



**Aurélio Moraes Figueiredo**

**Mapeamento Automático de Horizontes e Falhas em Dados Sísmicos 3D baseado no algoritmo de Gás Neural Evolutivo**

**Dissertação de Mestrado**

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

Orientador: Prof. Marcelo Gattass

Rio de Janeiro  
Junho de 2007



**Aurélio Moraes Figueiredo**

**Mapeamento Automático de Horizontes e Falhas em Dados Sísmicos 3D baseado no algoritmo de Gás Neural Evolutivo**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre pelo Programa de Pós-Graduação em Informática da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

**Prof. Marcelo Gattass**

Orientador

Departamento de Informática - PUC-Rio

**Prof. Ruy Luiz Milidiú**

Departamento de Informática - PUC-Rio

**Prof. Flavio Szenberg**

Tecgraf - PUC-Rio

**Doutor Paulo Marcos de Carvalho**

Petrobras

**Prof. José Eugenio Leal**

Coordenador Setorial do Centro

Técnico Científico - PUC-Rio

Rio de Janeiro, 29 de junho de 2007

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

### **Aurélio Moraes Figueiredo**

Engenheiro de Computação graduado pela Pontifícia Universidade Católica do Rio de Janeiro em dezembro de 2004. Em março de 2006 entrou para o Programa de Pós-graduação em Informática na mesma universidade.

#### Ficha Catalográfica

Figueiredo, Aurélio Moraes

Mapeamento automático de horizontes e falhas em dados sísmicos 3D baseado no algoritmo de gás neural evolutivo / Aurélio Moraes Figueiredo ; orientador: Marcelo Gattass. – 2007.

79 f. : il. (col.) ; 30 cm

Dissertação (Mestrado em Informática)– Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2007.

Inclui bibliografia

1. Informática – Teses. 2. Computação gráfica. 3. Volumes sísmicos. 4. Horizontes sísmicos. 5. Falhas sísmicas. 6. Gás neural evolutivo. I. Gattass, Marcelo. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Informática. III. Título.

CDD: 004

## **Agradecimentos**

Ao meu orientador Marcelo Gattass por todas as idéias e conselhos que foram indispensáveis na elaboração dessa dissertação.

Aos amigos Paulo Ivson Netto, Eduardo Teles Carlos, Rodrigo Toledo, Gustavo Vagner, Thiago Bastos, Pedro Pereira, Carlos Eduardo Augusto e Maurício Azevedo Ferreira pelas sugestões, e por ajudarem na revisão do texto.

Ao Tecgraf, por ser uma ótima fonte de problemas difíceis e interessantes e um lugar único para trabalhar.

À PUC-Rio e aos seus professores que ensinam com o mesmo empenho nas matérias mais simples e nos assuntos mais complexos.

## Resumo

Figueiredo, Aurélio Moraes; Gattass, Marcelo. **Mapeamento Automático de Horizontes e Falhas em Dados Sísmicos 3D baseado no algoritmo de Gás Neural Evolutivo**. Rio de Janeiro, 2007. 79p. Dissertação de Mestrado - Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

Neste trabalho apresentamos um algoritmo baseado em agrupamento de dados para o mapeamento automático de horizontes e de falhas sísmicas a partir de dados sísmicos 3D. Apresentamos uma técnica para quantizar o volume sísmico de entrada a partir dos neurônios do grafo resultante do processo de treinamento de uma instância do algoritmo Growing Neural Gas (GNG). No conjunto de amostras de entrada utilizadas pelo GNG, cada amostra representa um voxel do volume de entrada, e retém informações da vizinhança vertical desse voxel. Depois da etapa de treinamento, a partir do grafo gerado pelo GNG um novo volume quantizado é gerado, e nesse volume possíveis ambigüidades e imperfeições existentes no volume de entrada tendem a ser minimizadas. A partir do volume quantizado descrevemos uma nova técnica de extração de horizontes, desenvolvida com o objetivo de que seja possível mapear horizontes na presença de estruturas geológicas complexas, como por exemplo horizontes que possuam porções completamente desconectadas por uma ou mesmo diversas falhas sísmicas. Também iniciamos o desenvolvimento de uma abordagem de mapeamento de falhas sísmicas utilizando informações presentes no volume quantizado. Os resultados obtidos pelo processo de mapeamento de horizontes, testado em volumes diferentes, foram bastante promissores. Além disso, os resultados iniciais obtidos pelo processo de extração de falhas sugerem que a técnica pode vir a ser uma boa alternativa para a tarefa.

## Palavras-chave

Computação Gráfica; Volumes Sísmicos; Horizontes Sísmicos; Falhas Sísmicas; Gás Neural Evolutivo

## **Abstract**

Figueiredo, Aurélio Moraes; Gattass, Marcelo. **Mapping Horizons and Seismic Faults from 3D Seismic Data using the Growing Neural Gas Algorithm**. Rio de Janeiro, 2007. 79p. MSc. Dissertation - Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

In this work we present a clusterization-based method to map seismic horizons and faults from 3D seismic data. We describe a method used to quantize an initial seismic volume using a trained instance of the Growing Neural Gas (GNG) algorithm. To accomplish this task we create a training set where each sample corresponds to an entry volume voxel, retaining its vertical neighboring information. After the training procedure, the resulting graph is used to create a quantized version of the original volume. In this quantized volume both horizons and faults are more evidenced in the data, and we present a method that uses the created volume to map seismic horizons, even when they are completely disconnected by seismic faults. We also present another method that uses the quantized version of the volume to map the seismic faults. The horizon mapping procedure, tested in different volume data, yields good results. The preliminary results presented for the fault mapping procedure also yield good results, but needs further testing.

## **Keywords**

Computer Graphics; Seismic Volumes; Seismic Horizons; Seismic Faults; Growing Neural Gas

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>11</b>
1.1	Estrutura do documento da dissertação	13
1.2	Posicionamento da Instituição	14
1.3	Trabalhos Relacionados	14
<b>2</b>	<b>O MÉTODO SÍSMICO NA EXPLORAÇÃO DE PETRÓLEO</b>	<b>16</b>
2.1	Método sísmico de reflexão	177
2.1.1	Aquisição	188
2.1.2	Processamento	20
2.1.3	Interpretação	23
<b>3</b>	<b>AGRUPAMENTO DE DADOS E O ALGORITMO DE GNG</b>	<b>25</b>
3.1	Processos de Agrupamento de Dados	26
3.1.1	Um exemplo simples	26
3.2	Definição do processo	27
3.3	Algoritmos difundidos	28
3.4	O algoritmo de Gás Neural Evolutivo (GNG)	29
3.4.1	Comentários adicionais sobre o funcionamento do algoritmo	33
3.4.1.1	O erro local acumulado	33
3.4.1.2	A movimentação dos nós	34
3.4.1.3	A inserção de novos nós no grafo	34
<b>4</b>	<b>RASTREAMENTO DE HORIZONTES E FALHAS</b>	<b>36</b>
4.1	Criação do conjunto de amostras de entrada	38
4.2	Funções de similaridade adotadas	39
4.3	A geração do novo volume quantizado	40

<b>4.4 Uma interpretação geométrica do volume quantizado</b>	<b>41</b>
4.4.1 Erro médio dos neurônios	41
<b>4.5 O método de extração de horizontes sísmicos</b>	<b>43</b>
<b>4.6 Mapeamento de falhas sísmicas</b>	<b>47</b>
<b>5 RESULTADOS REPORTADOS</b>	<b>52</b>
5.1 Mapeamento de Horizontes	54
5.2 Coeficiente de Correlação como Função de Similaridade	65
5.3 Mapeamento das falhas sísmicas	67
5.4 Tempos de processamento e número de neurônios utilizados	674
<b>6 CONCLUSÕES E TRABALHOS FUTUROS</b>	<b>76</b>
<b>7 BIBLIOGRAFIA</b>	<b>78</b>

## Lista de símbolos

$\lambda$	Número de amostras utilizadas até um novo neurônio ser incluído no grafo GNG durante a fase de treinamento.
$\beta$	Taxa de decrescimento dos erros acumulados de todos os neurônios do GNG.
$\alpha$	Taxa de decrescimento dos erros acumulados dos vizinhos topológicos do neurônio vencedor a cada treinamento do GNG.
$a_{\max}$	Parâmetro de tempo de existência máximo de uma aresta no grafo do GNG.
<b>C</b>	Conjunto de vetores-amostra de entrada.
$\mathbf{c}_x$	Vetor de código do neurônio $\mathbf{n}_x$ .
<i>D</i>	Função que mede a similaridade entre duas amostras do volume quantizado.
<i>dist</i>	Função de similaridade utilizada na fase de treinamento da instância de GNG.
$d_{\max}$	Média das distâncias existentes entre um neurônio $\mathbf{n}_x$ e seus vizinhos topológicos.
$d_{xy}$	Critério de distância adotado entre os neurônios $\mathbf{n}_x$ e $\mathbf{n}_y$ , levando em conta a distância média $d_{\max}$ .
$err_x$	Erro médio do neurônio $\mathbf{n}_x$ em relação ao seu conjunto de amostras $\mathbf{S}_x$ .
<b>F</b>	Conjunto de voxels contendo o melhor voxel candidato de cada traço do volume sísmico ao mapear um horizonte.
$\mathbf{f}_{ti}$	Amostra obtida a partir do volume quantizado e que representa o voxel de índice $i$ no traço sísmico $t$ do volume.
$id_x$	Identificador numérico que representa o neurônio $\mathbf{n}_x$ no volume quantizado.

$k$	Número de identificadores utilizados acima e abaixo do voxel $v_{ti}$ ao criar a amostra $\mathbf{s}_{ti}$ .
$\mathbf{n}_x$	Neurônio de índice $x$ do grafo do GNG.
$n_{x\_error}$	Taxa de erro acumulado do neurônio $x$ .
$q$	Número de identificadores utilizados acima e abaixo do voxel $v_{ti}$ ao criar a amostra $\mathbf{f}_{ti}$ .
$r$	Coefficiente de correlação entre dois vetores.
$\mathbf{s}_{ti}$	Amostra obtida a partir do volume sísmico de entrada e que representa o voxel de índice $i$ no traço sísmico $t$ do volume.
$\mathbf{S}_x$	Conjunto de amostras que são representadas pelo neurônio $\mathbf{n}_x$ .
$v_{ti}$	Voxel de índice $i$ no traço sísmico $t$ .
$\varepsilon_b$	Parâmetro do GNG que define a taxa de aprendizado do neurônio vencedor.
$\varepsilon_t$	Parâmetro do GNG que define a taxa de aprendizado dos vizinhos topológicos do neurônio vencedor.