

PONTIFÍCIA UNIVERSIDADE CATÓLICA  
DO RIO DE JANEIRO



**Marcos de Carvalho Machado**

**Geração de Malhas de Falhas em Dados Sísmicos  
por Aprendizado Competitivo**

**Tese de Doutorado**

Tese apresentada como requisito parcial para obtenção do título de Doutor pelo Programa de Pós-Graduação em Informática da PUC-Rio.

Orientador: Prof. Marcelo Gattass

Rio de Janeiro, março de 2008

**Marcos de Carvalho Machado**

**Geração de Malhas de Falhas em Dados Sísmicos  
por Aprendizado Competitivo**

Tese apresentada como requisito parcial para obtenção do grau de Doutor pelo Programa de Pós-graduação em Informática do Departamento de Informática do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

**Prof. Marcelo Gattass**

Orientador  
Departamento de Informática – PUC-Rio

**Prof. Paulo Roma Cavalcanti**

Programa de Engenharia de Sistemas e Computação – COPPE/UFRJ

**Dr. Paulo Marcos de Carvalho**

Tecnologia Geofísica – E&P/Petrobras

**Prof. Paulo Cezar Pinto Carvalho**

Instituto Nacional de Matemática Pura e Aplicada (IMPA)

**Profa. Marley Maria Bernardes Rebuszi Vellasco**

Departamento de Engenharia Elétrica – PUC-Rio

**Prof. Ruy Luiz Milidiú**

Departamento de Informática – PUC-Rio

**Prof. José Eugenio Leal**

Coordenador Setorial do Centro Técnico Científico

Rio de Janeiro, 14 de março de 2008

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

### **Marcos de Carvalho Machado**

Graduou-se bacharel em Física pela Universidade Federal do Rio de Janeiro (UFRJ) em 1981. Concluiu o Mestrado em Física na UFRJ em 1984. Trabalha em desenvolvimento de software desde 1985. Funcionário da Petrobras a partir de 1990, participou de vários projetos na gerência de Tecnologia Geofísica. Mestrado em Computação Gráfica pela Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio) em 2000.

### Ficha Catalográfica

Machado, Marcos de Carvalho

Geração de malhas de falhas em dados sísmicos por aprendizado competitivo / Marcos de Carvalho Machado ; orientador: Marcelo Gattass. - 2008.

203 f. : il. ; 30 cm

Tese (Doutorado em Informática) - Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2008.

Inclui bibliografia

1. Informática - Teses. 2. Dados sísmicos. 3. Falhas geológicas. 4. Malhas. 5. Redes neurais. 6. Aprendizado competitivo. 7. Growing Neural Gas. 8. Neural Meshes. 9. Malhas Neurais Abertas. I. Gattass, Marcelo. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Informática. III. Título.

CDD: 004

À memória de meu pai,  
Francisco José Teixeira Machado,  
que me abriu as janelas da curiosidade científica.

## Agradecimentos

À Helena, minha amada e companheira de todas as batalhas, que mantém acesas nossa paixão e alegria de viver.

Aos meus queridos filhos Rafael e Juliana, pela compreensão de ver o pai tão perto e tão longe e à minha querida mãe, pelo doce espaço que me reserva em seu coração.

Ao meu orientador Professor Marcelo Gattass, pela confiança, dedicação e entusiasmo. Pela paciência e pelas palavras sempre positivas e sábias que me estimularam a seguir confiante no trabalho de pesquisa, mesmo diante de todas as incertezas inerentes ao processo de fazer Ciência. Além das inúmeras idéias e contribuições ao desenvolvimento desta tese. Meu muito obrigado.

À Petrobras, pela oportunidade e o suporte concedidos. Em particular, às pessoas de Jurandyr Shmidt, Ricardo Rosa e Neiva Zago.

A todos os professores e colegas da Pós-Graduação em Informática e da Engenharia Elétrica da PUC-Rio, do Tecgraf e do IMPA com quem tive o prazer de conviver e aprender. Em particular, ao professor Paulo Cezar Pinto Carvalho que acompanhou de perto meus trabalhos de pesquisa durante o curso.

Aos meus colegas do projeto v3o2, Mauren, Pedro, Sérgio, Flávia, André, Edinalda, Michel e Maurício, pelas sugestões e ajudas, em particular na implementação do *plug-in* com o qual pude testar os conceitos desta tese.

À amiga Elizabeth Monteiro pela luz que permitiu clarear os momentos difíceis do meu curso de Doutorado e da vida.

A todos os funcionários da PUC-Rio que me auxiliaram. Em particular à Rosane Castilho, pelo trabalho de levantamento bibliográfico, e a Carolina Alfaro de Carvalho, pela excelente e paciente revisão dos artigos e deste documento de tese desenvolvidos ao longo do meu curso de Doutorado.

Aos meus colegas da Gerência de Tecnologia Geofísica da Petrobras pela compreensão e apoio.

## Resumo

Machado, Marcos de Carvalho. **Geração de Malhas de Falhas em Dados Sísmicos por Aprendizado Competitivo**. Rio de Janeiro, 2008. 203p. Tese de Doutorado - Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

O mapeamento manual de falhas em dados sísmicos tridimensionais é uma tarefa que consome muito tempo do intérprete. Uma grande quantidade de atributos sísmicos tem sido proposta para realçar medidas de descontinuidades associadas com as falhas. Entretanto, as falhas vistas através desses atributos aparecem mais como tendências do que como superfícies contínuas bem definidas, o que torna difícil a automatização da construção de modelos de falhas. Esta tese explora técnicas de Aprendizado Competitivo aplicadas aos problemas de extração e visualização de falhas em dados sísmicos. A estratégia proposta parte de um atributo de falha previamente calculado e consiste de três etapas. Na primeira, os dados tridimensionais uniformemente amostrados do atributo de falha são convertidos em um grafo com uso do algoritmo de aprendizado competitivo Growing Neural Gas. Na segunda etapa, o grafo sofre um processo de segmentação de forma a extrair um conjunto de subgrafos, cada um compatível com uma superfície de falha. Na terceira etapa, é utilizado o algoritmo Malhas Neurais Abertas para construir uma malha triangular para cada uma das superfícies identificadas. Malhas Neurais Abertas é um algoritmo de Aprendizado Competitivo que é proposto nesta tese, o qual constrói uma malha a partir de uma função de probabilidades com topologia de uma superfície aberta sem buracos. Exemplos com dados bidimensionais e tridimensionais, sintéticos e reais, são apresentados. Outra aplicação de Aprendizado Competitivo introduzida nesta tese é a geração de malhas geológicas, isto é, malhas que podem ser utilizadas na simulação do comportamento de fluidos em subsuperfície.

## Palavras-chave

Dados sísmicos, falhas geológicas, malhas, redes neurais, Aprendizado Competitivo, Growing Neural Gas, Neural Meshes, Malhas Neurais Abertas

## Abstract

Machado, Marcos de Carvalho. **Fault Meshing Generation in Seismic Data by Competitive Learning**. Rio de Janeiro, 2008. 203p. PhD Thesis - Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

Manual fault mapping from 3D seismic data is a time-consuming task. A plethora of seismic attributes has been proposed to enhance the discontinuity measures associated with faults. However, faults viewed through these attributes appear more like trends than well-defined, continuous surfaces, posing obstacles to the automation of the fault modeling process. This thesis explores the use of Competitive Learning techniques in fault extraction and visualization. The proposed strategy starts with a pre-computed fault attribute and consists of three steps. In the first, the uniformly sampled 3D fault attribute data are converted into a graph using Growing Neural Gas, a Competitive Learning algorithm. In the second step, the graph is submitted to a segmentation process in order to extract a set of subgraphs, each one compatible with a fault surface. In the third step, the Open Neural Meshes algorithm is used to build a triangulated mesh for each previously identified surface. Open Neural Meshes is a Competitive Learning algorithm proposed in this thesis, which builds a mesh from a probability function with no-hole open surface topology. Examples with 2D and 3D, synthetic and real data are presented. Another Competitive Learning application introduced in this thesis is the generation of geologic meshes. These meshes can be used to simulate fluid flows in subsurface reservoirs.

## Keywords

Seismic data, geologic faults, mesh, neural networks, Competitive Learning, Growing Neural Gas, Neural Meshes, Open Neural Meshes

# Sumário

1	Introdução	26
1.1.	Interpretação sísmica e falhas	26
1.2.	Motivação e objetivos	30
1.3.	Estrutura do documento da tese	34
2	Atributos de Falhas	36
2.1.	Introdução	36
2.2.	Alguns atributos de falha	37
2.2.1.	Semblance	37
2.2.2.	Cubo de coerência por autoestrutura	38
2.2.3.	Coerência estimada pelo tensor de estrutura do gradiente	40
2.2.4.	Atributo de falha pelo tensor de estrutura do gradiente	41
2.2.5.	Atributo de caos sintonizado à orientação ( <i>orientation-tuned chaos</i> )	42
2.2.6.	Atributo de realce de borda ( <i>edge enhancement attribute</i> )	43
2.2.7.	Cubo de variância	45
2.2.8.	Mergulho estrutural	45
2.2.9.	Meta-atributo	47
2.2.10.	Atributo de energia vertical	48
2.3.	Pré-processamento (condicionamento dos dados)	50
2.3.1.	Filtragem direcional com preservação de bordas	51
2.4.	Pós-processamento	54
2.4.1.	Filtragem Direcional	54
2.4.2.	Ant Tracking	55
3	Extração das superfícies de falha	57
3.1.	Introdução	57
3.2.	Extração de falhas por processamento de imagens	59
3.2.1.	Supressão dos não-máximos	59
3.2.2.	Limiarização por histerese ( <i>hysteresis thresholding</i> )	61
3.2.3.	Esqueletonização de imagens binárias	62
3.3.	Método de Gibson-Spann-Turner	63
3.4.	Método de Hale-Emanuel	65

3.4.1. Construção da malha	65
3.4.2. Segmentação da malha	69
3.5. Método proposto	70
4 Construção do grafo de falhas utilizando Growing Neural Gas	73
4.1. Aprendizado Competitivo	73
4.2. Mapas que preservam a topologia	79
4.3. Growing Neural Gas	84
4.4. Aceleração do GNG	89
4.5. Usos do GNG	94
4.6. Geração do grafo por GNG para extração de falhas	98
4.6.1. Mapeamento do atributo de falha em probabilidades	99
4.6.2. Medida de erro local	100
4.6.3. Resultados	101
4.7. Escala	105
4.8. Geração de malha geológica por GNG	107
5 Segmentação do grafo de falhas	112
5.1. Introdução	112
5.2. Segmentação de grafos	113
5.3. Primeiro passo: segmentação baseada nos tamanhos das arestas	117
5.3.1. Algoritmo FH	117
5.3.2. Identificação de arestas frágeis via FH	119
5.3.3. Resultados	120
5.3.4. Eliminação de pontas	123
5.4. Segundo passo: segmentação de grafos baseada na orientação local	124
5.4.1. Cálculo da orientação local dos nós	125
5.4.2. Segmentação por crescimento de regiões	127
5.4.3. Resultados	130
6 Visualização de superfícies de falha por malhas neurais abertas	135
6.1. Introdução	135
6.2. Growing Cell Structures	137
6.3. Suavização de malhas	144
6.4. Neural Meshes	150
6.5. Malhas Neurais Abertas	160
6.6. Resultados	167

6.7. Exemplos de visualização de falhas por MNA	176
7 Conclusões e trabalhos futuros	184
7.1. Conclusões	184
7.2. Trabalhos futuros	186
8 Referências Bibliográficas	188
Apêndice A: Tensor de estrutura do gradiente	195
Apêndice B: Geradores para probabilidades discretas não-uniformes	199

## Lista de figuras

- Figura 1-1: Dados sísmicos. Traço sísmico (a). Seção sísmica 2D (b). Volume sísmico (c). Mapa de cores utilizado em b e c (d). 27
- Figura 1-2: Exemplos onde uma falha gera um bom selante (a) ou um mal selante (b). Adaptada de Lines et al. (2004). 28
- Figura 1-3: Bloco diagrama mostrando uma falha lítrica. Adaptada de Machado et al. (2000). 29
- Figura 1-4: Falha normal (a) e falha reversa (b). Adaptada de Machado et al. (2000). 30
- Figura 2-1: Ilustração de  $w_i$  fatias dos dados sísmicos, orientados por um vetor normal  $\mathbf{n}$ , centradas em torno de um ponto  $(x,y,z)$ . 37
- Figura 2-2: À esquerda uma imagem sísmica 2D, no centro o atributo de coerência por autoestrutura e à direita o atributo de Semblance. Adaptada de Bakker (2002). 40
- Figura 2-3: À esquerda fatia vertical de um volume sísmico; à direita, atributo de falha calculado com autovalores do TEG. Adaptada de Bakker (2002). 42
- Figura 2-4: (d) Atributo de caos sintonizado à orientação. (a) Dados de entrada. (b) Atributo de caos calculado em janelas isotrópicas. (c) Atributo de caos calculado em janelas alongadas na direção vertical. Adaptada de Randen (2005). 43
- Figura 2-5: Ilustração do conceito de realce de borda. Em (a) o gradiente gera uma projeção grande no plano: ocorre uma grande variação ao longo do refletor (situação compatível com uma falha); em (b) o gradiente é ortogonal ao refletor. Adaptada de Randen et al. (2001). 44
- Figura 2-6: (a) cubo sísmico. (b) cubo com atributo de borda realçada. Adaptada de Randen et al. (2001). 44
- Figura 2-7: Cubo com atributo de variância para dado sísmico da Figura 2-6(a). Adaptada de Randen et al. (2001). 45
- Figura 2-8: Identificação do mergulho estrutural pela pesquisa do mergulho de maior coerência. Adaptada de Marfurt (2006). 46
- Figura 2-9: Cubos de análise: à esquerda, conjunto de traços deslocados em tempo; à direita, dados obtidos por rotação. 47
- Figura 2-10: Redução de amplitudes sísmicas ao longo de falhas. 48
- Figura 2-11: Média quadrática calculada sobre uma janela deslizante de

tamanho  $M$  para cada amostra de cada traço. Adaptada de Bulhões (1999).

49

Figura 2-12: À esquerda, fatia vertical de um volume sísmico. À direita, média quadrática calculada sobre uma janela de 5 amostras.

49

Figura 2-13: À esquerda média quadrática calculada com janela de 23 amostras.

À direita, atributo de energia vertical correspondente.

50

Figura 2-14: À esquerda, cubo de coerência. À direita, atributo de falha resultante da combinação (como meta-atributo) do cubo de coerência com o atributo de energia vertical.

50

Figura 2-15: Comportamento da janela de filtragem (em forma de círculo) conforme o método de tratamento de bordas: filtragem sem restrição (a); escala adaptativa (b); janelas excêntricas (c). Adaptada de Bakker (2002).

52

Figura 2-16: Imagem sísmica original (a, b); resultado da filtragem por difusão anisotrópica (c); resultado da filtragem com preservação de bordas (d). Adaptada de Fehmers et al. (2003).

53

Figura 2-17: Difusão anisotrópica com variação do parâmetro de contraste  $k$ . À esquerda, imagem original; no centro  $k = 6$ ; à direita  $k = 100$ . Adaptada de Jeong et al. (2006).

53

Figura 2-18: Busca da janela de menor desvio padrão que contem o ponto de análise. Adaptada de Marfurt (2006).

54

Figura 2-19: Fatia de tempo de um atributo de falha (variância) (a) e seu resultado por Ant Tracking (b). Seção inline (c) e seu resultado por Ant Tracking (d). Adaptada de Pedersen (2002).

56

Figura 3-1: Interpretação de falhas sísmicas em um volume de dados sísmicos da plataforma marítima da Nigéria. Adaptada de Admasu et al. (2006).

58

Figura 3-2: Afinamento de uma imagem retendo apenas os pontos que são máximos locais na direção do gradiente. Adaptada de Forsyth et al. (2002).

60

Figura 3-3: À esquerda, falhas detectadas manualmente e à direita resultantes do afinamento por SNM e limiarização por histerese. Adaptada de Jeong et al. (2006).

62

Figura 3-4: Sementes superpostas com uma fatia vertical dos dados sísmicos. Adaptada de Gibson et al. (2003).

63

Figura 3-5: Ilustração da formação de uma superfície como a interpolação de um campo residual em um modelo de superfície plana. Adaptada de Gibson et

- al. (2003). 64
- Figura 3-6: À esquerda falhas estimadas; à direita falhas identificadas manualmente. Adaptada de Gibson et al. (2003). 65
- Figura 3-7: Efeito do pré-processamento utilizado por Hale (2002). À esquerda, atributo de falha; à direita, imagem processada. 66
- Figura 3-8: Energia potencial entre pares de átomos. Adaptada de Hale (2001). 68
- Figura 3-9: Malhas atômicas sobrepostas a uma fatia de tempo constante de um volume de atributo de falha normalizado. À esquerda malha construída pela triangulação de Delaunay; à direita, por polígonos de Voronoi. Imagens extraídas de Hale(2001) e Hale (2002). 69
- Figura 3-10: Malha segmentada através de um algoritmo de segmentação de grafos. As linhas brancas representam, na imagem à esquerda, a malha original e, à direita, a fronteira entre os segmentos. Adaptada de Hale et al. (2004). 70
- Figura 4-1: Passo de adaptação em uma rede de Kohonen: dado um sinal de entrada  $x$ , é identificada a unidade vencedora  $s$  e ocorre um deslocamento dos vetores de referência das unidades da vizinhança de  $s$  em direção a  $x$ . A rede  $G$  possui uma topologia quadrada. 77
- Figura 4-2: Comparação entre a maximização da entropia (à esquerda) e a minimização do erro de quantização (à direita). Nos dois casos, cada uma das duas regiões coloridas de azul escuro e de azul claro tem 50% dos sinais de entrada. 79
- Figura 4-3: Um grafo  $G$  de nove vértices é mapeado em uma variedade  $M$  de formato quadrado. No caso (a), o grafo tem topologia unidimensional, em (b) tridimensional e em (c) bidimensional. Adaptada de Martinetz et al. (1994) 81
- Figura 4-4: À esquerda, Triangulação de Delaunay (linhas grossas) e correspondentes polígonos de Voronoi (linhas finas). À direita, triangulação de Delaunay induzida (linhas grossas) e polígonos de Voronoi restritos (linhas finas) definidos sobre uma variedade  $M$  (região sombreada). Adaptada de Martinetz e Schulten (1994). 82
- Figura 4-5: CHL pode gerar aresta entre nós cujos poliedros de Voronoi restritos não são vizinhos, se a distribuição de vértices não é densa. 84
- Figura 4-6: GNG cria um grafo que se adapta a uma distribuição de sinais com diferentes topologias. Os dados de entrada são distribuídos em três

subconjuntos: com estrutura tridimensional (paralelepípedo), bidimensional (retângulo) e unidimensional (círculo e linha). Adaptada de Fritzke (1995).	87
Figura	<b>Erro! Indicador não definido.</b>
Figura 4-7: Desempenho do GNG com e sem a utilização da grade dinâmica.	92
Figura 4-8: Desempenho do GNG com e sem grade dinâmica para poucas unidades.	92
Figura 4-9: Desempenho do GNG com grade dinâmica, exibindo os pontos em que ocorre aumento no número de células de um a quatro bits.	93
Figura 4-10: Desempenho do GNG com grade dinâmica, exibindo os pontos em que ocorre aumento no número de células de três a seis bits.	93
Figura 4-11: Modelagem de mãos 2D. Da esquerda para direita: imagem original em tons de cinza; imagem em preto e branco gerada pela aplicação de um limiar; contorno da mão. Adaptada de Rodriguez et al. (2006).	96
Figura 4-12: Modelagem de mãos 2D. Grafo gerado por GNG com 25 (A), 64 (B), 100 (C), 144 (D) e 169 (E) nós. Adaptada de Rodriguez et al. (2006).	96
Figura 4-13: Exemplos de “atalhos” nos grafos GNG para modelos de mãos (duas imagens da parte de cima) e suas respectivas correções (duas imagens da parte de baixo). Adaptada de Rodriguez et al. (2006).	97
Figura 4-14: Duas maneiras de se classificar aplicações do Growing Neural Gas.	98
Figura 4-15: Gráfico do mapeamento proposto de atributo de coerência em probabilidades para extração de falhas.	100
Figura 4-16: Fatia de tempo de atributo de falha em tons de cinza, sobreposto por grafo gerado por GNG. À esquerda, com minimização do erro de quantização e, à direita, com maximização da entropia.	101
Figura 4-17: Três fatias do cubo de coerência do volume sísmico de teste.	102
Figura 4-18: Grafo gerado para o cubo de coerência do volume sísmico de teste.	102
Figura 4-19: Mesmas três fatias da Figura 4-17, sob um segundo ponto de observação.	103
Figura 4-20: Grafo visto sob mesmo ponto de observação da Figura anterior.	103
Figura 4-21: Mesmas três fatias da Figura 4-17, sob um terceiro ponto de observação.	104
Figura 4-22: Grafo visto sob mesmo ponto de observação da Figura anterior.	104
Figura 4-23: À esquerda, função de probabilidade bidimensional. À direita grafo gerado por GNG sem individualização das estruturas.	106

Figura 4-24: Continuação da evolução do grafo GNG da Figura anterior. Conforme o número de nós cresce, mais estruturas são individualizadas.	106
Figura 4-25: Desligamento da estrutura do canto superior esquerdo, como o aumento do número de nós.	107
Figura 4-26: Mapeamento de um atributo de coerência em probabilidades para geração de malha geológica.	108
Figura 4-27: Fatia de tempo de um atributo de falha (Agüero, 2005).	109
Figura 4-28: À esquerda: triangulação de Delaunay para um conjunto de 316 átomos gerados pela geração de malhas por átomos (Agüero, 2005). À direita: triangulação de Delaunay para um conjunto de 316 nós gerados por GNG.	110
Figura 4-29: À esquerda: grafo gerado por GNG com 316 nós sobre a imagem da Figura 4-27. À direita: triangulação de Delaunay para um conjunto de 316 nós gerados por GNG.	111
Figura 5-1: Grafo exibindo uma aresta frágil (em vermelho). A vizinhança do nó <i>a</i> contém outra aresta frágil, o que eleva a média local dos tamanhos de aresta.	114
Figura 5-2: Grafo gerado por GNG, com arestas frágeis	121
Figura 5-3: Grafo da Figura 5-2 segmentado por FH com $k=5$ . Nós isolados não são apresentados.	121
Figura 5-4: Grafo da Figura 5-2 segmentado por FH com $k=15$ . Nós isolados não são apresentados.	122
Figura 5-5: Grafo da Figura 5-2 segmentado por FH com $k=50$ . Nós isolados não são apresentados.	122
Figura 5-6: Detalhe da Figura 5-5, mostrando a ocorrência de estruturas não verticais.	123
Figura 5-7: Estrutura de uma nuvem de pontos e sua relação com os autovalores da matriz de covariância. À esquerda, distribuição isotrópica; no centro, distribuição em linha; e, à direita distribuição planar.	126
Figura 5-8: Resultado da segmentação pela orientação sem imposição de verticalidade. Comparar com a Figura 5-4.	131
Figura 5-9: Resultado da segmentação pela orientação, impondo verticalidade e número de nós maior do que 40, por segmento.	131
Figura 5-10: Fatias ao longo de uma mesma direção vertical do atributo de falhas em 3 posições diferentes, mostrando como o grafo resultante da	

- segmentação acompanha as principais estruturas de falha. 132
- Figura 5-11: Fatias ao longo de uma mesma direção vertical (mesma direção da Figura anterior) do atributo de falhas em 4 posições diferentes, mostrando como o grafo resultante da segmentação acompanha as principais estruturas de falha. 133
- Figura 5-12: Fatias ao longo de uma mesma direção vertical (direção perpendicular à da Figura anterior) do atributo de falhas em 3 posições diferentes, mostrando como o grafo resultante da segmentação acompanha as principais estruturas de falha. 134
- Figura 6-1: Volume de probabilidades é dividido em um conjunto de volumes de probabilidades específicos para cada falha identificada na segmentação do grafo (Mapeamento Grafo-Volume). 136
- Figura 6-2: Duas fatias verticais da amplitude sísmica de um dado sísmico sintético com o mapa de cores *flag*. O atributo de falha é exibido em duas fatias, uma vertical e outra horizontal, em tons de cinza. A superfície de falha vista pelo atributo gera uma região volumétrica com duas amostras de espessura. 141
- Figura 6-3: Visualização do grafo gerado por GCS com 100 nós em dois ciclos diferentes. Triângulos extraídos dos grafos são exibidos em verde. Os grafos se apresentam rasgados nas bordas. O grafo da imagem de baixo gera uma malha com defeito (círculo vermelho). 142
- Figura 6-4: Formação de rasgos em superfícies planas geradas pelo GCS. 143
- Figura 6-5: Vizinhança de um ponto da malha triangular 147
- Figura 6-6: Suavização de uma superfície triangular enrugada. a: superfície original. b: após um passo de suavização. c: após dois passos. d: após cinco passos. 149
- Figura 6-7: Componente tangencial do Laplaciano ( $\nabla_{\tau} \mathbf{x}$ ). 150
- Figura 6-8: Operações de colapso de aresta e divisão de vértice. Adaptada de Hoppe (1998). 151
- Figura 6-9: À esquerda: um vértice de valência 8 antes do processo de divisão. À direita: após o processo de divisão. O processo distribui as valências de forma mais igualitária possível. (Ivrissimtzis et al., 2003a) 152
- Figura 6-10: Resultado do processo de criação de um novo nó segundo a política do GCS para a situação da esquerda da Figura 6-9. O nó de maior atividade permanece com valência 8 e o novo nó tem valência 4. 152
- Figura 6-11: Aresta (a, b) sofre o processo de colapso de aresta. À esquerda, (a,

- b) é uma aresta interna. À direita, (a, b) é uma aresta de borda. (Ivrissimtzis et al., 2003b) 153
- Figura 6-12: Esfera gerada por NM. Da esquerda para a direita e de cima para baixo: tetraedro inicial, malha com 5, 7, 27, 49 e 351 nós. 157
- Figura 6-13: Esfera gerada por NM com 1000 nós. 158
- Figura 6-14: Detalhe de fatias do volume de probabilidades para uma superfície de falha. 160
- Figura 6-15: Geometria do processo de adaptação de um nó da borda (s). Do lado esquerdo, situação em que o nó forma uma vizinhança convexa com os nós vizinhos da borda a, b. Do lado direito, o nó s forma uma concavidade com seus vizinhos. 162
- Figura 6-16: Restrição de movimento dos nós da borda. Grafos gerados por MNA para o mesmo dado sintético utilizado no teste do GCS (ver Figura 6-2). Da esquerda para direita, de cima para baixo: grafo inicial, grafo inicial após 196 ciclos, e grafos com 4, 5, 20 e 100 vértices (comparar com Figura 6-3). 168
- Figura 6-17: Evolução de malha gerada por MNA para o volume de probabilidades ondulada1. 169
- Figura 6-18: Malha gerada por MNA para o volume de probabilidades ondulada25, sem (em cima) e com (embaixo) suavização pela componente normal do Laplaciano. 171
- Figura 6-19: Malha gerada por MNA para o volume de probabilidades ondulada25 com suavização de bordas pela componente normal do Laplaciano. 172
- Figura 6-20: MNA sem suavização de bordas (à esquerda) e com suavização de bordas (à direita). 173
- Figura 6-21: Efeito do aumento da componente normal do Laplaciano: na imagem de cima,  $e_{nin} = 0.05$  e na de baixo,  $e_{nin} = 0.5$  174
- Figura 6-22: Superfície reconstruída por MNA para o volume de probabilidades ondulada25. 175
- Figura 6-24: Superfície gerada por MNA para o segmento azul. Volume de probabilidades do segmento mapeado em fatias horizontais e verticais. 177
- Figura 6-25: Outro ângulo da superfície gerada por MNA para o segmento azul. Volume de probabilidades do segmento mapeado em fatias horizontais e verticais. 178
- Figura 6-26: Superfície gerada por MNA para o segmento amarelo. Volume de

- probabilidades do segmento mapeado em fatias horizontais e verticais. 179
- Figura 6-27: Superfície gerada por MNA para o segmento vermelho. Volume de probabilidades do segmento mapeado em fatias horizontais e verticais. 179
- Figura 6-28: Superfícies de falha geradas por MNA com o volume de atributo de falha mapeado em fatias horizontais e verticais. 180
- Figura 6-29: Superfícies de falha geradas por MNA exibidas em vermelho, azul e amarelo com o volume de atributo de falha mapeado em fatias horizontais e verticais. 181
- Figura 6-30: Superfícies geradas por MNA com volume de amplitudes sísmicas mapeado em fatias verticais. 182
- Figura 6-31: Na imagem de cima, visualização dos voxels identificados pelo método de SNM de Canny. Embaixo, superfícies geradas por MNA superpostas pelos voxels de Canny. 183

## Lista de tabelas

Tabela 1: Parâmetros do Growing Neural Gas.	89
Tabela 2: Custo computacional das operações de uma lista de prioridades implementada via <i>heap</i> .	94
Tabela 3: Parâmetros da segmentação por orientação.	130
Tabela 4: Parâmetros do algoritmo Growing Cell Structures	139
Tabela 5: Parâmetros do algoritmo Neural Meshes	156
Tabela 6: Parâmetros do algoritmo de Malhas Neurais Abertas.	166
Tabela 7: Estruturas locais identificadas pelos autovalores do tensor de estrutura do gradiente.	197
Tabela 8: Estruturas locais identificadas pelas medidas de confiança derivadas dos autovalores do tensor de estrutura do gradiente.	198

## Lista de siglas

AGM	Árvore Geradora Mínima ( <i>minimum spanning tree</i> ).
CHL	Aprendizado Competitivo Hebbiano ( <i>Competitive Hebbian Learning</i> ).
FH	Algoritmo de segmentação de grafos devido a Felzenszwalb e Huttenlocher (2004).
GCS	Growing Cell Structures.
GNG	Growing Neural Gas.
MNA	Malhas Neurais Abertas.
NG	Neural Gas.
NM	Neural Meshes.
SNM	Supressão de pontos Não-Máximos ( <i>non-maximal-supression</i> ).
SOFM	Mapa de Características Auto-organizável de Kohonen ( <i>Self Organizing Feature Map</i> ).
TEG	Tensor de Estrutura do Gradiente.

## Lista de símbolos

### Capítulo 2

<b>C</b>	Matriz de covariância.
$C_{\text{caos}}$	Atributo de caos.
$C_{\text{cov}}$	Coerência por autoestrutura.
$C_{\text{falha}}$	Atributo de falha do TEG.
$C_{\text{linear}}$	Confiança em estrutura linear.
$C_{\text{plano}}$	Confiança em estrutura planar.
$C_{\text{TEG}}$	Coerência pelo tensor de estrutura do gradiente.
<b>D</b>	Matriz formada pelos vetores $\mathbf{d}_i$ dispostos em coluna.
$\mathbf{d}_i$	Vetor de amostras na direção vertical do cubo de análise.
<b>g</b>	Vetor gradiente.
<b>n</b>	Vetor normal ao cubo de análise.
<b>S</b>	Semblance.
<b>T</b>	Tensor de estrutura do gradiente.
$T_D$	Tensor de difusão.
$\mathbf{v}_i$	Autovetores da matriz de covariância.
$w_x, w_y, w_z$	Dimensões do cubo de análise.
$\lambda_i$	Autovalores da matriz de covariância.

### Capítulo 3

<b>A</b>	Energia potencial entre os átomos.
<b>B</b>	Energia potencial devida às amostras da imagem.
$C(p)$	Função de compatibilidade de um ponto pertencer a um retalho plano.
$C(s_1, s_2)$	Função de compatibilidade entre dois retalhos planares.
<b>d</b>	Distância nominal.
<b>P</b>	Energia potencial total.
<b>f</b>	Energia potencial entre dois átomos.
$s_g$	Escala da filtragem Gaussiana do gradiente no método TEG.
$s_T$	Escala da filtragem Gaussiana do tensor no método TEG.

### Capítulo 4

<b>A</b>	Conjunto de unidades.
----------	-----------------------

$a_{\max}$	Parâmetro de idade do GNG (ver Tabela 1)
$c$	Limiar do mapeamento do atributo de falha em probabilidades.
$C$	Conjunto de conexões.
$c_i$	$i$ -ésima unidade.
$D_S^{(M)}$	Triangulação de Delaunay (dos pontos de $S$ ) induzida (por $M$ ).
$E$	Erro de quantização.
$G$	Grafo.
$H(X)$	Entropia da variável aleatória $X$ .
$I(x,y)$	Intensidade do ponto $(x,y)$ de uma imagem.
$k$	Número de bits da representação do número de células da grade regular.
$M$	Espaço de entrada.
$m_F$	Valor do atributo correspondendo à menor possibilidade de falha.
$M_F$	Valor do atributo correspondendo à maior possibilidade de falha.
$N,n$	Número de unidades.
$N_s$	Conjunto de vizinhos diretos da unidade $s$ .
$n_c$	Número de ciclos
$p$	Probabilidade de falha.
$R$	Matriz de adjacência do grafo.
$s$	Unidade vencedora.
$S$	Conjunto de vetores de referência.
$s_1$	Unidade vencedora.
$s_2$	Unidade segunda-vencedora.
$V_c$	Região de Voronoi da unidade $c$ .
$V_{ij}$	Poliedro de Voronoi de segunda ordem.
$V_i^{(M)}$	Poliedro de Voronoi (da unidade $i$ ) restrito (a $M$ ).
$w_c$	Vetor de referência da unidade $c$ .
$a, b, e_b, e_n, l$	Parâmetros do GNG (ver Tabela 1).
$\Phi$	Mapeamento do espaço de entrada no grafo.
$?$	Sinal de entrada.

## Capítulo 5

$A$	Conjunto de arestas.
$C$	Matriz de covariância.
$C_{\text{linha}}$	Confiança em estrutura linear.
$C_{\text{plano}}$	Confiança em estrutura planar.

$D(s_1, s_2)$	Predicado de segmentação.
$Dif(s_1, s_2)$	Função diferença-entre de dois segmentos.
$G$	Grafo.
$I$	Conjunto de pixels de uma imagem.
$Int$	Função diferença interna de um segmento.
$k$	Parâmetro de tolerância do algoritmo FH.
$limAng, limConf, p$	Parâmetros de segmentação pela orientação local (Tabela 3).
$MInt$	Função diferença interna de um segmento com tolerância.
$\mathbf{p}$	Vetor posição.
$\bar{\mathbf{p}}$	Centróide de um conjunto de pontos.
$S$	Subconjunto de um conjunto de vértices.
$S_i$	$i$ -ésimo subconjunto de pixels de uma imagem.
$V$	Conjunto de vértices de um grafo.
$v_i$	$i$ -ésimo vértice de um conj. De vértices.
$w(a)$	Peso da aresta $a$ .
$\mathbf{x}_i$	Autovetores da matriz de covariância.
$\lambda_i$	Autovalores da matriz de covariância.
$\mathbf{m}$	Média de valores escalares.
$s$	Desvio padrão
$t$	Função de tolerância do algoritmo FH.

## Capítulo 6

$A$	Conjunto de unidades.
$c$	Limiar do mapeamento do atributo de falha em probabilidades.
$C$	Conjunto de conexões.
$c_i$	$i$ -ésima unidade.
$D$	Coeficiente de difusão.
$E$	Erro de quantização.
$G$	Grafo.
$k$	Dimensionalidade da rede gerada pelo GCS.
$M$	Espaço de entrada.
$N, n$	Número de unidades.
$\mathbf{n}_a$	Vetor normal ao plano $a$ .
$\mathbf{n}_p$	Vetor normal ao plano $p$ .
$N_s$	Conjunto de vizinhos diretos da unidade $s$ .

$n_c$	Número de ciclos.
$p$	Probabilidade de falha.
$s$	Unidade vencedora.
$S$	Conjunto de vetores de referência.
$s_1$	Unidade vencedora.
$s_2$	Unidade segunda-vencedora.
$V_c$	Região de Voronoi da unidade $c$ .
$val(a)$	Valência do nó $a$ .
$w_c$	Vetor de referência da unidade $c$ .
$X(u, v)$	Função bidimensional.
$\mathbf{X}$	Superfície.
$x_i$	Ponto em uma superfície $\mathbf{X}$ .
$Y(u, v, t)$	Evolução ao longo do tempo de uma função bidimensional.
$a, e_b, l$	Parâmetros do GCS (ver Tabela 4), do NM (Tabela 5) e do MNA (Tabela 6).
$a_s$	Plano tangente ao grafo na vizinhança do nó $s$ .
$b$	Parâmetro do GCS.
$e_n$	Parâmetro do GCS (ver Tabela 4) do NM (Tabela 5).
$e_{nb}, e_{nin}, e_{nit}$	Parâmetros do MNA (Tabela 6).
$h$	Parâmetro extra do GCS para eliminação de nós supérfluos.
$m$	Parâmetro de remoção de nós do NM (Tabela 5) e do MNA (Tabela 6).
$p_s$	Plano que separa espaço na vizinhança do nó $s$ em interno e externo ao grafo.
$s_g$	Escala da filtragem Gaussiana do gradiente no método TEG.
$s_T$	Escala da filtragem Gaussiana do tensor no método TEG.
$t_c$	Contador de sinais da unidade $c$ .
$?$	Sinal de entrada.
$\nabla^2$	Laplaciano
$\nabla_n^2$	Componente do Laplaciano na direção da normal.
$\nabla_t^2$	Componente do Laplaciano na direção tangencial.

*You need the willingness to fail all the time. You have to generate many ideas and then you have to work very hard only to discover that they don't work. And you keep doing that over and over until you find one that does work.*

*John W. Backus*