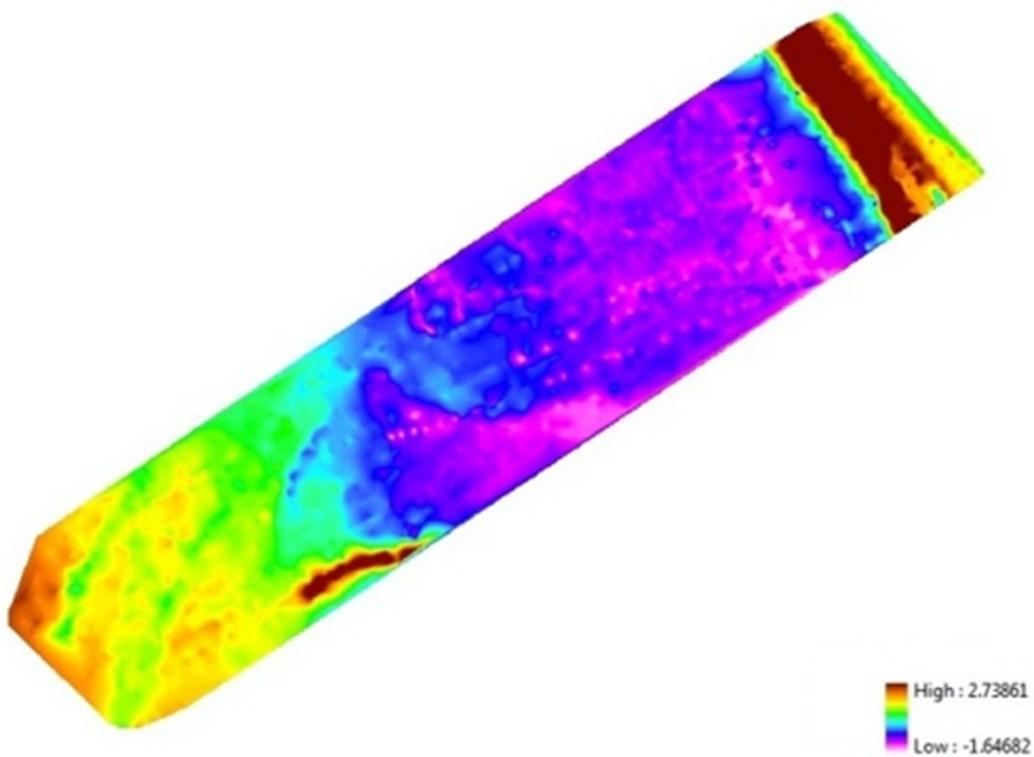


FIGURA 26 - Representação espacial do método do vizinho natural aplicado a 80% dos dados.

Os testes estatísticos, a 5% de significância, confirmaram o que os coeficientes de correlação sugeriram. Quando foram comparadas as amostras de 5%, 10% e 20% entre si e com as demais amostras os testes comprovaram que estas são estatisticamente diferentes. As comparações feitas com as amostras de 40% e 60%, e 60% e 80% aceitam a hipótese nula dos testes t e f demonstrando que as comparações não acusaram diferenças significativas entre amostras. Porém comparando a amostra 40% com a amostra 80% o teste de Fisher rejeitou a hipótese nula, demonstrando que as amostras são estatisticamente diferentes quanto à variância, ou seja, as diferenças observadas entre amostras são estatisticamente significativas. Portanto é possível que a amostragem de informações com densidade de 114 pontos por hectare (80% dos dados) produza resultados estatisticamente semelhantes a 85 pontos por hectare (60% dos dados). Sendo assim, uma coleta com esforços reduzidos pode atingir o mesmo resultado que uma coleta mais prolongada sem a coleta de informações redundantes.

5.2 KRIGAGEM

A aplicação do método de estimativa por krigagem utilizando diferentes densidades de pontos resultou nos modelos de terreno que podem ser observados nas figuras compreendidas entre os números 28 e 33. Os modelos que utilizaram maior quantidade de pontos foram os que apresentaram mais feições, enquanto que algumas delas não foram observadas nos modelos que utilizaram menos pontos, como já havia acontecido com o método de vizinho natural.

Os pontos de verificação (FIGURA 20 (a)) foram sobrepostos aos modelos e nesses pontos o valor de altitude estimado pelo modelo foi extraído.

As leituras nos pontos de verificação resultaram em uma matriz de altitudes estimadas, que foi comparada com a matriz das altitudes observadas em campo. A partir dessas duas matrizes foi possível calcular o coeficiente de correlação entre elas e pela diferença das duas obter o erro da estimativa, ou seja, o erro é igual ao valor calculado subtraído do valor observado em campo.

Os coeficientes de correlação obtidos com o método de krigagem (TABELA 4) foram todos bastante próximos ao ideal de 1 e também muito semelhantes ao método de vizinho natural. Neste caso novamente parece não haver diferenças significativas entre os coeficientes obtidos com os modelos que utilizaram 40 e 60% dos dados, nem entre os coeficientes obtidos com os modelos que utilizaram 60 e 80% dos dados. Essas semelhanças também podem ser observadas nos modelos espaciais (FIGURAS 28 a 33), pode-se notar que as diferenças não são fortemente destacadas entre os modelos.

TABELA 4 - Coeficientes de correlação encontrados pela comparação do resultado alcançado pelo método de krigagem aplicado as diferentes densidades e a verdade de campo, desvio padrão e variância dos erros obtidos pelo método de krigagem.

	Krigagem 5%	Krigagem 10%	Krigagem 20%	Krigagem 40%	Krigagem 60%	Krigagem 80%
Coeficiente de Correlação	0,945973	0,96271	0,974504	0,980554	0,981437	0,982297
Desvio Padrão	0,310189	0,251174	0,208646	0,182378	0,178283	0,174331
Variância	0,096217	0,063088	0,043533	0,033262	0,031785	0,030391

Para verificar se os coeficientes de correlação muito semelhantes são de amostras estatisticamente semelhantes foram empregados os teste f e t para o método de krigagem. Nas comparações foram realizadas a 5% de significância. Comparando as amostras 05%, 10% e 20% umas com as outras e, com as amostras de 40%, 60% e 80% houve a rejeição da hipótese nula para o teste de Fisher. As amostras de 05%, 10% e 20% produzem resultados que não se assemelham estatisticamente aos resultados obtidos com nenhuma das outras densidades.

Nas comparações entre as amostras 40%, 60% e 80% com elas mesmas houve a aceitação da hipótese nula para o teste de Fisher e de Student, provando então que estas amostras são estatisticamente semelhantes. Neste caso os esforços de amostragem poderiam ser ainda mais reduzidos, pois a densidade de 57 pontos por hectare (40 % dos dados) produziu resultados semelhantes a 114 pontos por hectare (80% dos dados).

Com o método de vizinho natural a redução de esforços, sem perda na qualidade do resultado, foi de 114 pontos por hectare para 85 pontos por hectare. Já o método de krigagem proporcionou uma redução do esforço ainda maior, para 57 pontos por hectare. Isso indica a melhor capacidade do método de estimativa utilizado pela krigagem em relação ao método de vizinho natural.

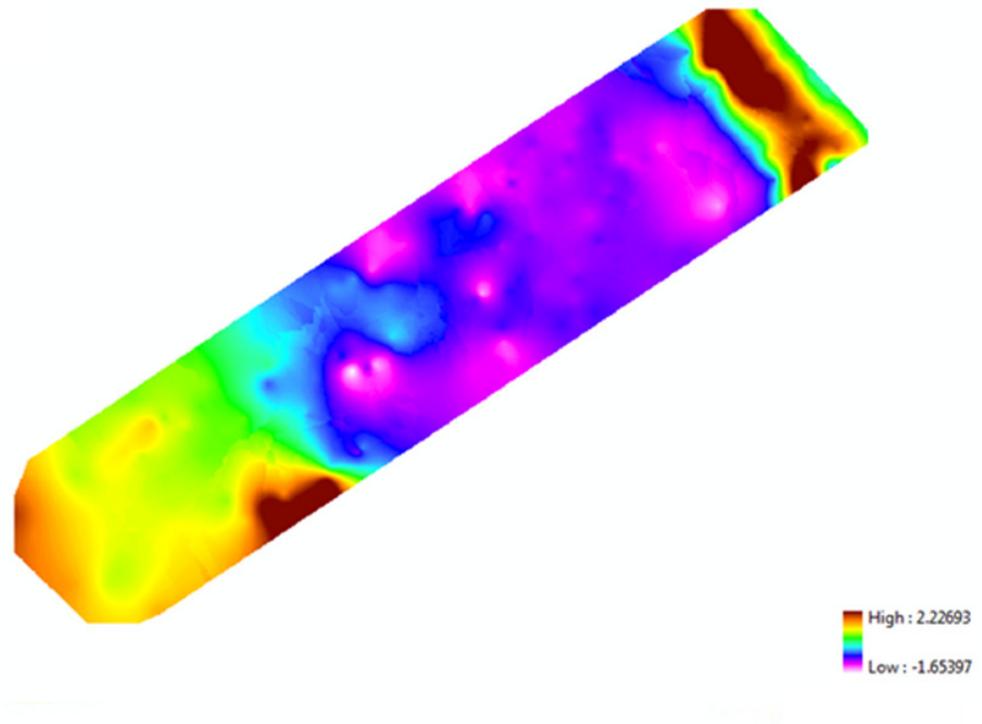


FIGURA 27 - Representação espacial do método de krigagem aplicado a 5% dos dados.

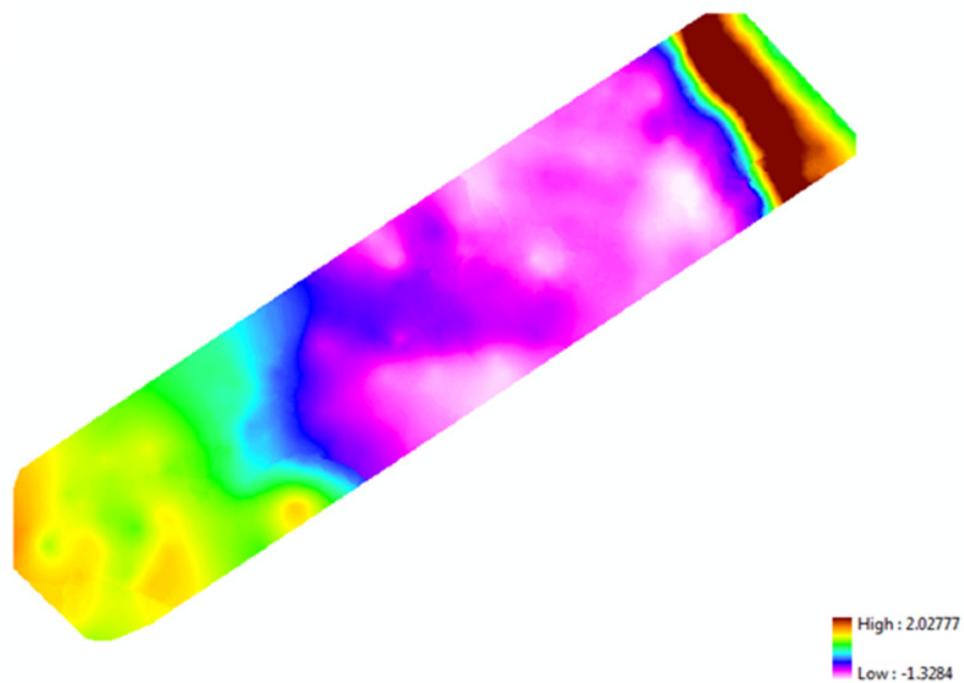


FIGURA 28 - Representação espacial do método de krigagem aplicado a 10% dos dados.

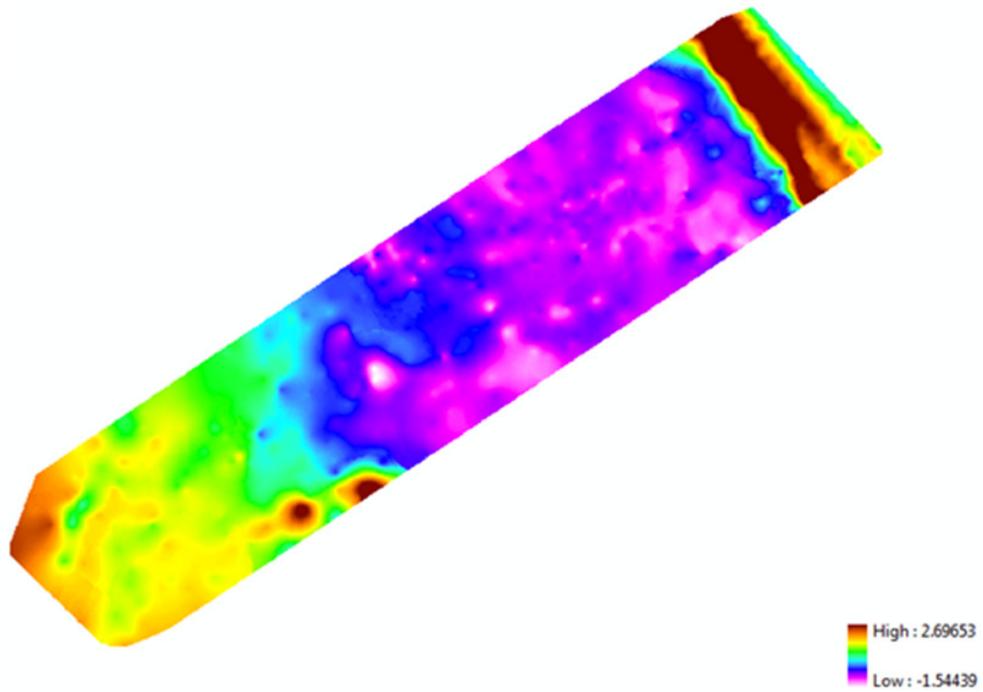


FIGURA 29 - Representação espacial do método de krigagem aplicado a 20% dos dados.

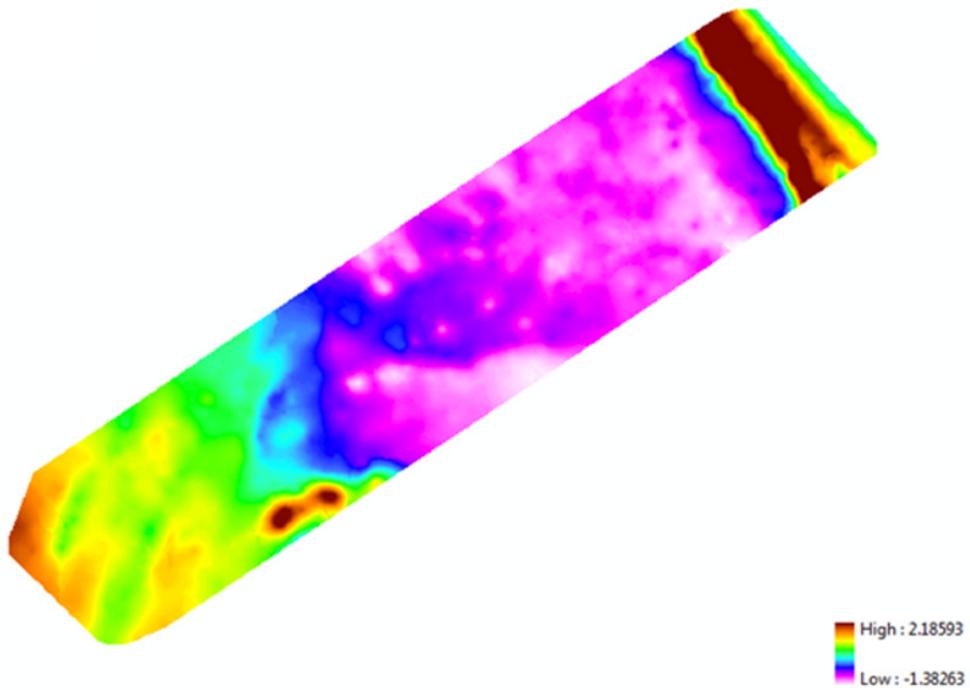


FIGURA 30 - Representação espacial do método de krigagem aplicado a 40% dos dados.

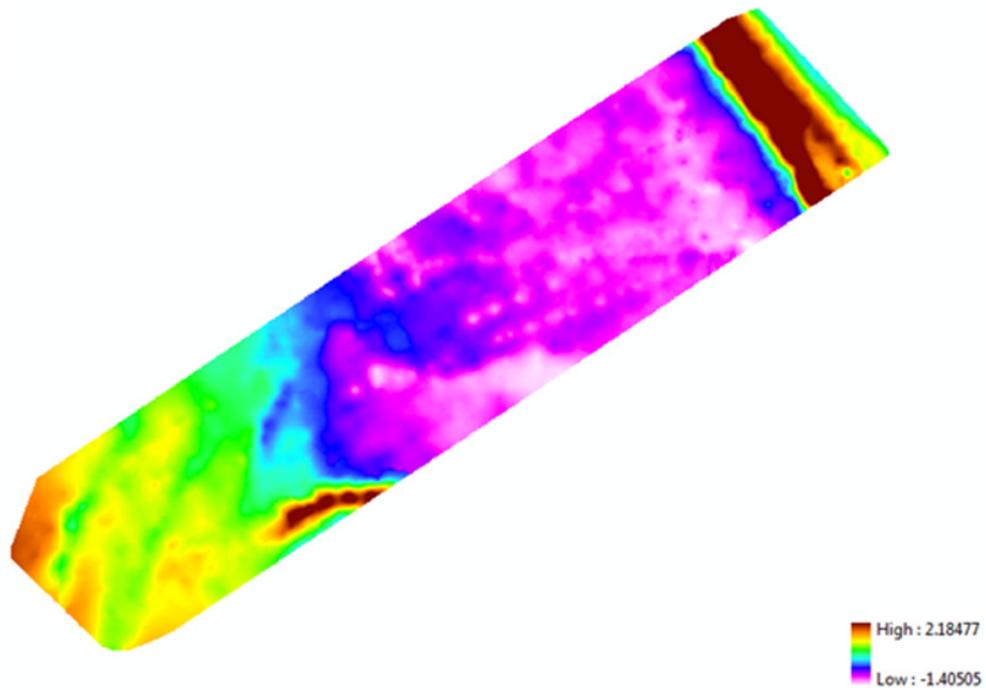


FIGURA 31 - Representação espacial do método de krigagem aplicado a 60% dos dados.

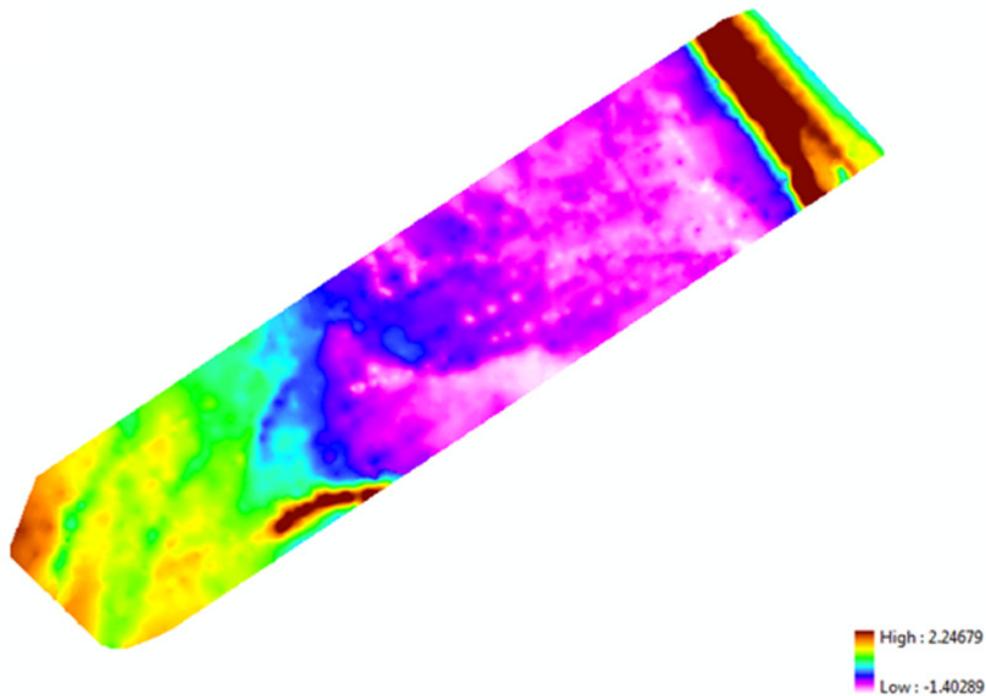


FIGURA 32 - Representação espacial do método de krigagem aplicado a 80% dos dados.

5.3 TRIANGULAÇÃO

A aplicação do método de estimativa por triangulação utilizando diferentes densidades de pontos resultou nos modelos de terreno que podem ser observados nas figuras compreendidas entre os números 34 e 39. Neste modelos as feições são mais retalhadas e angulares dos que as feições obtidas com os métodos de vizinho natural e krigagem.

Os pontos de verificação (FIGURA 20 (a)) foram sobrepostos aos modelos e nesses pontos o valor de altitude estimado pelo modelo foi extraído.

As leituras nos pontos de verificação resultaram em uma matriz de altitudes estimadas, que foi comparada com a matriz das altitudes observadas em campo. A partir dessas duas matrizes foi possível calcular o coeficiente de correlação entre elas e pela diferença das duas obter o erro da estimativa, ou seja, o erro é igual ao valor calculado subtraído do valor observado em campo.

Os coeficientes de correlação para o método TIN apresentaram valores bastante próximos a 1, estes podem ser observados na tabela 5. Os coeficientes demonstram que, quando se utiliza 10% dos dados, os resultados são semelhantes de quando se utiliza 20% dos dados, porém esta semelhança não se confirma espacialmente. Com 40, 60 e 80% dos dados, tanto os coeficientes de correlação, como os modelos espaciais, produzem resultados semelhantes.

TABELA 5 - Coeficientes de correlação encontrados pela comparação do resultado alcançado pelo método de triangulação aplicado as diferentes densidades e a verdade de campo, desvio padrão e variância dos erros obtidos pelo método de triangulação.

	Triangulação 5%	Triangulação 10%	Triangulação 20%	Triangulação 40%	Triangulação 60%	Triangulação 80%
Coeficiente de Correlação	0,947022	0,963582	0,967683	0,978476	0,978674	0,980922
Desvio Padrão	0,299384	0,250159	0,233918	0,192172	0,190617	0,180608
Variância	0,08963	0,06258	0,054718	0,03693	0,036335	0,032619

Para verificar se as amostras realmente produziram resultados semelhantes realizou-se a comparação estatística entre as amostras pelos testes de Fisher e Student, a significância de 5%. Houve a rejeição da hipótese nula do teste de Fisher para as amostras 5%, 10% e 20% comparadas entre elas mesmas e as demais. Porém, houve a aceitação da hipótese nula, tanto para o teste de Fisher como para o teste de Student, quando as amostras de 40%, 60% e 80 % foram comparadas entre si. Neste método, assim como aconteceu na krigagem, os esforços de amostragem podem ser reduzidos a 57 pontos por hectare (40% dos dados), revelando que este método produziu resultado superior ao método de vizinho natural na estimativa de altitudes.



FIGURA 33 - Representação espacial do método de triangulação aplicado a 5% dos dados.

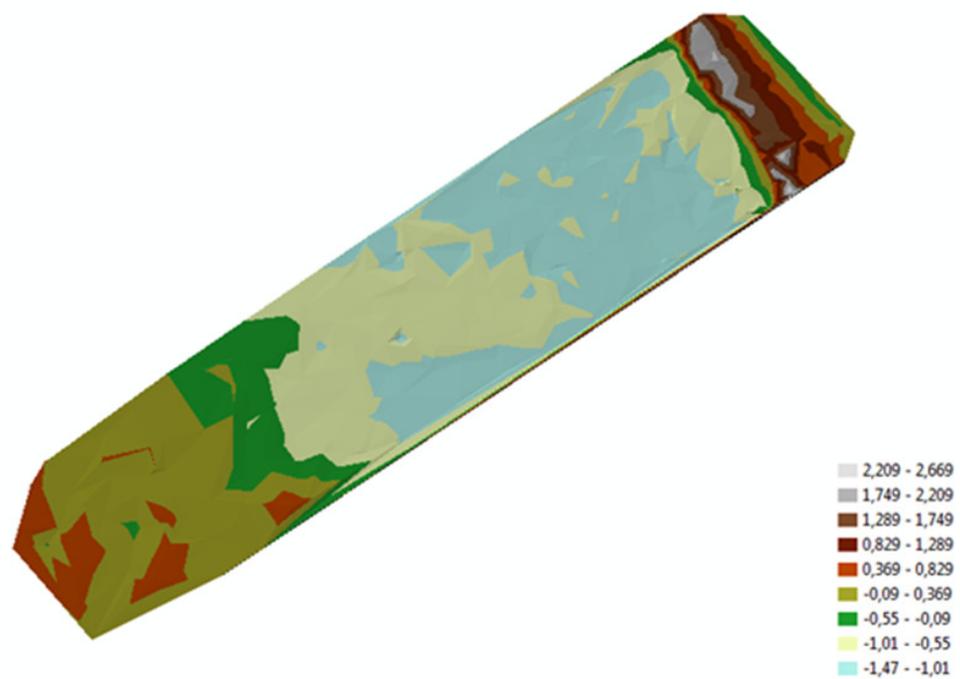


FIGURA 34 - Representação espacial do método de triangulação aplicado a 10% dos dados.

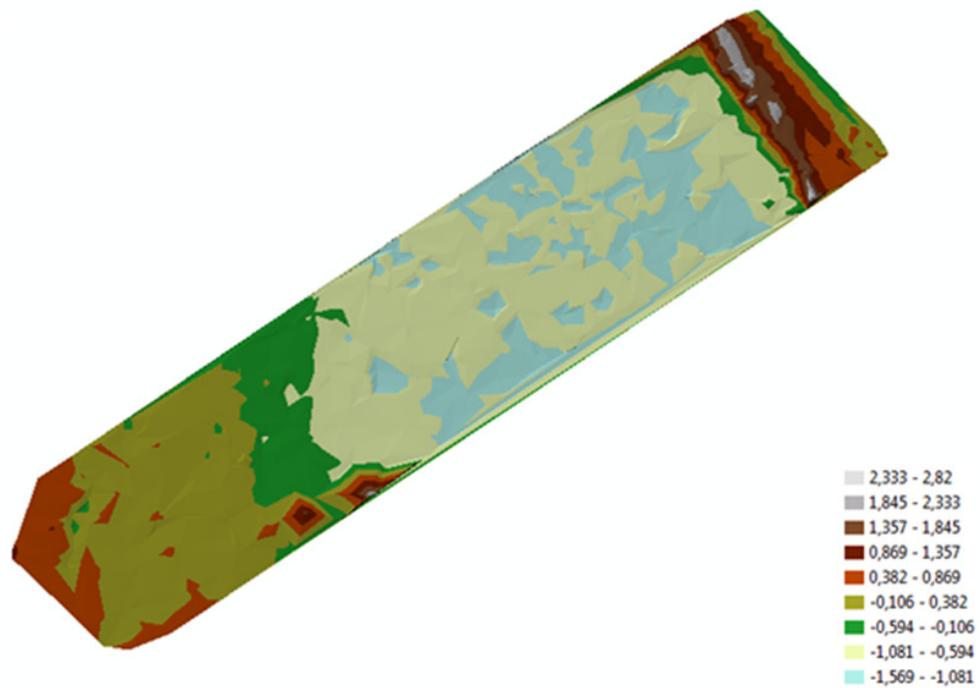


FIGURA 35 - Representação espacial do método de triangulação aplicado a 20% dos dados.

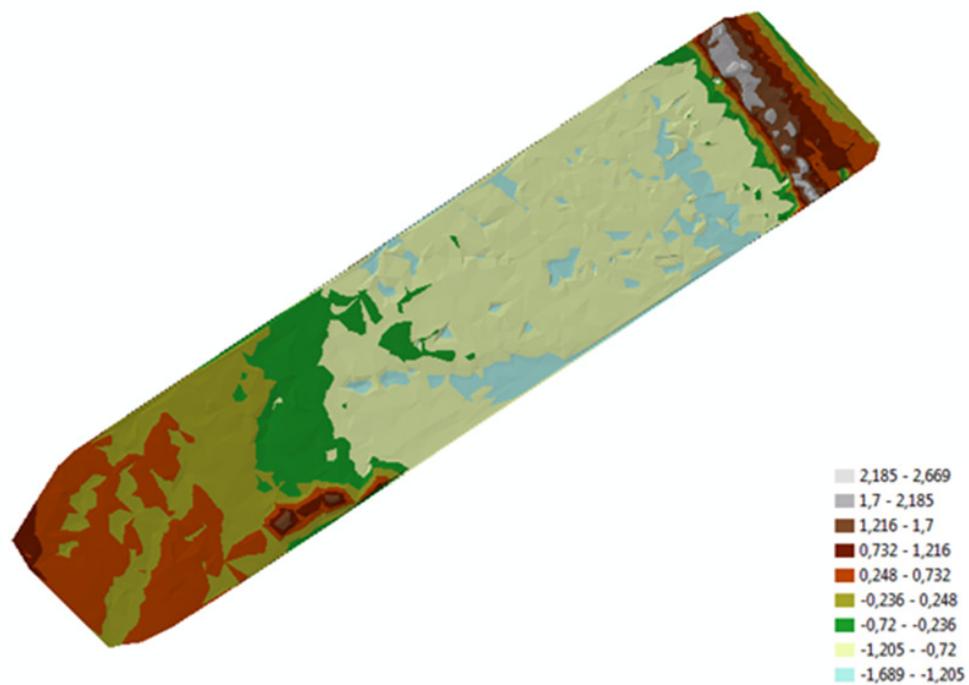


FIGURA 36 - Representação espacial do método de triangulação aplicado a 40% dos dados.

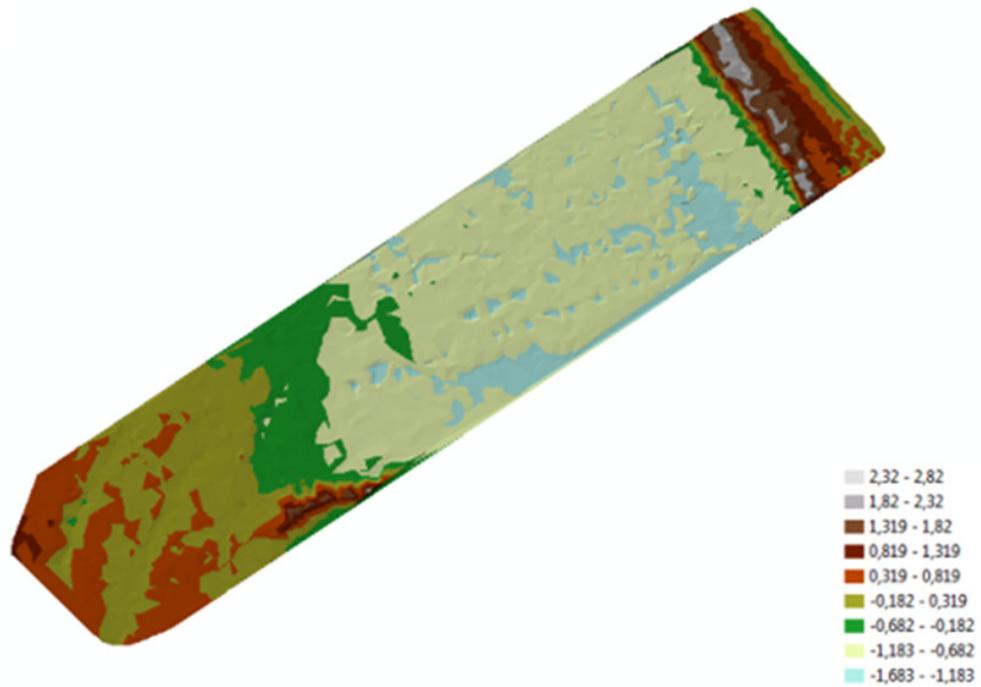


FIGURA 37 - Representação espacial do método de triangulação aplicado a 60% dos dados.

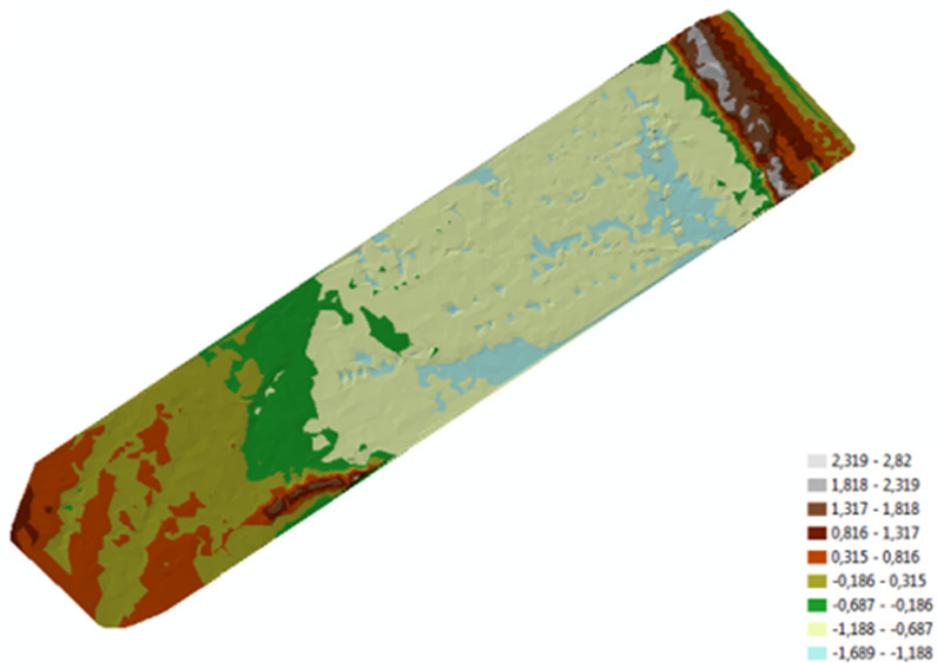


FIGURA 38 – Representação espacial do método de triangulação aplicado a 80% dos dados.

5.4 SUPERFÍCIE DE APROXIMAÇÃO POLINOMIAL

Foram criados, no MatLab, 3 algoritmos que determinaram os coeficientes das funções polinomiais capazes de ajustar os pontos amostrados a uma superfície. Estes algoritmos se baseiam no método paramétrico de ajuste por mínimos quadrados para determinar os coeficientes.

Os coeficientes encontrados para a função biquadrática, bicúbica e biquártica usando diferentes proporções da quantidade total de dados estão dispostos nas tabelas 6, 7 e 8.

TABELA 6 - Coeficientes das funções polinomiais biquadráticas ajustadas com 5%, 10%, 20%, 30%, 40%, 60% e 80%.

Coeficientes	5%	10%	20%	40%	60%	80%
a	-1,2531E-24	-3,044E-24	-1,7886E-24	-1,5922E-24	-1,6569E-24	-1,7538E-24
b	5,8454E-18	1,4144E-17	8,524E-18	7,4176E-18	7,7653E-18	8,2045E-18
c	-4,8398E-18	-1,1754E-17	-6,9181E-18	-6,149E-18	-6,4012E-18	-6,775E-18
d	9,7491E-12	2,3597E-11	1,4193E-11	1,2372E-11	1,2946E-11	1,3681E-11
e	4,512E-11	1,0921E-10	6,569E-11	5,7262E-11	5,9919E-11	6,3317E-11
f	-4,9647E-12	-1,2008E-11	-7,2249E-12	-6,2988E-12	-6,5901E-12	-6,9638E-12

TABELA 7 - Coeficientes das funções polinomiais bicúbicas ajustadas com 5%, 10%, 20%, 30%, 40%, 60% e 80%.

Coeficientes	5%	10%	20%	40%	60%	80%
a	-3,5569E-38	-8,6402E-38	-5,074E-38	-4,5193E-38	-4,7022E-38	-4,9775E-38
b	1,075E-31	2,5427E-31	1,5191E-31	1,3163E-31	1,3356E-31	1,4617E-31
c	-1,7532E-31	-4,2424E-31	-2,4893E-31	-2,2247E-31	-2,3088E-31	-2,4397E-31
d	1,8268E-25	4,4202E-25	2,6614E-25	2,3181E-25	2,4261E-25	2,5635E-25
e	8,1427E-25	1,9699E-24	1,1873E-24	1,0332E-24	1,0816E-24	1,1428E-24
f	-6,7423E-25	-1,6371E-24	-9,6365E-25	-8,5655E-25	-8,9167E-25	-9,4372E-25
g	2,1921E-19	5,305E-19	3,1911E-19	2,7817E-19	2,9107E-19	3,0758E-19
h	1,3581E-18	3,2865E-18	1,977E-18	1,7234E-18	1,8033E-18	1,9055E-18
i	6,2853E-18	1,5211E-17	9,1498E-18	7,9761E-18	8,346E-18	8,8192E-18
j	-6,9185E-19	-1,6731E-18	-1,0067E-18	-8,7771E-19	-9,1829E-19	-9,7035E-19

As funções obtidas foram então utilizadas novamente com os pontos de verificação para comparar a altitude calculada pelo modelo matemático à verdade de campo. Estas comparações geraram coeficientes de correlação que estão dispostos nas tabelas 9, 10 e 11.

Os coeficientes de correlação apresentaram valores muito distantes do ideal valor de 1, demonstrando que o método não foi capaz de ajustar os dados a um modelo mais realista do observado em campo. Em decorrência disso, os demais testes estatísticos com as matrizes de erros não foram realizados, nem este método foi comparado aos demais.

TABELA 8 - Coeficientes das funções polinomiais biquárticas ajustadas com 5%, 10%, 20%, 30%, 40%, 60% e 80%.

Coeficientes	5%	10%	20%	40%	60%	80%
a	-9,0996E-52	-2,2102E-51	-1,2976E-51	-1,1561E-51	-1,2028E-51	-1,2732E-51
b	-4,634E-40	1,697E-39	-3,2814E-40	4,6087E-40	-3,492E-40	-3,1629E-40
c	-3,1116E-49	-2,8158E-49	-2,8703E-49	-2,9278E-49	-2,6024E-49	-2,6937E-49
d	3,4224E-39	8,2784E-39	4,9896E-39	4,3422E-39	4,5456E-39	4,8026E-39
e	1,4626E-38	3,5365E-38	2,1364E-38	1,8555E-38	1,9434E-38	2,053E-38
f	-2,4343E-38	-5,9118E-38	-3,4741E-38	-3,0927E-38	-3,2182E-38	-3,4065E-38
g	4,1624E-33	1,0071E-32	6,0618E-33	5,2815E-33	5,5271E-33	5,8402E-33
h	2,5476E-32	6,1634E-32	3,7111E-32	3,2325E-32	3,3831E-32	3,5747E-32
i	1,1356E-31	2,7468E-31	1,6556E-31	1,4408E-31	1,5083E-31	1,5935E-31
j	-9,4026E-32	-2,2827E-31	-1,3437E-31	-1,1944E-31	-1,2434E-31	-1,316E-31
k	4,3819E-27	1,0603E-26	6,3782E-27	5,5601E-27	5,8179E-27	6,1478E-27
l	3,0571E-26	7,397E-26	4,4497E-26	3,879E-26	4,0589E-26	4,289E-26
m	1,8939E-25	4,5826E-25	2,7567E-25	2,4032E-25	2,5146E-25	2,6572E-25
n	8,7654E-25	2,1209E-24	1,2759E-24	1,1122E-24	1,1638E-24	1,2298E-24
o	-9,6485E-26	-2,3329E-25	-1,4038E-25	-1,224E-25	-1,2805E-25	-1,3531E-25

TABELA 9 - Coeficientes de correlação encontrados pela comparação do resultado atingido pelo método de aproximação polinomial com função biquadrática ajustando 5%, 10%, 20%, 30%, 40%, 60% e 80% e a verdade de campo.

	2° grau 5%	2° grau 10%	2° grau 20%	2° grau 40%	2° grau 60%	2° grau 80%
Coeficiente de correlação	0,181207	0,181211	0,181209	0,181209	0,181209	0,181209

TABELA 10 - Coeficientes de correlação encontrados pela comparação do resultado atingido pelo método de aproximação polinomial com função bicúbica ajustando 5%, 10%, 20%, 30%, 40%, 60% e 80% e a verdade de campo.

	3° grau 5%	3° grau 10%	3° grau 20%	3° grau 40%	3° grau 60%	3° grau 80%
Coeficiente de correlação	0,181220	0,181227	0,181225	0,181223	0,181224	0,181224

TABELA 11 - Coeficientes de correlação encontrados pela comparação do resultado atingido pelo método de aproximação polinomial com função biquártica ajustando 5%, 10%, 20%, 30%, 40%, 60% e 80% e a verdade de campo.

	4° grau 5%	4° grau 10%	4° grau 20%	4° grau 40%	4° grau 60%	4° grau 80%
Coeficiente de correlação	0,181234	0,181243	0,181240	0,181236	0,181239	0,181239

Mesmo assim os dados foram representados espacialmente com a aplicação das funções aos pontos centrais de uma grade regular com geometria igual à grade gerada pelo método da krigagem. Todos os modelos apresentaram formas muito semelhantes não sendo possível destacar diferenças entre eles, muito menos as feições que foram possíveis reconhecer nos métodos de vizinho natural, krigagem e triangulação. Um exemplo destes modelos é mostrado na figura 40.

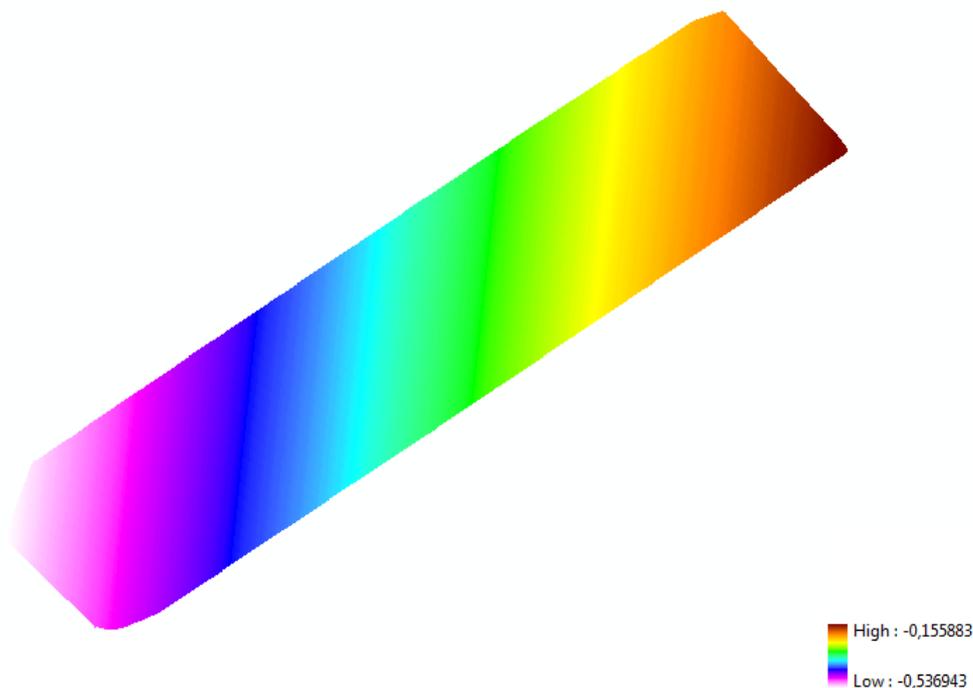


FIGURA 39 - Representação espacial do método de aproximação polinomial aplicando a função biquadrática a 5% dos dados.

5.5 REDES NEURAIS ARTIFICIAIS

Os procedimentos com redes neurais tiveram início com teses para verificar qual a melhor método de aprendizado e função de ativação. Para isso foi criada uma sequência de comandos padrão para todos os testes. A esta se aplicam os 6 métodos de aprendizado testados e também as 3 funções de transferência. Nesta fase foram treinadas três topologias de rede com a proporção de 80% do total dos dados.

As topologias testadas possuem 2 camadas escondidas. O código apresentado na coluna Rede (TABELA 12) segue o exemplo da rede 2461 que corresponde a rede com 24 células na primeira camada escondida e 6 na segunda, seguindo a regra de Hilton (1989, *apud* Souza, 2006) que estabelece que a segunda camada deve ter 1/3 da quantidade de células contida na camada anterior. Cada RNA é testada por 3 vezes para alterar os pesos iniciais usados pela rede, por isso ao final de cada código pode haver “1” para o primeiro treinamento, “2” para o segundo ou “3” para o terceiro.

As tabelas 12, 13 e 14 mostram as diferentes topologias de redes treinadas (coluna Redes), a função de ativação (purelin, logsig, tansig), o método de aprendizado (LM, GD, GDA, GDM, GDX, RP) e o valor do coeficiente de correlação calculado entre a verdade de campo dos pontos de verificação e os dados obtidos das redes para os mesmos pontos.

TABELA 12 - Coeficientes de correlação obtidos pela aplicação de diferentes topologias de rede e métodos de aprendizado utilizando a função de transferencia Purelin.

Purelin						
Rede	LM	GD	GDA	GDM	GDX	RP
2461	0,1970	-----	0,1999	-----	0,2003	0,1955
2462	0,1939	-----	0,0013	-----	0,1308	0,1973
2463	0,1966	-----	0,1360	-----	0,0866	0,1953
30101	0,1970	-----	0,2004	-----	0,0486	0,1987
30102	0,1936	-----	0,1732	-----	0,1957	0,1991
30103	0,1927	-----	0,1648	-----	0,1770	0,1860
96321	0,1947	-----	-0,0932	-----	-0,0219	0,1988
96322	0,2002	-----	0,1145	-----	0,1045	0,1845
96323	0,1964	-----	0,0750	-----	0,1963	0,1954

TABELA 13 - Coeficientes de correlação obtidos pela aplicação de diferentes topologias de rede e métodos de aprendizado utilizando a função de transferencia Logsig.

Logsig						
	LM	GD	GDA	GDM	GDX	RP
2461	-3.96e-016	0,1803	0,0894	0,1029	0,5191	0,3854
2462	0,6307	0,5509	0,5785	0,1933	0,7288	0,6264
2463	0,0043	0,6442	0,5252	0,1838	0,6024	0,5856
30101	-3.96e-017	0,5332	0,3081	0,7057	0,1805	0,6168
30102	-3.96e-017	0,6714	0,6344	-0,0495	0,2019	0,4097
30103	-0,0098	0,5033	0,0176	0,5742	0,2094	0,5208
96321	-0,1107	0,4755	0,6274	0,4877	0,0724	0,6270
96322	0,7290	0,3996	0,7088	0,1935	0,1281	0,5903
96323	-3.96e-017	0,2058	0,7078	0,1652	0,6980	0,5678

TABELA 14 - Coeficientes de correlação obtidos pela aplicação de diferentes topologias de rede e métodos de aprendizado utilizando a função de transferencia Tansig.

Tansig						
	LM	GD	GDA	GDM	GDX	RP
2461	0,9619	0,2427	0,8301	0,1379	0,8637	0,9582
2462	0,9037	0,9488	0,8187	0,9597	0,9181	0,9567
2463	0,9003	0,8801	0,8540	0,9559	0,8887	0,9610
30101	0,9646	0,6738	0,8232	0,6302	0,8890	0,9601
30102	0,9625	0,8007	0,8409	-0,6149	0,5870	0,9604
30103	0,9611	0,4068	0,7891	0,7208	0,7497	0,9625
96321	0,9570	0,6189	0,8280	-0,2028	0,1523	0,2834
96322	0,9598	0,6785	0,2100	0,1347	0,6712	0,9630
96323	0,6924	0,5617	0,2215	0,1024	0,2251	0,9601

As melhores redes são aquelas que geram os coeficientes de correlação mais próximos a 1. As redes que apresentaram melhores coeficientes de correlação foram

as redes treinadas com a função de ativação tansig. As funções purelin e logsig não atingiram resultados satisfatórios. Além disso os métodos de aprendizado que se mostraram mais eficientes foram o LM e RP.

Utilizando somente a função tansig e os métodos de aprendizado selecionados no teste anterior, o teste seguinte busca a melhor taxa de aprendizagem. Quanto menor se fizer a taxa de aprendizagem, tanto menor será a mudança nos pesos sinápticos da rede de uma iteração para a próxima. Por outro lado, quanto maior for a taxa de aprendizagem, maior será a mudança nos pesos sinápticos de uma iteração para a outra. Neste caso, a rede pode se tornar instável, isto é, oscilatória.

Foram testadas as mesmas redes do teste anterior com excessão da rede com 96 neuronios na primeira camada e 32 na segunda camada que se mostrou muito lenta durante o processamento e não apresentou melhoras significativas em relação as demais. Os resultados são apresentados na tabela 15 e 16, que recebe as mesmas códigos de topologia de rede e método de aprendizado da tabela 12. Os valores encontrados no topo da tabela, abaixo do método de aprendizado, se referem as taxas de aprendizagem aplicadas.

TABELA 15 - Coeficientes de correlação obtidos pela aplicação de RNA com método de aprendizado LM e diferentes taxas de aprendizagem.

	LM					
	0,01	0,025	0,1	0,2	0,3	0,8
2461	0.9619	0.9615	0.9616	0.6369	0.9611	-6.95e-017
2462	0.9037	0.9622	0.9622	0.9619	0.9566	0.9640
2463	0.9003	0.9624	0.9023	0.9618	0.9614	0.9603
30101	0.9646	0.9617	0.9630	0.9623	0.9601	0.9651
30102	0.9625	0.1746	0.9651	0.9649	0.9654	0.9627
30103	0.9611	0.9618	0.9523	0.9612	0.9642	0.9635

TABELA 16 - Coeficientes de correlação obtidos pela aplicação de RNA com método de aprendizado LM e diferentes taxas de aprendizagem.

	RP					
	0,01	0,025	0,1	0,2	0,3	0,8
2461	0.9612	0.9624	0.9592	0.9617	0.9516	0.9620
2462	0.9591	0.9607	0.9587	0.9438	0.9563	0.9611
2463	0.9597	0.9643	0.9622	0.9589	0.9634	0.9569
30101	0.9611	0.9589	0.9601	0.9609	0.9607	0.9610
30102	0.9592	0.9639	0.9621	0.9581	0.9619	0.9611
30103	0.9599	0.9612	0.9644	0.9594	0.9616	0.9640

De acordo com as tabelas 15 e 16, todos os testes apresentaram coeficientes de correlação próximos a 1 em um dos três treinamentos realizados para a mesma topologia. Em algumas topologias o coeficiente de correlação é próximo a 1 nos três treinamentos, em outras topologias somente dois treinamentos apresentaram coeficientes de correlação próximos a 1.

Foram escolhidas seis redes para serem representadas espacialmente. Para determinar as seis melhores redes calculou-se a média dos resultados obtidos empregando cada taxa de aprendizagem. Foram selecionadas três taxas de aprendizagem que apresentaram as melhores médias para cada um dos métodos de aprendizagem. Assim, para o método LM as melhores taxas foram: 0,01, 0,1, 0,3 e para o método RP as melhores taxas foram: 0,025, 0,1 e 0,8.

Para criar as representações espaciais os pontos centrais de uma grade regular com geometria igual à criada pela krigagem tiveram suas altitudes interpoladas pelas redes neurais de 2 camadas escondidas, sendo que a primeira camada contém 30 neurônios e a segunda contém 10. Estas foram treinadas com os diferentes métodos de aprendizagem e com as diferentes taxas de aprendizagem selecionadas anteriormente. As figuras 41 a 46 a seguir correspondem a representação espacial das redes selecionadas anteriormente.

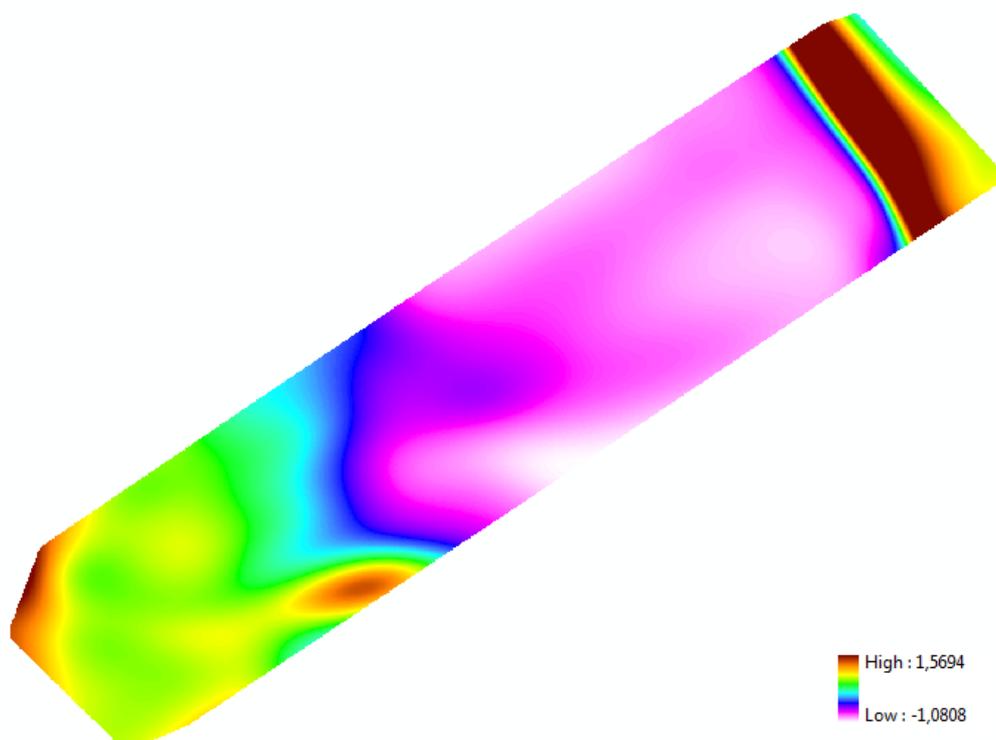


Figura 40 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizagem LM com taxa de aprendizagem de 0.01 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda.

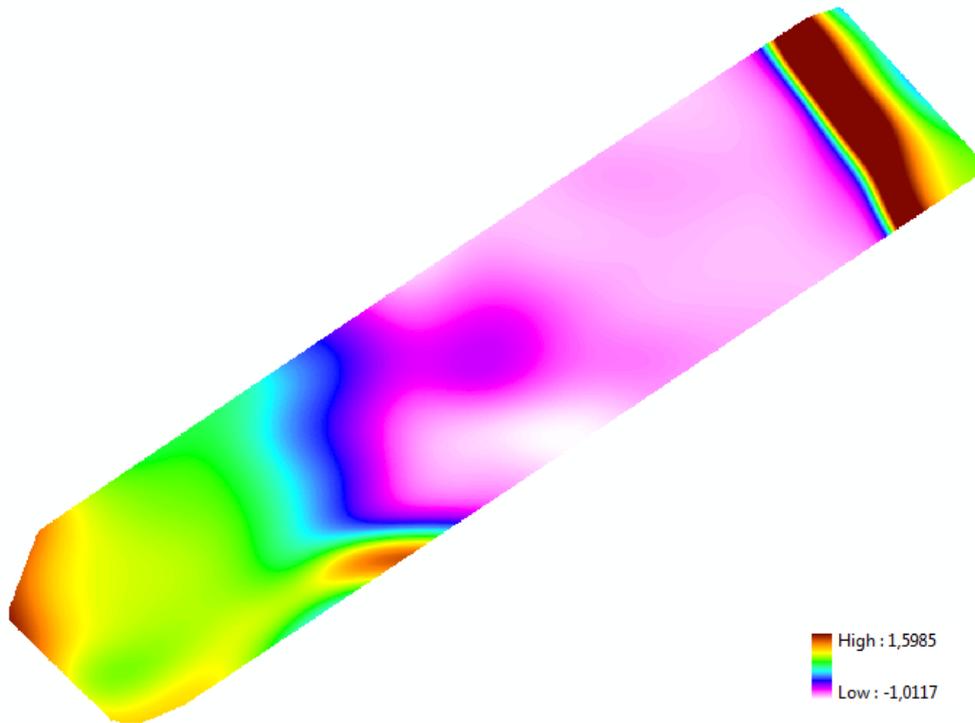


Figura 41 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado LM com taxa de aprendizagem de 0.1 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda.

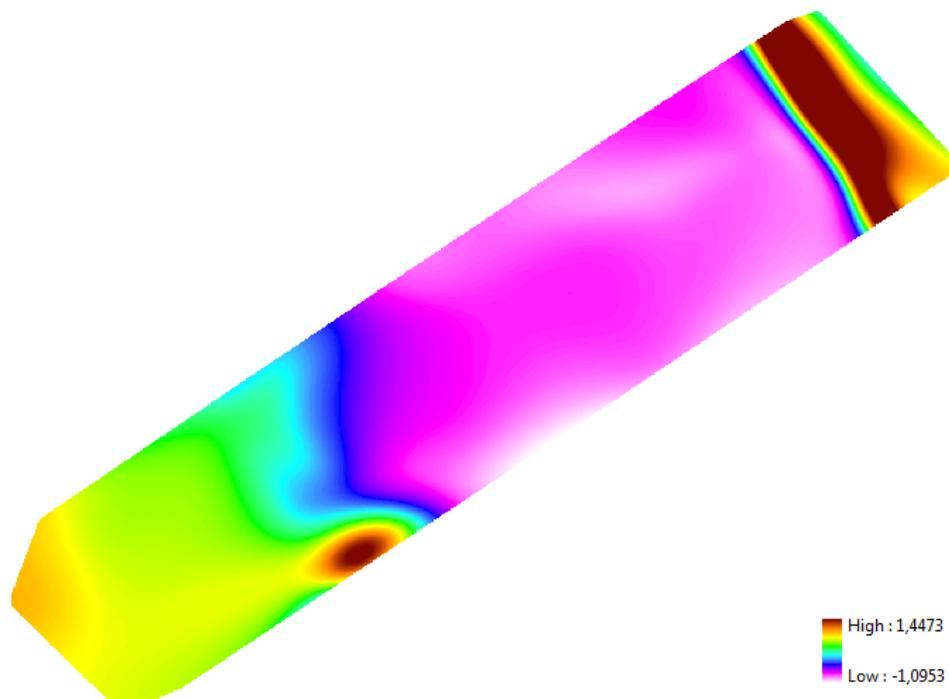


Figura 42- Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado LM com taxa de aprendizagem de 0.3 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda.

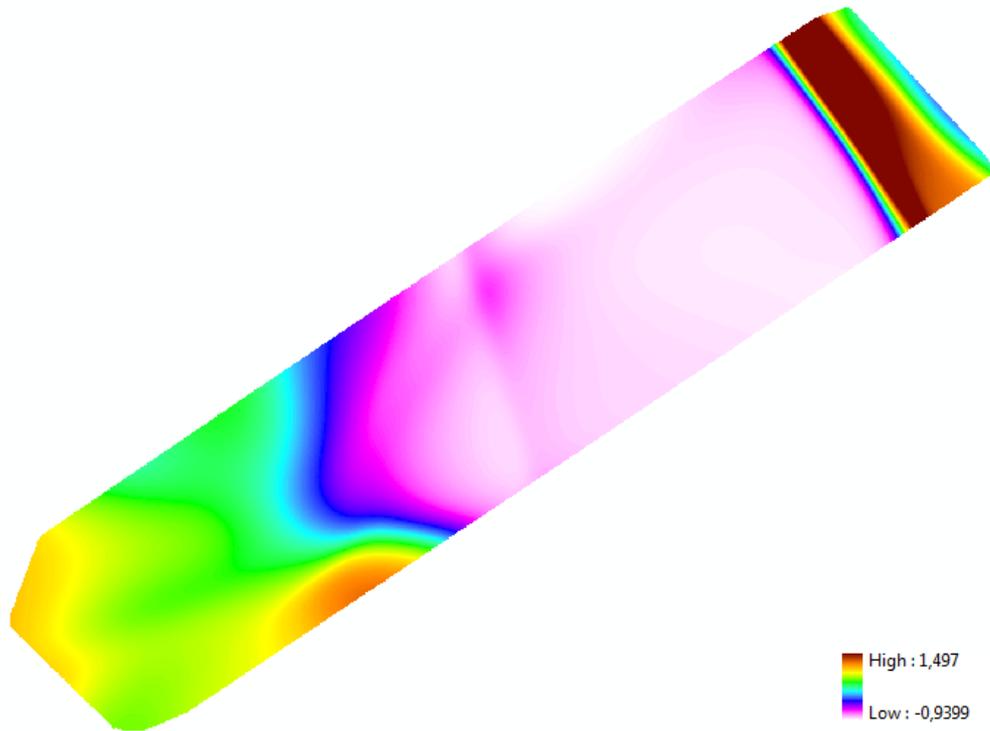


Figura 43 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.025 e topologia de 24 neurônios na primeira camada escondida e 6 na segunda.

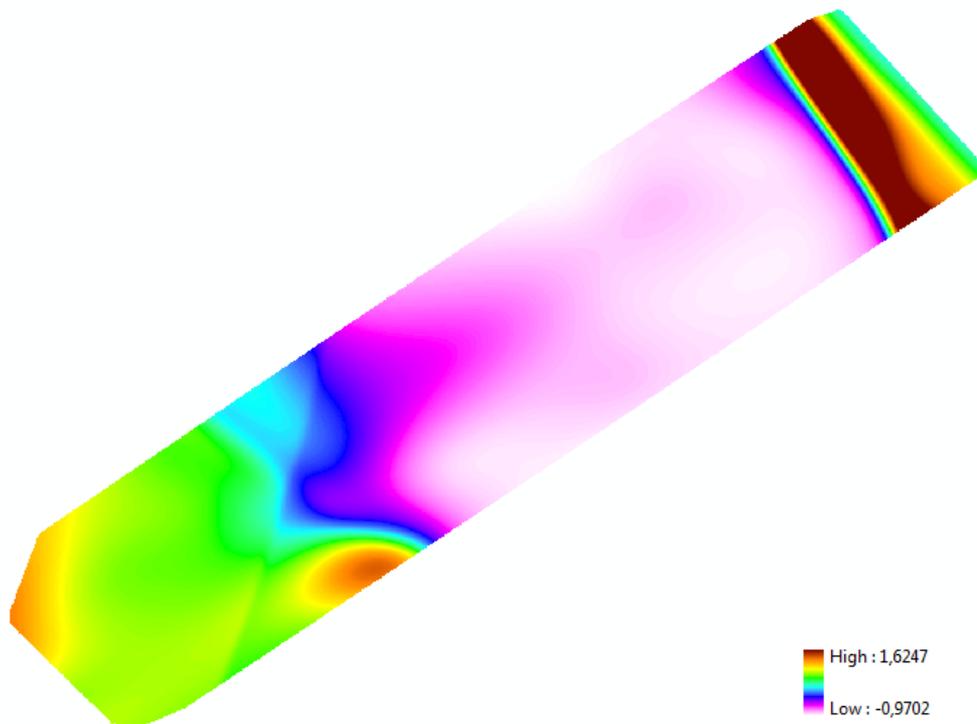


Figura 44 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.1 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda.

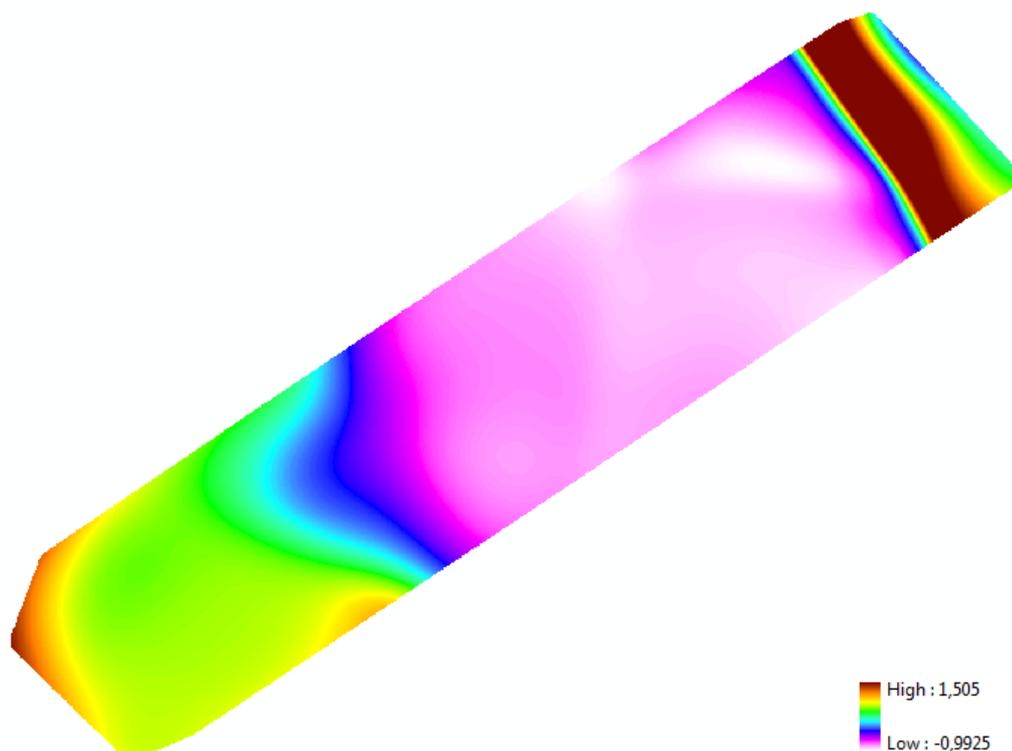


Figura 45 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizado de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda.

As representações espaciais das figuras 40 a 45 parecem revelar que o método LM produziu superfícies mais acidentada que as superfícies produzidas pelo método RP. Alguns bancos de areia estão mais destacados pelas superfícies criadas por LM do que as criadas pela rede RP.

A fase seguinte irá considerar somente a topologia de rede com 30 neurônios na primeira camada escondida e 10 neurônios na segunda camada. Das seis redes selecionadas anteriormente, quatro foram utilizadas para dar sequência aos testes. Foram escolhidas as redes com maior e menor taxa de aprendizado para aplicar os dados com diferentes distribuições. Espera-se observar se diferentes taxas de aprendizagem podem responder melhor a diferentes densidades de dados.

A análise da influência da densidade dos dados sobre uma mesma topologia de rede aplicando diferentes métodos de aprendizado com diversas taxa de aprendizagem teve início com a elaboração da tabela 17.

Tabela 17 - Coeficientes de correlação obtidos pela aplicação de diferentes métodos de aprendizado e taxas de aprendizagem.

	LM 0.01					
	05%	10%	20%	40%	60%	80%
30101	0.1792	-6.95 e-017	0.0411	0.9717	0.9697	0.9646
30102	0.9205	0.9439	0.9633	0.9708	0.9700	0.9625
30103	0.8591	0.9450	0.9651	0.9719	0.9693	0.9611
	LM 0.3					
	05%	10%	20%	40%	60%	80%
30101	-1.7075e-017	-0.0610	0.9584	0.9751	0.7159	0.9601
30102	0.8662	0.9461	0.9648	0.9735	0.1350	0.9654
30103	0.9164	0.7903	0.9621	0.9751	0.9707	0.9642
	RP 0.025					
	05%	10%	20%	40%	60%	80%
30101	0.8495	0.9504	0.9614	0.9709	0.9629	0.9589
30102	0.9075	0.9519	0.9604	0.9667	0.9628	0.9639
30103	0.8769	0.9467	0.9636	0.9695	0.9614	0.9612
	RP 0.8					
	05%	10%	20%	40%	60%	80%
30101	0.8495	0.9504	0.9614	0.9709	0.9629	0.9610
30102	0.9075	0.9519	0.9604	0.9667	0.9628	0.9611
30103	0.8892	0.9198	0.9636	0.9695	0.9614	0.9640

De acordo com a tabela 17, nos testes que utilizaram o método LM, pode-se notar que para baixas densidades os resultados não foram consistentes como com o método RP. Resultados satisfatórios foram alcançados pela rede LM porém eles não aconteceram para as três repetições de cada teste. Pode-se observar ainda que com 60% dos dados e taxa de 0.3 o método LM não se mostrou eficiente pois o coeficiente de correlação foi superior a 0.90 somente em uma das três repetições.

Já nas redes RP, mesmo com baixa densidade de dados, os coeficientes de correlação não atingiram valores inferiores a 0.80, reforçando que o método RP é realmente mais constante.

Foram selecionadas as redes RP com taxa de 0.8 treinadas com diferentes densidades de dados para terem seus resultados representados espacialmente. Os pontos centrais de uma grade regular com geometria igual à criada pela krigagem tiveram suas altitudes interpoladas por estas redes. A representação espacial pode ser observada nas figuras 46 a 51 a seguir.

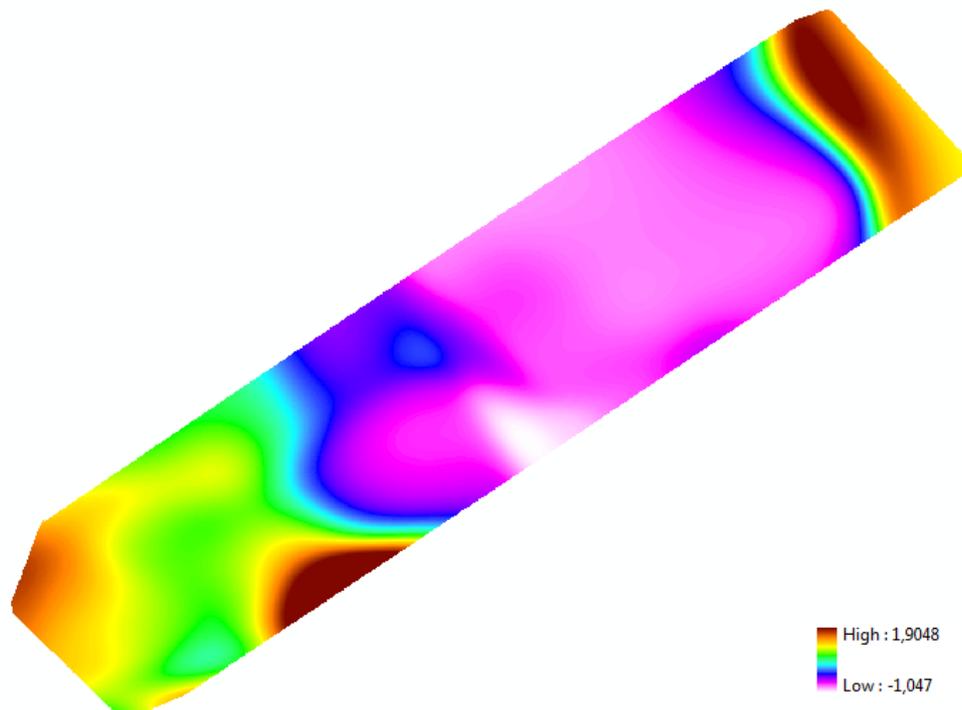


Figura 46- Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda e foi treinada com 5% dos dados.

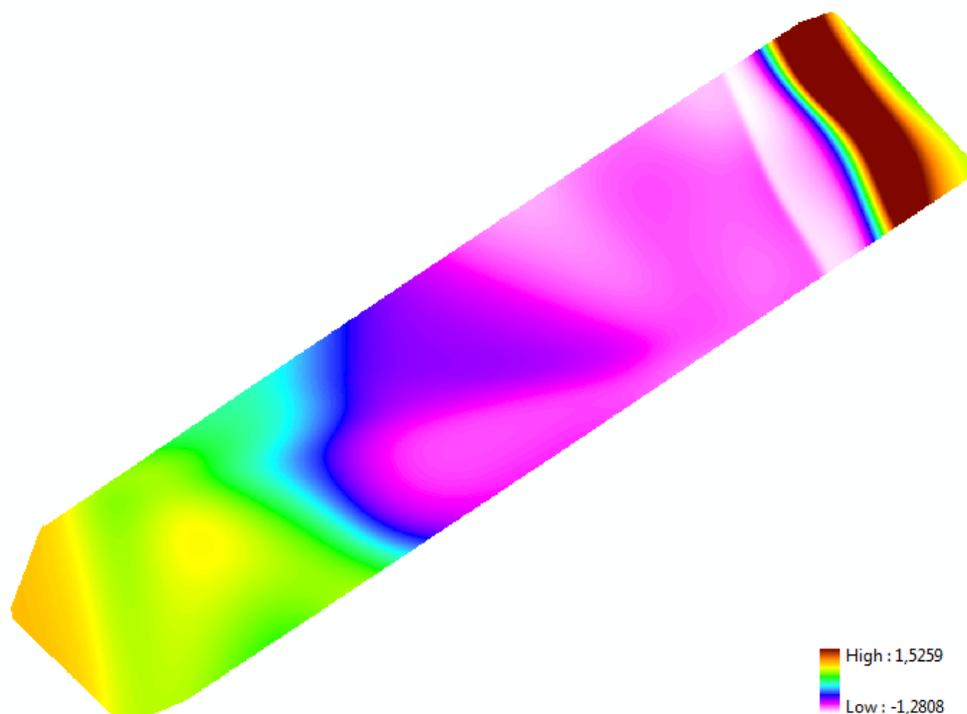


Figura 47 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda e foi treinada com 10% dos dados.

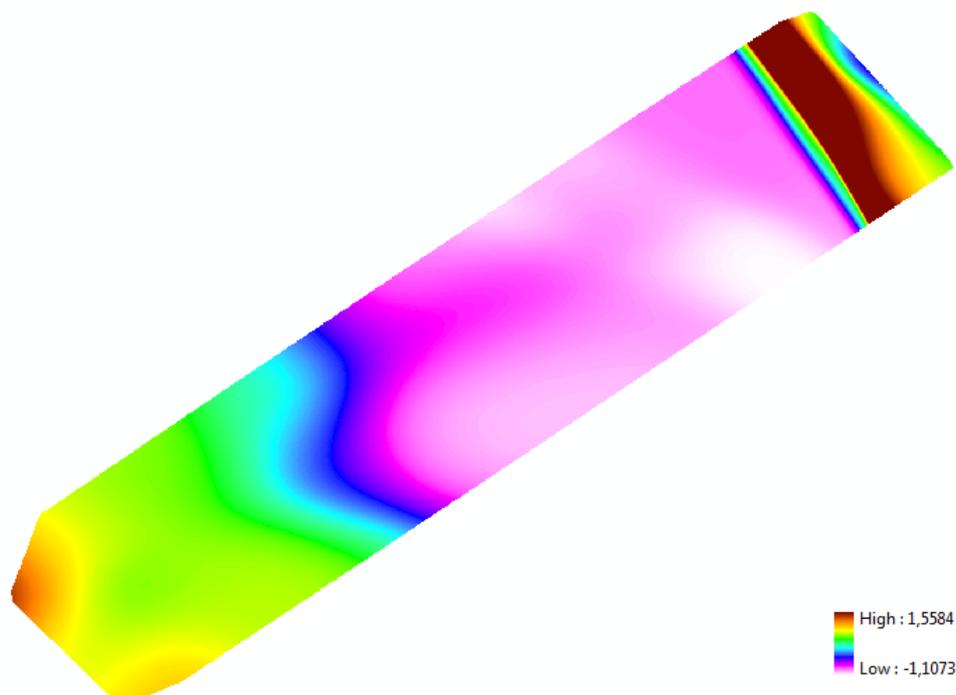


Figura 48 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda e foi treinada com 20% dos dados

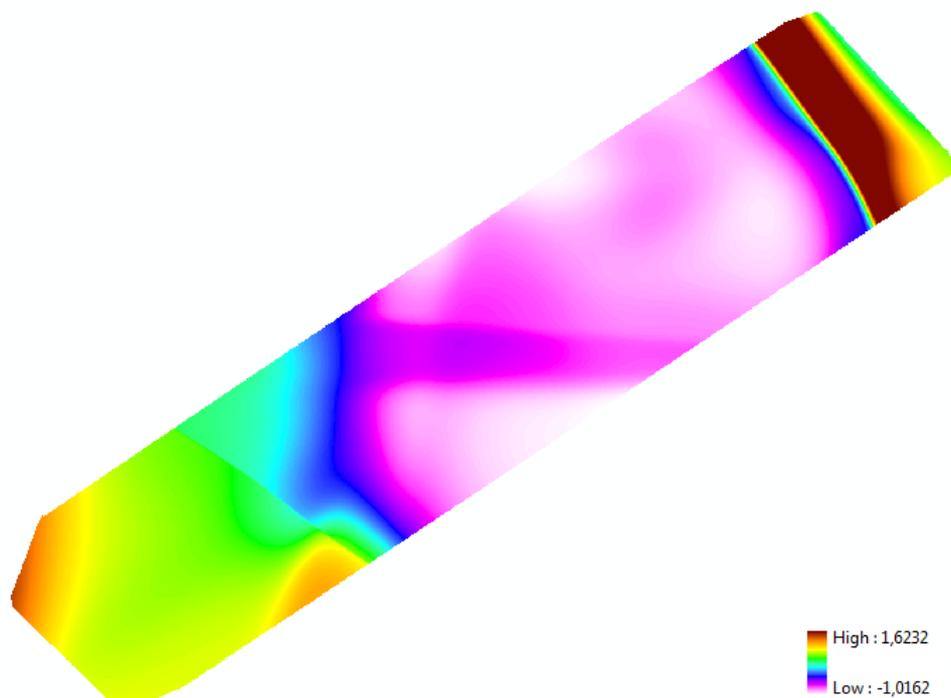


Figura 49 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda e foi treinada com 40% dos dados

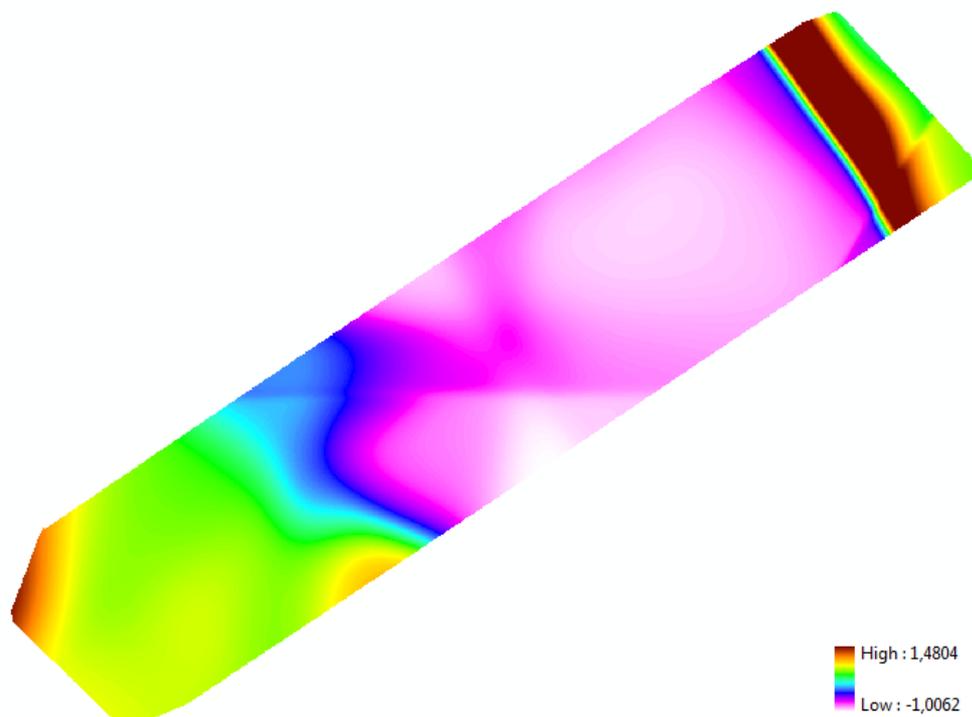


Figura 50 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda e foi treinada com 60% dos dados.

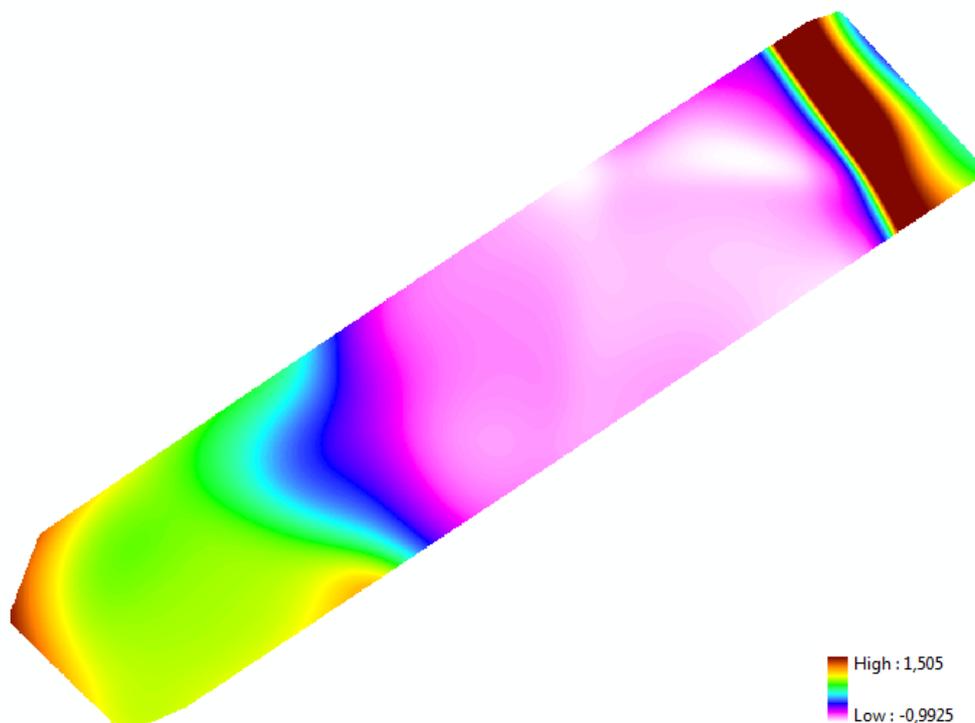


Figura 51 - Representação espacial dos resultados obtidos com uma RNA que utilizou o método de aprendizado RP com taxa de aprendizagem de 0.8 e topologia de 30 neurônios na primeira camada escondida e 10 na segunda e foi treinada com 80% dos dados.

Os erros calculados pelos resultados obtidos com essas redes subtraídos da verdade de campo passaram pelo teste de Fisher e de Student. Os desvios padrões e variâncias destes podem ser observados na tabela 18.

Tabela 18 - Desvio padrão e variâncias dos testes com redes neurais artificiais que apresentaram maior coeficiente de correlação para as redes treinadas com diferentes densidade de dados de entrada.

	RN 5%	RN 10%	RN 20%	RN 40%	RN 60%	RN 80%
Desvio Padrão	0,390908	0.290206	0.249457	0.222694	0.256298	0.252743
Variância	0.152809	0.0842198	0.062229	0.0495928	0.0656885	0.063879

Os testes estatísticos foram aplicados a 5% de significância e se verificou que, com exceção da comparação 60 % com 80%, todas as demais amostras tiveram as hipóteses nulas rejeitadas para os teste de Fisher ou Student e, na maioria dos casos, para os dois testes. A amostras que demonstraram ser estatisticamente semelhantes foram as amostras de 60% com relação a de 80%.

Nos testes com os métodos de krigagem e triangulação foi observado que 40% dos dados poderiam produzir resultados semelhantes, isso poderia reduzir o esforço de coleta de informações pela metade. Com as redes neurais se observou que esse esforço não pode ser tão reduzido, pois somente 60% dos dados, e não 40%, produzem resultados semelhante a 80% dos dados. Utilizando o método de redes neurais artificiais, 85 pontos por hectare produzem resultados semelhantes do que quando se usando 114 pontos por hectare. Esse resultado é o mesmo atingido pelo método de vizinho natural.

5.6 COMPARAÇÃO DOS MÉTODOS DE ESTIMATIVA

Ao final destes experimentos, o método de redes neurais artificiais foi comparado aos demais métodos com o auxílio dos testes de Fisher e de Student. As comparações realizadas podem ser observadas na figura 66. As redes neurais RP com taxa de aprendizado de 0.8 treinadas com todas as densidades de dados estão listadas na primeira caixa da figura. Cada item desta caixa foi comparado a cada item da segunda caixa, que corresponde aos testes feitos utilizando os outros métodos e cada uma das densidades testadas.

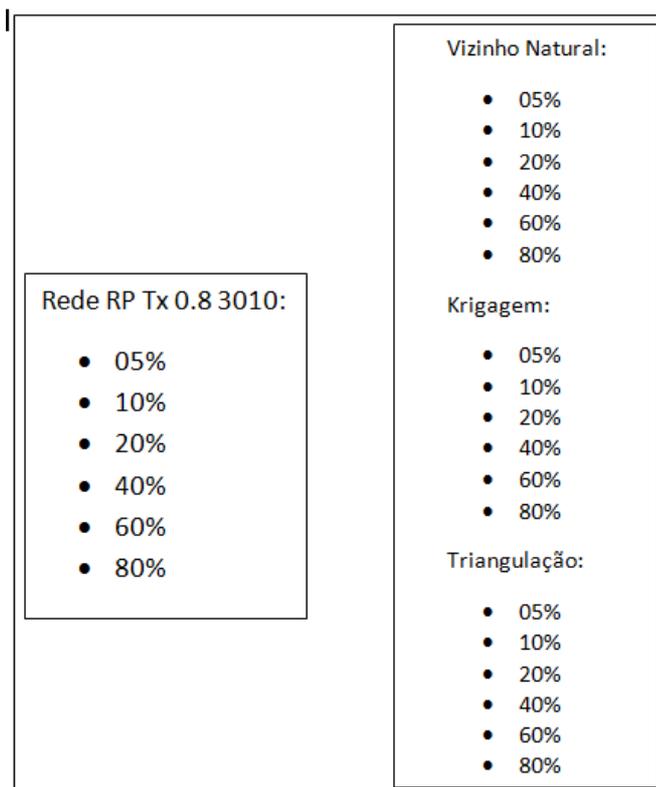


FIGURA 52 - Caixas demonstrando os métodos e densidades (caixa 2) que foram comparadas as redes neurais (caixa 1).

Observou-se que nenhum dos itens que constam na primeira caixa da figura 52 é estatisticamente semelhantes aos itens que constam na segunda coluna, todos rejeitaram a hipótese nula dos testes de Fisher ou de Student. Sendo assim o método de redes neurais produzem resultados estatisticamente diferentes a todos os resultados produzidos pelos métodos de vizinho natural, krigagem e triangulação, seja qual for a densidade utilizada.

As únicas hipóteses nulas que foram aceitas para os testes de Fisher e de Student, envolvendo redes neurais artificiais, são comparações entre as próprias redes neurais de diferentes densidades, ou seja, a rede que utilizou 60% dos dados para treinamento é estatisticamente semelhante à rede que usou 80% dos dados durante o treinamento, como já havia sido revelado no item 5.5.

5.7 APLICAÇÃO DOS MÉTODOS DE ESTIMATIVA DE ALTITUDE PARA ÁREA DE POSSÍVEL ESCASSEZ DE INFORMAÇÃO

Os testes executados até agora se mostram promissores na estimativa de altitude, porém, estes utilizaram dados distribuídos por toda área de estudo. Isso não implica que os resultados serão satisfatórios quando os dados forem organizados de maneira que não compreendam a área de maior dificuldade na coleta das informações batimétricas e geodésicas.

Para estes testes todos os pontos contidos na área de difícil acesso foram removidos dos dados que são usados na estimativa e passaram a fazer parte dos dados de verificação. Os pontos usados nos testes e na verificação podem ser observados na figura 54.

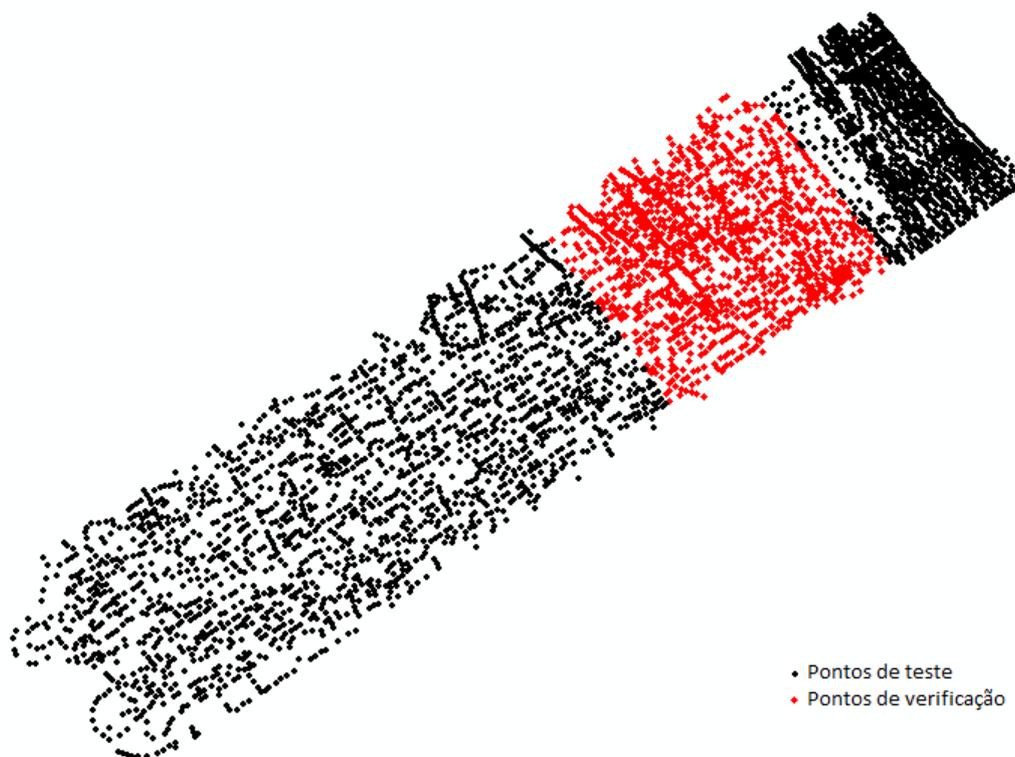


FIGURA 53 - Divisão dos pontos que foram utilizados nos testes da área de difícil acesso.

Com base nos resultados dos testes anteriores, determinou-se os procedimentos para a realização destes testes com os dados organizados de maneira que não abranjam a região de difícil acesso. Assim, os testes com os métodos vizinho natural, krigagem, triangulação e redes neurais artificiais voltaram a ser realizados, enquanto o método de superfície por aproximação polinomial não, pois não apresentou resultados satisfatórios nos testes anteriores.

Optou-se também por utilizar somente 60% do total dos dados, já que estes produziram resultados estatisticamente semelhantes a 80% em todos os testes.

Para os testes usando redes neurais artificiais foram escolhidas 3 topologias de rede:

- 2 camadas escondidas com 30 neurônios na primeira camada e 10 na segunda, método de aprendizagem LM com taxa de aprendizagem de 0.01.
- 2 camadas escondidas com 30 neurônios na primeira camada e 10 na segunda, método de aprendizagem LM com taxa de aprendizagem de 0.3.
- 2 camadas escondidas com 30 neurônios na primeira camada e 10 na segunda, método de aprendizagem RP com taxa de aprendizagem de 0.025.
- 2 camadas escondidas com 30 neurônios na primeira camada e 10 na segunda, método de aprendizagem RP com taxa de aprendizagem de 0.8.

O teste que utilizou o método de vizinho natural para estimativa de altitudes na área de possível escassez de informação apresentou coeficiente de correlação igual a 0,073904, este coeficiente não foi satisfatório como havia se apresentado no item 5.1. Isso pode ser observado na sua representação espacial, na região de possível escassez de dados por difícil acesso, em destaque na figura 55, a representação foi inadequada pois a estimativa de altitude não gerou a resposta esperada.

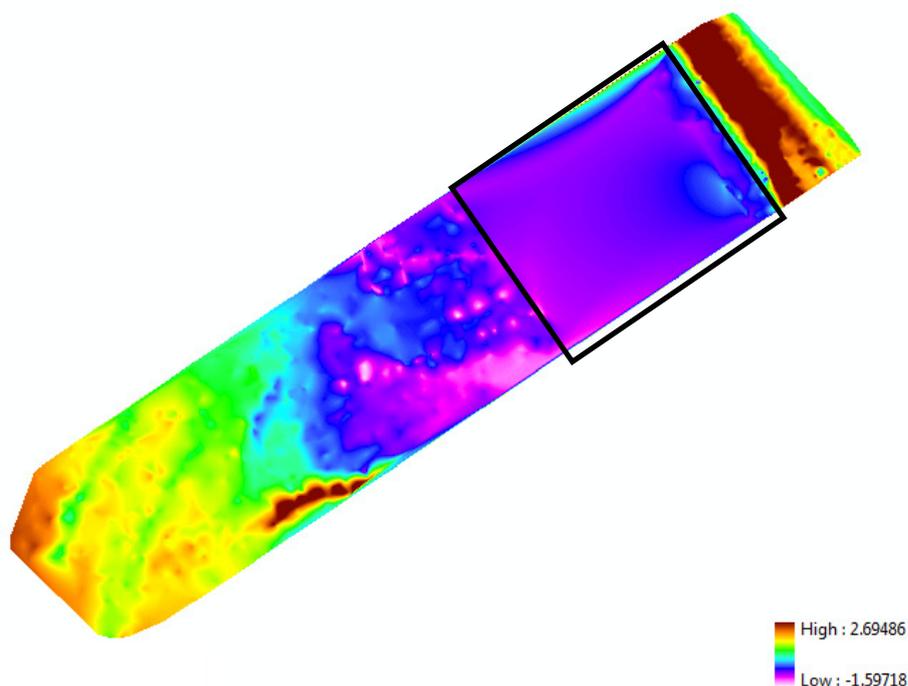


FIGURA 54- Representação espacial do método de vizinho natural aplicado aos dados do teste na área de possível escassez de informação.

Com o método de krigagem a resposta para a área de estudo objeto deste item também não foi adequada. Tanto o coeficiente de correlação, que foi de 0,073888,

como a representação espacial (FIGURA 56) não apresentaram os resultados satisfatórios como o método havia atingido no item 5.2.

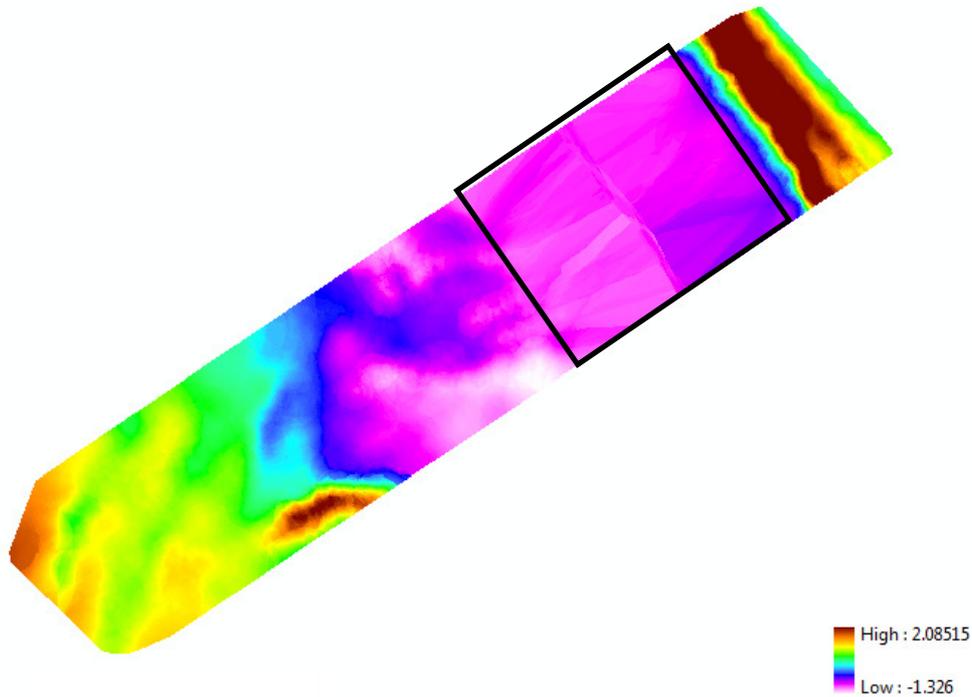


FIGURA 55 - Representação espacial do método de krigagem aplicado aos dados do teste na área de possível escassez de informação.

O mesmo pode ser observado com o método de triangulação, o coeficiente de correlação, de 0,0738247 e a representação espacial (FIGURA 57) não atingiram resultado satisfatórios.

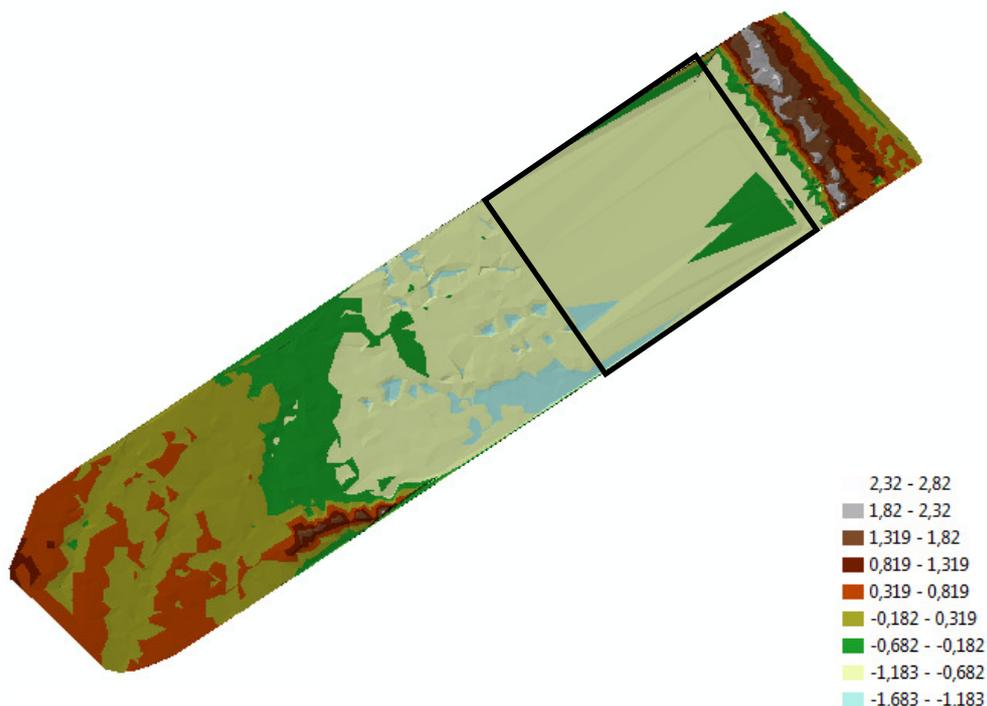


FIGURA 56 - Representação espacial do método de triangulação aplicado aos dados do teste na área de possível escassez de informação.

No método de redes neurais artificiais, quando se observa as representações espaciais (FIGURAS 57 a 60), os resultados parecem ser satisfatórios, pois a representação é suave, não apresentando diferenças bruscas e disformes na região de acesso restrito, em relação as regiões adjacentes, como aconteceu nos métodos vizinho natural, krigagem e triangulação.

Porém, quando se observa os coeficientes de correlação (TABELA 20) pode-se notar que os valores calculados pelas redes neurais artificiais não estão suficientemente correlacionados aos valores medidos em campo, mostrando que o método de estimativa não foi eficaz para esse objetivo.

TABELA 19 - Coeficientes de correlação encontrados pela comparação dos resultados obtidos com os métodos de redes neurais que foram utilizados no teste da área de possível escassez de informação e a verdade de campo.

	LM 0.01	LM 0.3	RP 0.025	RP 0.8
30101	1.2859e-014	0.0653	0.0587	0.0587
30102	-0.0232	0.0876	0.0907	0.0907
30103	0.0122	-0.0018	0.1549	0.1549

Contudo o método de redes neurais atingiu maior coeficiente de correlação em alguns treinamentos em relação aos métodos de vizinho natural, krigagem, e vizinho natural. Isso indica que este método teve maior capacidade de resposta quando exposto aos problemas de escassez de informação.

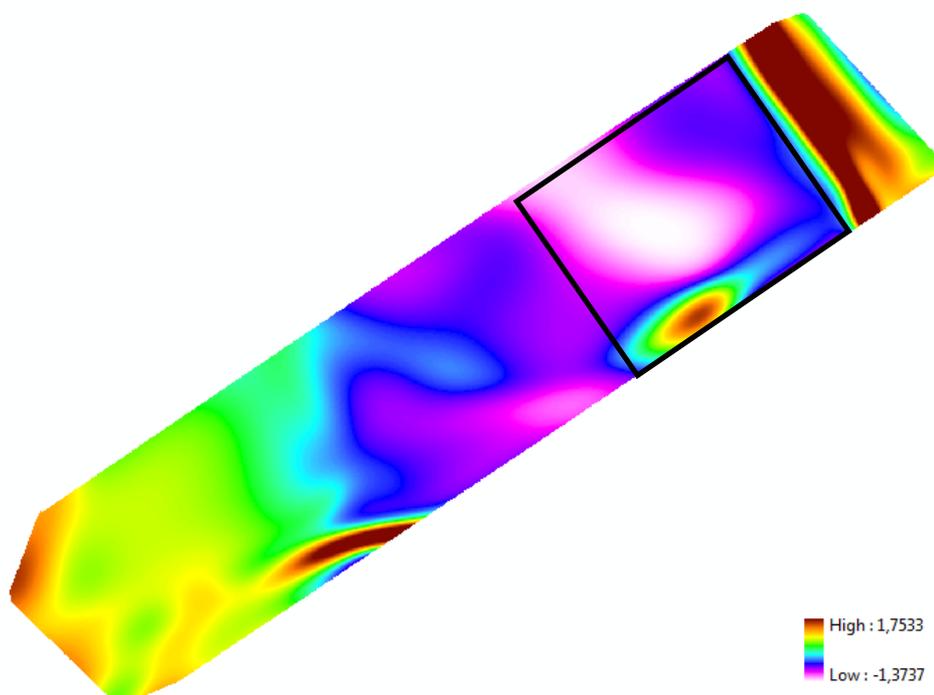


Figura 57 - Representação espacial do resultado da rede LM com taxa de aprendizagem 0.01 e topologia de duas camadas escondidas sendo que a primeira contém 30 neurios e a segunda 10 neuronios.

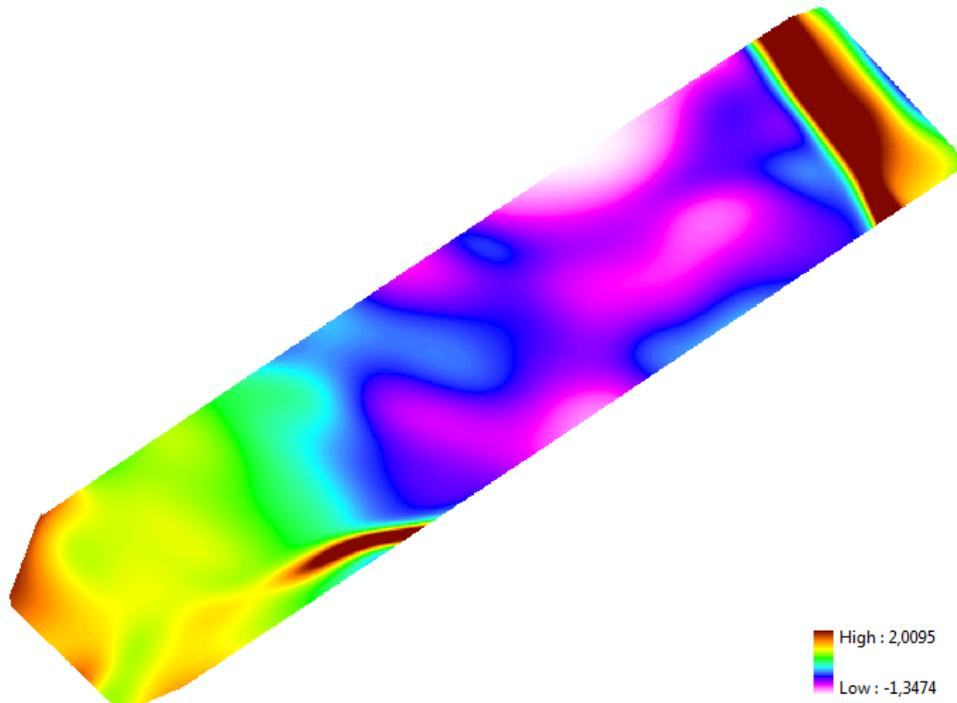


FIGURA 58 - Representação espacial do resultado da rede LM com taxa de aprendizagem 0.3 e topologia de duas camadas escondidas sendo que a primeira contém 30 neurios e a segunda 10 neuronios.

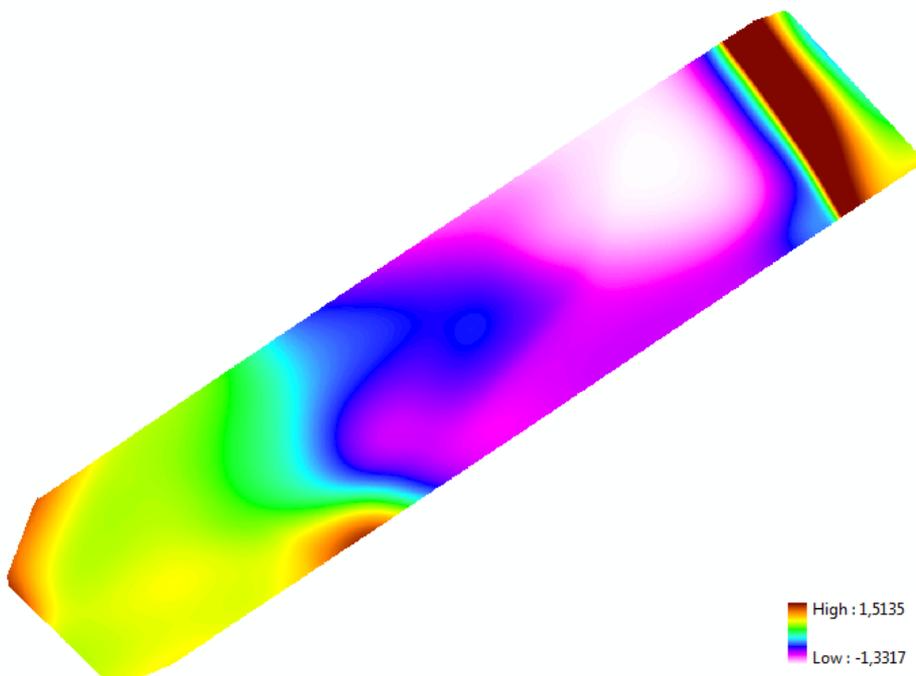


Figura 59 - Representação espacial do resultado da rede RP com taxa de aprendizagem 0.025 e topologia de duas camadas escondidas sendo que a primeira contém 30 neurios e a segunda 10 neuronios.

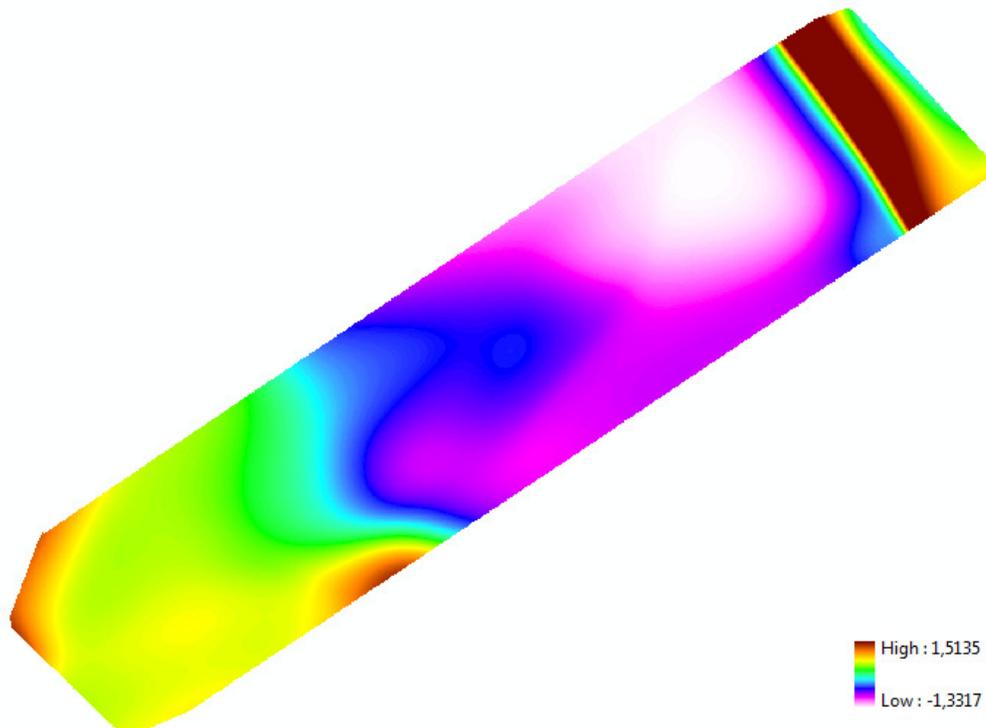


Figura 60 - Representação espacial do resultado da rede RP com taxa de aprendizagem 0.8 e topologia de duas camadas escondidas sendo que a primeira contém 30 neurios e a segunda 10 neuronios.

6 CONCLUSÃO

Com exceção do método de superfície por aproximação polinomial, todos os métodos se demonstraram eficazes na estimativa de altitude com os dados distribuídos aleatoriamente por toda área de estudo, apresentando estimativas que correspondem a realidade de campo e capazes de projetar modelos de superfície.

O volume de dados utilizado pode influenciar na estimativa. Na maioria dos casos, quando se utilizou 5, 10, 20 e 40% dos dados, correspondente a aproximadamente 7, 14, 28 e 56 pontos por 10.000m² respectivamente, as estimativas melhoraram com o aumento do volume de dados. Porém, para todos os métodos, quando se utilizou 60 e 80% dos dados, correspondentes a aproximadamente 85 e 114 pontos por 10.000 m², a melhora não pode ser observada com o aumento do volume de informação. Isso indica que um esforço de coleta de dados de 85 pontos por hectare pode produzir um resultado semelhante a um esforço de 114 pontos por hectare. Considerando apenas os métodos de krigagem e triangulação o esforço de coleta de informações reduz pela metade, 57 pontos por hectare produzem resultados similares a 114 pontos por hectare.

Os métodos de vizinho natural, krigagem e triangulação foram capazes de representar feições locais quando foi utilizado maior volume de dados. O método de rede neural artificial não foi capaz de representar tão detalhadamente feições como bancos ou depósitos de areia, ele produziu formas mais suaves, mesmo quando se utilizou maior volume de dados.

Os resultados dos testes dos itens 5.1, 5.2, 5.3 e 5.5 estimularam a utilização desses métodos para estimativa de altitude na área onde poderia acontecer a escassez de dados, porém nenhum desses métodos se mostrou completamente eficaz. Os métodos de vizinho natural, krigagem e triangulação apresentaram estimativas pouco precisas e modelos descontínuos na área de interesse. O método de redes neurais artificiais apresentou modelos mais contínuos e uniformes, apesar de seus coeficientes de correlação não estarem próximos do valor ideal 1.

Ainda assim o método de redes neurais artificiais foi o que apresentou melhores resultados em relação aos métodos de vizinho natural, krigagem e triangulação.

O método de redes neurais artificiais demonstrou maior capacidade de se adaptar a escassez de informação, provavelmente por ele ter revelado um caráter mais global. Contudo, o método de superfície por aproximação polinomial também é um método considerado de caráter global, e esse não conseguiu se ajustar as informações da área de estudo como o método de redes neurais artificiais. Sendo assim, o método que utilizou redes neurais artificiais se mostrou promissor para ser utilizado com esse objetivo, apesar de ele também não ter atingido resultados adequados neste trabalho.

O fato deste trabalho não ter alcançado os resultados esperados pode ser resultado da necessidade de muitos testes até se encontrar uma topologia de rede ideal, o método de aprendizado mais adequado com a taxa de aprendizagem mais eficiente. Os treinamentos realizados indicaram uma resposta diferente para os treinamentos realizados com diferentes métodos de aprendizagem. O método LM criou superfícies mais acidentadas que as criadas pelo método RP. Além disso, os testes aqui realizados utilizaram diferentes densidades de dados e as diferentes topologias de redes neurais artificiais obtiveram respostas diferentes para cada densidade. Neste trabalho optou-se por buscar uma rede que melhor se adaptasse a qualquer densidade, mas se essa escolha tivesse sido feita por uma rede que se adaptasse a uma única densidade de dados talvez as respostas tivessem sido mais adequadas.

Por isso os resultados encontrados neste trabalho incentivam a busca por uma topologia de rede neural artificial mais adequada, usando o método e taxa de aprendizagem mais eficientes, levando em consideração que esta poderá ter uma melhor resposta para uma determinada densidade de dados, e ainda que as redes neurais podem ser mais indicadas para uma determinada escala de trabalho, provavelmente uma escala regional, menor que a utilizada neste trabalho, mas também uma escala maior daquela que o método de aproximação polinomial se ajusta adequadamente.

REFERÊNCIAS

ANGULO, R. J., 1999. **Morphological characterization of the tidal deltas on the coast of the State of Paraná.** Anais Academia Brasileira de Ciências São Paulo 1(4-II):935-959.

ARAÚJO, A. D. 2001. **Dinâmica sedimentar e evolução paleogeográfica do saco do limoeiro na Ilha do Mel, e sua relação com o canal de acesso ao porto de Paranaguá.** Dissertação de Mestrado (Geologia Ambiental). UFPR. 73pp.

AZEVEDO, F.M.; BRASIL, L.M.; OLIVEIRA, R.C.L.de. **Redes Neurais com. Aplicações em Controle e em Sistemas Especialistas.** 1.ed. Florianópolis: Visual Books, 2000.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações.** Rio de Janeiro: LTC, 2000.

BRASIL. **Portaria n. 121 / MB, de 23 de abril de 2003.** Aprova as "Instruções para Controle dos Levantamentos Hidrográficos pela Marinha do Brasil". Disponível em <<https://www.mar.mil.br/dhn/dhn/index.html> > Acesso em: 16 fev. 2009.

HOFMANN-WELLENHOF, B.; LICHTENEGGER, H.; COLLINS, J. **Global Positioning System: theory and practice.** 3. ed. Wien: Springer-Verlag, 1994. 355 p.

IHO. International Hydrographic Organization. **IHO Standards for Hydrographic Surveys. Special Publication n. 44.** 5a edição, Principado de Monaco: International Hydrographic Bureau , 2008, 28 p.

_____. **Regulations of the IHO for International (INT) Charts and Chart Specifications of the IHO.** Edition 3.006. Principado de Monaco: International Hydrographic Bureau, 2009, 392 p.

IOC. Intergovernmental Oceanographic Commission. **Manual on Sea Level Measurement and Interpretation Volume IV : An update to 2006.** IOC Manuals and Guides no. 14, UNESCO, 2006. 87 p.

KRUEGER, C.P. **Investigações sobre aplicações de alta precisão do GPS no âmbito marinho,** Universidade Federal do Paraná, Tese de Doutorado em Ciências Geodésicas, Curitiba, Paraná, 267 páginas. 1996.

MARREIROS, P. e ARTILHEIRO, F. **Desenvolvimentos recentes da Hidrografia em Portugal.** Anais do Instituto Hidrográfico. - Lisboa. - Nº 14 (1995-2000), p. 7-17.

MAUNE, T.A. BLACK and E.W. CONSTANCE. **DEM user requirements.** In: D.F. Maune, Editor, **Digital Elevation Model Technologies and Applications: The DEM Users Manual,** American Society of Photogrammetry and Remote Sensing, Bethesda, MD (2001), pp. 441-460.

MIGUENS, A. P. **Navegação: a ciência e a arte - Navegação Costeira, estimada e em águas restritas.** v. 1. Rio de Janeiro: DHN,1996.

MIGUENS, A. P. **Navegação: a ciência e a arte - Navegação Costeira, estimada e em águas restritas.** v. 2. Rio de Janeiro: DHN,1996.

MUEHE, D. **Método de levantamento topo-batimétrico do sistema praia-antepraia.** Revista Brasileira de Geomorfologia, Uberlandia, v. 5, n. 1, p. 95-100,2004.

PAGLIOSA, A. L. **Obtenção das funções de pertinência de um Sistema neurofuzzy modificado Pela rede de Kohonen.** Dissertação de mestrado –Universidade do estado de Santa Catarina- UDESC – Florianópolis –SC, 2003.

SCHULZER, Michael; MILLS, Richard P.; HOPP, Richard H.; LAU, Wing; DRANCE, Stephen. **Estimation of the short-term fluctuation from a single determination of the visual field.** Investigative ophthalmology & visual science 1990;31(4):730-5.

SEEBER, G. **Satellite Geodesy.** Berlin: de Gruyter. 2003.

SOUZA, Elaine Cristine Barros de; KRUEGER, Claudia Pereira (Orient.); SEEBER, Gunter; RIBEIRO, Selma Regina Aranha (Co-orient.). **Modelagem do relevo oceânico usando Redes Neurais Artificiais** . xiv, 208f. Tese (doutorado) - Universidade Federal do Paraná, Setor de Ciências da Terra, Programa de Pós-Graduação em Ciências Geodésicas. Defesa: Curitiba, 2006, 2006.

SOUZA, G. A. **Utilizando Redes Neurais Artificiais para Modelar a Confiabilidade de Software.** Dissertação de mestrado –Universidade Federal do Paraná – Curitiba –PR, 2004.

TEDESCO, A. **Viabilidade do uso de imagens de alta resolução para a atualização de mapas batimétricos.** Dissertação de mestrado –Universidade federal do Paraná – Curitiba –PR, 2003.

WATSON, David F. **Contouring: a guide to the analysis and Display of Spatial Data :** (with programs on diskette). Oxford: Pergamon, 1992. 321p

WEIBEL, R. and M. HELLER. **Terrain Modelling.** In MAGUIRE, D.,. GOODCHILD, M.F., and RHIND, D. (Eds.) **Geographic Information Systems: Principles and Applications.** London: Longman: 269 – 297. 1991.