

5 Resultados

Neste capítulo apresentamos os resultados obtidos pelos procedimentos descritos ao longo desta dissertação, tanto o de mapeamento de horizontes quanto o método de extração dos voxels pertencentes às falhas sísmicas. O capítulo concentra os resultados no processo de mapeamento de horizontes, mas também são apresentados resultados para o método de mapeamento automático das falhas.

No que diz respeito ao mapeamento de horizontes, reportamos vários resultados obtidos com três dados de volume diferentes, informando o conjunto de parâmetros correspondentes utilizados tanto na etapa de treinamento quanto na de extração.

Uma observação a ser feita em relação aos resultados alcançados diz respeito às funções de similaridade utilizadas durante a fase de treinamento dos grafos do GNG. Duas delas foram testadas: o coeficiente de correlação e a distância euclidiana. Nos testes aqui realizados, o desempenho alcançado pela utilização desses dois critérios de medida foi bastante similar. No entanto, constatamos que nos nossos dados o coeficiente de correlação é menos tolerante à presença de ruído, o que faz com que a superfície resultante do mapeamento seja composta de pequenas ranhuras, prejudicando a qualidade de visualização. Além disso, o cálculo do coeficiente de correlação é computacionalmente mais caro quando comparado ao cálculo da distância euclidiana. Dessa forma, ao longo de todo o capítulo os resultados reportados utilizam distância euclidiana como função de similaridade, e ao final da seção em que são reportados os resultados obtidos para o mapeamento de horizontes apresentamos alguns resultados comparativos entre as duas funções de similaridade testadas, sugerindo ser a distância euclidiana uma melhor opção.

O capítulo está organizado da seguinte maneira: na seção 5.1 apresentamos os resultados do processo de mapeamento automático de horizontes, obtidos para os três volumes sísmicos de teste de que dispúnhamos. São também apresentados os resultados para o volume onde inserimos ruído propositalmente no dado. Depois

dos resultados obtidos pelo mapeamento dos horizontes, na seção 5.2 apresentamos alguns resultados comparativos entre as duas funções de similaridade testadas, a distância euclidiana e o coeficiente de correlação.

Na seção 5.3 apresentamos os resultados do procedimento de mapeamento das falhas sísmicas acompanhado dos parâmetros de mapeamento desse algoritmo, tanto de treinamento quanto o valor de tolerância utilizado na extração.

Não nos preocupamos em encontrar uma superfície simples a partir do conjunto de voxels obtido pelo processo de mapeamento das falhas, de forma que os resultados são apresentados apenas como o conjunto de voxels resultante, com os voxels individualmente iluminados. A qualidade de visualização, no entanto, permite avaliar corretamente o desempenho obtido pelo método.

Finalmente, na seção 5.4 apresentamos algumas tabelas demonstrando o comportamento do método de treinamento do GNG e geração do volume quantizado, e de classificação dos horizontes sísmicos. Mostramos que o método, é consideravelmente tolerante à variação do número de neurônios no que diz respeito à qualidade do processo de mapeamento de horizontes. Também fornecemos tabelas que relacionam tempos de treinamento, classificação do volume quantizado, e de mapeamento de horizontes em relação ao número de neurônios utilizados.

Todos os testes foram realizados em um Pentium D 3.0GHz, com 2 GB de memória RAM. A placa gráfica utilizada nos testes foi uma NVidia Quadro FX 3550. Entretanto nessa versão da implementação não foram utilizados recursos de programação em placa gráfica.

5.1 Mapeamento de horizontes

O primeiro dado volumétrico era o de maior coerência espacial lateral entre os voxels. Nesse primeiro volume, por mais que variássemos o conjunto de parâmetros de treinamento, os resultados do processo de mapeamento eram sempre satisfatórios. As dimensões são 171x371x111, e os voxels são do tipo ponto flutuante de 32 bits.

Para esse dado sísmico, mostramos os resultados obtidos no mapeamento de três horizontes. Para os três, os parâmetros de treinamento utilizados no GNG foram: $\varepsilon_b = 0,06$, $\varepsilon_t = 0,003$, $a_{\max} = 700$, $\lambda = 30000$, $\alpha = 0,5$, $\beta = 0,005$. As amostras no volume de entrada têm 19 voxels ($k=9$), e as amostras no volume quantizado têm 15 voxels ($q=7$).

A função de similaridade do treinamento foi a distância euclidiana, e o valor da tolerância máxima para o voxel candidato em cada traço foi de 14 distâncias médias para os três horizontes. Além disso, nesse treinamento foram gerados 88 neurônios, ou seja, no volume quantizado os voxels possuem somente 88 identificadores diferentes.

Nas figuras 5.1 e 5.2 apresentamos os dois primeiros resultados. Esses horizontes são caracterizados no dado pelas altas amplitudes (em módulo) dos seus voxels. Isso facilitou o procedimento de mapeamento automático.

Na figura 5.3 podemos ver outro resultado para o mesmo volume, situado em uma região onde os voxels são caracterizados pelos baixos valores das suas amplitudes, e o horizonte que eles representam não está bem caracterizado no dado. Mesmo nesse caso pode-se considerar o resultado satisfatório. Na figura 5.4 apresentamos as três superfícies simultaneamente.




Figura 5.1: horizonte sísmico representado nos dados por voxels de alta amplitude e numa região de traços bem definidos.




Figura 5.2: horizonte sísmico representado nos dados por voxels de alta amplitude.




Figura 5.3: horizonte sísmico representado nos dados por voxels de baixa amplitude. Isso faz com que o horizonte seja mal caracterizado.




Figura 5.4: Última ilustração mostrando simultaneamente os três horizontes mapeados.

No segundo arquivo de dados sísmicos utilizado nos testes a taxa de ruído existente nos dados já é bastante acentuada. Além disso, as superfícies que foram mapeadas não estão representadas em vários dos traços sísmicos do dado, e a vizinhança vertical dos voxels da superfície varia consideravelmente ao longo do volume.

Dessa forma, para esse dado, apesar de os parâmetros de treinamento do algoritmo de GNG não sofrerem variações em relação àqueles utilizados no primeiro volume testado, o número de neurônios gerado e as dimensões das amostras de treinamento e de extração foram aumentados. Neste caso as amostras no volume de entrada têm 25 voxels ($k=12$), e as amostras no volume quantizado têm 19 voxels ($q=9$). O número de neurônios do grafo resultante do treinamento teve 120 neurônios. As dimensões do dado são $182 \times 202 \times 126$, e os voxels são do tipo ponto flutuante de 32 bits.

A função de distância do treinamento foi a distância euclidiana, e o valor da tolerância máxima para o voxel candidato em cada traço foi aumentado para 30 distâncias médias. Mostramos os resultados obtidos para dois horizontes mapeados. Nas figuras 5.5 e 5.6 temos os resultados das superfícies mapeadas. Mostramos a mesma fatia com e sem a visualização dos horizontes, evidenciando as dificuldades existentes.




Figura 5.5: O horizonte não está presente em vários dos traços do volume, o que dificulta o mapeamento. O horizonte em contraste com algumas fatias.




Figura 5.6: A relação sinal/ruído e as características do dado dificultaram o procedimento de mapeamento. Outro exemplo de horizonte mapeado.

O último volume de dados utilizado nos testes é, sem dúvida, aquele que tem a pior relação sinal/ruído, o que fica claro quando observamos fatias contíguas do volume. Esse foi o dado de teste em que os resultados foram mais difíceis de serem obtidos, sendo o volume em que o conjunto de parâmetros adequado mais influenciou o desempenho alcançado. As dimensões do dado são 100x70x126, e os voxels são do tipo ponto flutuante de 32 bits.

Nesse caso mostramos os resultados do mapeamento de dois horizontes sísmicos. Para ambos os parâmetros de treinamento utilizados no GNG foram $\varepsilon_b = 0,06$, $\varepsilon_t = 0,003$, $a_{\max} = 900$, $\lambda = 35000$, $\alpha = 0,5$, $\beta = 0,005$. As amostras no volume de entrada têm 25 voxels ($k=12$), e as amostras no volume quantizado têm 21 voxels ($q=10$).

Uma observação a ser feita é que, devido à qualidade do dado, a similaridade existente entre voxels pertencentes a um mesmo horizonte tende a ser relativamente baixa. Com isso o valor da tolerância máxima para o voxel candidato em cada traço foi de 50 distâncias médias para os dois horizontes mapeados. Além disso, visando minimizar o impacto do ruído, o número de neurônios gerados pelo treinamento teve que ser aumentado, tendo sido gerados 140 neurônios.

Os resultados alcançados pelo procedimento de mapeamento para esse dado sísmico podem ser visualizados nas figuras 5.7 e 5.8, onde são mostradas as superfícies obtidas em contraste com três fatias volumétricas. Em cada caso na porção esquerda da figura são apresentadas somente as fatias, e na porção direita apresentamos também a superfície obtida. Na figura 5.9 vemos as mesmas superfícies, porém com maior grau de detalhe.




Figura 5.7: Horizonte mapeado no volume de pior relação sinal/ruído.




Figura 5.8: Horizonte mapeado no volume de pior relação sinal/ruído.




Figura 5.9: Uma vista mais detalhada dos horizontes mapeados.

5.2 Coeficiente de correlação como função de similaridade

Nesta seção demonstramos alguns dos resultados obtidos pelo uso do coeficiente de correlação como função de similaridade utilizada para a etapa de treinamento do GNG.

Não constatamos diferença significativa na utilização desta função em relação ao uso da distância euclidiana, exceto pelo fato de que ao utilizar o coeficiente de correlação é bastante comum que a superfície mapeada apresente pequenos deslocamentos relativos entre voxels vizinhos, o que causa pequenas ranhuras na superfície mapeada, prejudicando a visualização.

Outra vantagem da utilização da distância euclidiana como critério de similaridade diz respeito ao seu tempo de computação consideravelmente menor quando relacionado ao tempo gasto pelo cálculo do coeficiente de correlação. Essas vantagens foram as que nos motivaram a utilizar a distância euclidiana como critério de similaridade ao longo dos demais testes reportados na dissertação.

Na figura 5.10 são comparadas as superfícies resultantes do processo de mapeamento de um mesmo horizonte utilizando como critério de similaridade a distância euclidiana (porção superior da figura) e o coeficiente de correlação (porção inferior). Apesar de os conjuntos de voxels retornados pelos procedimentos serem similares, aqueles retornados pelo procedimento que utiliza o coeficiente de correlação sofrem pequenos deslocamentos verticais em relação aos seus vizinhos imediatos, o que prejudica a visualização.




Figura 5.10: Duas superfícies, indicando a maior uniformidade da superfície obtida a partir do grafo gerado utilizando distância euclidiana.

5.3 Mapeamento das falhas sísmicas

O procedimento de mapeamento das falhas sísmicas foi realizado em apenas um dado sísmico, o que não nos permitiu avaliar de maneira mais conclusiva seu desempenho. No entanto, os resultados apresentados aqui sugerem que esse é um procedimento que merece um estudo mais abrangente.

O mapeamento de cada falha presente no dado se inicia a partir de uma semente. Uma vez definidos a semente e o valor de tolerância a ser utilizado, caso o voxel semente seja considerado falha, é imediatamente adicionado à lista de voxels que representam a falha em questão, e seus vizinhos são incluídos na lista de voxels candidatos que serão testados posteriormente. O processo é repetido para cada um dos voxels da lista de candidatos até que essa lista esteja vazia.

Ao final tem-se um conjunto de voxels formando uma nuvem de pontos conexa onde a falha mapeada está definida, e espera-se que essa nuvem de pontos defina a região de falha com precisão.

Nas próximas páginas são demonstrados os resultados obtidos pelo procedimento de mapeamento das falhas sísmicas. Na figura 5.11 são mostradas algumas fatias volumétricas, onde pode-se verificar a existência e a região de ocorrência das falhas sísmicas. Nas figuras 5.12, 5.13, 5.14 e 5.15 as falhas encontradas são mostradas em contraste com horizontes mapeados do volume, ficando evidenciada sua existência.




Figura 5.11: Fatias indicando a presença de falhas sísmicas através do volume de dados sísmicos.




Figura 5.12: As falhas sísmicas (em amarelo) obtidas pelo procedimento de mapeamento automático em contraste com um horizonte.




Figura 5.13: As falhas sísmicas (em amarelo) obtidas vistas em maior detalhe.




Figura 5.14: As mesmas falhas sísmicas (em amarelo) em contraste com outro horizonte sísmico.




Figura 5.15: As falhas sísmicas (em amarelo) vistas em maior detalhe.

5.4 Tempos de processamento e número de neurônios utilizados

Nessa seção apresentamos demonstramos o comportamento do método no que diz respeito ao treinamento do GNG e geração do volume quantizado, além da classificação dos horizontes sísmicos. Mostramos que o método é consideravelmente tolerante à variação do número de neurônios no que diz respeito à qualidade do processo de mapeamento de horizontes. Também fornecemos tabelas que relacionam tempos de treinamento, classificação do volume quantizado, e de mapeamento de horizontes em relação ao número de neurônios utilizados.

A tabela 5.1 e o gráfico da figura 5.16 fornecidos abaixo resumem os tempos de treinamento, classificação e triangulação (todos em segundos) obtidos pelo método utilizando-se o primeiro volume de dados. Na tabela pode ser constatado que, enquanto o tempo de treinamento é quadrático no número de neurônios (a cada treinamento é preciso encontrar a distância euclidiana da amostra sendo treinada em relação a todos os neurônios criados até então), o tempo de classificação é linear no número de neurônios.

Num. de Neurônios	Treino	Mapeamento + Triangulação	Classificação
30	9	46	22
40	14	45	29
50	22	44	37
60	32	43	46
70	42	43	56
80	56	44	65
90	72	46	70
100	90	45	82
110	108	44	87
120	129	44	97
130	151	44	110
140	177	44	119
150	209	45	120

Tempos em segundos

Tabela 5.1: Tempos de treino, triangulação e classificação obtidos.

Já o procedimento de triangulação depende somente do número de voxels descobertos do horizonte (os tempos foram aproximadamente constantes).




Figura 5.16: Tempos de treino, triangulação e classificação obtidos.

O método se mostrou consideravelmente tolerante a variações do número de neurônios utilizados no processo de criação do volume de quantização em relação a qualidade obtida no processo de extração dos horizontes. Tal fato é demonstrado na tabela 5.2 abaixo. Para a construção dessa tabela primeiramente foi gerado um volume quantizado a partir de uma instância de GNG treinada onde foram obtidos 140 neurônios. Esse primeiro horizonte foi formado por 5310 voxels. Tal horizonte foi visualizado, e após a constatação de que todos os seus voxels efetivamente estavam posicionados corretamente, foi tomado como padrão. Feito isso, novas instâncias de GNG foram treinadas com o número de neurônios variando a cada instância, e para cada uma dessas instância de GNG foi gerado o volume quantizado correspondente, e o mesmo horizonte foi extraído. A tabela mostra os resultados obtidos. Fica claro que, variando-se o número de neurônios,

o número de voxels classificados como sendo do horizonte padrão pode sofrer variações, ou seja, parte dos voxels descobertos no horizonte padrão não foram descobertos. No entanto, uma vez que um vértice foi descoberto, quase sempre esse vértice pertencia ao horizonte padrão extraído (o pior caso ocorreu para o caso de uma instância de 110 neurônios onde, dos vértices descobertos, 98,53% pertenciam ao horizonte padrão).

Neurônios	Ref(voxels)	% do total	% Correta
20	3259	61.37	99.42
30	2788	52.50	98.63
40	4556	85.80	99.81
50	5107	96.17	99.77
60	4750	89.45	99.71
70	4756	89.56	99.49
80	4721	88.90	99.91
90	4976	93.70	99.60
100	4592	86.47	99.86
110	5232	98.53	98.53
120	5310	100	99.70
130	5310	100	99.72
140	5310	100	100

Tabela 5.2: Sensibilidade em relação ao número de neurônios .