



Jeff Maynard Guillen

**Estudo sobre Caracterização de Reservatórios por
Programação Genética**

Dissertação de Mestrado

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

Orientador: Prof. Marco Aurélio Cavalcanti Pacheco

Rio de Janeiro
Agosto de 2015



Jeff Maynard Guillen

Estudo sobre Caracterização de Reservatórios por Programação Genética

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Prof. Marco Aurélio Cavalcanti Pacheco

Orientador

Departamento de Engenharia Elétrica – PUC-Rio

Dr. André Bulcão

Petróleo Brasileiro – Rio de Janeiro - Matriz

Prof. Geovan Tavares dos Santos

LNCC

Dr. Álvaro Gustavo Talavera Lopez

Departamento de Engenharia Elétrica – PUC-Rio

Prof. José Eugenio Leal

Coordenador Setorial do Centro

Técnico Científico

Rio de Janeiro, 19 de agosto de 2015

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

Jeff Maynard Guillen

Graduou-se em Ciências Atuariais pela Universidade de Costa Rica (UCR) em 2012.

Ficha Catalográfica

Guillen, Jeff Maynard

Estudo sobre caracterização de reservatórios por programação genética / Jeff Maynard Guillen; orientador: Marco Aurélio Cavalcanti Pacheco. – 2015.

113 f. ; 30 cm

Dissertação (mestrado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2015.

Inclui bibliografia

1. Engenharia elétrica – Teses. 2. Programação genética. 3. Inversão sísmica. 4. Atributos sísmicos. 5. Caracterização de reservatórios. 6. Impedância acústica. I. Pacheco, Marco Aurélio Cavalcanti. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. III. Título.

CDD: 621.3

Agradecimentos

À Deus por tudo, porque sem Ele nada teria acontecido.

Ao meu orientador Professor Marco Aurélio, pela confiança em mim para realizar este trabalho, pelas importantes contribuições e pela constante ajuda nestes dois anos.

À minha esposa pela sua paciência infinita, apoio e amor constante, que foi o que me permitiu seguir em frente.

Aos meus pais, pela educação, pelo amor e o apoio incondicional em cada momento.

À Aurora pelo apoio constante neste tempo todo.

Ao Alvaro e ao João, pela ajuda recebida para a conclusão deste trabalho.

Aos Professores Alex, Eduardo, Santiago e William da Universidade de Costa Rica, pela motivação e pelo apoio, sem os quais não estaria aqui.

Aos professores que participaram da Comissão examinadora pelas suas recomendações.

À todos os meus amigos e familiares da Costa Rica e do Brasil, que de uma ou outra maneira me estimularam e me ajudaram. Especialmente aos que estiveram presentes sempre, Karen, Adriana e Rafael.

Ao CAPES, ao CNPq, à PUC-RIO e à Petrobras, pelos auxílios concedidos, sem os quais este trabalho não poderia ter sido realizado.

Resumo

Guillen, Jeff Maynard; Pacheco, Marco Aurélio Cavalcanti (Orientador). **Estudo sobre Caracterização de Reservatórios por Programação Genética.** Rio de Janeiro, 2015. 113p. Dissertação de Mestrado - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Na área de exploração e produção de petróleo são alocados grandes investimentos para conseguir diminuir os riscos associados à baixos níveis de produção, que podem ser minimizados mediante a acertada caracterização do reservatório de petróleo. Uma valiosa fonte de informação pode ser extraída de dados sísmicos 3D, obtidos do campo em estudo. O custo econômico de aquisição de esta base de dados para o reservatório completo é relativamente baixo, se comparado com uma amostragem direta por meio de perfurações de poços. Embora, a relação entre os dados sísmicos e as propriedades de reservatório seja considerada ambígua, esta deve ser integrada com informação confiável, como aquela obtida mediante perfilagem de poços. Fazendo uso dos abundantes dados sísmicos e das escassas, mas, precisas medições em perfurações existentes, foi desenvolvido neste trabalho um sistema baseado no algoritmo de Programação Genética (PG) para caracterizar geologicamente um reservatório de petróleo. PG é uma técnica de computação evolucionária capaz de estimar relações não lineares entre um conjunto de entrada e de saída, mediante uma expressão simbólica explícita. Para extrair informação adicional nos registros sísmicos são calculados atributos sísmicos, que facilitam a identificação de características estratigráficas ou estruturais do subsolo representadas indiretamente pela sísmica. Adicionalmente, é utilizado o método de inversão sísmica para o cálculo da impedância acústica, que é uma variável auxiliar derivada de sísmica calibrada com perfis de poço. Os atributos sísmicos junto com a impedância acústica servirão para a estimação de propriedades geológicas. Esta metodologia de trabalho foi testada em um reservatório real de grande complexidade geológica. Por meio de PG, foi representada satisfatoriamente a relação entre dados derivados da sísmica e a porosidade do campo, demonstrando assim que PG é uma alternativa viável para a caracterização geológica de reservatórios. Posteriormente, foi realizada uma *clusterização* do campo baseada em características geofísicas que permitiram a construção de estimadores por PG especializados para cada zona.

Palavras-chave

Programação Genética; Inversão Sísmica; Atributos Sísmicos; Caracterização de Reservatórios; Impedância Acústica.

Abstract

Guillen, Jeff Maynard; Pacheco, Marco Aurélio Cavalcanti (Advisor). **Studies on Reservoir Characterization via Genetic Programming.** Rio de Janeiro, 2015. 113p. MSc Dissertation - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

In the field of oil exploration and production a great deal of investment is allocated in reducing the risks associated to low production levels that can be minimized through an accurate oil reservoir characterization. A valuable source of information can be extracted from 3D seismic data, obtained from the studied reservoir. The economic cost of the acquisition of this data base for the whole reservoir is relatively low, if compared to the direct sampling method of well drilling. Being that the relationship between seismic data and reservoir properties is considered ambiguous, it must be integrated with reliable information, such as that obtained by well logging. Making use of abundant seismic data and scarce, yet accurate, measurements from the existing drillings, it was developed in this study a system based in the algorithm of Genetic Programming (GP), to geologically characterize an oil reservoir. GP is an evolutionary computational technique capable of estimating the non-linear relationships between input and output parameter, through an explicit symbolic expression. In order to extract additional information from seismic records, seismic attributes are calculated, which facilitate tasks of identifying stratigraphic and structural characteristics of the subsurface, represented indirectly by seismic data. Moreover, a seismic inversion method is used to estimate the acoustic impedance, an auxiliary variable derived from seismic data calibrated by well logs. The seismic attributes along with the acoustic impedance will be used to estimate geological properties. This workflow was tested on a real reservoir, thus presenting geological complexity. Through GP, the relationship between seismic derived data and the field porosity was represented satisfactorily, demonstrating that GP is a viable alternative for geologic reservoir characterization. Afterwards, the reservoir was divided in clusters according to geophysical properties, this allowed the construction of GP based estimators for each zone.

Keywords

Genetic Programming; Seismic Inversion; Seismic Attributes; Reservoir Characterization; Acoustic Impedance.

Sumário

1	Introdução	13
1.1.	Motivações	13
1.2.	Objetivos	16
1.3.	Organização do Trabalho	16
2	Dados de Reservatório	18
2.1.	Introdução	18
2.2.	Dados Sísmicos	19
2.2.1.	Aquisição Sísmica	20
2.2.2.	Processamento de Dados Sísmicos	21
2.3.	Dados Sísmicos 3D	23
2.4.	Atributos Sísmicos	24
2.4.1.	Classificação dos Atributos Sísmicos	25
2.5.	Dados Geofísicos	31
2.5.1.	Perfis de Poço	32
2.5.2.	Impedância Acústica	34
3	Tratamento de Variáveis	35
3.1.	Introdução	35
3.2.	Pré-processamento de Dados Sísmicos	35
3.3.	Pré-processamento de Perfis de Poço	36
3.4.	Problemas de Escala	38
3.5.	Seleção de Atributos Sísmicos	39
3.6.	Estimação de Perfis de Poço	41
4	Métodos de Inteligência Computacional	43
4.1.	Introdução	43
4.2.	Programação Genética	43
4.2.1.	Componentes de Programação Genética	45
4.2.2.	Programação Genética Multi-Gene	47
4.3.	Redes Neurais	49
4.3.1.	Redes Neurais Multilayer Perceptron (MLP)	49
4.3.2.	Métodos de Otimização de Pesos	51
4.3.3.	Clusterização	52
5	Inversão Sísmica e Geostatística	55
5.1.	Introdução	55
5.2.	Inversão Sísmica	56
5.2.1.	Inversão Genética	58
5.3.	Geostatística	60
5.3.1.	Simulação Indicadora Sequencial	61
6	Modelagem da Caracterização de Reservatórios	64
6.1.	Introdução	64
6.2.	Modelagem do Problema	64

6.3. Estimativa de Propriedades em Poços	69
6.4. Estimativa de Propriedades 3D	69
7 Caso de Estudo	72
7.1. Introdução	72
7.2. Campo de Namorado	72
7.2.1. Dados de Poço	73
7.2.2. Dados Sísmicos	74
7.3. Estimativa de Perfis de Poço	75
7.4. Estimativa de Parâmetros de Reservatório	81
7.4.1. Inversão Genética	81
7.4.2. Estimativa da Porosidade Neutrônica por meio de PG	85
8 Conclusões e Trabalhos Futuros	104
8.1. Conclusões	104
8.2. Trabalhos Futuros	106
Referências Bibliográficas	107
Apêndice	112

Lista de Figuras

Figura 2.1: Aquisição Sísmica Marinha.....	21
Figura 2.2: Efeito da correção NMO. Modificado de (SCHLUMBERGER).	23
Figura 2.3: Traça sísmica (esquerda) e cubo sísmico (direita).....	24
Figura 2.4: a) Seção sísmica da amplitude original, b) O atributo sísmico apparent polarity.	28
Figura 2.5: a) Seção sísmica da amplitude original, b) O atributo sísmico structural smoothing.	29
Figura 2.6: a) Seção sísmica da amplitude original, b) O atributo sísmico iso- frequency component.	30
Figura 2.7: a) Seção sísmica da amplitude original, b) O atributo sísmico relative acoustic impedance.	30
Figura 2.8: a) Seção sísmica da amplitude original, b) O atributo sísmico t*Attenuation.....	31
Figura 2.9. Principais perfis de poço.	33
Figura 3.1: Efeito de utilizar o método de controle automático de ganho a uma seção sísmica 2d.....	36
Figura 3.2: Presença de valores extremos em um perfil de poço sônico.	37
Figura 3.3: Aplicação do método de média móvel em um registro de porosidade.....	38
Figura 3.4: Diferenças de escala entre dados sísmicos e perfis de poço.....	39
Figura 4.1 Operador de cruzamento para PG.	47
Figura 4.2: Modelo multi-gene	48
Figura 4.3: a) Funcionamento de cada neurônio. b) Estrutura da rede neural MLP.....	50
Figura 5.1. Classificação dos métodos de inversão sísmica. Modificado de (RUSSELL, 1988).....	56
Figura 5.2. a) Funcionamento da modelagem mediante o método direto. b) Funcionamento da modelagem mediante a inversão. Modificados de (BARCLAY, et al., 2008).....	57

Figura 5.3: Seleção inteligente de amostras. As amostras a considerar são delimitadas por zonas em forma de diamante, modificado de (VEEKEN, et al., 2009).	60
Figura 5.4: Modelo de semivariograma esférico. Tomado de (DA COSTA, 2013).	62
Figura 6.1: Esquema do processo de estimação de uma variável por meio de PG.	66
Figura 6.2: Calculadora do software de análise e interpretação de dados sísmicos Petrel.	67
Figura 6.3: Esquema do workflow para estimação da porosidade 3D.	68
Figura 6.4: Esquema do workflow para a estimação de perfis de poço.	69
Figura 6.5: Esquema do workflow para a estimação de propriedades 3D.	70
Figura 7.1: Localização do campo Namorado. Modificado de (BIZZI, et al., 2003).	73
Figura 7.2: Distribuição espacial dos poços do campo de Namorado.	74
Figura 7.3: Distribuição dos valores de cada perfil de poço.	76
Figura 7.4: Distribuição espacial dos poços de treino e teste para a estimação do perfil de poço no campo de Namorado. Os quadros são poços de treino e os círculos poços de teste.	77
Figura 7.5: Estimativa do perfil de poço sônico nos poços de teste. Comparação entre a estimação por programação genética e por RN.	80
Figura 7.6: Efeito da suavização nos perfis de poço de impedância acústica.	82
Figura 7.7: Distribuição espacial dos poços de treino e teste para a inversão sísmica no campo de Namorado. Os quadrados são poços de treino e os círculos poços de teste.	82
Figura 7.8: Resultados da inversão genética em poços de teste.	85
Figura 7.9: Seleção de atributos sísmicos por meio de uma análise de correlação.	86
Figura 7.10: Upscale da porosidade neutrônica por meio da média móvel.	88
Figura 7.11: Resultados da estimação por meio de PG e RN da porosidade neutrônica, avaliados em poços de teste.	91
Figura 7.12: Estimação da porosidade neutrônica em todo o reservatório.	92
Figura 7.13: Valores de índice de Davies-Bouldin para diferentes números de <i>clusters</i> .	93

Figura 7.14: a) <i>Clusters</i> em poços de teste. b) Distribuição dos <i>clusters</i> nos poços de teste.	93
Figura 7.15: <i>Clusters</i> interpolados ao reservatório completo.....	95
Figura 7.16: Resultados da estimação por meio de PG <i>clusterizada</i> e global da porosidade neutrônica, avaliadas em poços de teste.....	97
Figura 7.17: Distribuição espacial do conjunto de treinamento utilizado para os testes do experimento 1.....	99
Figura 7.18: Distribuição espacial do conjunto de treinamento utilizado para os testes do experimento 2.....	101
Figura 7.19: Comparação dos erros dos experimentos 1 e 2 com o caso base....	102

Lista de Tabelas

Tabela 2.1: Avanços da indústria sísmica. Modificado de (YILMAZ, 2001)	19
Tabela 2.2: Métodos básicos de processamento de dados sísmicos.	22
Tabela 2.3: Lista de Atributos Sísmicos em Petrel E&P Software.	27
Tabela 7.1: Número de poços no campo de Namorado com determinado perfil de poço.	74
Tabela 7.2: Parâmetros dos dados sísmicos no campo de Namorado.	75
Tabela 7.3: Resultado da análise de correlação entre os perfis de poço GR, NPHI, RHOB e o logaritmo do perfil ILD, com o perfil sônico.	77
Tabela 7.4: Parâmetros de PG selecionados para a estimação do perfil de poço sônico.	78
Tabela 7.5: Resultados na estimativa do perfil de poço sônico.	79
Tabela 7.6: Parâmetros selecionados para a inversão genética.	83
Tabela 7.7: Resultado da inversão genética para cada um dos poços de teste.	84
Tabela 7.8: Normalização realizada às variáveis de localização.	87
Tabela 7.9: Parâmetros de PG selecionados para a estimação da porosidade.	89
Tabela 7.10: Resultados na estimação da porosidade neutrônica utilizando PG e RN. Erro médio medido em unidades de porosidade.	90
Tabela 7.11: Parâmetros de melhor ajuste da função semivariograma.	94
Tabela 7.12: Parâmetros selecionados para PG em cada <i>cluster</i> .	95
Tabela 7.13: Resultados de PG clusterizada, PG global e a porcentagem de melhoria.	96
Tabela 7.14: Resultados da estimação do NPHI para os testes do experimento 1.	100
Tabela 7.15: Resultados da estimação do NPHI para os testes do experimento 2.	101
Tabela 7.16: Comparação dos erros dos experimentos 1 e 2 com o caso base.	102

1 Introdução

1.1. Motivações

O estudo sobre a caracterização de reservatórios de petróleo tem por objetivo fornecer conhecimento sobre as características do campo, para poder estabelecer melhores estratégias de extração. Na área de exploração e produção de petróleo a correta descrição geológica do reservatório pode minimizar consideravelmente os riscos associados à baixos níveis de produção. Com este objetivo é integrada a informação imprecisa, mas abundante dos dados sísmicos, com as medições exatas das limitadas perfurações. O estudo de dados sísmicos vem ganhando destaque na literatura com o aumento na capacidade computacional e a melhoria em técnicas de aquisição sísmica. A informação sísmica é fundamental para descobrir as características do reservatório em zonas com escassos poços perfurados, principalmente ao princípio da vida do campo petrolífero.

Avanços nas técnicas de aquisição, processamento e análise de dados sísmicos permitem atualmente, obter estimativas mais precisas de propriedades no reservatório completo. Os métodos mais utilizados para fazer isto podem ser separados em duas categorias, os métodos geostatísticos e os métodos que utilizam inversão sísmica. No primeiro grupo utilizam-se os perfis de poço como informação primária e os dados sísmicos como informação secundária, para interpolar a informação dos perfis de poço (DOYEN, 1988) (SRIVASTAVA, 1992). Os métodos da segunda categoria foram desenvolvidos a partir da ideia de que existe uma relação não linear entre as informações mensuráveis dos dados sísmicos e as propriedades geológicas (SCHULTZ, et al., 1994). Portanto estes métodos dependem principalmente dos dados sísmicos, e os perfis de poço servirão como uma ferramenta de calibração (BANCHS, et al., 2002), (VEEKEN, et al., 2009), (PENDREL, 2006), (LEITE, et al., 2011).

Por outro lado, técnicas de inteligência computacional têm sido utilizadas com muita frequência na indústria de petróleo. Simuladores para a caracterização de reservatórios (como o Petrel da Schlumberger e OpendTect) já possuem desde alguns anos atrás ferramentas de redes neurais (RN) e aplicações com algoritmos genéticos. Trabalhos como (MOHAGHEGH, et al., 1995), (MOHAGHEGH, 2005) e (PACHECO, et al., 2009), formulam propostas de soluções a diferentes áreas na engenharia de petróleo, por meio de algoritmos genéticos, redes neurais e lógica fuzzy.

Adicionalmente, programação genética (PG) é uma técnica da família de computação evolucionária, que permite aproximar a relação existente entre um conjunto de variáveis de entrada e uma variável de saída. Este algoritmo está definido como um método de regressão simbólica, que tem por objetivo encontrar um programa de computador ou expressão matemática que se ajuste aos dados amostrados (KOZA, 1992). Esta técnica computacional vem-se destacando cada vez mais em aplicações onde seja preciso uma expressão matemática explícita para descrever um problema com informação inexata (YU, et al., 2008) (BURKE, et al., 2009).

Na área de exploração de petróleo, desde anos atrás existe um grande interesse por estimar relações não lineares, porém a programação genética está começando a ser utilizada apenas recentemente. Em (KAYDANI, et al., 2014) é apresentada uma aplicação para a estimação da permeabilidade num reservatório de petróleo heterogêneo. Kaydani afirma que PG é uma poderosa ferramenta para reconhecer possíveis padrões entre conjuntos de entrada e saída, o qual pode ser aplicado para prever parâmetros de reservatório. Outras pesquisas utilizam com sucesso PG nas áreas de: ajuste de histórico, criação de *proxies* de simuladores de reservatório e controle operacional de reservatório (YU, et al., 2007), (YU, et al., 2008), (FALLAH-MEHDIPOUR, et al., 2012).

Neste trabalho foi utilizado o algoritmo de PG, para a caracterização de um reservatório de petróleo a partir de dados sísmicos e perfis de poço. PG tem a capacidade de estimar relações não lineares entre um conjunto de dados de entrada e de saída, por meio de uma expressão simbólica explícita, que pode ser utilizada para posteriores estudos ou análises. Especificamente neste trabalho, foi estudada a caracterização de reservatórios, utilizando PG para obter uma função que aproxime a porosidade em toda a região considerada.

Para extrair a maior quantidade de informações (relevantes) dos dados sísmicos, foi calculado um conjunto de atributos que contribuam à estimação de propriedades de reservatório. Por outro lado, a impedância acústica nos poços pode ser estendida ao reservatório completo, por meio de um processo de inversão sísmica. O método selecionado de inversão sísmica está baseado em metodologias de inteligência computacional, portanto é capaz de captar relações não necessariamente lineares, entre a sísmica e as mudanças na impedância acústica entre camadas do reservatório.

A impedância acústica (resultante do processo de inversão sísmica) e os atributos derivados da sísmica foram utilizados como variáveis de entrada num modelo de aproximação, construído por meio de programação genética. O modelo terá por objetivo a estimação da porosidade como uma propriedade “densa” em todo o reservatório. O desempenho deste resultado será avaliado com poços de teste não utilizados no aprendizado do modelo. Os atributos sísmicos utilizados foram selecionados por meio de um estudo de correlações, avaliando a similitude com o comportamento da variável que se deseja estimar.

Adicionalmente, com o propósito de melhorar o desempenho do algoritmo de PG, foi realizada uma *clusterização* do reservatório de acordo às propriedades geofísicas. Este agrupamento diminui a heterogeneidade dentro de cada grupo, facilitando a construção de expressões simbólicas de PG, que aproximem a porosidade no reservatório completo. O resultado foi comparado com a estimação de uma PG global, com a finalidade de mostrar a porcentagem de melhoria.

Finalmente, a lógica antes exposta, nos permite expressar por meio de PG, propriedades de reservatório como uma função que depende de dados sísmicos e/ou perfis de poço. Esta inovadora metodologia vai ser testada e avaliada num modelo baseado no campo Namorado, que possui um alto grau de complexidade geológica. Os resultados são medidos utilizando os seguintes erros de estimação: MAPE, que é uma medida de erro absoluto porcentual e o erro médio, que corresponde à média do valor absoluto dos erros.

1.2. Objetivos

Objetivo geral:

Investigar o desempenho de programação genética na caracterização de reservatórios de petróleo por meio da integração de dados sísmicos e geofísicos.

Objetivos específicos:

- Estudo e implementação do algoritmo de programação genética para a estimação de perfis de poço faltantes, a partir de outros perfis de poço disponíveis.
- Estudo e implementação de métodos que permitam a integração de dados sísmicos e geofísicos, resolvendo problemas de escala, de interpolação e de esparcidade horizontal ou vertical nos dados a serem utilizados.
- Estudo e aplicação do algoritmo de inversão sísmica, chamado de inversão genética, para a obtenção de propriedades de reservatório. Especificamente, para estimar a impedância acústica no reservatório completo.
- Estudo e avaliação do desempenho de PG em zonas *clusterizadas* do reservatório, de acordo a características geofísicas.
- Integração dos processos e resultados obtidos nos objetivos anteriores, para gerar por meio de PG, uma expressão que aproxime a porosidade no reservatório de petróleo completo.

1.3. Organização do Trabalho

Esta dissertação contém mais oito capítulos, cujos conteúdos estão descritos a seguir.

No Capítulo 2 é descrita a base de dados, que será o fundamento do estudo nos restantes capítulos deste trabalho. São enunciados os conceitos correspondentes à aquisição e manipulação de dados sísmicos e perfis de poço.

No Capítulo 3 são apresentadas as metodologias empregadas, para o tratamento das diferentes variáveis utilizadas no estudo realizado nesta

dissertação. Também é exposto o cálculo de derivados dessas variáveis, como atributos sísmicos ou perfis de poço faltantes.

No Capítulo 4 é descrito o funcionamento e as aplicações dos métodos de inteligência computacional utilizados nesta pesquisa. Os quais são programação genética, redes neurais e *clusterização*.

No Capítulo 5 são apresentadas as técnicas de inversão sísmica e de geostatística. No caso da inversão sísmica, é descrita a inversão genética enfocando-se na estimação da impedância acústica, como uma variável de fundamental importância para estimativas posteriores. Por outro lado, são descritos métodos geostatísticos de interpolação para variáveis discretas, com o propósito de estender os resultados de *clusterização* ao reservatório completo.

No Capítulo 6 é desenvolvido o principal objetivo desta dissertação, que é a caracterização de reservatórios de petróleo utilizando PG. Faz-se uma descrição dos modelos baseados em PG, que serão construídos a partir de dados sísmicos e perfis de poço.

No Capítulo 7 são apresentados os resultados dos modelos desenvolvidos, tanto para a estimação de perfis de poço faltantes, como para a estimação de propriedades geológicas no reservatório completo.

Finalmente, no Capítulo 8, são expostas as conclusões e os possíveis direcionamentos para trabalhos futuros.

2 Dados de Reservatório

2.1. Introdução

A exploração de reservatórios de petróleo *offshore* apresenta um desafio importante para as companhias de petróleo, esta tarefa é enfrentada por meio do uso de numerosos levantamentos sísmicos e medições diretas de propriedades, obtidas de um número pequeno de perfurações realizadas através do reservatório. As estimativas realizadas por geólogos e geofísicos sobre o modelo do reservatório serão o resultado do uso conjunto de estas informações.

Os dados sísmicos representam uma fonte de informação relativamente barata, se comparada com os altos custos económicos de uma perfuração, que fornecem medições indiretas das características do reservatório. Porém, devido à heterogeneidade da subsuperfície, ao tipo de dispositivo e às configurações geométricas empregadas na aquisição dos dados sísmicos, apresentam um alto grau de ambiguidade. Um conjunto de processos prévios deve ser realizado para minimizar o ruído inerente aos dados sísmicos. O processamento correto de estes dados é fundamental para converter estas medições em informação confiável. Depois da etapa de processamento, são extraídas propriedades existentes no comportamento dos dados sísmicos, por meio de variáveis diretamente derivadas da sísmica, chamadas de atributos sísmicos.

Por outro lado, os dados geofísicos amostrados diretamente em perfurações provêm informações mais exatas, embora localizadas. Estes dados são amostrados por meio da aplicação de ferramentas descidas no poço, calculando diversas propriedades dos materiais que conformam o reservatório. Porém, as perfurações são escassas, devido aos seus altos custos de escavação.

2.2. Dados Sísmicos

Os dados sísmicos representam uma das principais ferramentas para o mapeamento de hidrocarbonetos. Estes são produzidos principalmente pela propagação de ondas sísmicas, criadas por explosões controladas, que se propagam no subsolo. Quando essas ondas encontram uma diferença abrupta no meio em que transitam, como falhas ou uma estratigrafia distinta, uma fracção da energia da onda é refletida para a superfície e o resto é transmitido para a próxima camada. Um conjunto de receptores se encarrega de registrar a energia refletida ou refratada.

Desde o início do método sísmico, há mais de 70 anos, os avanços alcançados nesta área têm demonstrado uma criatividade e inovação impressionante. Mesmo sendo um setor relativamente pequeno da indústria de petróleo, tem o maior impacto no aumento de reservatórios comprovados e na taxa de recuperação em reservatórios (RPR, por suas siglas em inglês) (YILMAZ, 2001). Na Tabela 2.1 são apresentados os avanços mais significativos na história do desenvolvimento da exploração por meio de dados sísmicos.

Tabela 2.1: Avanços da indústria sísmica. Modificado de (YILMAZ, 2001).

Acontecimentos Importantes da Indústria Sísmica	
1960s	De analógico a digital
1970s	De calculadoras a computadores
1980s	De 2-D a 3-D
1990s	Avanços Computacionais
2000s	4-D, Inversão

A década de sessenta trouxe a revolução digital que permitiu uma maior capacidade de armazenagem, o que foi aproveitado pouco devido à limitada capacidade de análise, isso mudou na década seguinte com o advento dos computadores. Neste período surgiram os métodos de processamento sísmico como deconvolução, análise de velocidade, empilhamento, difração, correção *normal moveout* (NMO) e migração (YILMAZ, 2001).

Nos anos oitenta foi possível representar imagens do subsolo de forma tridimensional, como um conjunto de representações bidimensionais. Ainda uma relação entre o tempo — unidade de medida das imagens sísmicas — e a

respectiva profundidade do traço sísmico, era ambígua. Foi até dez anos mais tarde que o modelo de profundidade foi aperfeiçoado e posto em prática, permitindo assim criar imagens tridimensionais em profundidade.

Nos últimos anos, houveram grandes avanços na aquisição de dados sísmicos, na qualidade dos dados registrados, devido ao aumento do número de canais. O aumento na capacidade de processamento e armazenamento dos computadores também tem contribuído fortemente na evolução de métodos de mapeamento sísmico. Um exemplo disto é a sísmica 4-D, que é o estudo de imagens tridimensionais de um reservatório de petróleo em produção através do tempo, desta forma são monitorados os movimentos de fluidos no campo. Mais ainda, com o desenvolvimento de softwares de visualização sísmica, que proveem ferramentas para análises volumétricas, foram especialmente potencializadas as técnicas de inversão sísmica e interpretação.

2.2.1. Aquisição Sísmica

A aquisição sísmica corresponde ao início do processo de criar uma imagem da subsuperfície, por meio do uso de ondas sísmicas geradas artificialmente. Devido ao fato de que as estruturas geológicas que contém hidrocarbonetos podem ser encontradas tanto em terra como no mar, existe diferenciação entre a aquisição sísmica terrestre e marinha. Cada uma de estas têm especificidades no que se refere a metodologia, instrumentos e terminologias, assim como nas informações que podem ser coletadas das ondas sísmicas (IKELLE, et al., 2005). Será dada, neste trabalho, uma ênfase especial ao método marinho, devido ao caso de estudo selecionado para esta pesquisa.

Geralmente, a obtenção de informação na superfície marinha é realizada por meio de uma explosão concentrada de uma fonte de energia, tipicamente um canhão de ar, e registrando as ondas refletidas pelo subsolo marinho. Com cada variação do material no meio da propagação da onda, parte da sua energia é refletida para a superfície onde é captada por dispositivos de medição de intensidade, chamadas hidrofones. Conhecendo os tempos de trânsito das ondas desde a fonte até os receptores e as velocidades do meio de propagação, pode ser criada uma imagem da subsuperfície (EVANS, et al., 1997). Na configuração tradicional, um navio de pesquisa transporta em sua parte posterior uma ou duas

fontes de energia e várias linhas paralelas de recepção contendo os hidrofones. As linhas receptoras são rebocadas a uma profundidade de aproximadamente 10m abaixo a superfície marinha, cada uma delas pode medir entre 5.000 e 10.000m com centenas de hidrofones regularmente espaçados. O espaçamento entre cada linha receptora em torno de entre 50 e 100m, manter constante esta distância tem uma alta dificuldade devido às marés e outras forças (IKELLE, et al., 2005). Uma representação gráfica de este procedimento pode ser apreciada na Figura 2.1.

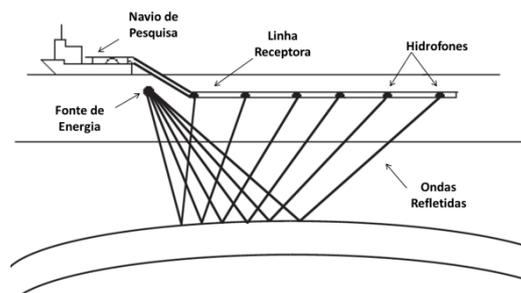


Figura 2.1: Aquisição Sísmica Marinha.

Ondas sísmicas são emitidas pelos canhões de ar com intervalos de tempo regulares, geralmente entre 4 a 20 segundos, este tempo pode ser reduzido utilizando duas fontes de energia. Cada hidrofone ao longo do cabo de receptores armazena informações das intensidades de energia que incidem sobre ele. Utilizando linhas de recepção paralelas, próximas entre sé, um dado volumétrico sísmico pode ser registrado.

2.2.2. Processamento de Dados Sísmicos

Distintos métodos de processamento foram desenvolvidos para diminuir consideravelmente o ruído das medições sísmicas e colocar as informações em formatos adequados, de tal forma a proporcionar uma melhor interpretabilidade dos dados sísmicos registrados. Uma sequência de métodos tem evoluído com os avanços da tecnologia e investigação. Existem três passos fundamentais que serão brevemente introduzidos, (i) deconvolução, (ii) empilhamento e (iii) migração. Uma lista completa dos processos usuais é apresentada em

Tabela 2.2. Os processos secundários têm por objetivo compatibilizar os dados com as suposições dos processos primários (YILMAZ, 2001).

Inicialmente os dados sísmicos são colocados em arquivos com formatos convenientes, usualmente SEG-Y, com os registros agrupados por tempo e por instrumento de registro utilizado, estes são denominados canais.

Tabela 2.2: Métodos básicos de processamento de dados sísmicos.

Sequência Básica de Processamento de Dados
Pré-processamento
Deconvolução
CMP ordenação
Análise de velocidade
NMO correção
Atenuação de múltiplas
Correção DMO
CMP empilhamento
Processamento pós-empilhado
Migração
Correções de estáticas residuais
Controle de qualidade

O processo de deconvolução aplicado a dados sísmicos pré-empilhados consegue melhorar a resolução temporal, comprimindo a ondícula ou *wavelet* do traço sísmico a um conjunto de picos. Cada traço deve ser analisado individualmente, na prática um mesmo operador de deconvolução é utilizado em todos os traços gravados de um mesmo registro de tiro. As técnicas de deconvolução utilizadas convencionalmente no processamento estão baseadas na filtragem ótima de Wiener (YILMAZ, 2001).

A metodologia para empilhar ou unir os dados correspondentes a distintos canais de um mesmo tiro, precisa da hipótese de que cada hidrofone estava localizado à mesma distância da fonte de energia, esta distância é conhecida como afastamento. Para isso é efetuado a correção *normal moveout* (NMO), conceito que pode ser melhor expressado pela Figura 2.2, onde o efeito provocado pelo afastamento é removido dos traços sísmicos. Uma vez feito isso, os traços sísmicos são empilhados. Este é um método de imageamento utilizado para simulação de seções com afastamento nulo, que produz um aumento da razão sinal/ruído na seção simulada.

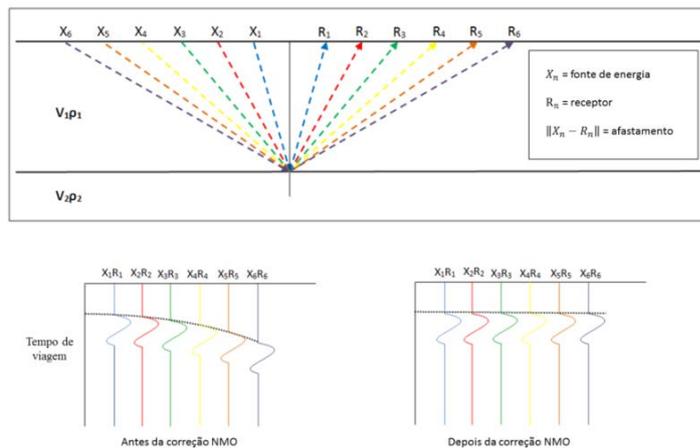


Figura 2.2: Efeito da correção NMO. Modificado de (SCHLUMBERGER).

O último dos processos principais é a migração, que se encarrega de colocar os eventos sísmicos na posição geométrica onde aconteceram na subsuperfície marinha, em vez da posição onde estes foram registrados na superfície (YILMAZ, 2001). Os eventos sísmicos podem ser migrados numa escala de tempo ou numa escala de profundidade, para esta última é indispensável construir um modelo de velocidade, um processo com uma alta complexidade (IKELLE, et al., 2005).

Terminada a sequência de processamento de dados sísmicos o resultado será um conjunto de seções sísmicas pós-empilhadas, aptas para serem utilizadas na interpretação de eventos no subsolo marino. É importante destacar que, o sucesso do processo dependerá da efetividade individual de cada etapa.

2.3. Dados Sísmicos 3D

O resultado do processamento descrito na seção anterior, para uma seção sísmica 3D, é conhecido como cubo sísmico. Cada cubo sísmico está composto de três vetores, os quais são *inline*, *crossline* e tempo ou profundidade. Em uma aquisição marinha a direção de tiro, que é a direção na que viajam os cabos que carregam os hidrofones, é a direção do *inline*. Num eixo de coordenadas esta direção é representada no eixo X. O *crossline* é a direção que é perpendicular à *inline* e é representado no eixo Y. Por último, o vetor de tempo ou profundidade é representado no eixo Z (YILMAZ, 2001). Uma imagem de um cubo sísmico é apresentada na Figura 2.3, onde podem ser claramente evidenciados os três eixos de coordenadas.

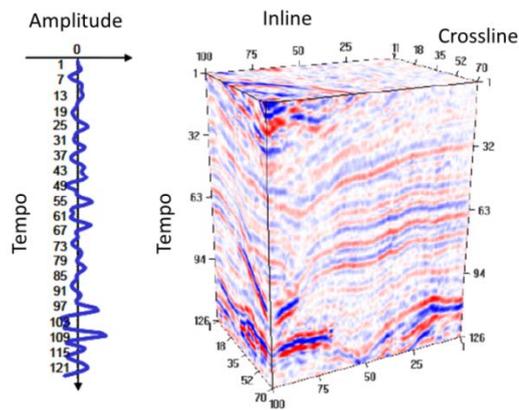


Figura 2.3: Traça sísmica (esquerda) e cubo sísmico (direita).

Os cubos estão compostos pelos valores das amplitudes dos traços sísmicos. Desta forma, um cubo sísmico fornece a informação que está relacionada à amplitude das ondas sísmicas na área de estudo. A amplitude sísmica proveniente do cubo sísmico representará a base para o cálculo de atributos sísmicos, descritos na próxima seção.

2.4. Atributos Sísmicos

Os atributos sísmicos representam uma informação derivada diretamente de um cubo sísmico. Podem ser definidos como quaisquer informações obtidas através dos dados sísmicos, por meio de medições diretas, lógicas ou baseadas na experiência e conhecimentos anteriores (TANER, 1997).

Foram desenvolvidos no princípio dos anos 70 como uma ferramenta de visualização para a gerência, já que permitiam uma obtenção de informação adicional dos dados sísmicos previamente amostrados. Evidentemente, essa visão mudou rapidamente e lhes foi dado um papel fundamental na interpretação e exploração de petróleo (CHOPRA, et al., 2006).

Recentemente, os atributos sísmicos estão presentes em múltiplas aplicações de inferência de informações de reservatório. Em (RANDEN, 2000) é descrito um conjunto de atributos que podem ser utilizados para o mapeamento de chaminés de gás, propriedades estruturais, como sistemas de falhas e domos de sal e, além disso, propriedades estratigráficas como recifes de carbonato, canais de areia e sistemas de ventilação. A correta estimação das propriedades estruturais ajuda a identificar possíveis reservatórios de petróleo. Com este objetivo (NEVES, et al.,

2004) sugerem um grupo de atributos sísmicos que oferecem informação de potenciais fraturas e falhas, que podem ser interpretadas por meio de alterações sutis nos traços sísmicos ou descontinuidades entre os traços. Desta forma é possível encontrar tendências nas falhas e trapas de óleo.

A classificação de litografias foi impulsada pela invenção de atributos que permitem separar ou delinear os limites entre fácies estratigráficas. Em (BARNES, 2001) se predisse que os atributos sísmicos teriam um papel fundamental na classificação automática de fácies, afirmando que a caracterização automatizada com dados sísmicos, baseada em atributos sísmicos, reescreverá as regras de interpretação sísmica. Pouco depois, por meio do uso de atributos sísmicos e uma análise de texturas West em (WEST, 2002) apresenta um método interativo, baseado em redes neurais, capaz de criar uma classificação das fácies, que pretende substituir ao processo manual. Com vantagens, como uma melhoria significativa no tempo de análise e uma representação tridimensional das fácies classificadas.

Mais ainda, utilizando atributos sísmicos 3D desenvolveram-se metodologias para estimar propriedades de reservatório, como a porosidade ou a impedância acústica, que será o enfoque de esta pesquisa. Este é um tema previamente tratado com outras ferramentas como regressões lineares ou redes neurais. Em (LEIPHART, et al., 2001) é apresentada uma comparação entre os dois métodos previamente mencionados, com resultados significativamente melhores para a rede neural, fato explicado pela relação não linear entre os atributos sísmicos e as propriedades geológicas. Por outro lado, (CALDERON, et al., 2007) demonstra que a impedância acústica, derivada por meio de inversão sísmica, pode ser utilizada como o atributo sísmico principal para estimar a distribuição espacial das propriedades das rochas.

2.4.1. Classificação dos Atributos Sísmicos

A classificação dos atributos sísmicos de uma maneira única e aceita de forma consensual ainda não foi alcançada. Numerosos artigos utilizam diversos critérios (BROWN, 1996), (TANER, et al., 1994), (CHOPRA, et al., 2005) para dividir estas informações em subconjuntos razoáveis. A dificuldade da sua

classificação se deve ao fato de que constantemente novos atributos sísmicos e grupos de atributos são propostos.

Inicialmente no ano 1994 (TANER, et al., 1994) foi proposta uma classificação dos atributos sísmicos em dois conjuntos, geométricos e físicos, de acordo à informação que estes poderiam aportar ao interprete. O primeiro grupo seria utilizado em interpretação estratigráfica ou interpretação estrutural e de falhas. Por outro lado, os atributos físicos deveriam ser utilizados para interpretação de litologias e interpretação de características do reservatório. Estes grupos seriam ainda subdivididos em pré-empilhados e pós-empilhados.

Uma classificação alternativa seria construída pouco depois, em (BROWN, 1996) foi sugerida uma distribuição em quatro grupos principais, com uma estrutura de árvore. Baseado no suposto de que um atributo sísmico é derivado de uma medição sísmica básica, o autor sugere que esta medição sísmica pode ser uma informação de tempo, amplitude, frequência ou atenuação; os quatro grupos da classificação. Cada grupo principal é subdividido em pré-empilhados ou pós-empilhados. Os atributos de tempo brindam informação de eventos estruturais, os derivados da amplitude provem informação estratigráfica. Uma atualização foi feita pelo mesmo autor no ano 2001, para adicionar novos atributos sísmicos à classificação (BROWN, 2001).

Em softwares comerciais de interpretação e análise de dados sísmicos também é apresentada uma classificação dos atributos sísmicos. Para esta dissertação foi utilizado Petrel E&P Software. Este programa permite a visualização, análise e interpretação de dados sísmicos. Também disponibiliza ferramentas para o cálculo de atributos sísmicos e possui uma classificação própria, baseada na informação que pode ser extraída de cada atributo sísmico. Na Tabela 2.3 é apresentada a lista completa dos atributos sísmicos disponíveis no programa.

Tabela 2.3: Lista de Atributos Sísmicos em Petrel E&P Software.

Signal Processing	Complex Attributes	Structural Attributes	Stratigraphic Attributes	AVO Attributes
First Derivative	Apparent Polarity	3D Curvature	Chaos	Filtered Polarized AB
Frequency Filter	Cosine of Phase	3D Edge Enhancement	GLCM	Fluid Angle
Graphic Equalizer	Envelope	Amplitude Contrast	Iso-frequency Component	Fluid Strength
Median Filter	Inst. Bandwidth	Ant Tracking	Local Flatness	Linear Corr. Coefficient
Original Amplitude	Inst. Frequency	Consistent Dip	Rel. Acoustic Impedance	Polarization Angle
Phase Shift	Inst. Phase	Dip Deviation	t*Attenuation	Polarized AB Strength
RMS Amplitude	Inst. Quality	Dip Illumination		
Reflection	Quad.	Edge		
Intensity	Amplitude	Evidence		
Remove Bias	Sweetness	Gradient Magnitude		
Second Derivative		Local Structural Azimuth		
Time Gain		Local Structural Dip		
Trace AGC		Structural Smoothing		
Trace Gradient		Variance		

A classificação apresentada anteriormente não é subdivida em dados sísmicos pré-empilhados e pós-empilhados, mas é importante mencionar que os atributos AVO na última coluna da tabela, pelas siglas em inglês de amplitude versus afastamento, somente podem ser calculados para dados sísmicos pré-empilhados. Além disso, os atributos sísmicos podem ser estimados em superfícies ou em volumes sísmicos.

Cada uma das categorias mencionadas na tabela anterior, com exceção dos atributos AVO, será descrita a seguir, assim como os atributos sísmicos mais importantes para o desenvolvimento de este trabalho.

1. **Seismic Signal Processing Attributes:** Nesta categoria são incluídos os atributos relacionados ao processamento e visualização de dados, assim como filtros de frequência e correções de amplitude (SCHLUMBERGER, 2007).
2. **Complex-trace Attributes:** Os atributos de traço complexo supõem que o traço é um sinal analítico com parte real e imaginária. A parte real seria o traço sísmico e a parte imaginária pode ser calculada a partir desta por meio da

transformada de Hilbert (AZEVEDO, et al., 2009). Desta forma, o sinal analítico F_{HI} , que representa o traço sísmico complexo, é dado pela eq. (2.1).

$$F_{HI} = f(t) + i f^*(t) \quad (2.1)$$

Onde $f(t)$ é a parte real, que é o traço sísmico convencional e $f^*(t)$ é a parte complexa, que é calculada pela transformada de Hilbert, $H\{f(t)\}$. Dentro desta categoria será destacado o atributo *apparent polarity*, pela sua importância para este trabalho.

- *Apparent Polarity*: é o sinal de $f(t)$, a parte real do traço complexo, em pontos máximos da envolventória dentro uma janela de tamanho fixo. A representação gráfica depende do sinal de $f(t)$, os valores negativos serão da cor azul e os positivos da cor vermelha, como se pode ver na Figura 2.4.

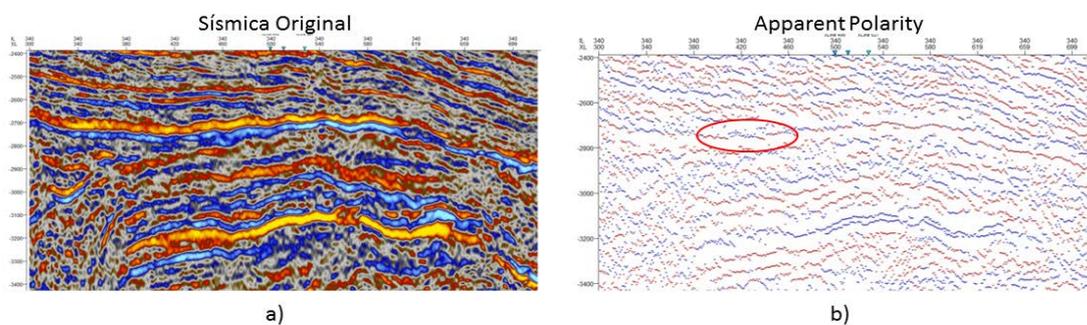


Figura 2.4: a) Seção sísmica da amplitude original, b) O atributo sísmico *apparent polarity*.

Este atributo sísmico é utilizado particularmente para realçar a continuidade de eventos geológicos, já que variações laterais deste podem indicar variações laterais em litologia. Um exemplo das variações laterais pode ser visto na figura anterior, indicado pela figura vermelha.

3. **Structural Attributes:** Os atributos estruturais permitem destacar elementos que auxiliem na interpretação de estruturas geológicas. Estes detectam bordas (*edges*), calculam a orientação local e inclinação (*dip*) de refletores sísmicos e realçam a continuidade de eventos sísmicos paralelos à orientação estimada da camada (AZEVEDO, et al., 2009). A diferença dos atributos de traço complexo, a maioria dos atributos estruturais utilizam para sua criação múltiplos traços. Dentro destes atributos cabe destacar o atributo *structural smoothing* pelo seu uso para este trabalho.
- *Structural Smoothing*: este é um método volumétrico de processamento de sinais que aplica um filtro gaussiano 3D para reduzir o conteúdo de ruído nos

dados de entrada. Este atributo realiza uma filtragem orientada pela estrutura, levando-se em conta as interfaces existentes e a orientação estimada da camada. O efeito que gera nos dados sísmicos originais é exemplificado na Figura 2.5.

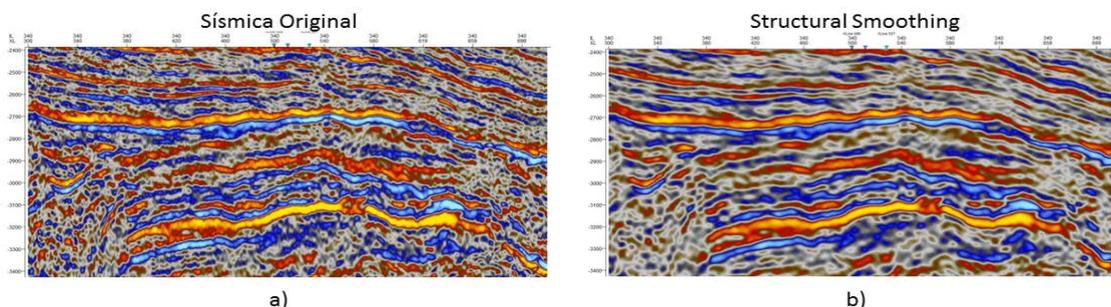


Figura 2.5: a) Seção sísmica da amplitude original, b) O atributo sísmico structural smoothing.

Este atributo sísmico é de grande utilidade para preparar os dados sísmicos para o uso de ferramentas de interpretação automática, já que o aumento na continuidade dos refletores representa um aumento na estabilidade da escolha (*picking*) automatizada (AZEVEDO, et al., 2009). Embora se aplicando em demasia pode reduzir a detectabilidade de falhas e descontinuidades.

4. **Stratigraphic Attributes:** Os atributos estratigráficos oferecem ferramentas na difícil tarefa de identificar sequências estratigráficas, variações laterais e horizontais de litologias, medições de orientação estrutural, decomposição de frequência e distribuição de fácies. Entre eles serão descritos os atributos *iso-frequency component*, *relative acoustic impedance* e t^* *Attenuation*.
 - *Iso-frequency Component:* Consiste numa decomposição espectral, realizada localmente e composta por dois processos. Primeiro é aplicada a função de autocorrelação aos dados sísmicos numa janela pequena, alinhando a sísmica com zero defasagem (*lag*). Imediatamente, é avaliada a função de correlação cruzada entre os dados sísmicos autocorrelacionados do primeiro passo e uma função cossenoide. Esta metodologia é chamada de transformada da correlação do cosseno (CCT), por suas siglas em inglês, para mais detalhes ver (SCHLUMBERGER, 2007). O resultado é apresentado na Figura 2.6, onde podem ser vistas as características deste atributo sísmico.

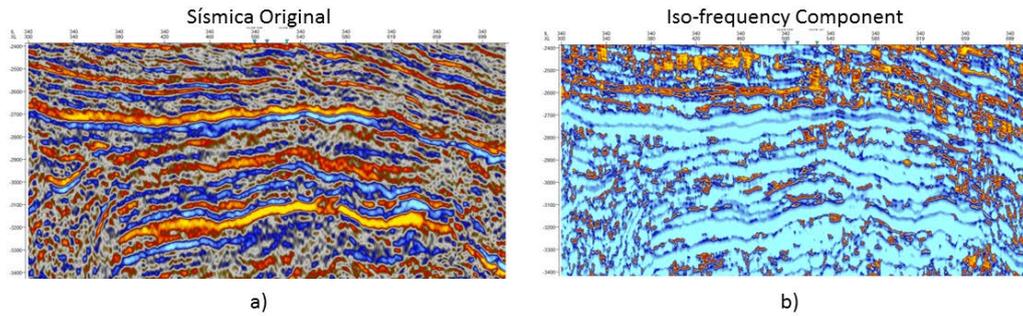


Figura 2.6: a) Seção sísmica da amplitude original, b) O atributo sísmico iso-frequency component.

Este atributo tem a capacidade de revelar variações sutis na litologia, que pode implicar armadilhas de hidrocarbonetos. Além disso, pode determinar fácies que já tenham sido correlacionadas com características de potenciais reservatórios de petróleo (AZEVEDO, et al., 2009).

- *Relative Acoustic Impedance*: este atributo é uma aproximação relativa da impedância acústica, que é uma propriedade física das rochas. Pode ser definida como a densidade da formação geológica multiplicada pela velocidade de propagação das ondas P, esta será explicada com mais detalhe na seção 2.5.2. Este atributo é calculado por meio da integração do traço sísmico, supondo que este é produto das mudanças relativas entre camadas geológicas. O resultado é uma aproximação do logaritmo natural da impedância acústica, ao qual posteriormente é aplicado um filtro de Butterworth para remover tendências longas nos comprimentos de onda, causados pela integração (AZEVEDO, et al., 2009). Na Figura 2.7 podem-se apreciar os contrastes relativos em impedâncias acústicas.

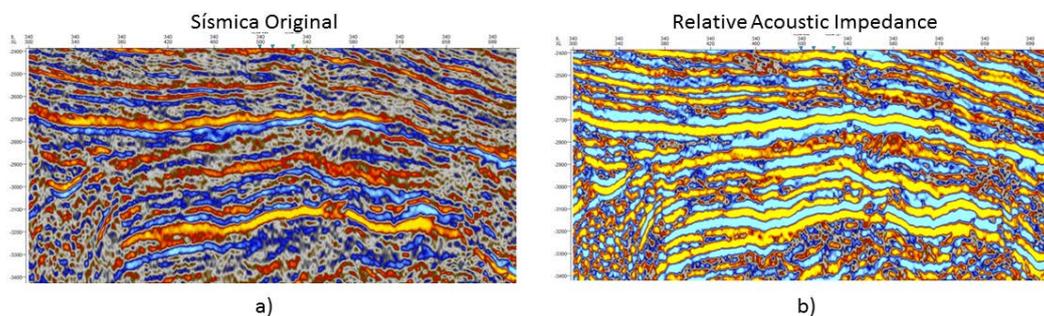


Figura 2.7: a) Seção sísmica da amplitude original, b) O atributo sísmico relative acoustic impedance.

A informação apresentada por este atributo é utilizada em procedimentos de calibração. Para a interpretação sísmica, é combinado com dados sísmicos

originais para indicar as fronteiras das sequencias geológicas, associadas com altos contrastes de impedância ou descontinuidades.

- *t*Attenuation*: O atributo de atenuação mede a perda de diferencial de altas frequências comparada com as baixas frequências, medida acima e abaixo do ponto de interesse. Na Figura 2.8 é apresentado um exemplo de uma seção sísmica com este atributo sísmico.

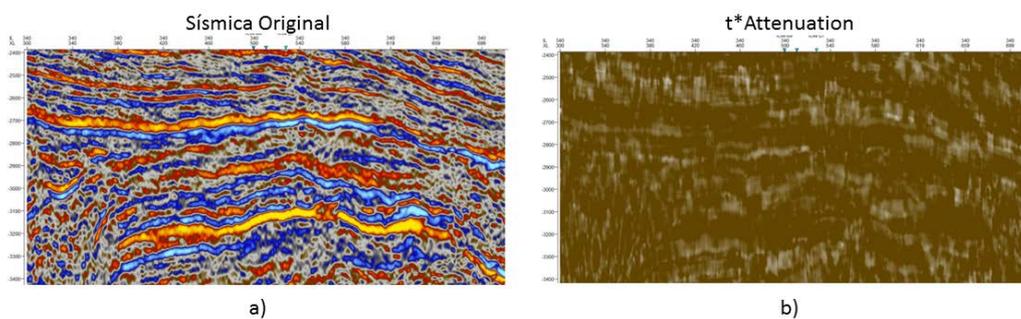


Figura 2.8: a) Seção sísmica da amplitude original, b) O atributo sísmico *t*Attenuation*.

A atenuação está relacionada à densidade de fraturas e espessura vertical da zona fraturada, portanto é utilizada para identificar fraturas abertas no volume sísmico.

2.5. Dados Geofísicos

Os dados geofísicos são comumente adquiridos, já que trazem informação mais precisa da vizinhança imediata ao poço, em comparação com as medições indiretas. Porém existem erros de medida associados ao processo de medição.

Existem duas alternativas para sua obtenção, medições de núcleo ou perfilagem de poços. A primeira técnica é uma amostragem de rochas, que envolve distintos testes de laboratório nas rochas de reservatório levadas à superfície, onde são simuladas as condições de pressão e temperatura dentro do reservatório, para estudar as características das rochas coletadas. O segundo método, consiste num deslocamento contínuo de uma sonda equipada com sensores dentro das perfurações dos poços. Estes sensores fazem medições utilizando diversas técnicas e registrando a resposta registrada em intervalos regulares, dentro de cada poço.

Neste trabalho será abordado somente o segundo procedimento de perfilagem de poços, que provê informação fundamental para a caracterização de

poços. Isto devido à dificuldade da obtenção de medições de núcleo para o campo de estudo.

2.5.1. Perfis de Poço

Por meio de registros regularmente espaçados dentro de um poço são criados gráficos das medições contra a profundidade, estes são chamados perfis de poço. Existem diversos tipos de perfis de poço, cujos nomes dependem da informação que fornecem ou da técnica de coleta. Estes podem ser classificados em três categorias: perfis elétricos, acústicos, ou radioativos (THOMAS, 2001). Os perfis elétricos medem a resistividade ou condutividade nas formações de rochas e o potencial espontâneo em seções não revestidas do poço. A solução salina em espaços porosos e a água ligada à argila são condutoras, e a presença delas é registrada por meio da condutividade, que indica a litologia provável e a saturação de água. Por outro lado, formações com porosidades baixas ou ocupadas por materiais não condutores, como óleo e gás, são identificadas com altas resistividades (DEAN, et al., 2008).

Da mesma forma, os perfis acústicos são medições do tempo de viagem de uma onda acústica, criada por uma fonte e registrada por receptores, que se transmite através das rochas próximas às paredes do poço. Este tipo de perfil pode ser utilizado para inferir informação sobre porosidade, litologias, propriedades mecânicas das rochas e a existência de fraturas.

Diversos tipos de perfis de radioatividade medem a radioatividade natural das rochas, como o perfil de raios gama. Outros emitem partículas radioativas e medem a resposta da formação, estes são os mais importantes. Entre eles podem ser mencionados o perfil de porosidade neutrônica e o perfil de densidade, utilizados para conhecer a composição das formações rochosas.

Os principais perfis e os que serão utilizados para a caracterização de reservatórios neste trabalho são os seguintes, para uma explicação mais detalhada ver (THOMAS, 2001):

1. *Resistividade (ILD)*: Fornece leitura aproximada da resistividade das rochas contendo hidrocarbonetos, através da medição de campos elétricos e magnéticos induzidos nas rochas.

2. *Sônico (DT)*: O perfil mede a velocidade de trânsito das ondas sônicas em camadas de rochas. É utilizado para estimativas da porosidade, correlação poço a poço, estimativas do grau de compactação das rochas ou estimativas das constantes elásticas, detecção de fraturas e apoio à sísmica na caracterização de reservatórios.
3. *Raios Gama (GR)*: Detecta a radioatividade total da formação geológica. Utilizado para a identificação da litologia, de minerais radioativos e para o cálculo do volume de argilas.
4. *Porosidade Neutrônica (NPHI)*: Os perfis antigos medem a quantidade de raios gama de captura após excitação artificial através do bombardeio dirigido de nêutrons rápidos. Os mais modernos medem a quantidade de nêutrons epitermais e/ou termiais da rocha após o bombardeio. São utilizados para estimativas da porosidade, litologia e detecção de hidrocarbonetos leves ou gás.
5. *Densidade (RHOB)*: Detecta os raios gama defletidos pelos elétrons orbitais dos componentes das rochas, após terem sido emitidos por uma fonte situada dentro do poço. Além de informar sobre a densidade das camadas, permite o cálculo da porosidade e a identificação das zonas de gás. É utilizado também como apoio à sísmica para o cálculo do sismograma sintético.

Um exemplo de estes perfis pode ser observado na Figura 2.9, onde são apresentados os cinco principais perfis para um determinado poço. As medições de cada perfil podem ser observadas por profundidade em intervalos usualmente pequenos, neste caso cada 20 cm.

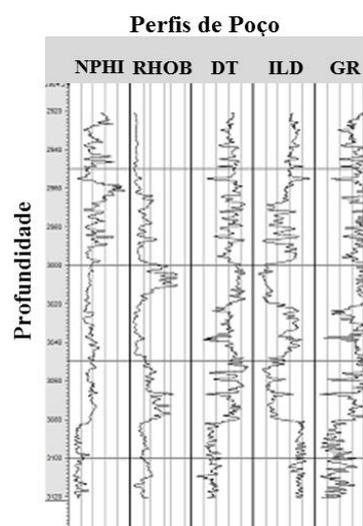


Figura 2.9. Principais perfis de poço.

A informação obtida a partir de estes perfis de poço é combinada com dados sísmicos para estimar características ou propriedades do reservatório.

2.5.2. Impedância Acústica

A impedância acústica (IA) pode ser calculada mediante a seguinte fórmula,

$$IA = \textit{densidade} \cdot \textit{velocidade} \quad (2.2)$$

Onde a *densidade* é a densidade da formação rochosa, pela qual se movimenta a onda sísmica e a *velocidade* é a velocidade da P-onda nesse meio. Portanto, é claro que IA é uma propriedade de rocha e não da sísmica de reflexão. A impedância acústica tem ganhado destaque na exploração de petróleo devido a sua relação com os dados sísmicos. A sísmica de reflexão é simplificada a convolução de uma ondícula com uma série de refletividades, que representa mudanças relativas na impedância acústica. Fazendo com que esta propriedade seja a união natural entre dados sísmicos e perfis de poço (LATIMER, et al., 2000). Em aplicações reais, a impedância acústica é calculada por meio da multiplicação do inverso do perfil sônico, representando a velocidade, pelo perfil de densidade (VIDAL, et al., 2007).

Este capítulo é finalizado reafirmando a importância da integração entre os dois tipos de dados que vão ser manipulados e analisados para a caracterização de reservatórios, os dados sísmicos e os perfis de poço. Como foi mencionado, os dados sísmicos mostram-se abundantes em todo o reservatório, mas apresentam uma baixa frequência de amostragem vertical. Por outro lado, os perfis de poço são escassos devido à limitante econômica na perfuração de poços, porém as amostras obtidas têm uma alta resolução vertical.

No próximo capítulo vão desenvolver-se as técnicas para um adequado tratamento das variáveis anteriormente estudadas.

3 Tratamento de Variáveis

3.1. Introdução

A construção de modelos por meio de algoritmos de inteligência computacional requer da existência de dados confiáveis para conseguir estimativas aceitáveis. Na área de petróleo são utilizados principalmente dados geofísicos e dados sísmicos, cada um deles representa medições imperfeitas com um determinado nível de erro. Estas informações precisam de um tratamento individual e posteriormente um tratamento conjunto, para superar os desafios causados pelas diferenças de medição. A maneira em que os erros são tratados afeta a integração dos dados e determina a qualidade do modelo final de reservatório (JARVIS, 2006).

Será realizado um acoplamento entre os dados sísmicos e os perfis de poço, solucionando assim, os problemas de escala entre eles. Também serão descritas abordagens que permitam a seleção de um conjunto ótimo de atributos sísmicos de acordo com certos critérios de avaliação.

3.2. Pré-processamento de Dados Sísmicos

Os dados sísmicos pós-empilhados depois de um processamento, como o descrito na seção 2.2.2, serão a base desta análise. Estes ainda devem ser tratados para ser utilizados na caracterização de reservatórios de petróleo. Para isto, uma ferramenta apropriada é Petrel, que é um software comercial de interpretação e análise de dados sísmicos.

Para melhorar a qualidade destes dados, alguns filtros no domínio da frequência podem ser aplicados aos traços sísmicos, atenuando o ruído presente nos registros. Além disso, podem ser calculados atributos sísmicos que têm por objetivo de diminuir a ambiguidade dos dados sísmicos, entre eles a *amplitude de quadratura* (QA) ou o *controle automático de ganho* (AGC). Na Figura 3.1 são

apresentadas as diferenças entre a sísmica original e a sísmica tratada com o método de AGC. Os filtros automáticos devem ser utilizados com cuidado, já que podem amplificar os ruídos presentes nos dados sísmicos.

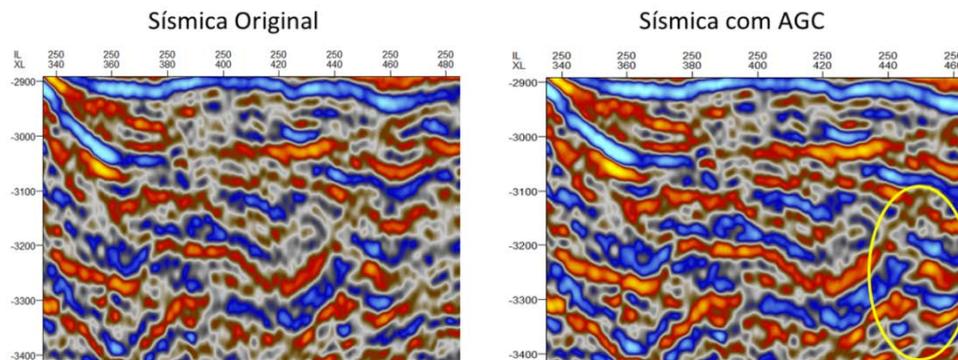


Figura 3.1: Efeito de utilizar o método de controle automático de ganho a uma seção sísmica 2d.

Por outro lado, os dados sísmicos são registros de amplitude de onda para distintos tempos e os perfis de poço são medições para distintas profundidades. Para combinar corretamente ambas as fontes de informação, deve ser feita uma mudança em um dos tipos de dados. Aos dados sísmicos considerados neste trabalho lhes foi realizada uma conversão de tempo para profundidade. Esta migração pode ser feita por meio de um relacionamento dos perfis de poço e os dados sísmicos. Para isto é estimada a velocidade dos meios de trânsito e assim estimar a profundidade de ocorrência dos eventos sísmicos.

3.3. Pré-processamento de Perfis de Poço

Os parâmetros geofísicos obtidos por meio da perfilagem de poços são normalmente denominados dados rígidos ou *hard data*, fazendo referência à confiabilidade das medições obtidas. Embora, estas também são afetadas pelas irregularidades do poço, como rugosidade, filtrações de lama, pontos de revestimento, também são altamente dependentes do tempo decorrido entre a perfuração e a perfilagem (JARVIS, 2006). Para a identificação dos valores extremos podem ser construídos gráficos para cada poço, que permitam visualizar e distinguir com facilidade estes elementos. Estes devem ser tratados cuidadosamente, devido ao fato de que podem também ser produto de fenômeno geológicos. Na Figura 3.2 podem se observar um conjunto de valores extremos

em um perfil de poço sônico, indicados por um círculo, afastados da maioria dos dados.

Antes de poder trabalhar com os perfis de poços são realizadas análises de cada perfil para eliminar valores extremos, caso sejam produto de erros de medição, para evitar resultados indesejáveis em futuros passos do processo de caracterização.

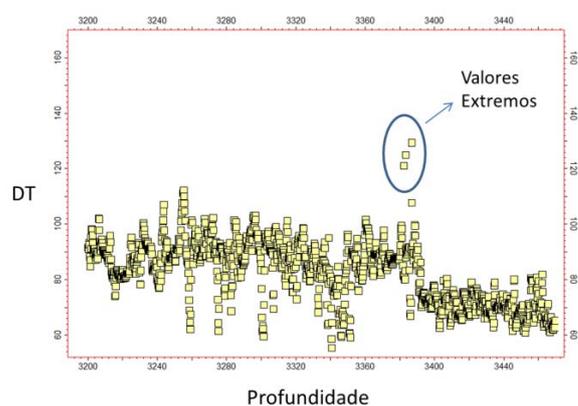


Figura 3.2: Presença de valores extremos em um perfil de poço sônico.

Adicionalmente, nos perfis de poço são comuns alterações drásticas nos valores das medições, graficamente representados por picos. Estes podem ser causados por alguns fatores, como por exemplo, camadas delgadas, zonas fraturadas ou falhas nos receptores dos sinais (BISASO, 2011).

Diversos métodos podem ser utilizados para remover os picos presentes nos perfis de poço. Entre os mais comuns estão o uso de filtros que diminuem as variações para facilitar a análise de cada variável, eliminando as oscilações erráticas. Este procedimento pode ser feito por meio de métodos de análises de séries como a média móvel ou o filtro de mediana.

Pode se observar na Figura 3.3 o efeito da aplicação da média móvel na série vermelha, que apresenta um comportamento com menor conteúdo de frequência espacial. Além disso, também está presente a janela, cujo tamanho é previamente definido e determinará a quantidade de elementos a considerar. O valor do elemento alvo será o elemento em meio da janela e receberá por valor a média de todos os valores na janela. A janela é deslocada uma posição e este procedimento é repetido sobre a série completa.

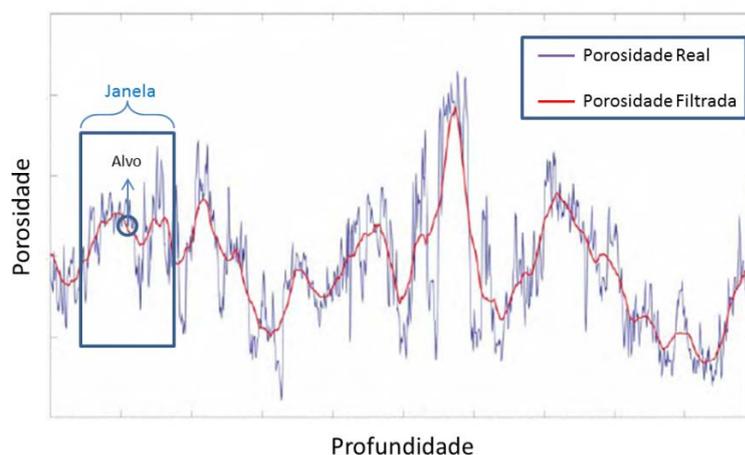


Figura 3.3: Aplicação do método de média móvel em um registro de porosidade.

Desta forma é criada uma nova série com a mesma tendência que a original, mas sem os picos, que podem interferir com o processo de estimação e análise que será realizado em capítulos subsequentes. O filtro da mediana mencionado anteriormente tem um funcionamento similar, mas é utilizado o valor da mediana em vez da média. Adicionalmente podem ser utilizados algoritmos de blocos, que substituem porções do perfil de poço, do tamanho determinado por uma janela previamente definida, por um valor constante correspondente à média dos valores na janela. A diferença desta técnica para a média móvel, é que neste algoritmo a janela é deslocada tantas posições quanto o número de elementos da janela, desta forma a série resultante tem uma forma escalonada.

3.4. Problemas de Escala

Geralmente, os dados sísmicos 3D, apresentam uma cobertura lateral densa e completa do reservatório, o maior inconveniente é a falta de resolução vertical quando comparada com os perfis de poço (DOYEN, et al., 1997). Portanto é necessário um método de escalamento que permita a integração destes dados, podendo ser realizado um método de *downscaling*, estimando valores de uma propriedade para uma escala menor, ou *upscaling* que estima valores de uma propriedade para uma escala maior. Com o propósito de minimizar a perda de informação é realizado sempre o *upscaling* dos perfis de poço, que são redimensionados à escala dos dados sísmicos. Na Figura 3.4 pode se observar as diferenças nas escalas, os perfis de poço passam de estar amostrados em intervalos de poucos centímetros a vários metros.

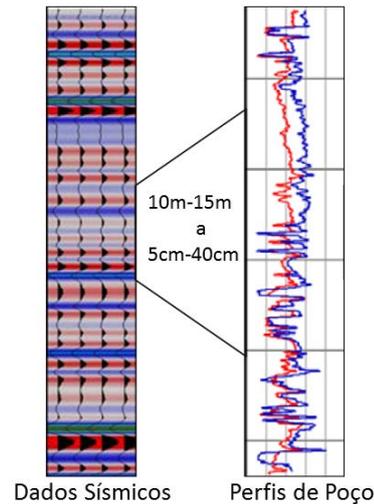


Figura 3.4: Diferenças de escala entre dados sísmicos e perfis de poço.

Os métodos mais utilizados que conseguem comprimir a informação dos perfis de poço, em amostras espaceadas na escala da sísmica são:

- *Média Móvel*, descrita na seção 3.3.
- *Média de Backus*, técnica que envolve o cálculo da média de módulos elásticos e volumes de densidade de um conjunto de camadas delgadas, criando propriedades médias similares às de uma camada grossa (TIWARY, et al., 2009), apresenta vantagens em meios anisotrópicos.
- *Função de Correlação de pares*, que é um método da teoria aleatória de meios, construído para meios com alta heterogeneidade (BISASO, 2011).

Em (TIWARY, et al., 2009) é realizado um *upscaling* de velocidades de onda para 50hz, uma frequência próxima à da sísmica, com os três métodos. Os resultados mostram uma variação pequena entre os métodos, portanto é selecionado neste trabalho o método de média móvel, já que tem o menor custo computacional.

3.5. Seleção de Atributos Sísmicos

Os atributos sísmicos permitem realçar a informação sobre as características do subsolo presente nos dados sísmicos. Com este propósito é comum derivar uma grande quantidade de atributos, mas em vista disso, uma seleção deve ser feita a modo de selecionar o conjunto de atributos sísmicos que forneça a

informação mais relevante, evitando um número elevado de variáveis a considerar. Para isto podem ser utilizadas as seguintes abordagens,

- *Seleção por interpretabilidade*: é selecionado o conjunto de atributos de acordo a sua interpretação geofísica, como por exemplo, a estipulada em (TANER, et al., 1994). Embora, a maioria dos atributos sísmicos carece de interpretação geológica (BARNES, 2001) e isto limita a seleção de possíveis elementos úteis.
- *Seleção por correlações*: são calculadas as correlações entre os atributos sísmicos e amostras da variável a estimar, para distinguir os elementos significativos, ver (LEIPHART, et al., 2001). Depois podem ser calculadas as correlações entre os elementos restantes, dos quais serão removidos os atributos altamente correlacionados entre si, com o objetivo de eliminar informação redundante.
- *Métodos de inteligência computacional*: métodos como algoritmos genéticos podem ser adaptados para atuar como selecionadores e determinar que conjunto de atributos sísmicos é o melhor (DORRINGTON, et al., 2004). Deve ter-se especial cuidado quando a avaliação do algoritmo é de caráter estocástico, como uma rede neural, já que pode gerar resultados altamente voláteis.
- *Heurísticas*: pertencem aos métodos de algoritmos que podem ajudar na escolha do conjunto ótimo de atributos. A heurística mais popular é a *regressão passo a passo*, que está baseada no suposto de que o melhor conjunto de n elementos contém ao melhor conjunto de $n-1$ elementos (CALDERON, et al., 2007), (HAMPSON, et al., 2001). Desta forma são construídos os melhores grupos começando por grupos de um elemento até chegar ao número desejado, adicionando um a um todos os atributos sísmicos e avaliando para a seleção do melhor conjunto. De novo o método de avaliação é de caráter estocástico e isto aumenta a variabilidade do resultado.
- *Análise de Componentes Principais*: por meio deste método podem ser utilizados todos os atributos sísmicos condensados em um eixo de componentes principais, que resume a informação em um número menor de variáveis, em contrapartida há uma pequena perda de informação (AZEVEDO, et al., 2009). Mesmo assim, a quantidade de atributos sísmicos

existentes é cada vez maior, fazendo com que a redução seja cada vez mais difícil.

Para este trabalho foi selecionado a seleção por correlações, devido ao fato de que utiliza um enfoque baseado nos dados que representa uma boa alternativa para seleção de parâmetros significativos. Para a análise por correlações será calculado o coeficiente de correlação de Spearman, pois é uma medida não paramétrica da dependência entre duas variáveis.

3.6. Estimação de Perfis de Poço

As perfurações realizadas em reservatórios de petróleo nem sempre têm todos os perfis de poço, devido aos altos custos de amostragem, que podem representar até 5% do custo total de perfuração (SERRA, 1984). Por conseguinte, foram desenvolvidas metodologias que estimam perfis de poço faltantes, por meio de perfis de poço existentes. Primeiramente foram desenvolvidas estimações empíricas baseadas em observações, estas podem ser de ajuda para cálculos rápidos, mas dependem do material das rochas e por isso devem ser utilizadas cuidadosamente. Entre as relações empíricas pode ser destacada a relação de Faust, enunciada na eq. (3.1), a qual estima o perfil de poço sônico (DT) a partir do perfil de poço de resistividade (ILD).

$$DT = \frac{10^6}{K_1 \cdot ILD^{1/k_2} \cdot MD^{1/k_3}} \quad (3.1)$$

Onde K_1 é a constante de *Faust* com valores entre 2000 e 3400 dependendo do material da formação, MD representa a profundidade e as constantes K_2, K_3 podem tomar o valor seis ou podem ser calculadas por meio de uma análise de regressão (CRAIN, 2015).

Outra relação importante é a relação de *Gardner*, dada pela eq. (3.2), a qual estima o perfil de poço de densidade (RHOB) utilizando uma função exponencial do perfil sônico (DT).

$$RHOB = A \cdot DT^B \quad (3.2)$$

Onde $A = 0.31$ e $B = 0.25$, embora, as constantes podem ser calculadas com estimações lineares em dados disponíveis ou atribuindo um valor determinado pelos tipos de rocha (CRAIN, 2015).

Posteriormente, foram introduzidos modelos de regressão multivariados que são capazes de estimar relações lineares entre um conjunto de variáveis de entrada e um perfil de poço desejado (CHAGAS, et al., 2010). Isto representa uma vantagem frente à rigidez das relações empíricas. Desafortunadamente, a relação existente entre perfis de poço pode ser não linear e, portanto, não podia ser completamente estimada por estes modelos. Atualmente são utilizadas metodologias de inteligência computacional como Redes Neurais (LEITE, et al., 2008) ou Programação Genética.

Nesta investigação serão comparados os métodos de RN e PG na estimação de perfis de poço faltantes. Para isso será realizada uma seleção prévia, por meio de correlações, dos perfis de poço que vão ser utilizados como variáveis de entrada no modelo. Com esta motivação, no próximo capítulo, será apresentada uma breve descrição teórica e prática destas duas técnicas de inteligência computacional.

4 Métodos de Inteligência Computacional

4.1. Introdução

Os métodos de inteligência computacional foram desenvolvidos para encontrar soluções para problemas de otimização global, não convexos. Estas técnicas são estudadas nesta pesquisa com o propósito de estimar relações não evidentes, entre as medições de perfilagens de poços e/ou levantamentos sísmicos e as propriedades do reservatório. Na primeira seção será estudado o algoritmo de programação genética, que representa uma alternativa moderna para a estimação de relações não lineares entre variáveis de entrada e saída. Este método é proposto neste trabalho para a estimativa de propriedades geológicas num reservatório de petróleo. Na segunda seção, será descrito o algoritmo de redes neurais que já foi extensamente utilizado na exploração de petróleo em trabalhos como (LEIPHART, et al., 2001), (TANG, et al., 2011) e (CALDERON, et al., 2007). Este método será utilizado para validar os resultados obtidos por meio de PG. Finalmente, é apresentada uma breve descrição de agrupamento por *clustering*. A justificativa desta seção deve-se à alta heterogeneidade dos reservatórios de petróleo, a qual motiva a agrupar o campo por zonas geológicas, com o propósito de obter melhores aproximações.

4.2. Programação Genética

O algoritmo de programação genética (PG) é uma coleção de técnicas de computação evolucionária que constrói programas de computador, para solucionar problemas automaticamente, sem que o usuário tenha necessidade de conhecer ou especificar a forma da solução (POLI, et al., 2008). Esta técnica está inspirada na natureza, especificamente na evolução de estruturas biológicas como uma consequência da seleção natural de Darwin. Desta forma, os indivíduos mais sucedidos tendem a sobreviver e a se reproduzir numa taxa maior. Analogamente,

este método simula uma população conformada por indivíduos, cada um destes representa uma solução para o problema em estudo. Esta população artificial evoluirá de uma maneira sistemática, definida pelo princípio de seleção natural, para criar uma solução que satisfaça os requerimentos previamente definidos.

Foi definido em (KOZA, 1992) como um método de regressão simbólica que tem por objetivo encontrar uma expressão matemática, numa forma simbólica que provê um ajuste ótimo entre um conjunto finito de variáveis independentes e o valor associado da variável dependente, similar ao contexto de regressão estatística. Isto é, a procura de um modelo simbólico que se ajuste aos dados amostrados. O resultado deste processo será uma função analítica que pode ser analisada ou aplicada em outros contextos facilmente.

Usualmente, em programação genética, os indivíduos são representados como estruturas de computador em forma de árvore, compostas por nós e folhas. Os nós representam funções aritméticas básicas (soma, subtração) ou operadores mais complexos (sen, cos, exp) e as folhas são os terminais que podem ser variáveis ou constantes. O algoritmo de PG cria uma população inicial, formada por indivíduos deste tipo. Cada indivíduo tem associado um valor numérico chamado aptidão, que indica quanto a solução, representada por este indivíduo, é boa em relação às outras soluções da população. A população de soluções candidatas é modificada iterativamente, cada iteração envolve a aplicação de operadores genéticos (seleção, *crossover* e mutação) na espera de evoluir novos e melhores candidatos (KOZA, 1992).

Para compreender a funcionalidade de PG é preciso conhecer a metodologia e, além disso, um conjunto de termos envolvidos na simulação, que consegue com sucesso uma aproximação à solução desejada. Esta metodologia pode ser representada por um pseudocódigo com a seguinte estrutura:

1. Construção da população inicial, utilizando um *método de criação de indivíduos iniciais*.
2. Avaliação de cada indivíduo, por meio de uma *função de avaliação*.
3. Seleção de indivíduos que serão utilizados para formar novas soluções, por meio de um *método de seleção*.
4. Cálculo de novos indivíduos aplicando um conjunto de *operadores genéticos* com certas probabilidades:
 - a. *Crossover*

b. Mutação

c. Elitismo

5. Avaliação da nova população, se um erro aceitável é atingido a simulação termina, caso contrário volta para o passo 2. Cada passo iterativo é chamado geração.
6. O melhor indivíduo representa a solução final.

Este esquema apresenta a configuração essencial do algoritmo, mas para cada passo, existentes opções que devem ser consideradas para cada problema em particular.

4.2.1. Componentes de Programação Genética

Cada componente, mencionado no pseudocódigo da seção anterior como uma palavra chave, será desenvolvido mais detalhadamente a seguir.

- *Método de criação de indivíduos iniciais:* A criação da população inicial é usualmente um processo aleatório, onde cada novo indivíduo recebe características distintas, respeitando as restrições do problema. Entretanto, uma criação com indivíduos fornecidos pelo usuário pode ser também utilizada, caso se tenham soluções preliminares para o problema. Estes indivíduos já definidos são chamados de sementes iniciais e podem melhorar os resultados consideravelmente, fazendo com que o ponto de partida esteja mais próximo à solução ótima.
- *Função de Avaliação:* A função de avaliação determina uma medida de erro entre as soluções que representa cada indivíduo e a saída desejada. Em aplicações de programação genética é normalmente utilizado o erro que calcula a raiz da média dos erros quadráticos (RMSE) ou o erro percentual absoluto médio (MAPE). Esta função atribui a cada indivíduo um valor numérico de avaliação ou aptidão que determina quanto um indivíduo é bom em comparação com os outros.
- *Método de Seleção:* Analogamente à seleção biológica, a programação genética utiliza um método de seleção que dá prioridade aos indivíduos mais

aptos para que estes se reproduzam, mas seleciona também indivíduos com avaliações médias e baixas. Isto para ter diversidade de características para criar novos indivíduos. O método mais popular de seleção em PG é o torneio (POLI, et al., 2008). Neste, um número de indivíduos é selecionado aleatoriamente da população, cada um deles é comparado com os outros e o melhor é selecionado para ser um pai. Devido à seleção aleatória dos indivíduos para realizar o torneio, a diversidade de características em cada grupo selecionado é conservada. Um parâmetro importante que deve ser selecionado é o tamanho de indivíduos por torneio, quanto maior for este número, maior será a probabilidade de selecionar os mesmos indivíduos, com melhores aptidões, para serem pais.

- *Operadores Genéticos*: Estes operadores são os responsáveis por calcular novos indivíduos para a próxima geração. Estes são o *crossover*, a mutação e o elitismo. Em cada um deles são utilizados indivíduos pais para o cálculo de indivíduos filhos que substituirão aos pais na próxima geração.
- *Crossover*: Este operador representa um cruzamento entre dois indivíduos, normalmente representados por árvores. O método mais utilizado é chamado de cruzamento de subárvores. Neste é selecionado aleatoriamente um ponto de corte em cada pai e as subárvores são intercambiadas, criando assim dois novos indivíduos. Este processo pode ser visualizado em Figura 4.1.
- *Mutação*: O operador de mutação tem por objetivo um aumento da diversidade, desta forma o algoritmo tem a capacidade de explorar novas alternativas no espaço de busca. O método mais utilizado de mutação é chamado de mutação de subárvores. Similarmente é selecionado um ponto de corte, é apagado a subárvore existente e é criada outra aleatoriamente, gerando assim um novo indivíduo.
- *Elitismo*: Este operador faz uma cópia do pai que será passado sem alterações para a próxima geração. Normalmente uma pequena porcentagem da população com a melhor aptidão é transmitida mediante elitismo, desta forma

é assegurado que a próxima geração tenha um indivíduo pelo menos tão bom quanto à geração anterior.

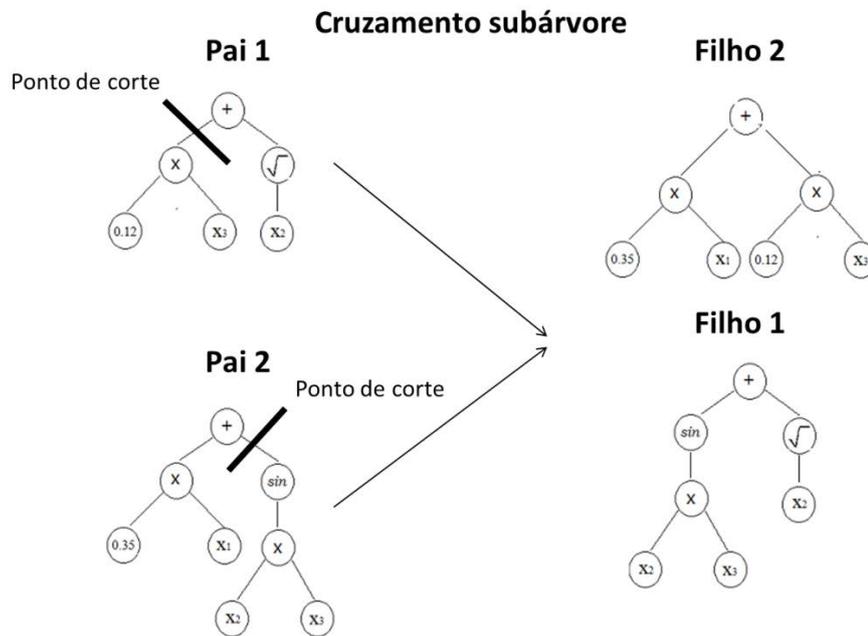


Figura 4.1 Operador de cruzamento para PG.

4.2.2. Programação Genética Multi-Gene

Programação genética multi-gene é uma variação de programação genética clássica, na qual, cada indivíduo multi-gene é formado por um ou mais genes e cada um deles é uma árvore da programação genética tradicional. Os genes são incrementados em cada indivíduo de maneira tal que seja melhorado o valor de aptidão. O modelo geral, é uma combinação linear ponderada de cada gene e os pesos dos genes, neste trabalho foram otimizados por meio de uma regressão de mínimos quadrados ordinária. Desta maneira, o modelo pseudo-linear resultante pode capturar o comportamento não linear (SEARSON, et al., 2010).

Matematicamente o modelo de regressão multi-gene pode ser escrito como, $\hat{y} = d_0 + d_1 \cdot \text{árvore}_1 + d_2 \cdot \text{árvore}_2 + \dots + d_M \cdot \text{árvore}_M$ onde cada árvore é uma função de zero ou mais das N variáveis de entrada x_1, \dots, x_N , d_0 é o viés, os termos d_1, \dots, d_M , são os pesos dos genes e M é o número de genes, ou seja, de árvores que compõem o indivíduo (SEARSON, et al., 2010). Na Figura 4.2 pode-se observar um modelo multi-gene com saída y e variáveis de entrada x_1, x_2, x_3 .

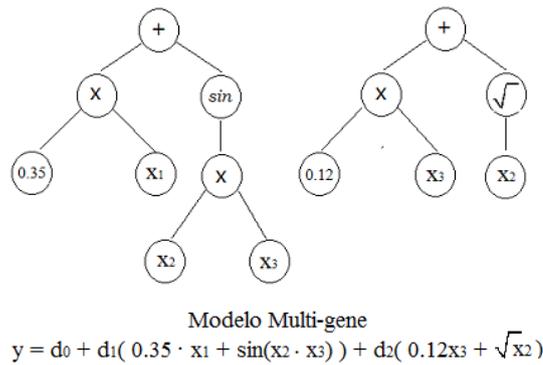


Figura 4.2: Modelo multi-gene

Os operadores genéticos aplicados em PG multi-gene estão baseados nos definidos para PG convencional, modificados para que sejam capazes de funcionar com múltiplas árvores (SEARSON, et al., 2010). Neste trabalho foi utilizado o pacote de programação genética multi-gene fornecido livremente para *matlab*: *GPTIPS*. Neste programa foram adaptados os operadores para funcionar com indivíduos formados por várias árvores.

No caso do *crossover*, podem-se mencionar dois tipos: *crossover de dois pontos de alto nível* e *crossover de baixo nível*. No primeiro caso, são selecionados dois genes, chamados pontos de *crossover*, nos dois pais. Então os genes no meio dos pontos de *crossover* são trocados entre os pais para gerar dois novos filhos. No segundo caso, um gene é extraído aleatoriamente de cada pai, se realiza o *crossover* tradicional para genes e os dois genes resultantes são colocados nos pais originais, gerando assim dois filhos. Para o caso da mutação, é selecionado aleatoriamente um gene no pai e a mutação tradicional de PG é efetuada. O gene mutado é substituído no pai original gerando um novo filho (SEARSON, et al., 2010).

Finalmente, o tamanho da população, o número de gerações, a taxa de *crossover*, a profundidade máxima da árvore e demais parâmetros são testados para encontrar o modelo que tenha o erro menor. Como é usual, ao aplicar técnicas de inteligência computacional, estas provas são feitas em conjuntos de dados de treinamento e validação fornecidos pelo usuário. A solução obtida é avaliada posteriormente num conjunto de teste. Nesta dissertação foi utilizado o RMSE (a raiz da média dos erros quadráticos) como função de avaliação.

4.3. Redes Neurais

Uma rede neural (RN) é um método de inteligência computacional concebido para modelar o funcionamento do cérebro humano e sua capacidade de fazer associações, lidar com abstrações e generalizar. Em (HAYKIN, 2009) RN é definido como um processador paralelo altamente distribuído, composto por unidades de processamento individuais, chamadas neurônios, que têm uma propensão natural para armazenar conhecimento empírico e disponibilizá-lo para o uso. Análogo ao cérebro humano a rede adquire conhecimento de seu ambiente, através de um processo de aprendizado e as conexões entre neurônios, denominadas pesos sinápticos, são utilizadas para armazenar a informação adquirida. A habilidade das redes neurais de realizar mapeamentos não lineares entre suas entradas e saídas, as tem tornado prósperas no reconhecimento de padrões (BISHOP, 1995) e na modelagem de sistemas complexos.

4.3.1. Redes Neurais Multilayer Perceptron (MLP)

Diversos tipos de redes neurais existem, com diferenças em funcionamento, estrutura e processos de aprendizado. A mais conhecida e utilizada é chamada de multilayer perceptron (HORNE, 1993). Este tipo de rede estima uma ou múltiplas saídas baseadas nos parâmetros de entrada e cria um modelo a partir de um processo conhecido como aprendizado supervisionado. Esse modelo poderá ser posteriormente utilizado como um substituto (*proxy*) das saídas. Para entender como funciona é preciso definir um conjunto de termos dos elementos que compõem a rede neural MLP.

- *Neurônio*: unidades de processamento individual. Encarregados de receber, processar e transmitir informação. Recebem uma combinação linear de valores, que é avaliada numa função de ativação associada ao neurônio e o resultado é passado para os neurônios do nível seguinte de processamento, este processo pode se apreciar em Figura 4.3, na parte b.
- *Camada*: Existem diversos tipos de camadas. A camada de entrada representa os valores de entrada da rede. As camadas escondidas são um conjunto de neurônios. O número de camadas escondidas é selecionado

pelo usuário. Por último a camada de saída está composta pela saída ou saídas do modelo.

- *Pesos sinápticos:* Para cada neurônio existe um conjunto de pesos sinápticos, estes determinam o valor de entrada que o neurônio recebe. Estes pesos são alterados por meio de um algoritmo de aprendizado para minimizar o erro entre as saídas do modelo e as saídas desejadas.
- *Função de ativação:* A função de ativação está presente em cada neurônio e deve ser uma função sigmoide, já que são funções limitadas e deriváveis em qualquer ponto.
- *Algoritmo de aprendizado:* Este é o método selecionado para modificar os pesos sinápticos da rede neural, para minimizar o erro nas saídas do modelo.

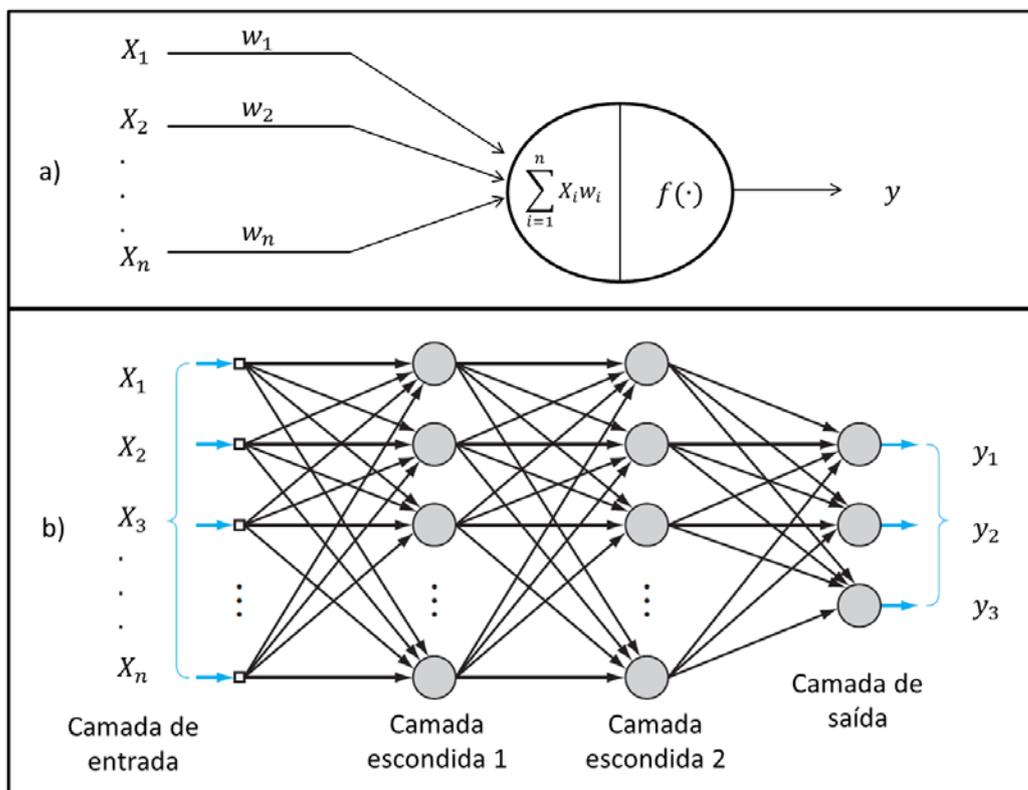


Figura 4.3: a) Funcionamento de cada neurônio. b) Estrutura da rede neural MLP.

A seleção do algoritmo de aprendizado deve ser feita cuidadosamente, já que controla a rapidez da convergência à solução ótima da rede neural. Existem

diversos algoritmos que podem otimizar a escolha dos pesos sinápticos baseados em algoritmos inteligência computacional ou em gradientes, estes últimos podem ser utilizados devido as propriedades de derivabilidade das funções de ativação.

4.3.2. Métodos de Otimização de Pesos

O algoritmo de aprendizado mais utilizado em aplicações para reconhecimento de padrões é método retropropagação reversa (*backpropagation*) (HAYKIN, 2009). Este método está baseado em gradientes decrescentes, buscando minimizar um erro global. Definindo uma maneira sistemática de atualizar os pesos das diversas camadas, baseados na ideia de que os erros dos neurônios das camadas escondidas são determinados pela retropropagação dos erros dos neurônios da camada de saída. O objetivo do algoritmo de aprendizado é minimizar o erro dado pela eq. (4.1).

$$E = \sum_{i=1}^{n_t} \sum_{j=1}^{n_s} (t_{ij} - s_{ij})^2 \quad (4.1)$$

Onde, n_t é o número de amostras utilizadas para realizar o processo de aprendizado, n_s é o número de saídas, t_{ij} é a saída j estimada para a amostra i e s_{ij} a correspondente saída desejada. Esta minimização é conseguida mediante a procura dos valores para $\Delta w_{ij}(t)$ correspondentes à variação no peso sináptico que conecta o neurônio i da camada t com o neurônio j da camada $t + 1$ para cada uma das camadas escondidas. Estas variações são calculadas por meio de

$$\Delta w_{ij}(t) = \eta \frac{\partial E}{\partial w_{ij}} \quad (4.2)$$

Onde η é um parâmetro artificial, denominado taxa de aprendizado, inserido para controlar as variações nos pesos sinápticos e conseguir diminuições controladas no erro quadrático. Evitando assim treinamentos demasiado lentos com valores baixos de η ou dificuldades para encontrar mínimos locais, devido a oscilações nas saídas estimadas, com valores altos de η . Uma expressão explícita para a eq. (4.2) é calculada em (HAYKIN, 2009), utilizando a regra da cadeia.

4.3.3. Clusterização

As técnicas de *clustering* caracterizam-se por agrupar vetores de dados utilizando alguma medida de similitude. O resultado deste processo é a formação de classes ou grupos (*clusters*). Os elementos que são agrupados encontram-se representados através de seus respectivos vetores de características e se assume que os pertencentes a uma mesma classe representam valores próximos para uma medida de similitude definida. Os tipos de algoritmos de *clustering* de dados mais comuns são os: particionais e os hierárquicos.

Um dos métodos particionais mais utilizados é o chamado de *k-means*. Este algoritmo de agrupamento tem por objetivo particionar um conjunto de n observações em k *clusters*, tal que o erro quadrático entre a média empírica do *cluster* e os pontos no *cluster* seja mínimo (JAIN, 2010) (DREYFUS, 2005).

Mais formalmente, seja $X = \{x_i\}, i = 1, \dots, n$ um conjunto de n pontos d -dimensionais para ser agrupados em um conjunto de k *clusters*, $C = \{c_j\}, j = 1, \dots, k$. Por outro lado, seja μ_j a média do *cluster* c_j . O erro quadrático entre μ_j e os pontos no *cluster* c_j é definido como,

$$J(c_k) = \sum_{x_i \in c_j} \|x_i - \mu_j\|^2$$

O objetivo de *k-means* é minimizar a soma dos erros quadráticos sobre todos os k *clusters*,

$$J(C) = \sum_{j=1}^k \sum_{x_i \in c_j} \|x_i - \mu_j\|^2$$

O algoritmo de *k-means* pode convergir a um mínimo local, embora estudos mais recentes têm demonstrado que com uma alta probabilidade *k-means* converge para um ótimo global quando os agrupamentos são bem separados (MEILA, 2006).

Por outro lado, na área de redes neurais, tem proposto várias soluções para o problema de *clustering*. As arquiteturas existentes podem ser divididas em duas categorias: as que utilizam um único representante por cada classe, também chamadas de *winner-take-all*, e as que utilizam vários representantes.

As primeiras produzem resultados eficientes quando são aplicadas em problemas onde as classes apresentam pouca dispersão, já que com um único

representante somente pode-se reconhecer o que pertence à hiper-esfera que lhe rodeia. No entanto, os que utilizam vários representantes requerem estabelecer parâmetros iniciais de similitude, dependentes do problema, que permitem relacionar os representantes. Os valores destes parâmetros devem ser calculados em base a um subconjunto de representantes de uma classe definida e se aplicam por igual a todas as classes do problema. Isto apresenta uma forte restrição sobre as classes, já que todas devem responder à mesma medida de similitude.

Com respeito ao algoritmo de aprendizado, na área do *clustering*, a classificação não supervisionada é cada vez mais utilizada nos casos onde a única informação disponível é a correspondente ao espaço de amostras de entrada. Portanto, a tarefa no aprendizado é descobrir correlações entre os exemplos fornecidos no treino. Um dos enfoques mais usados é a rede neural de Kohonen ou mapa auto-organizado (SOM) que utilizam uma função de vizinhança para preservar as propriedades topológicas do espaço de entrada (DREYFUS, 2005).

Finalmente, independente da metodologia empregada, o número de *clusters* a serem detectados, pode ser escolhido a priori, analisando a distribuição dos dados ou utilizando algum critério que permita otimizar a quantidade de partições. De tal maneira que sejam obtidos grupos exclusivos com elementos que apresentem um nível de similitude alta. Uma alternativa para a seleção do número de *cluster* é utilizar o critério para levar em consideração o número de *clusters* (como o critério de Davies-Bouldin) e um algoritmo de *clustering* que varie o número de clusters (como *k-means*). Particularmente, o critério de Davies-Bouldin com *k-means*, foi utilizado em (KURODA, et al., 2012) para a caracterização de electrofácies, com resultados eficientes, medidos na qualidade dos *clusters* resultantes.

O critério de Davies-Bouldin, introduzido por David L. Davies e W. Bouldin em 1979, é uma métrica para avaliar algoritmos de *clustering* (DAVIES, et al., 1979). Está baseado numa proporção das distâncias dentro do *cluster* (centróides) e entre os *clusters*. O índice de Davies-Bouldin está definido por:

$$DB = \frac{1}{k} \sum_{i=1}^k \max_{j \neq i} \{D_{ij}\}$$

Onde D_{ij} é a proporção entre a distância dentro do *cluster* e entre os *clusters* para o i -ésimo e j -ésimo *cluster*, i.e.

$$D_{ij} = \frac{(\bar{d}_i + \bar{d}_j)}{d_{ij}}$$

Onde

\bar{d}_i é a distância média entre cada ponto no i -ésimo e j -ésimo cluster.

\bar{d}_j é a distância média entre cada ponto no i -ésimo e o centroide do j -ésimo cluster.

\bar{d}_{ij} é a distância euclidiana entre os centroides do i -ésimo e j -ésimo cluster.

O valor máximo do D_{ij} representa o pior dos casos da proporção dentro do *cluster* e entre os *clusters* para o i -ésimo *cluster*. A solução ótima do número de *clusters* tem o menor valor do índice de Davies-Bouldin. Além disso, os valores do índice de Davies-Bouldin por baixo de 1 indicam *clusters* separados, por outro lado, valores superiores a 1 representam *clusters* possivelmente cruzados.

Comentário:

Nesta investigação são utilizadas as redes neurais implementadas no software de interpretação e análise de dados sísmicos PETREL. Este software utiliza redes neurais MLP com um algoritmo de aprendizado de retropropagação reversa. Também apresenta a opção de utilizar a rede neural para realizar estimativas (aprendizado supervisionado) ou para a classificação (aprendizado não supervisionado). Uma rede neural não supervisionada será utilizada para separar em *clusters* o reservatório completo, a quantidade de grupos será determinada pelo critério de Davies-Bouldin. Estes grupos são comumente chamados de electrofácies, que é uma terminologia utilizada para determinar grupos de acordo às respostas que caracterizam uma zona e as distingue de outras. Estas podem ser atribuídas a uma ou mais fácies litológicas, já que as medições dos perfis medem propriedades físicas das rochas. A delimitação de electrofácies em reservatórios de petróleo pode ser vista em (KUMAR, et al., 2006) e (KURODA, et al., 2012).

Por outro lado, uma rede neural supervisionada será utilizada como um método de comparação para validar os resultados obtidos por meio do algoritmo de programação genética. Foi escolhida esta técnica de RN, devido ao grande número de aplicações na área de exploração de petróleo. (BANCHS, et al., 2002), (DORRINGTON, et al., 2004), (LEITE, et al., 2011).

5 Inversão Sísmica e Geostatística

5.1. Introdução

O processo de determinar as características físicas das rochas ou dos fluidos que podem produzir um registro sísmico é denominado inversão sísmica. Este problema pode ser visto como a estimativa dos parâmetros de entrada de um sistema, por meio do estudo do comportamento da variável de saída, em vista disso é utilizado o termo de inversão. Em outras palavras, estão se transformando um conjunto de traços sísmicos processados nas propriedades que os determinaram. Na maioria dos casos as variáveis estimadas são a impedância, a velocidade e a densidade. Uma vez que estas grandezas proporcionam uma melhor estimativa de propriedades de reservatório, como a porosidade (PENDREL, 2006).

A geostatística é um conjunto de técnicas estatísticas aplicadas na indústria de petróleo para a modelagem de dados espaciais. Esta fornece estimativas de propriedades em posições onde estas não estejam disponíveis. Os métodos geostatísticos são capazes de construir a função distribuição de probabilidade de uma variável a ser estimada, a partir de medições próximas, e assim simular distintos valores para ela.

Neste capítulo são estudados alguns métodos convencionais de inversão sísmica, aplicados ao cálculo da impedância acústica a partir de traços sísmicos e calibrações com perfis de poço. Além disso, é introduzida a inversão genética, que utiliza métodos de inteligência computacional para estimar a relação entre os dados sísmicos e a propriedade desejada. Na última seção, é descrita a teoria de geostatística, dando principal ênfase à interpolação de variáveis discretas, devido aos objetivos deste trabalho.

5.2. Inversão Sísmica

A inversão sísmica foi criada há mais de 40 anos com o objetivo de utilizar os dados sísmicos para a estimativa de propriedades do reservatório (OLDENBURG, et al., 1983). Na década de 90 esta informação era somente utilizada para estimar a estrutura dos reservatórios, mas não tinha uma regra fundamental na estimativa da distribuição de propriedades de reservatório ou de rochas (SCHULTZ, et al., 1994). Entretanto, já era conhecido que os eventos nos traços sísmicos adquiridos, causados por fenômenos da física das rochas, podiam ser utilizados para obter mais informação sobre a subsuperfície do reservatório. Isto requer do desenvolvimento de metodologias que permitam encontrar relações entre as propriedades de rocha e os dados sísmicos.

Vários métodos têm sido desenvolvidos para estimar propriedades elásticas a partir dos dados sísmicos, para classifica-los estes foram divididos em dois grupos principais, dependendo de se utilizam dados sísmicos pós-empilhados ou pré-empilhados. Pode-se observar na Figura 5.1 a classificação utilizada em (RUSSELL, 1988).

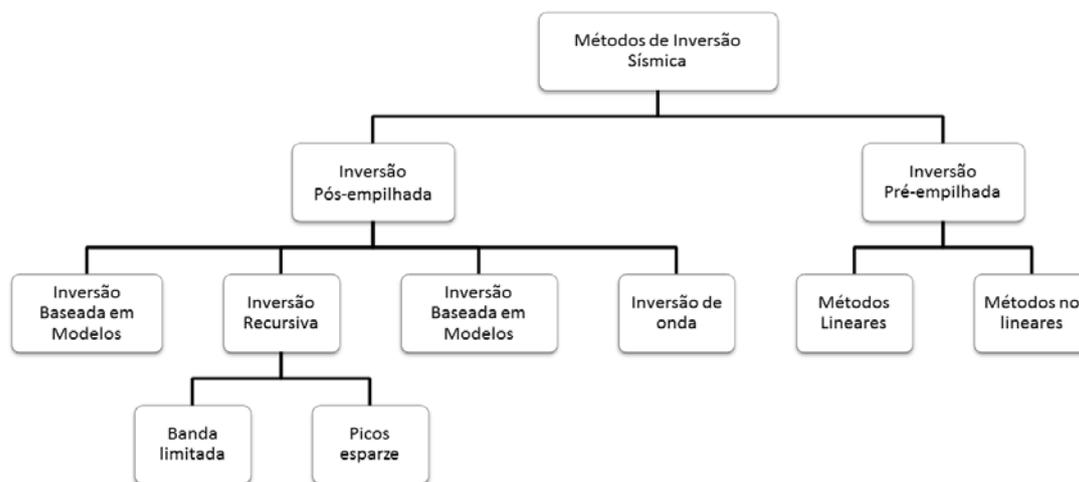


Figura 5.1. Classificação dos métodos de inversão sísmica. Modificado de (RUSSELL, 1988).

Os métodos de inversão pós-empilhada utilizam dados sísmicos empilhados com amplitude preservada no processamento. Estes métodos foram desenvolvidos para estimar a impedância acústica, que proporciona informação adicional para uma caracterização do reservatório. Estas metodologias supõem que os dados sísmicos podem ser decompostos mediante a eq. (5.1), denominado modelo convolucional.

$$s(t) = r(t) * w(t) + n(t) \quad (5.1)$$

Onde $s(t)$ é a traça sísmica, $r(t)$ é a refletividade da terra, $w(t)$ a ondícula sísmica e $n(t)$ o ruído presente nas medições. As mais importantes são as técnicas de inversão por meio de picos esparsos (*sparse-spike inversion*) e inversão baseada em modelos. Para os métodos de inversão sísmica convencional o objetivo será encontrar o termo da refletividade da terra, $r(t)$. Para compreender este processo, se mostra na Figura 5.2, na imagem da esquerda, como funciona o método direto. Começa com um modelo estimado da terra que se convolve com uma ondícula e o resultado é um traço sísmico sintético. Por outro lado, no lado direito da Figura 5.2, se descreve a inversão. Esta inicia com um traço sísmico real, é removido o efeito da ondícula e obtém-se uma estimativa da refletividade. Os métodos de inversão sísmica utilizam um sistema iterativo entre o modelado direto e a inversão, procurando minimizar a diferença entre o traço sísmico sintético e real (BARCLAY, et al., 2008).

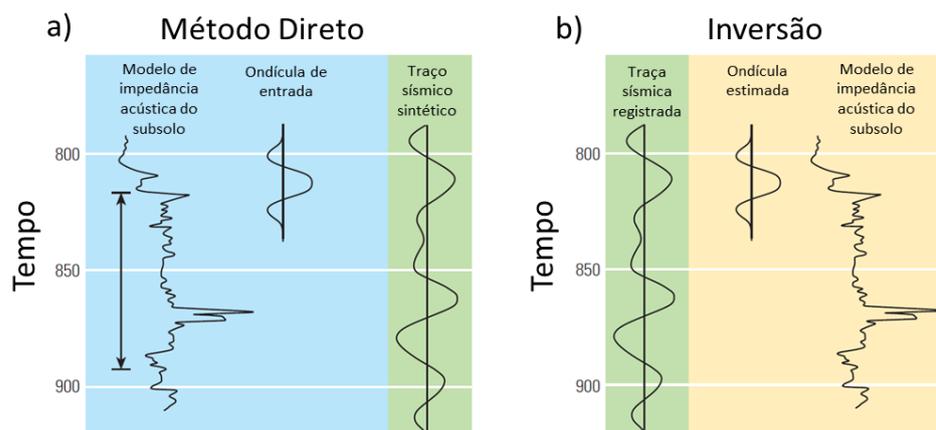


Figura 5.2. a) Funcionamento da modelagem mediante o método direto. b) Funcionamento da modelagem mediante a inversão. Modificados de (BARCLAY, et al., 2008).

A metodologia de picos esparsos foi formulada inicialmente em (OLDENBURG, et al., 1983) e supõe que a série de refletividades, dada por $r(t)$ na eq. (5.1), é esparsa e cada valor não nulo representa as camadas da subsuperfície da terra. Neste método são calculadas as refletividades e a partir destas a impedância acústica. Adicionalmente, a inversão baseada em modelos começa com um modelo inicial, que é perturbado iterativamente até que um critério de minimização seja atingido (BARCLAY, et al., 2008). Para a avaliação

do modelo é calculado um traço sísmico sintético, que é comparado com o traço sísmico real e assim obter um erro na predição.

Por outro lado, as técnicas utilizadas para dados sísmicos pré-empilhados são aplicadas a dados sísmicos já processados, mas antes de realizar o empilhamento. Estes métodos ganharam bastante destaque na literatura, especialmente aqueles que interpretam as variações da amplitude da sísmica contra as mudanças nas distâncias entre a fonte e o receptor, conhecido na literatura como amplitude contra afastamento ou AVO pelas siglas em inglês. O incremento na popularidade foi causado pelo aumento da capacidade computacional e a melhoria na qualidade dos dados sísmicos. Embora, as análises feitas para dados pós-empilhados são ainda comumente utilizados devido à disponibilidade dos dados e um processamento de baixo custo computacional (LEITE, et al., 2011).

Recentemente, surgiram técnicas de inversão que utilizam metodologias de inteligência computacional, para construir um modelo tridimensional da terra (HAMPSON, et al., 2001) (VEEKEN, et al., 2009), estes serão explicados com maior detalhe na próxima seção.

5.2.1. Inversão Genética

O processo de inverter os dados sísmicos para obter uma representação tridimensional da impedância acústica é uma área com um grande número de aportes na literatura, devido à acurácia na interpretação da impedância acústica (LATIMER, et al., 2000). Embora, realizar uma inversão do reservatório completo é um problema de difícil solução que requer um estudo da relação existente entre a sísmica e a impedância acústica. Para isto, podem ser utilizadas metodologias de inteligência computacional como as redes neurais, que dentro da área de exploração de petróleo já tem numerosas aplicações na estimativa de tais relações (LEIPHART, et al., 2001), (HAMPSON, et al., 2001), (DORRINGTON, et al., 2004), (CALDERON, et al., 2007).

Estas técnicas surgem como uma alternativa revolucionária aos métodos convencionais de inversão sísmica. Ao contrário dos enfoques tradicionais, que precisam de um fluxo de dados elevado e de um profissional experiente para algumas das manipulações (VEEKEN, et al., 2009), esta opção pretende

disponibilizar ao investigador ferramentas rápidas, efetivas e com baixo custo computacional que facilitem a interpretação dos dados sísmicos. Para isso, são necessários como dados de entrada, apenas os dados da amplitude sísmica e a impedância acústica nos poços como dados de controle. Este conjunto de entradas não precisa ser manipulado previamente pelo interprete, uma vantagem que facilita o uso destes métodos de inversão.

Será explicado principalmente o método de inversão genética que já foi testado e obteve resultados promissores, para a estimativa da impedância acústica em reservatórios de petróleo, a partir de dados da amplitude sísmica (VEEKEN, et al., 2009), (WATANABE, et al., 2013). Este método está baseado em redes neurais Multi-layer perceptron descritas na seção 4.3, selecionado pela relação não linear entre a impedância acústica e os dados da amplitude sísmica. A técnica utiliza uma metodologia com algoritmos genéticos para a otimização dos pesos sinápticos, desta forma é obtido um operador não linear de melhor ajuste. O método de ajuste restringe o processo de inversão, de tal forma que as chances de alcançar um erro mínimo global são maiores que mediante inversões somente baseadas em redes neurais (SCHLUMBERGER, 2010).

Adicionalmente, a inversão genética considera um esquema globalizado, que utiliza informação dos traços sísmicos vizinhos e de amostras sísmicas numa janela de tempo ou profundidade, dependendo do formato da sísmica. Ao considerar uma quantidade maior de fontes de informação é diminuído o efeito do ruído. A utilização de traços sísmicos em torno do traço alvo ajuda a evitar soluções locais e a estabilizar a saída (VEEKEN, et al., 2009). A janela de tempo ou profundidade selecionada deve ser aproximadamente o tamanho da ondícula da sísmica. Além disso, se realiza uma redução inteligente de dados para reduzir o número de pesos a estimar, este é descrito na Figura 5.3. A seleção é realizada através de um método de amostragem, que seleciona amostras a utilizar em zonas delimitadas por diamantes. Este procedimento permite a diminuição do número de nós na camada de entrada da rede neural, com uma perda pequena de acurácia.

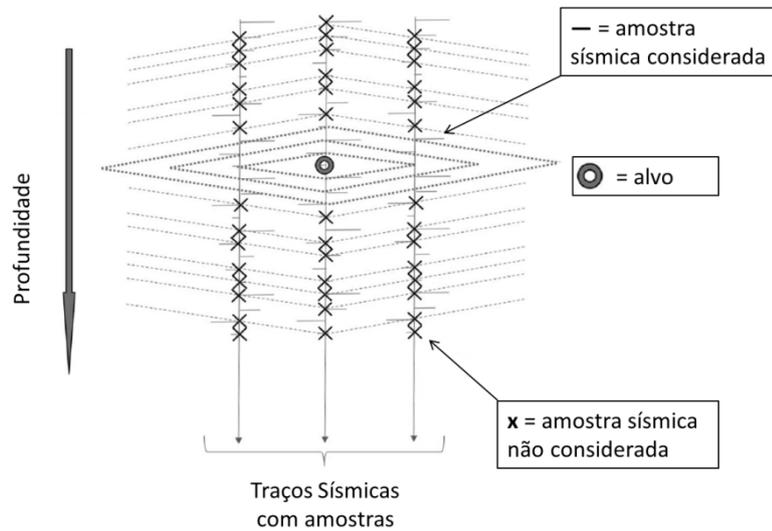


Figura 5.3: Seleção inteligente de amostras. As amostras a considerar são delimitadas por zonas em forma de diamante, modificado de (VEEKEN, et al., 2009).

A seleção dos parâmetros do modelo, como o tamanho de janela e número de traços sísmicos a considerar, determinarão a quantidade de amostras a utilizar. Essa escolha é realizada para cada caso em particular, dependendo das características dos dados sísmicos e através de numerosos experimentos. Um alto número de amostras incrementa significativamente o custo. Para a estimativa da impedância acústica, neste trabalho foi utilizada a ferramenta de inversão genética implementada no software de análise e manipulação sísmica Petrel.

5.3. Geostatística

A geostatística fornece um conjunto de métodos para a estimativa de variáveis incertas distribuídas espacialmente. Em (ISAACKS, et al., 1989), esta é definida como uma coleção de técnicas numéricas que lidam com a caracterização de atributos espaciais, utilizando principalmente modelos aleatórios de uma maneira similar à forma em que uma série temporal caracteriza dados temporais. Os métodos geostatísticos utilizam as medições disponíveis para construir uma função distribuição de probabilidade, assim capturando o comportamento aproximado da variável a estimar.

Na área de exploração de petróleo, estas técnicas são comumente utilizadas para estender variáveis definidas nos poços, ao reservatório completo, como se pode observar em (DOYEN, 1988), (SRIVASTAVA, 1992) e (VIDAL, et al.,

2007). Podem ser utilizados para interpolar tanto variáveis discretas como contínuas. Adicionalmente utilizam modelos, ajustados para cada caso em particular, para determinar o comportamento da variável de estudo. Estes modelos utilizam como base a correlação existente entre medições da variável de estudo nas posições amostradas. Nesta dissertação, a geostatística é utilizada para estender os *clusters* determinados em poços ao reservatório completo. Para isto foi selecionada a técnica de simulação indicadora sequencial (SIS).

5.3.1. Simulação Indicadora Sequencial

A simulação indicadora sequencial (SIS) é uma técnica geostatística especializada em interpolar variáveis categóricas, como clusters ou fácies. O método considera cada variável em determinada posição como uma variável aleatória, cuja distribuição é estimada. Para a interpolação de uma variável em cada bloco do reservatório, o método utiliza os seguintes passos:

- Um caminho aleatório é selecionado. Este determina a ordem em que os blocos do grid são estimados.
- É estimada a distribuição do próximo bloco do caminho aleatório para estimar a função distribuição de probabilidade.
- Um valor aleatório é gerado, de acordo à distribuição, este é atribuído ao bloco atual.
- Cada bloco do grid é visitado sequencialmente, encontrando um valor para cada bloco.

Note-se que a interpolação resultante varia com cada simulação, devido ao caminho aleatório e a natureza estocástica da atribuição dos valores a cada bloco. O segundo passo da técnica, a estimação da distribuição de probabilidade, é normalmente realizada por meio de Kriging.

O método de Kriging é um estimador linear utilizado para aproximar a média e variância da variável a estimar, em cada bloco do grid. Esta aproximação está baseada nas correlações que existem entre as medições existentes e a estimação a realizar. A correlação é modelada por uma função dependente da distância entre as amostras, desta forma, amostras próximas têm uma influência maior no resultado. Esta função é chamada de semivariograma e representa a diferença entre os valores da variável em estudo com respeito à distância

(ISAACS, et al., 1989), um exemplo deste é apresentado na Figura 5.4. Para que esta se ajuste corretamente aos dados de estudo, são determinados parâmetros particulares.

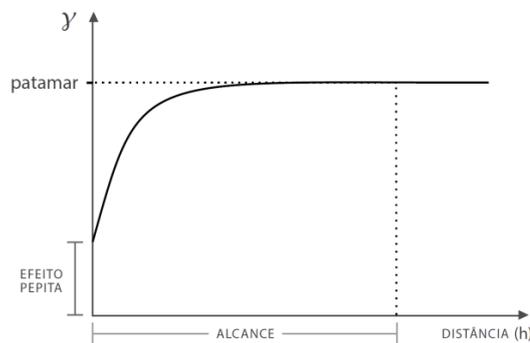


Figura 5.4: Modelo de semivariograma esférico. Tomado de (DA COSTA, 2013).

Na figura anterior é possível observar como aumenta a diferença entre valores da variável conforme aumenta a distância entre eles. Os parâmetros do semivariograma são listados a seguir.

- *Efeito pepita*: Em teoria o valor do semivariograma na origem deve ser 0, porém a heterogeneidade da variável pode causar descontinuidades imediatas no valor da variável a estimar.
- *Alcance*: Determina o limite na distância da influência da variável. Isto é, para distâncias maiores ao alcance, as amostras não possuem mais correlação espacial.
- *Patamar*: O valor no semivariograma para o qual o alcance é atingido.
- *Tipo de Semivariograma*: O semivariograma pode ser esférico, exponencial ou gaussiano. As expressões que os definem estão dadas a seguir.

Semivariograma Esférico:

$$\gamma(h) = \begin{cases} \frac{3}{2}||h|| - \frac{1}{2}||h||^3 & \text{se } ||h|| \leq \text{alcance} \\ 1 & \text{outro caso} \end{cases}$$

Semivariograma Exponencial:

$$\gamma(h) = 1 - e^{-3||h||}$$

Semivariograma Gaussiano:

$$\gamma(h) = 1 - e^{-3||h||^2}$$

Adicionalmente, o valor do alcance deve ser selecionado em três direções. A direção major que determina a direção em que as amostras têm a maior

correlação. A direção menor que é perpendicular à direção maior e na direção vertical. A direção maior é determinada selecionando o azimuth que determina o ângulo da direção maior com respeito aos eixos usuais (norte, sul, leste, oeste).

Como informação adicional, podem ser utilizadas curvas verticais proporcionais, que determinam a proporção das fácies em cada nível, integradas lateralmente no reservatório completo. Estas refletem as variações verticais das proporções das fácies e aproximam o processo deposicional que determina a distribuição das fácies (RAVENNE, et al., 2000). São construídas por meio de histogramas baseados na distribuição vertical da variável a estimar.

6

Modelagem da Caracterização de Reservatórios

6.1.

Introdução

O estudo de reservatórios de petróleo depende de medições realizadas diretamente, como os perfis de poço, estudados na seção 2.5, ou indiretamente, com levantamentos sísmicos expostos na seção 2.2. Estas medições servem para caracterizar o reservatório, isto é a estimativa de propriedades de reservatório como a porosidade, a permeabilidade e a saturação de água, em cada posição do reservatório. A caracterização por si só é uma valiosa fonte de informação ao traçar estratégias para perfuração e extração de óleo, mas comumente, é utilizada para a construção de um modelo de reservatório, capaz de prever o resultado de qualquer ação. Para conseguir uma correta caracterização é necessária uma modelagem do processo, para integrar as medições e estimar as propriedades desejadas em todo o reservatório, considerando a geologia do campo.

Neste capítulo é exposto o processo da modelagem do problema de caracterização de reservatórios de petróleo via programação genética. Especificamente são expostos os passos realizados na estimativa da porosidade neutrónica, como uma propriedade volumétrica a ser estimada em todo o volume sísmico. Cada passo envolve metodologias diferentes para: a integração de dados, a seleção de atributos (como análises de correlações), a construção de variáveis no reservatório completo (como inversão genética), a interpolação de dados a todo o reservatório (como geoestatística) e melhora dos resultados (como clustering). Porém, todas são realizadas com o propósito de obter, por meio de programação genética, uma expressão que aproxime a porosidade do reservatório.

6.2.

Modelagem do Problema

A caracterização de reservatórios neste trabalho foi abordada por meio de um enfoque baseado nos dados, ao contrário de um enfoque baseado em relações

teóricas. A modelagem utilizada, assim como em (SCHULTZ, et al., 1994), assume que existe uma relação, possivelmente não linear, entre a sísmica e as propriedades de reservatório. Portanto, a relação existente é também dependente dos dados e necessariamente variante de acordo à geologia do campo. O objetivo é, conseqüentemente, identificar vestígios de informação em cada uma das medições disponíveis no campo e integrá-la de forma que possa ser utilizada na caracterização do reservatório.

Para integrar os dados sísmicos e os perfis de poço é preciso lidar com duas problemáticas, a diferença de informação e de escala. A sísmica fornece informação das propriedades acústicas (densidade e velocidade) das camadas da terra; os perfis de poço proporcionam dados sobre as características das formações rochosas e dos fluídos numa vizinhança aos poços. Mais ainda, os dados sísmicos são amostrados em intervalos regulares de tempo e depois podem ser transformados de tempo para profundidade. Estes estão disponíveis em todo o reservatório, mas têm uma baixa resolução vertical com dados separados por vários metros. Por outro lado, as amostras nos perfis de poço estão distanciadas verticalmente por poucos centímetros. Trabalhar conjuntamente com estes tipos de dados torna-se extremamente difícil sem um software de interpretação sísmica, que seja capaz de mesclar as fontes de dados em um mesmo plano. Estes programas também permitem de uma maneira eficiente, a interpolação de traços sísmicos em torno do poço, de forma que seja possível a construção de um *perfil sísmico*. Isto é um conjunto de valores derivados dos dados sísmicos na escala dos perfis de poço, o que facilita consideravelmente o trabalho do investigador, ao utilizar simultaneamente sísmica e perfis.

Adicionalmente, é comum que alguns poços do reservatório não disponham do conjunto completo de perfis de poço. Isto se deve ao fato de que o conjunto completo de perfis não foi coletado no momento da perfilagem ou surgiram problemas com o processo da perfilagem, tais como instrumentos defeituosos ou condições inapropriadas durante o processo de amostragem de algum dos perfis (SAGGAF, et al., 2003). Nestes casos, uma estimativa dos perfis de poço ausentes é necessária, principalmente se são o perfil sônico ou de densidade, utilizados para o cálculo da impedância acústica (propriedade de interesse neste trabalho). A estimativa destes perfis pode ser realizada via distintos métodos,

estudados na seção 3.6, nesta dissertação tal tarefa vai ser realizada por meio de PG.

Para representar a relação, que se assume existe, entre a sísmica e as propriedades geológicas, será utilizada a técnica de programação genética, definida na seção 4.2. PG aprende a representar relações baseando-se em um histórico de dados que deve ser consistente, representativo e livre de erros. Para isso é construída uma matriz $X \in \mathbb{R}^{m \times n}$, de variáveis de entrada, e o correspondente vetor de saídas desejadas $Y \in \mathbb{R}^{m \times 1}$, onde m é o número de amostras e n o número de variáveis de entrada. Na Figura 6.1 é esquematizado o funcionamento de PG.

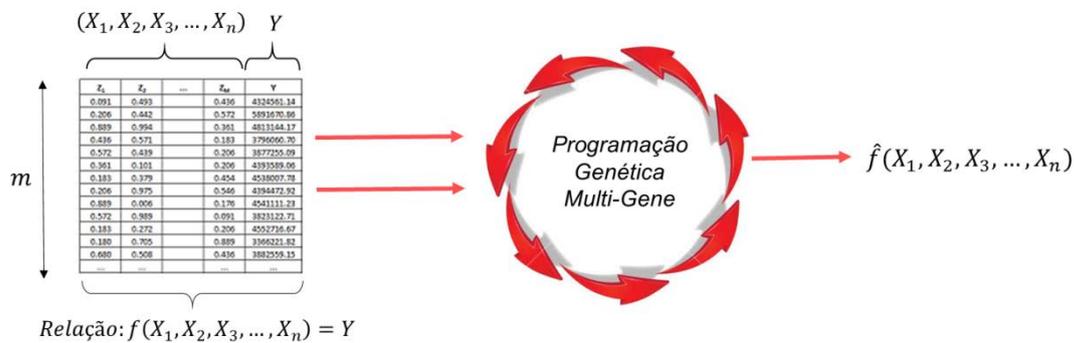


Figura 6.1: Esquema do processo de estimação de uma variável por meio de PG.

O resultado desta técnica é uma função explícita analítica, \hat{f} capaz de estimar as saídas Y , como uma função das variáveis de entrada X , como se apresenta na Figura 6.1. Desta forma, pode-se aproximar a variável de saída a partir das variáveis de entrada em bases de dados onde a variável Y não exista.

Ainda mais, como a função resultante \hat{f} é explícita, pode ser estudada em busca de informação sobre a relação construída, por exemplo, pode-se estudar que variáveis estão presentes em \hat{f} , que peso tem cada uma delas na função. Uma das maiores vantagens é poder utilizá-la facilmente em outros contextos ou softwares de programação. Neste trabalho a PG foi desenvolvida em *Matlab* e a função obtida foi inserida e utilizada com relativa facilidade no software de interpretação e análise sísmico, Petrel. Este processo foi possível, pela disponibilidade da função de PG e por uma ferramenta de Petrel que simula uma calculadora. Tal funcionalidade pode ser visualizada na Figura 6.2.

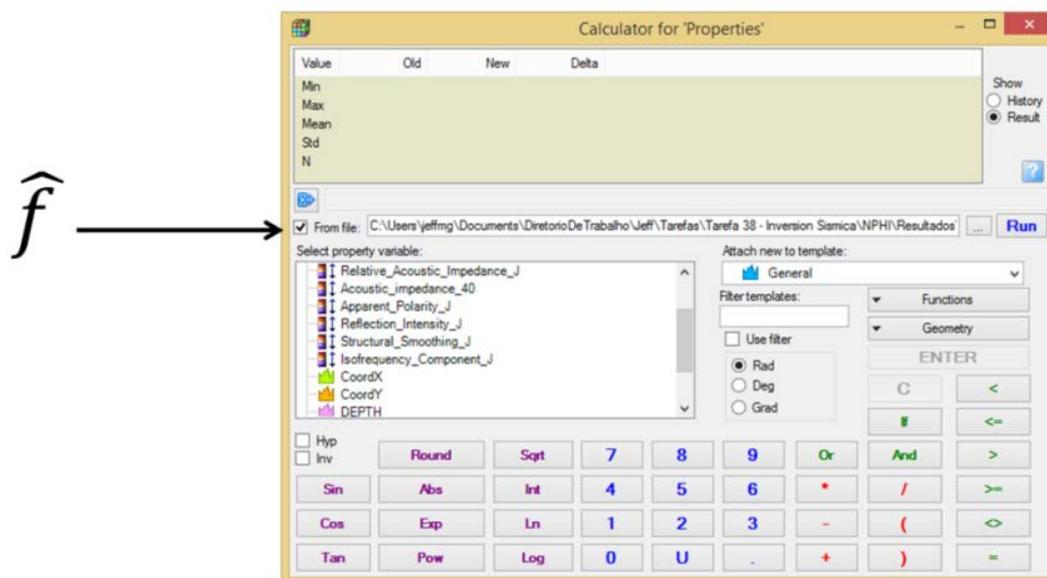


Figura 6.2: Calculadora do software de análise e interpretação de dados sísmicos Petrel.

Esta ferramenta do Petrel permite o cálculo de novas variáveis, em função das já existentes, algumas delas podem ser observadas na parte central esquerda da Figura 6.2, por exemplo, *Relative Acoustic Impedance* ou *CoordX*. Adicionalmente, é disponibilizado um conjunto de operadores, como seno e cosseno, na parte inferior esquerda, e como soma e subtração, na parte inferior direita. A função construída através de PG é uma combinação de operadores ou funções básicas previamente definidas. A seleção de estas depende de cada problema em particular, neste trabalho foram escolhidas de acordo com dois critérios, que sejam capazes de representar a relação entre entradas e saídas e que os operadores estejam presentes na calculadora de Petrel. Desta forma assegura-se que \hat{f} possa ser avaliada através da ferramenta. Além disso, a calculadora pode ser utilizada tanto para variáveis definidas somente em poços como para variáveis em 3D, definidas pela sísmica em todo o reservatório. Deste modo, \hat{f} pode calcular uma variável nos poços ou em 3D, dependendo do tipo das variáveis de entrada na função.

No caso das estimativas em 3D podem ser utilizados, como entradas ao modelo, os atributos sísmicos ou as propriedades invertidas da sísmica. A impedância acústica obtida da inversão genética tem demonstrado ser uma fonte de informação importante para estimar propriedades geológicas (CALDERON, et al., 2007) e conseqüentemente será utilizada como um dos principais elementos na caracterização do reservatório em 3D.

Por outro lado, devido à heterogeneidade dos campos de petróleo, foi realizada uma clusterização, com o propósito de agrupar em zonas geológicas e ajudar o algoritmo de programação genética a obter uma melhor aproximação. Isto por meio de uma função explícita definida por partes, que dependa dos grupos construídos no *clustering*.

A metodologia selecionada neste trabalho pretende evidenciar a utilidade da técnica de programação genética para a caracterização de reservatórios. O esquema do processo completo pode ser apreciado na Figura 6.3.

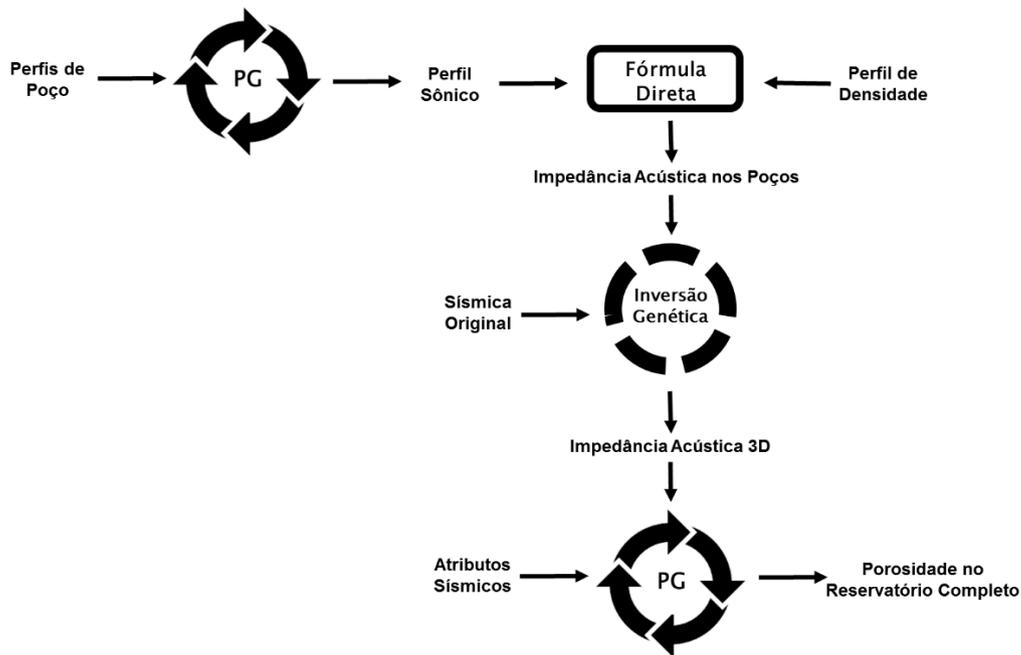


Figura 6.3: Esquema do workflow para estimação da porosidade 3D.

Na figura anterior é indicado cada um dos passos a seguir, envolvendo tanto os perfis de poço como os dados sísmicos, de uma maneira integral. Fazendo uso dos métodos de PG e de inversão genética através de todo o processo, até obter uma estimativa completa da porosidade. O esquema será aplicado a um reservatório real com uma alta complexidade geológica. Além disso, o último passo do procedimento foi realizado em dois testes. No primeiro teste é construída, por meio de PG, uma expressão global para o reservatório completo. No segundo teste, é construído um conjunto de funções independentes, cada uma por meio de PG, que estimem a porosidade por zonas.

6.3. Estimativa de Propriedades em Poços

A necessidade de estimar propriedades nos poços surge pela falta de perfis de poço, uma situação já discutida na seção 3.6. Em particular, neste trabalho a falta do perfil de poço sônico (DT), limita os avanços na caracterização do reservatório. Este perfil é utilizado para calcular diretamente a impedância acústica, uma propriedade imprescindível para estimativas posteriores.

Por meio de PG foi reproduzida a relação entre os outros perfis de poço, disponíveis na maioria das perfurações, e o perfil sônico. Na Figura 6.4 é apresentado o procedimento que permite, calculando os perfis de DT, obter nos poços um perfil de impedância acústica. Adicionalmente, é importante destacar que para o algoritmo de PG será selecionado um subconjunto dos perfis de poço, que servirá como entrada, junto com os valores disponíveis do perfil de DT como saída desejada. Esta seleção estará baseada em análises de correlações. Desta forma, somente serão utilizados os perfis de poço que aportam informação valiosa sobre o comportamento do perfil sônico.

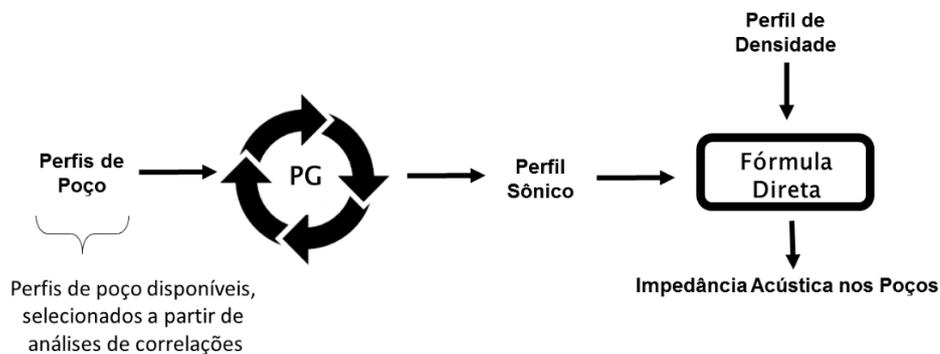


Figura 6.4: Esquema do workflow para a estimativa de perfis de poço.

O resultado final deste processo é utilizado como uma nova variável de entrada num sistema de inferência posterior, que permite a estimativa de propriedades em 3D.

6.4. Estimativa de Propriedades 3D

A maior dificuldade na caracterização de reservatórios é fazer estimativas longe do controle que oferecem os poços, onde a incerteza das propriedades das rochas aumenta. Neste trabalho essa problemática foi abordada por meio de uma

análise exhaustiva dos dados sísmicos. Foi utilizada uma metodologia de inversão sísmica (seção 5.2.1) para a obtenção da impedância acústica como uma propriedade em 3D. Este processo requer de dados sísmicos pós-empilhados, como base da inversão e como dados de calibração é utilizada a impedância acústica nos poços. A impedância invertida servirá, junto com atributos sísmicos para estimar, por meio de PG, a porosidade.

Para estimar a porosidade em todo o reservatório, será calculada uma função de propriedades em 3D baseada na relação entre as variáveis de entrada e a saída. Este esquema de trabalho selecionado é apresentado na Figura 6.5.

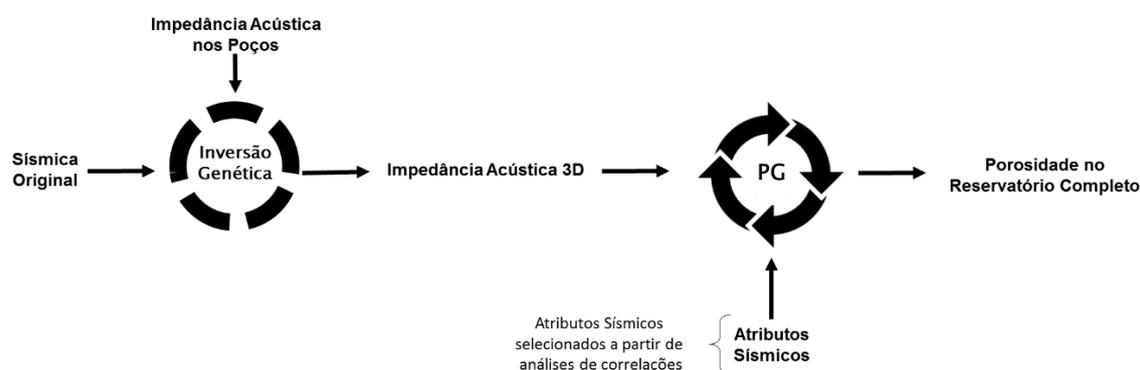


Figura 6.5: Esquema do workflow para a estimativa de propriedades 3D.

Adicionalmente, uma metodologia de seleção de atributos sísmicos foi realizada, pelo grande número de atributos disponíveis. Devido à abordagem focada nos dados, a seleção foi baseada em análises de correlações e não na interpretação geológica que estes atributos têm.

Também, como foi mencionado anteriormente, o campo de petróleo foi particionado de acordo às propriedades geofísicas. Este agrupamento foi realizado por meio de uma rede neural não supervisionada, que utiliza como variáveis de entrada, a informação dos perfis de poço do conjunto de treinamento. O número de *clusters* foi calculado utilizando o critério de Davies-Bouldin aplicado ao algoritmo de *k-means* (subseção 4.3.3). Por outro lado, devido ao fato de que a separação por zonas geológicas foi realizada no conjunto de treino, foi necessário aplicar um algoritmo de interpolação para levar esta informação ao resto do reservatório, em particular, ao conjunto de teste de PG.

A relação entre os dados sísmicos, a impedância acústica invertida e a porosidade, é capturada numa função \hat{f} , por meio do algoritmo de PG. Para o primeiro teste (global) a função obtida é uma única expressão, aplicada a todo o

reservatório. No caso da separação por n clusters, a função obtida é uma expressão definida por partes, com um formato dado por,

$$\hat{f} = \begin{cases} \hat{f}_1 & \text{em cluster 1} \\ \hat{f}_2 & \text{em cluster 2} \\ \vdots & \\ \hat{f}_n & \text{em cluster } n \end{cases}$$

Esta expressão final é inserida posteriormente no software Petrel, por meio da calculadora para propriedades (Figura 6.2), para assim estimar a porosidade em todo o reservatório.

Posteriormente, será realizada uma análise de sensibilidade da quantidade de poços selecionados para a estimativa de propriedades geológicas. Com este propósito, serão feitos diversos testes, utilizando o mesmo conjunto de poços de teste e distintos conjuntos para o treinamento. Serão escolhidos conjuntos de treinamento com uma quantidade de poços menor que para o experimento inicial. Desta maneira pode-se determinar a eficiência da metodologia proposta em reservatórios com menos perfurações.

7

Caso de Estudo

7.1.

Introdução

Neste capítulo será desenvolvida a modelagem proposta no capítulo 6, aplicada especificamente ao campo de Namorado, um reservatório real extensamente explorado. O reservatório será descrito em detalhe, junto com as características e os tipos de medições disponibilizadas.

Na primeira parte, serão realizadas estimativas em perfis de poço. O perfil de poço sônico será aproximado nos poços onde tal perfil não foi adquirido, a partir de outros perfis. A impedância acústica (IA) será calculada por meio de um cálculo direto.

Na segunda seção, serão realizadas estimativas no reservatório completo. A impedância acústica é invertida por meio de inversão genética. Esta variável invertida e alguns atributos sísmicos foram utilizados para estimar propriedades geológicas. Em particular, será estimada a porosidade neutrônica. Dois testes serão desenvolvidos para realizar esta aproximação. No primeiro teste, é aplicado o algoritmo de programação genética em todo o reservatório de Namorado. No segundo teste, é realizado um agrupamento por *clustering*, de acordo com as propriedades geofísicas, gerando várias electrofácies do reservatório. Finalmente, será aplicado PG a cada electrofície detectada, construindo várias expressões para estimar a porosidade, que dependem das zonas geológicas determinadas.

7.2.

Campo de Namorado

O campo de Namorado é um reservatório de petróleo localizado a 80 km da costa, ao sudeste de Brasil, no estado de Rio de Janeiro, como se pode observar na Figura 7.1. Esta situado em zonas de pouca profundidade sob lâmina de água entre 110 e 250m, delimitado por fechamentos estratigráficos e estruturais a uma área

aproximada de $7 \times 3 = 21 \text{ km}^2$ (MENESES, et al., 1990). É uma parte fundamental da bacia sedimentar de Campos, a mais importante já explorada do país.



Figura 7.1: Localização do campo Namorado. Modificado de (BIZZI, et al., 2003).

A composição do campo de estudo é predominantemente formada de arenitos e folhelhos, secundariamente, por conglomerados, brechas, siltitos e margas, de modo que apresenta uma grande complexidade geológica (VIDAL, et al., 2007). De acordo com as descrições de testemunho, são observadas, no total, 23 fácies litológicas. As principais rochas de reservatórios descritas são referentes a duas fácies de arenitos. A fácies de maior ocorrência nos testemunhos corresponde a fácies arenito médio maciço, arcoseano e bem selecionado. A segunda fácies são arenitos grossos amalgamados, com gradação da fração areia grossa-conglomerática na base para fração grossa no topo (VIDAL, et al., 2007).

O campo de Namorado foi selecionado para este estudo por se tratar de um campo bem explorado, com 56 perfurações disponíveis e um arquivo de dados sísmicos 3D correspondente à área total do reservatório.

7.2.1. Dados de Poço

Cada um dos poços do reservatório está disponível como um arquivo LAS, com os correspondentes perfis de poço amostrados, o total de perfis para cada poço pode ser observado no apêndice. Todos têm medições realizadas por meio da perfilagem de poços, mas não todos os tipos foram sempre registrados, isto é um acontecimento comum estudado na seção 3.6. Na Tabela 7.1 pode se observar o número de poços que tem determinado tipo de perfil.

Tabela 7.1: Número de poços no campo de Namorado com determinado perfil de poço.

Perfil de Poço	Número de Poços
GR	55
ILD	56
DT	17
RHOB	56
NPHI	54

Uma observação adicional à tabela anterior permite distinguir um grande número de perfis de poço sônico faltantes, motivando uma posterior estimativa destes. O campo apresenta um número elevado de perfurações, distribuídas em toda sua extensão, isto é evidenciado na Figura 7.2.

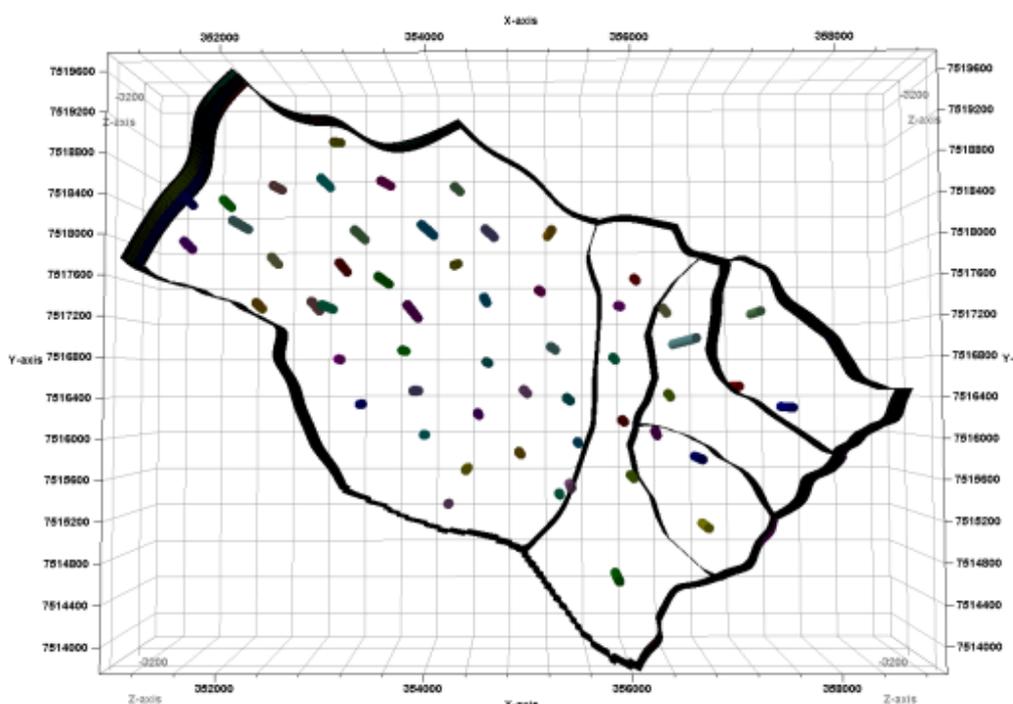


Figura 7.2: Distribuição espacial dos poços do campo de Namorado.

7.2.2. Dados Sísmicos

Por outro lado, o arquivo de dados sísmicos, disponibilizado em formato seg-y, corresponde à sísmica 3D migrada em profundidade e pós-empilhada. Assim, os dados sísmicos são representados numa escala de profundidade em vez de tempo. As características principais dos dados sísmicos são detalhadas na Tabela 7.2.

Tabela 7.2: Parâmetros dos dados sísmicos no campo de Namorado.

Parâmetros dos Dados Sísmicos	
Número de traças em <i>inline</i>	200
Número de traças em <i>crossline</i>	421
Intervalo de <i>inline</i>	33m
Intervalo de <i>crossline</i>	25m
Rotação do <i>inline</i> (azimuth)	118°
Amostras por traço	1298
Intervalo de amostragem	3m

O cubo sísmico, correspondente ao campo Namorado, é construído a partir dos valores das amplitudes de onda dos traços sísmicos registrados na aquisição. Como foi mencionado na seção 2.3, o *inline* e *crossline* correspondem ao eixo X e Y respectivamente. Os traços sísmicos são amostrados cada 3m desde a profundidade zero até 3891m de profundidade, mas é considerada somente a área delimitada pelo reservatório.

7.3. Estimativa de Perfis de Poço

Nesta seção será realizado o processo descrito na seção 6.3, o qual apresenta um fluxo de trabalho que tem por objetivo a estimativa dos perfis de poço sônicos ausentes, a partir dos outros perfis de poço. A estimativa é justificada pela importância do perfil sônico em estimativas posteriores e a elevada quantidade de perfurações sem este valor registrado.

Inicialmente foi realizada uma análise dos perfis de poço, identificando valores extremos ou atipicidades que pudessem dificultar à estimativa. Para isto foram estudadas as distribuições dos valores de cada perfil de poço, para todos os poços em conjunto. Os resultados do estudo de cada perfil de poço são apresentados na Figura 7.3.

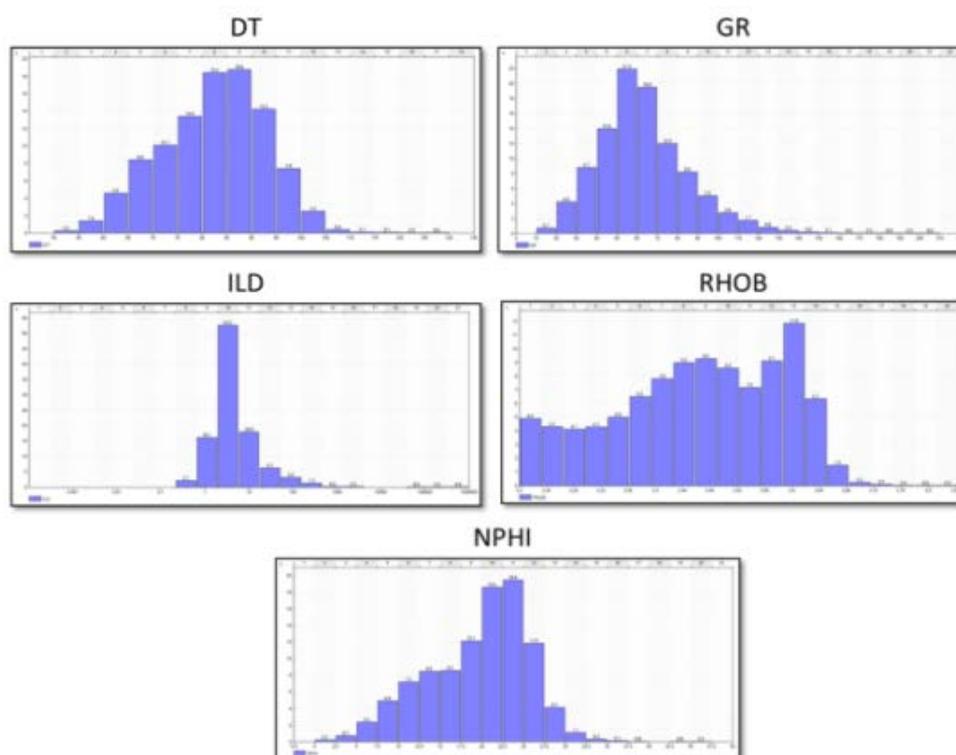


Figura 7.3: Distribuição dos valores de cada perfil de poço.

O perfil de poço de resistividade foi o único que apresentou valores extremos, na figura anterior é apresentado numa escala logarítmica, devido à alta volatilidade de seus registros. Os valores deste perfil estão concentrados entre zero e cem, mas aproximadamente 0.4% superam os 500 ohms e alguns inclusive superam um milhão de ohms. Estes valores extremos são característicos de minerais com altas resistividades, mas podem causar dificuldades para os algoritmos de estimativa, por conseguinte, neste trabalho é utilizado o logaritmo da ILD. Assim, o intervalo de variação é $\log(ILD) \in] 0,6]$, considerando as resistividades presentes no reservatório.

Em seguida, foram separados os poços em dois grupos, o primeiro, corresponde ao conjunto de treino e validação, que é utilizado para a construção da relação aproximada por PG. O segundo grupo é o conjunto de teste, que serve para avaliar esta aproximação. O número inicial de poços com o perfil sônico era de 17, destes somente 15 tinham também os outros quatro tipos de perfis. Então, estes 15 poços com a série completa de perfis foi a base de dados inicial, 11 poços foram selecionados para treinamento e validação e quatro poços para teste. A distribuição espacial desta seleção é apresentada na Figura 7.4.

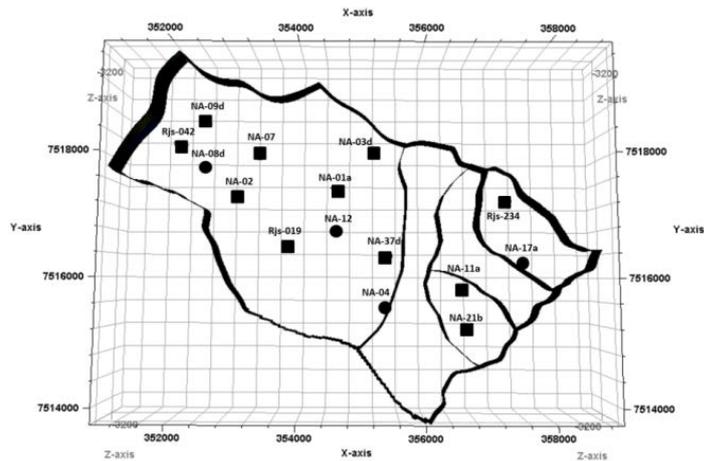


Figura 7.4: Distribuição espacial dos poços de treino e teste para a estimação do perfil de poço no campo de Namorado. Os quadros são poços de treino e os círculos poços de teste.

É possível observar que os poços de treinamento e validação estão distribuídos em todo o reservatório. Adicionalmente, destes 11 poços 80% dos dados será o conjunto de treinamento e 20% o conjunto de validação, selecionados aleatoriamente.

Por outro lado, para realizar a estimativa do perfil sônico é necessário selecionar o conjunto de variáveis de entrada para o algoritmo de PG. Este algoritmo permite estimar a relação que existe entre as variáveis de entrada selecionadas e o perfil objetivo. Para a seleção do conjunto de entradas foi realizada uma análise de correlação, entre os perfis disponíveis e o perfil sônico. A análise utilizou os perfis de todos os 15 poços antes mencionados. Estes resultados podem ser apreciados na Tabela 7.3.

Tabela 7.3: Resultado da análise de correlação entre os perfis de poço GR, NPHI, RHOB e o logaritmo do perfil ILD, com o perfil sônico.

Análise de Correlação				
	GR	NPHI	RHOB	Log(ILD)
DT	57.6%	80.7%	73.8%	0.9%

O perfil de poço de resistividade apresenta uma correlação extremamente baixa, portanto não será utilizado este perfil para a estimativa do perfil sônico. As variáveis RHOB, NPHI e GR apresentam uma correlação alta e poderiam ser escolhidas como variáveis de entrada, porém o perfil NPHI não será selecionado. Isto devido a que o perfil sônico será utilizado indiretamente em testes posteriores para a estimação da porosidade neutrônica como uma propriedade 3D, se o perfil

NPHI fosse utilizado, passaria características próprias para o perfil sônico estimado, facilitando indevidamente posteriores testes. Conseqüentemente o conjunto de variáveis de entrada estará conformado pelos perfis GR e RHOB.

Uma vez selecionadas as variáveis de entrada do algoritmo de programação genética, é possível realizar experimentos numéricos objetivando a escolha ótima dos parâmetros próprios deste algoritmo de regressão simbólica. Isto foi realizado por meio de uma inspeção sequencial de cada parâmetro, otimizando-os um a um. Na Tabela 7.4, são apresentados cada um dos parâmetros pertinentes para PG.

Tabela 7.4: Parâmetros de PG selecionados para a estimação do perfil de poço sônico.

Parâmetros	Valores
Tamanho da População	200
Número de Gerações	100
Tamanho do Torneio	4
Profundidade Máxima de árvore	7
Número Máximo de Genes	6
Taxa de <i>Crossover</i>	0.65
Taxa de Mutação	0.3
Taxa de elitismo	0.05
Intervalo de Variação dos nodos constantes	[-10,10]

Os parâmetros da tabela anterior são os correspondentes à solução que consegue um menor erro, entre o perfil sônico real e o estimado por PG, no conjunto de teste.

Similarmente, foram selecionados os operadores básicos (funções aritméticas) que formarão a função de PG. Os operadores selecionados que ajudam na estimativa da relação entre os perfis são: soma, subtração, produto, potência quadrada, seno, cosseno, função máximo e função mínimo.

O resultado de PG é uma função explícita composta por estas oito funções básicas, que permitirá utilizar a relação estimada e inclusive incorporar esta em outros softwares. Para validar os resultados obtidos com PG, será utilizado o método de redes neurais MLP com retropropagação reversa como algoritmo de aprendizado. Esta ferramenta está integrada no software de interpretação sísmica Petrel. A rede utiliza as mesmas variáveis de entrada e a mesma distribuição nos grupos de treinamento, validação e teste. Os resultados de este experimento podem ser apreciados na Tabela 7.5, foi selecionado o erro MAPE para

quantificar o ajuste das aproximações, devido à representatividade deste erro para a estimativa do perfil sônico.

Tabela 7.5: Resultados na estimativa do perfil de poço sônico.

Resultados		
Poço	PG	RN
Na04	4.68%	5.48%
Na08d	5.30%	5.46%
Na12	5.28%	5.50%
Na17a	6.51%	6.82%
Média	5.44%	5.82%

Pode-se ver que ambos os métodos conseguem aproximar com um erro baixo o perfil de poço sônico. Os erros são apresentados individualmente para cada um dos poços no conjunto de teste. Isto para poder determinar se algum dos poços exibe um comportamento anormal. O algoritmo de PG tem erros ligeiramente menores que redes neurais em cada um dos poços. Na Figura 7.5 é possível observar o nível de ajuste dos resultados tanto para PG quanto para RN.

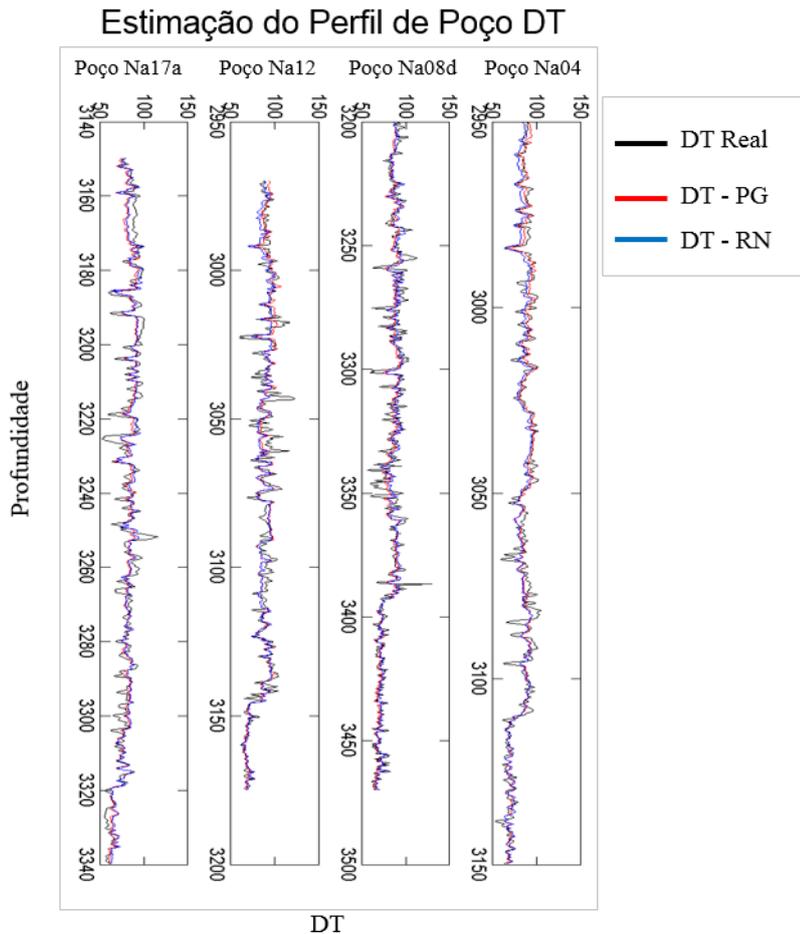


Figura 7.5: Estimativa do perfil de poço sônico nos poços de teste. Comparação entre a estimativa por programação genética e por RN.

O método de PG consegue um ajuste preciso na extensão total de todos os poços, a exceção de uma quantidade mínima de pontos extremos ou picos. Visualmente é possível determinar leves diferenças entre a estimativa de PG e RN. Adicionalmente, o algoritmo de PG permite observar e manipular a expressão final, que aproxima o perfil de poço sônico, o que representa uma importante vantagem sobre RN.

A expressão conseguida com PG permite a aproximação dos perfis de poços sônicos faltantes em todos aqueles poços do reservatório que possuam os perfis de poço GR e RHOB. Assim, o perfil sônico foi calculado em 38 poços adicionais. Estes perfis sônicos completos (os reais e estimados) junto com o perfil de densidade, foram utilizados para o cálculo direto da impedância acústica nos poços, como foi descrito na eq. (2.2). O cálculo desta propriedade é fundamental para a estimativa de propriedades geológicas em todo o reservatório.

7.4. Estimativa de Parâmetros de Reservatório

Na seção anterior foram estimados perfis de poço sônico, que junto com os perfis de poço de densidade permitiram o cálculo da impedância acústica nos poços. O procedimento mostrado na seção 6.4 será aplicado aos perfis de impedância acústica nos poços e aos dados sísmicos.

Na primeira subseção será utilizada a técnica de inversão genética para a estimativa da impedância acústica como uma propriedade 3D. Posteriormente, na segunda subseção será utilizado o algoritmo de PG para realizar uma estimativa da porosidade neutrônica, a partir da impedância acústica invertida e de atributos sísmicos.

A estimativa da porosidade neutrônica por meio de PG será realizada de duas diferentes maneiras. No primeiro teste será aplicado PG ao reservatório completo, construindo uma expressão global que aproxima a porosidade neutrônica, a partir das variáveis de entrada antes mencionadas. No segundo teste, será realizada uma clusterização do reservatório de acordo a suas propriedades geofísicas, com o propósito de obter expressões específicas para cada *cluster*. Isto permite uma melhor representação para a porosidade de acordo à zona geológica.

7.4.1. Inversão Genética

Para realizar a inversão sísmica foram utilizados os dados sísmicos originais, sem nenhum tipo de filtragem ou pré-processamento, e os perfis de poço de impedância acústica, suavizados por meio do algoritmo de média móvel, comentado na seção 3.3. Este processo facilita o aprendizado por parte do algoritmo de inversão genética e elimina mudanças drásticas nos perfis de treinamento, como se pode ver na Figura 7.6.

Impedância Acústica Suavizada

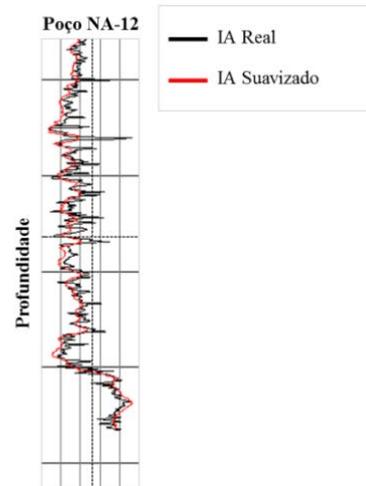


Figura 7.6: Efeito da suavização nos perfis de poço de impedância acústica.

Na figura anterior pode-se notar que o perfil de poço suavizado mantém o comportamento do perfil original.

De todos os perfis de poço de IA os mais confiáveis são os calculados utilizando o perfil sônico real, por esta razão serão considerados especialmente para a seleção dos conjuntos de treinamento, validação e teste na inversão genética. De modo que, a metade dos poços com perfis sônicos reais estarão no conjunto de treinamento e validação, e a outra metade, no conjunto de teste. Os poços selecionados para cada um destes conjuntos podem ser apreciados na Figura 7.7.

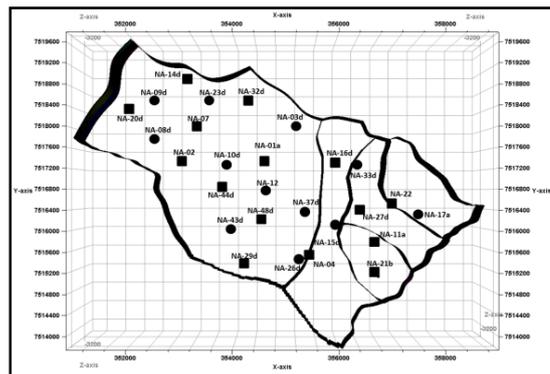


Figura 7.7: Distribuição espacial dos poços de treino e teste para a inversão sísmica no campo de Namorado. Os quadrados são poços de treino e os círculos poços de teste.

Na figura anterior pode-se observar a distribuição dos poços de treino, validação e teste que serão utilizados, os poços de treino são representados por quadrados e os poços de teste por círculos. No total o conjunto de treino é

composto por 15 poços e o conjunto de teste por 12, distribuídos em todo o reservatório.

Por outro lado, a seleção dos parâmetros do método de inversão genética foi realizada sequencialmente, realizando múltiplos experimentos para cada escolha dos valores. Os parâmetros foram atualizados um por um, deixando os demais elementos fixos. O conjunto de parâmetros ótimos utilizados está listado na Tabela 7.6. Além destes parâmetros, que estão relacionados à rede neural utilizada, o método seleciona uma sub-região sísmica para cada ponto de interesse, as dimensões desta sub-região também deverão ser selecionadas de acordo às características dos dados sísmicos. Uma escolha certa beneficiará a convergência do método a uma solução ótima.

Tabela 7.6: Parâmetros selecionados para a inversão genética.

Parâmetros da Inversão Sísmica	
Intervalo Vertical	50m
Intervalo em inline	3m
Intervalo em crossline	3m
Interações	2000
Limite de ajuste	0.95
Nodos em camada escondida	5
Taxa de aprendizado	0.1

Na tabela anterior os primeiros três parâmetros determinam o tamanho da sub-região sísmica, neste caso terá 50m de altura, 3m de largura e de comprimento. Os últimos quatro parâmetros afetam a rede neural, conforme foram estudados na seção 4.3. Com estes parâmetros foi invertida a impedância acústica, utilizando para isso a ferramenta fornecida no software Petrel. O modelo da inversão genética construído foi aplicado aos poços de teste para avaliar seu ajuste. O resultado para cada um dos poços de teste pode ser apreciado na Tabela 7.7. Foi selecionado para a avaliação do ajuste dos resultados o erro MAPE e o coeficiente de correlação.

Tabela 7.7: Resultado da inversão genética para cada um dos poços de teste.

Resultado da Inversão		
Poço	MAPE	Coef. de Correlação
Na03d	6.75%	68.41%
Na08d	8.33%	78.62%
Na09d	8.95%	57.74%
Na10d	11.14%	77.92%
Na12	11.41%	77.64%
Na15d	11.38%	74.83%
Na17a	11.07%	56.23%
Na23d	7.44%	81.97%
Na26d	8.88%	71.32%
Na33d	12.11%	65.08%
Na37d	8.91%	80.22%
Na43d	8.31%	50.23%
Média	9.56%	70.02%

Os resultados apresentados na tabela anterior demonstram um ajuste aceitável nos poços de teste, com aproximadamente um 10% de erro MAPE e um 70% de correlação média. Deve ser considerado que a estimativa é realizada utilizando como base os dados sísmicos e, portanto os resultados apresentam uma frequência significativamente menor à propriedade de rocha IA. Adicionalmente, os dados sísmicos calibrados com a informação dos perfis de poço permite a obtenção de uma propriedade de reservatório densa dentro do campo, em particular pode ser extraída nos poços de teste. Na Figura 7.8 são apresentados alguns perfis de poço do conjunto de teste para poder medir visualmente o ajuste obtido pela inversão sísmica.

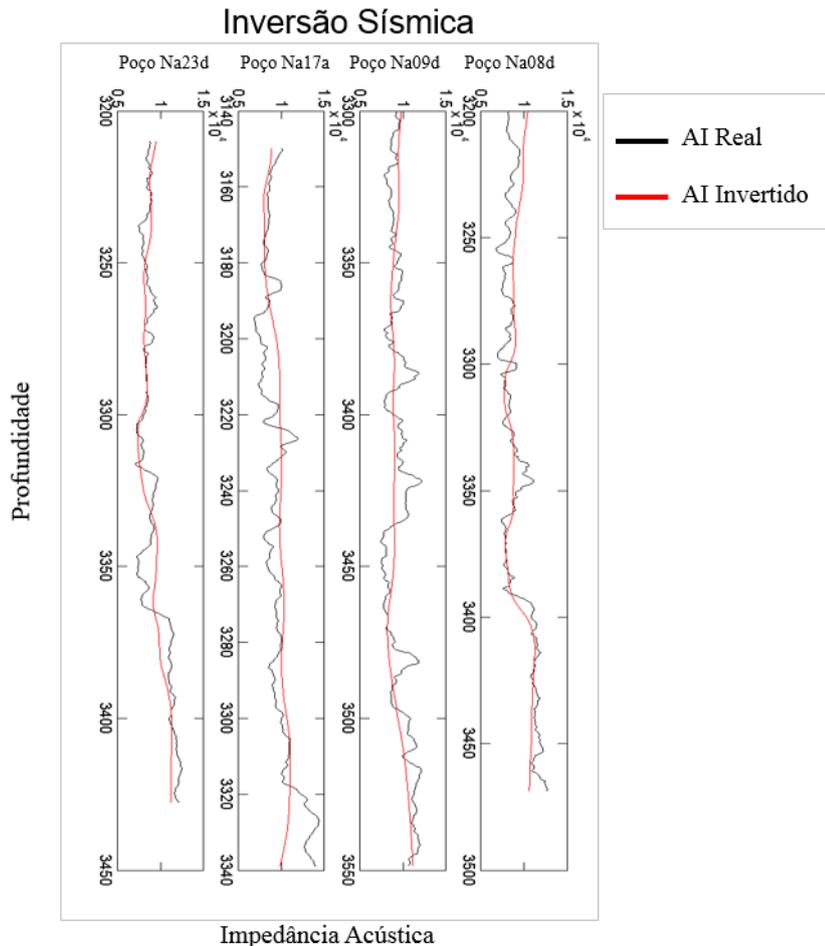


Figura 7.8: Resultados da inversão genética em poços de teste.

Pode-se ver na figura anterior a estimativa resultante da inversão genética em quatro poços do conjunto de teste, com diversos resultados. O poço Na23d, o último na figura, apresenta um erro MAPE baixo e um alto coeficiente de correlação, o que representa um comportamento similar ao perfil real. Os poços Na08d e Na09d, correspondente aos primeiros dois gráficos, tem um erro MAPE médio, os coeficientes de correlação são, alto e baixo respectivamente. Por último o poço Na17a apresenta um erro MAPE alto e um coeficiente de correlação baixo. Porém em cada um dos resultados, é evidenciado que as estimações seguem o comportamento do perfil real.

7.4.2. Estimativa da Porosidade Neutrônica por meio de PG

Nesta subseção será estimada a porosidade neutrônica em todo o reservatório, utilizando o algoritmo de PG. A impedância acústica, estimada anteriormente com inversão genética, será utilizada como uma variável de entrada

em PG. Por meio de este algoritmo será extraída informação da impedância acústica invertida e de um conjunto previamente selecionado de atributos sísmicos, para estimar finalmente a porosidade neutrônica.

Para os testes desta subseção foram utilizados os mesmos conjuntos de treino, validação e teste que na inversão sísmica. Inicialmente, foram calculados 33 atributos sísmicos, utilizando o software de interpretação sísmica, Petrel. Por meio de uma análise de correlação se determinaram quais atributos fornecem mais informação para a estimativa da porosidade neutrônica. Neste processo foi calculado o coeficiente de correlação de cada atributo sísmico com a saída desejada. O coeficiente calculado permitiu realizar uma escolha prévia de 14 atributos, como se pode observar na Figura 7.9. Este conjunto preliminar foi analisado novamente para eliminar aqueles atributos sísmicos com uma alta correlação entre si, de forma que a informação redundante seja minimizada.

Número	Variável	NPHI
1	Structural Smoothing	0.3288
2	Median Filter	0.3036
3	Time Gain	0.2993
4	Trace AGC	0.2972
5	Remove Bias	0.2955
6	Original Amplitude	0.2951
7	Phase Shift	0.2951
8	Cosine of Phase	0.2863
9	tAttenuation	0.182
10	Quadrature Amplitude	0.1536
11	Apparent Polarity	0.1473
12	Relative Acoustic Impedance	0.1352
13	Isofrequency Component	0.1293
14	Instantaneous Phase	0.1127
15	First Derivative	0.0974
16	Reflection Intensity	0.094
17	Local Structural Dip	0.0934
18	Instantaneous Frequency	0.081
19	Instantaneous Quality	0.081
20	RMS Amplitude	0.0739
21	Envelope	0.0697
22	Sweetness	0.0693
23	Dominant Frequency	0.0656
24	Local Flatness	0.0485
25	Variance	0.046
26	Second Derivative	0.0353
27	Local Structural Azimuth	0.0309
28	Gradient Magnitude	0.0279
29	Dip Deviation	0.0231
30	Trace Gradient	0.0194
31	Instantaneous Bandwidth	0.0162
32	Dip Illumination	0.0136
33	Chaos	0.0096

Variável
Structural_Smoothing
tAttenuation
Apparent_Polarity
Relative_Acoustic_Impedance
Isofrequency_Component

Maiores incidências na saída

Sem informação redundante

Figura 7.9: Seleção de atributos sísmicos por meio de uma análise de correlação.

Na figura anterior são apresentados os 33 atributos sísmicos calculados para este problema, na terceira coluna da tabela da esquerda, são mostrados os

coeficientes de correlação entre o atributo e a variável de saída. Os atributos estão ordenados de acordo ao coeficiente de correlação, em ordem decrescente. O conjunto final de cinco atributos sísmicos pode se observar na tabela da direita. Desta forma, as variáveis de entrada para PG são: os cinco atributos sísmicos, a impedância acústica invertida e as variáveis de localização, dadas pelas coordenadas X, Y e Z. Estas três variáveis foram normalizadas como se mostra na

Tabela 7.8.

Tabela 7.8: Normalização realizada às variáveis de localização.

Variável	Antes de Normalizar			Variáveis Normalizadas		
	Mínimo	Máximo	Diferença	Mínimo Normalizado	Máximo Normalizado	Diferença
X	350891	358991	8100	0	7	7
Y	7513745	7519785	6040	0	3	3
Z	2907	3369	462	0	4	4

A normalização correspondente a cada uma das variáveis foi selecionada de acordo às características do campo de Namorado, com 7km de comprimento na coordenada X, 3km na coordenada Y e aproximadamente 400m na coordenada Z.

Estimar uma propriedade geológica utilizando variáveis derivadas da sísmica requer de um tratamento prévio que permita integrar os dados na escala da sísmica, com aqueles na escala dos perfis de poço. Para isso foi utilizado o algoritmo da média móvel, algoritmo estudado na seção 3.4, onde são tratados os problemas de escala. O objetivo aqui foi utilizar o método mencionado, para comprimir a informação do poço à escala da sísmica, que apresenta uma frequência significativamente menor. Depois de realizar este algoritmo de *upscale*, foram selecionadas as amostras espaçadas regularmente na escala da sísmica. O procedimento descrito anteriormente é exemplificado na Figura 7.10. É importante destacar que concentrar a informação do perfil do poço, também ajudará a eliminar picos presentes nos registros da porosidade neutrônica.

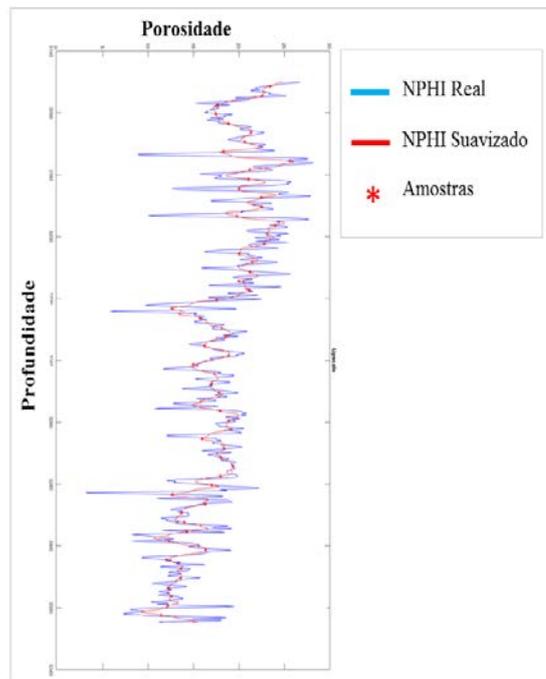


Figura 7.10: Upscale da porosidade neutônica por meio da média móvel.

Pode-se observar na figura anterior o efeito do algoritmo de *upscale*: média móvel, sobre o perfil da porosidade neutônica. Os pontos vermelhos representam as amostras que foram utilizadas para a estimativa. A distância entre quaisquer pontos sucessivos é exatamente a escala da sísmica. Além disso, para cada um destes pontos existe um valor correspondente da sísmica, resolvendo assim o problema da diferença de escalas.

Finalmente, uma vez realizado o tratamento dos dados utilizados para a estimativa da porosidade neutônica é possível aplicar o algoritmo de PG. Para isto foi construída uma matriz composta pelos valores de cada uma das variáveis nos poços de treinamento, com o correspondente valor da saída (porosidade neutônica). O número de dados foi reduzido devido ao escalamento realizado para a integração dos dados. O algoritmo de programação genética foi utilizado para representar a relação entre as variáveis de entrada e a resposta desejada.

- **PG aplicado no Reservatório Completo**

Neste teste foi aplicado PG no reservatório completo, isto é, a construção de uma expressão global que represente a porosidade neutônica do campo completo, a partir das variáveis de entrada.

Os operadores selecionados para a construção das soluções candidatas foram: soma, subtração, produto, potência quadrada, função mínimo, função máximo, seno e cosseno. O operador de mutação utilizado foi aquele descrito na seção 4.2.2. Para o caso do *crossover*, foram utilizados os *crossovers* de alto e baixo nível (ver seção 4.2.2), numa porcentagem de 20% e 80% respectivamente. Os parâmetros para o algoritmo de PG foram selecionados sequencialmente, otimizando um a um cada valor. A Tabela 7.9 lista os parâmetros selecionados para PG.

Tabela 7.9: Parâmetros de PG selecionados para a estimação da porosidade.

Parâmetros de PG	Valores
Tamanho da População	200
Número de Gerações	100
Tamanho do Torneio	4
Profundidade Máxima de árvore	7
Número Máximo de Genes	10
Taxa de <i>Crossover</i>	0.65
Taxa de Mutação	0.3
Taxa de elitismo	0.05
Intervalo de Variação dos nodos constantes	[-10,10]

Uma vez escolhidos os parâmetros para o algoritmo PG, cada algoritmo foi rodado trinta vezes, para garantir que os resultados são consistentes, os erros em cada rodada ficam dentro de um intervalo pequeno e a convergência é mantida. Os resultados foram avaliados utilizando os erros: MAPE e erro médio, medido em unidades de porosidade; e comparados com uma rede neural MLP que utiliza retropropagação reversa como algoritmo de aprendizado, a qual pertence ao software de interpretação sísmica Petrel. Esta rede utiliza as mesmas variáveis de entrada e a mesma distribuição de grupos de treinamento, validação e teste. Os resultados deste experimento podem ser apreciados na Tabela 7.10.

Tabela 7.10: Resultados na estimação da porosidade neutrônica utilizando PG e RN. Erro médio medido em unidades de porosidade.

Poços Teste	Programação Genética		Redes Neurais	
	MAPE	Erro Médio	MAPE	Erro Médio
Na03d	14.5%	2.28	13.3%	2.35
Na08d	12.5%	2.48	25.9%	4.05
Na09d	20.9%	3.71	17.9%	2.85
Na10d	13.9%	2.29	14.3%	2.17
Na12	16.0%	3.65	14.4%	3.48
Na15d	14.5%	2.92	15.5%	3.06
Na17a	21.9%	3.71	26.0%	4.81
Na23d	15.5%	3.13	16.7%	3.31
Na26d	12.5%	2.13	16.1%	2.74
Na33d	17.7%	3.17	23.5%	4.50
Na37d	11.3%	2.35	17.8%	4.15
Na43d	15%	2.16	23%	4.02
Média	15.5%	2.83	18.7%	3.46

Na tabela anterior são apresentados os melhores resultados obtidos por PG e de RN para todos os poços de teste, evidenciando o desempenho da estimativa do algoritmo de programação genética. Ambos os métodos apresentam erros médios considerados aceitáveis na estimativa da porosidade neutrônica, como uma propriedade completa do reservatório. Na Figura 7.11 são apresentados gráficos dos quatro poços de teste marcados na tabela anterior. Estas imagens mostram o ajuste das estimativas, para os métodos antes mencionados, permitindo determinar visualmente a proximidade das soluções com a saída real.

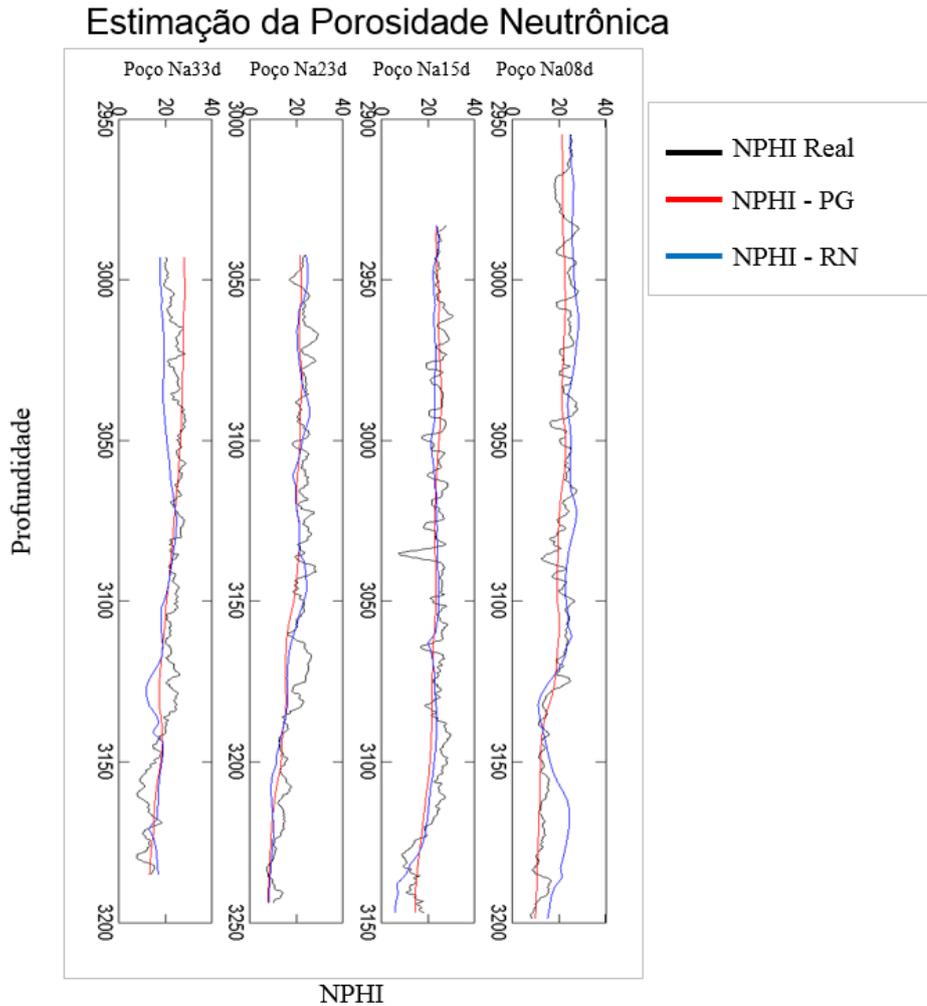


Figura 7.11: Resultados da estimação por meio de PG e RN da porosidade neutrônica, avaliados em poços de teste.

Observe-se a representatividade do erro médio na resposta. O poço Na08d apresenta um erro baixo de acordo à Tabela 7.10, o qual é consistente ao visualizar o ajuste da solução por parte de PG com o comportamento da porosidade. O segundo poço, Na15d tem um erro médio um pouco maior, devido a algumas mudanças drásticas que não foram representadas pela estimativa. Os últimos dois poços (Na23d e Na33d) apresentam erros médios superiores a três unidades de porosidade, porém a estimativa consegue determinar o comportamento da propriedade.

Utilizando a expressão explícita estimada pelo algoritmo de programação genética e por meio da calculadora de Petrel, mencionada na seção 6.2, foi possível calcular a porosidade neutrônica como um cubo denso de pseudo-poços. Desta forma, para cada posição do reservatório é possível obter um valor da porosidade. O resultado deste processo é apresentado na Figura 7.12.

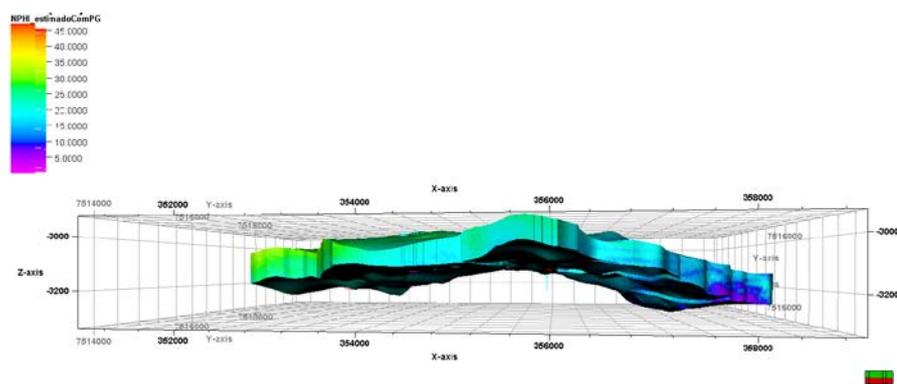


Figura 7.12: Estimação da porosidade neutrônica em todo o reservatório.

A metodologia aplicada neste teste mostrou ter um alto desempenho, em termos dos erros MAPE e Erro Médio. No entanto, estes valores podem melhorar se o reservatório é separado em zonas de acordo às características geológicas. Estas zonas não precisam ser contínuas dentro do reservatório, como as comumente utilizadas camadas estratigráficas, mas devem representar um comportamento geológico similar. Com esta motivação, no seguinte teste é realizada uma clusterização geológica do campo de petróleo de Namorado.

- **PG aplicado em Electrofácies do Reservatório**

A heterogeneidade presente no reservatório de petróleo dificulta a estimativa completa das propriedades geológicas, em particular da porosidade. Uma adequada separação do reservatório, em seções com características similares, diminui a variabilidade das propriedades geológicas dentro de cada grupo. Desta forma, a estimativa por meio do algoritmo de PG em cada grupo é facilitada.

Nesta dissertação foi utilizada uma separação em grupos por meio da identificação de electrofácies (ver seção 4.3.3). Este processo foi realizado, por meio de uma rede neural não supervisionada, utilizando a informação dos perfis de poço. Foram construídos conjuntos que apresentaram medições geofísicas similares, sem se importar sua posição relativa dentro do reservatório.

Inicialmente, foi preciso determinar o número de *clusters* que deviam ser construídos. Esta escolha pode ser determinada de acordo com critérios empíricos, necessidades específicas a cada problema ou de acordo à distribuição dos dados. Neste trabalho, este número foi determinado estudando os dados, seguindo a metodologia estudada na seção 4.3.3, onde é calculado para cada número de *clusters* o índice de Davies-Bouldin, que mede a similaridade entre os distintos

clusters. Desta forma, quanto menor for este índice, menos relacionados estão os grupos e, portanto, melhor será a separação. Os resultados obtidos para o número de *clusters* variando entre dois e oito são apresentados na Figura 7.13.

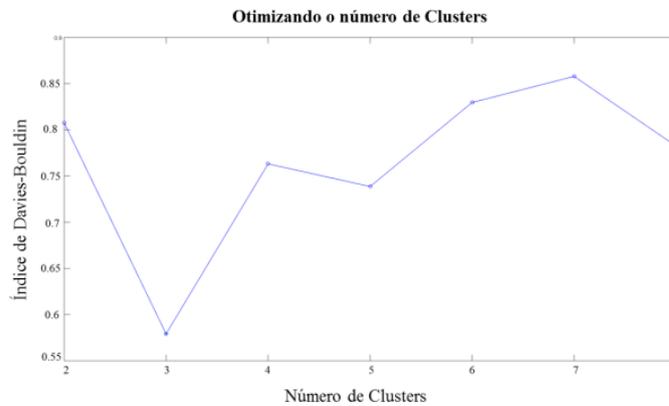


Figura 7.13: Valores de índice de Davies-Bouldin para diferentes números de *clusters*.

Na figura anterior é evidenciado que o número de *clusters* com o menor índice de Davies-Bouldin é o número três, isto é, o agrupamento em três *clusters* apresenta a menor similitude entre os conjuntos.

Uma vez determinado este número, são construídos os *clusters* em cada um dos quinze poços de treinamento por meio de uma rede neural não supervisionada, que utiliza como variáveis de entrada os seguintes perfis de poço: GR, ILD, NPHI, RHOB e DT. Para o caso do perfil sônico, foi utilizado o perfil estimado na seção 7.3, caso o real não estiver disponível. Os *clusters* são representados graficamente na Figura 7.14 à esquerda, em três dos poços de treinamento.

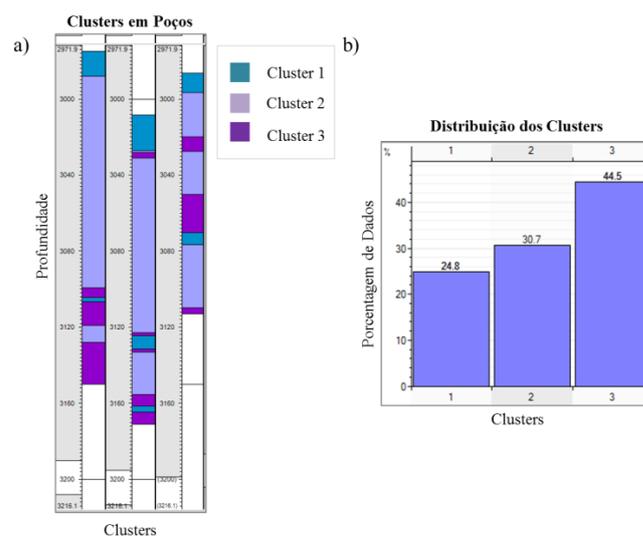


Figura 7.14: a) *Clusters* em poços de teste. b) Distribuição dos *clusters* nos poços de teste.

Pode-se observar na parte b) da figura anterior a distribuição dos dados para cada *cluster*, calculada para o total dos poços de treinamento. Para poder determinar os correspondentes grupos nos poços de teste foi utilizado o método geostatístico de Simulação Indicadora Sequencial (SIS), técnica especializada na interpolação de variáveis discretas, estudada na seção 5.3. Este método permite, utilizando estimativas sequenciais, interpolar uma variável presente em um conjunto discreto de pontos, como os poços, a todo o reservatório. As estimativas dependem da função semivariograma, definida na subseção 5.3.1, que determina o intervalo e grau de influência dos pontos já definidos, na estimativa de novos valores. Para isto foram realizados ajustes, baseados nos dados, aos parâmetros desta função. Os parâmetros de melhor ajuste são apresentados na seguinte Tabela 7.11.

Tabela 7.11: Parâmetros de melhor ajuste da função semivariograma.

Parâmetros do Semivariograma	
Tipo	Esférico
Efeito Pepita	0.6
Altura	0.3
Azimuth	-57.7
Alcance na direção Maior	6130.6
Alcance na direção Menor	4641.2
Alcance Vertical	21.9

Utilizando o modelo de semivariograma anterior e curvas verticais proporcionais, definidas em 5.3.1, determinadas de acordo às variações verticais dos *clusters* em cada poço, foi realizada a interpolação. Desta forma os grupos foram representados em todo o reservatório, em particular foram determinados nos poços de teste. A representação gráfica do processo de interpolação é apresentada na Figura 7.15.

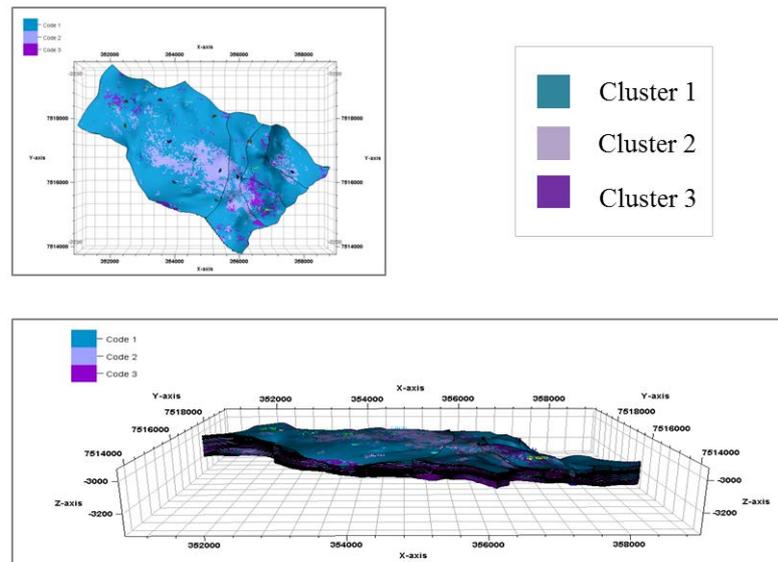


Figura 7.15: Clusters interpolados ao reservatório completo.

Uma vez que os *clusters* são definidos nos poços de teste, foram desenvolvidas expressões simbólicas, por meio de PG, para cada um deles. Cada uma destas representará a porosidade neutrônica a partir das variáveis de entrada. As variáveis de entrada e saída terão propriedades distintas dependendo do cluster, e cada função construída por PG, será um estimador especializado.

Os operadores selecionados para a construção das soluções candidatas foram: soma, subtração, produto, potência quadrada, função mínimo, função máximo, seno e cosseno. Os operadores de mutação e *crossover* foram os mesmos utilizados no teste anterior (ver seção 4.2.2). Os parâmetros para os algoritmos de PG foram selecionados sequencialmente, otimizando um a um cada valor. A Tabela 7.12 lista os parâmetros selecionados para cada PG nos diferentes *clusters*.

Tabela 7.12: Parâmetros selecionados para PG em cada *cluster*.

Parâmetros	Cluster 1	Cluster 2	Cluster 3
Tamanho da População	150	100	50
Número de Gerações	50	100	50
Tamanho do Torneio	6	4	10
Profundidade Máxima de árvore	7	11	11
Número Máximo de Genes	8	4	4
Taxa de <i>Crossover</i>	0.6	0.6	0.7
Taxa de Mutação	0.35	0.35	0.25
Taxa de elitismo	0.05	0.05	0.05
Intervalo de Variação dos nodos constantes	[-10,10]	[-10,10]	[-10,10]

Uma vez escolhidos os parâmetros adequados para o algoritmo de programação genética, cada algoritmo foi rodado trinta vezes, para garantir que os resultados são consistentes, os erros em cada rodada ficam dentro de um intervalo pequeno e a convergência é mantida. Cada PG representou uma expressão simbólica que determinou o valor da porosidade neutrônica em seu respectivo cluster. Para o cálculo do perfil completo foi construída uma função definida por partes, como foi mencionado na seção 6.4. Posteriormente foi realizada uma suavização para eliminar o efeito degrau, causado pelas mudanças ao passar de um cluster a outro. Os resultados foram avaliados utilizando os erros: MAPE e erro médio, medido em unidades de porosidade. Estes podem ser apreciados na Tabela 7.13, junto com os resultados de PG correspondentes ao teste anterior.

Tabela 7.13: Resultados de PG clusterizada, PG global e a porcentagem de melhoria.

Poços Teste	Programação Genética Clusterizada		Programação Genética Global		Porcentagem de Melhoria	
	MAPE	Erro Médio	MAPE	Erro Médio	MAPE	Erro Médio
Na03d	10.3%	1.80	14.50%	2.28	29.2%	20.9%
Na08d	10.4%	2.21	12.50%	2.48	17.0%	10.9%
Na09d	12.8%	2.04	20.90%	3.71	38.8%	45.0%
Na10d	11.5%	1.99	13.90%	2.29	16.9%	13.3%
Na12	16.3%	4.04	16.00%	3.65	-1.9%	-10.6%
Na15d	16.1%	3.87	14.50%	2.92	-10.7%	-32.5%
Na17a	24.2%	4.62	21.90%	3.71	-10.6%	-24.6%
Na23d	13.9%	3.00	15.50%	3.13	10.6%	4.1%
Na26d	7.2%	1.39	12.50%	2.13	42.6%	34.8%
Na33d	8.6%	1.97	17.70%	3.17	51.4%	37.8%
Na37d	11.5%	2.61	11.30%	2.35	-1.9%	-11.1%
Na43d	8.8%	1.71	15%	2.16	41.4%	20.8%
Média	12.6%	2.60	15.50%	2.83	18.5%	8.0%

Na tabela anterior são apresentados os erros da estimação da PG clusterizada e global nos poços de teste. Os valores das últimas duas colunas correspondem à porcentagem de melhoria obtida pelas expressões de PG clusterizada. Este método conseguiu uma melhoria média nas estimativas de 18.5% em termos do MAPE e de um 8% em termos do erro médio. Além disso, alguns dos poços de teste apresentam melhorias de até 51% do erro MAPE (NA33d) e 45% do erro médio (NA09d), demonstrando assim sua efetividade. Na Figura 7.16 são apresentados gráficos dos quatro poços de teste marcados na

tabela anterior. Estas imagens mostram o ajuste das estimativas, para os métodos antes mencionados, permitindo determinar visualmente a proximidade das soluções com a saída real.

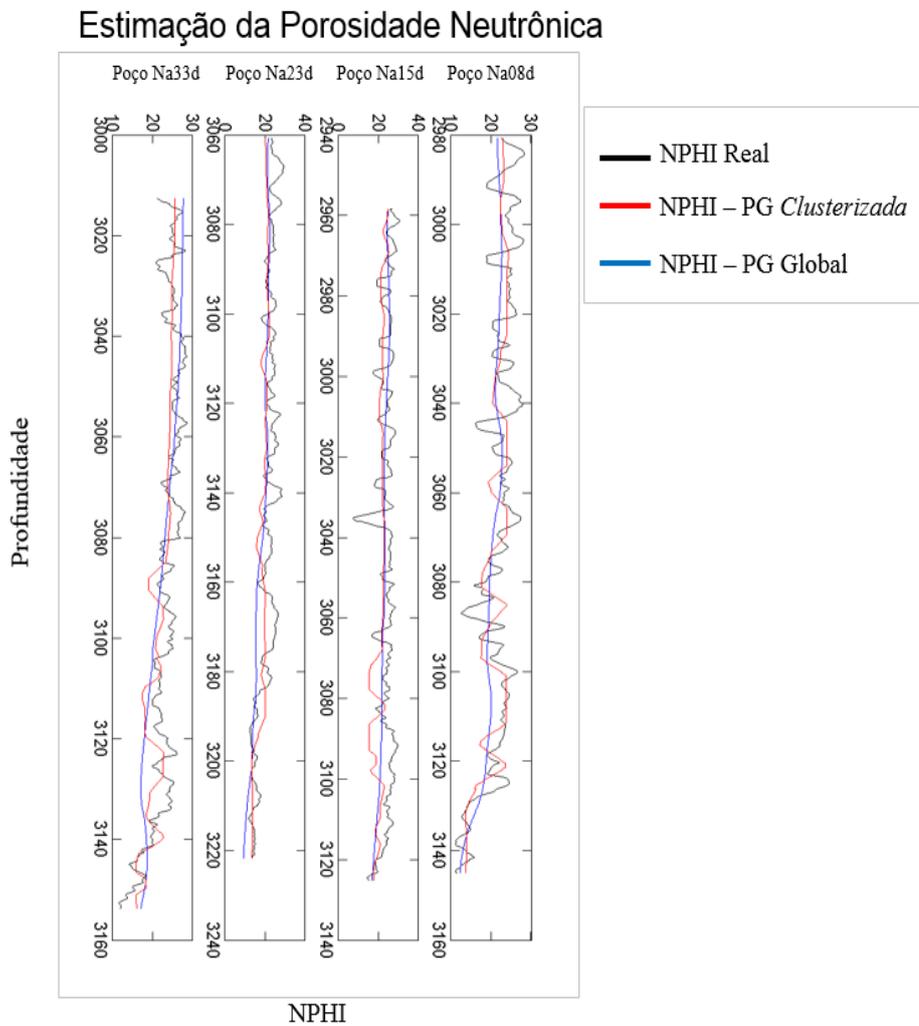


Figura 7.16: Resultados da estimação por meio de PG *clusterizada* e global da porosidade neutrônica, avaliadas em poços de teste.

O gráfico anterior apresenta o ajuste de PG *clusterizada*, é possível observar como a frequência do resultado é incrementada, mostrando assim variações mais pronunciadas. Além disso, o comportamento da porosidade neutrônica é melhor ajustado pela metodologia utilizando clusters do que pela estimativa globalizada. Isto se deve ao fato de que as funções têm informação particular de cada zona, o que permite uma estimativa diferenciada.

- **Análise de Sensibilidade**

A acurácia do método de PG, empregado nas estimativas da porosidade como uma propriedade densa, é determinada parcialmente pela quantidade de poços no conjunto de treinamento. Uma maior quantidade implica que mais informação será utilizada na construção da estimativa por PG, o que representa uma vantagem. Será realizada uma análise para determinar o quanto depende a metodologia proposta do número de poços que são utilizados para a construção da aproximação por PG. Com este propósito serão feitos dois experimentos com uma menor quantidade de poços no conjunto de treinamento. Cada experimento está composto por três testes, cada um com o mesmo número de poços no conjunto de treinamento, para determinar o efeito da diminuição dos poços no conjunto de treinamento, eliminando o efeito do azar na seleção dos conjuntos dos testes.

São selecionados aleatoriamente seis subconjuntos do conjunto de treinamento original. O primeiro experimento utilizará três conjuntos com 10 poços e o segundo experimento três conjuntos com 5 poços. Cada um dos seis conjuntos será o treinamento para a metodologia proposta na seção 6.4, o conjunto de teste estará formado por os mesmos 12 poços previamente utilizados.

Experimento 1

Os três testes neste experimento utilizam 10 poços no conjunto de treinamento, o que representa 66% da quantidade de poços utilizados no caso inicial o qual será referido como caso base. Cada subconjunto é selecionado aleatoriamente do total de poços do caso base. A distribuição espacial dos poços para cada teste é representada na Figura 7.17.

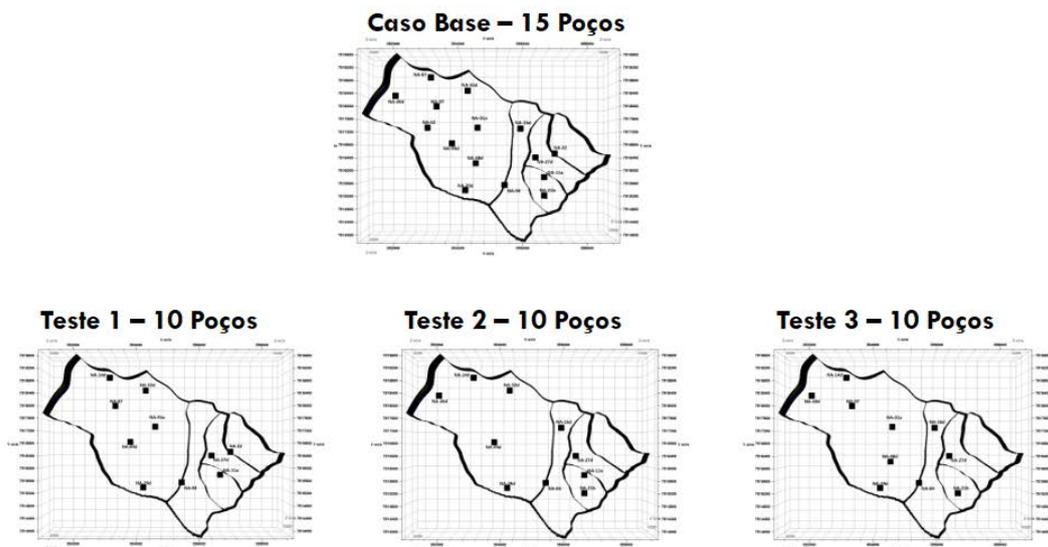


Figura 7.17: Distribuição espacial do conjunto de treinamento utilizado para os testes do experimento 1.

Cada teste foi realizado replicando a metodologia proposta na seção 6.4, a mesma utilizada para o caso base. Os parâmetros selecionados para os métodos de inversão sísmica e para a estimação por meio de PG foram os mesmos determinados para o caso base. Desta maneira a diferença nos resultados corresponderá exclusivamente ao conjunto de treinamento selecionado para cada teste. Na Tabela 7.14 são apresentados os resultados da estimação da porosidade como uma propriedade densa no reservatório.

Tabela 7.14: Resultados da estimação do NPHI para os testes do experimento 1.

Poços de Teste	Teste 1		Teste 2		Teste 3	
	MAPE	Erro Médio	MAPE	Erro Médio	MAPE	Erro Médio
Na03d	31.9%	5.38	13.7%	2.13	18.4%	2.85
Na08d	18.1%	3.67	16.6%	3.33	12.3%	2.30
Na09d	17.5%	2.82	15.9%	2.67	15.3%	2.53
Na10d	15.5%	2.47	16.4%	2.62	16.4%	2.35
Na12	15.8%	3.51	13.3%	2.42	17.9%	4.30
Na15d	15.7%	3.12	13.9%	2.71	15.1%	3.08
Na17a	31.4%	4.98	27.9%	4.89	28.1%	5.10
Na23d	15.9%	2.91	13.8%	2.61	13.0%	2.52
Na26d	10.7%	1.97	13.0%	2.20	10.0%	1.92
Na33d	12.5%	2.27	15.4%	2.76	18.3%	3.89
Na37d	12.7%	2.65	12.2%	2.69	10.5%	2.15
Na43d	15.8%	2.48	27.3%	4.37	15.5%	2.48
Média	17.8%	3.19	16.6%	2.95	15.9%	2.96

Os erros médios das estimações para os três testes são menores a 3.19 e o erro MAPE menor a 17.8%. Os resultados dos testes deste experimento serão comparados com o case base posteriormente.

Experimento 2

Para este experimento são utilizados 5 poços no conjunto de treinamento, o que representa 33% da quantidade de poços utilizados no caso base. Similarmente, cada subconjunto é selecionado aleatoriamente do total de poços do caso base. A distribuição espacial dos poços para cada teste é representada na Figura 7.17.

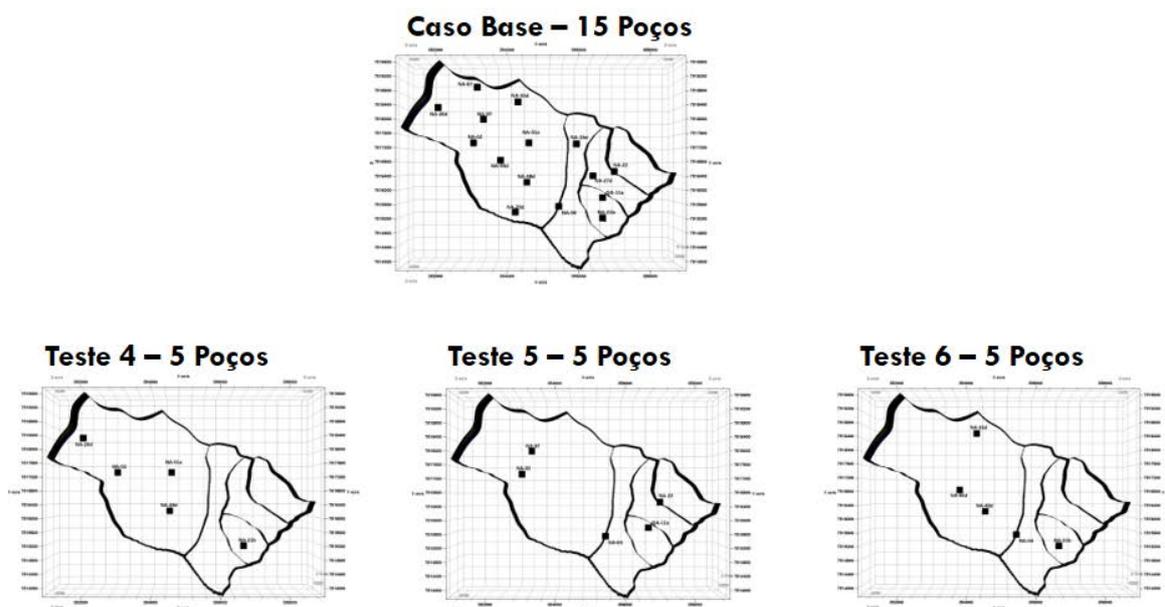


Figura 7.18: Distribuição espacial do conjunto de treinamento utilizado para os testes do experimento 2.

Estes três testes também foram realizados com a mesma metodologia e mesmos parâmetros que os testes do experimento anterior. Os resultados da estimação da porosidade como uma propriedade densa no reservatório para estes três testes são apresentados na Tabela 7.15.

Tabela 7.15: Resultados da estimação do NPHI para os testes do experimento 2.

Poços de Teste	Teste 4		Teste 5		Teste 6	
	MAPE	Erro Médio	MAPE	Erro Médio	MAPE	Erro Médio
Na03d	20.7%	3.73	18.8%	3.29	16.3%	2.62
Na08d	36.9%	5.61	24.7%	4.14	24.0%	4.93
Na09d	19.2%	3.46	19.5%	3.03	18.6%	3.42
Na10d	21.6%	3.16	23.0%	3.65	17.3%	3.12
Na12	15.0%	3.48	13.4%	3.09	23.3%	5.52
Na15d	20.0%	4.41	16.2%	3.09	24.0%	4.82
Na17a	25.7%	3.96	33.2%	4.79	38.3%	6.09
Na23d	58.0%	11.51	15.3%	2.67	27.3%	4.46
Na26d	20.3%	4.28	23.9%	4.31	11.2%	2.09
Na33d	19.0%	3.69	34.1%	5.89	18.3%	3.07
Na37d	23.3%	5.35	14.7%	3.28	15.4%	3.14
Na43d	25.5%	3.83	24.3%	4.00	13.2%	2.14
Média	25.4%	4.71	21.7%	3.77	20.6%	3.78

Os resultados do experimento 2 têm erros menores a 25% no erro MAPE e 4.71 no erro médio. Deve ser considerado que a quantidade de poços empregados para este experimento é significativamente inferior do que o caso base.

Com os resultados dos testes anteriores é determinada a sensibilidade da modelagem proposta ao número de poços no conjunto de treinamento. São comparadas na Tabela 7.16 as médias dos erros correspondentes aos experimentos 1 e 2, com os erros do caso base.

Tabela 7.16: Comparação dos erros dos experimentos 1 e 2 com o caso base.

Erros	Caso Base	10 Poços	5 Poços
MAPE	15.5%	16.8%	23%
Erro Médio	2.83	3.03	4.09

A tabela anterior permite observar um aumento nos erros conforme é diminuído o número de poços no conjunto de treinamento. Porém, o aumento nos erros cresce em distintas proporções, isto é evidenciado na Figura 7.19.

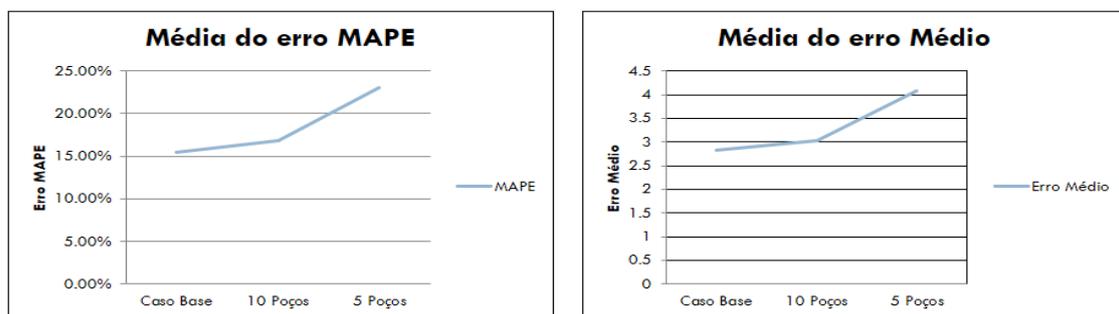


Figura 7.19: Comparação dos erros dos experimentos 1 e 2 com o caso base.

Pode-se determinar da figura anterior um aumento leve nos erros para o experimento 1 e um aumento significativamente maior para o experimento 2. Isto é, os resultados da metodologia proposta utilizando 10 poços não apresenta uma perda significativa na acurácia da estimativa. Por outro lado, os resultados são afetados consideravelmente ao utilizar 5 poços.

Nesta dissertação foi desenvolvida uma abordagem baseada nos dados, já que foram utilizados métodos de inteligência computacional capazes de aprender a partir dos dados coletados para inferir zonas ainda não investigadas. Deve ser destacada a utilização do método de programação genética e a integração dos resultados com um software de interpretação e análise sísmica, o que permite a

visualização conjunta dos dados sísmicos, geofísicos e dos resultados numa mesma plataforma.

8 Conclusões e Trabalhos Futuros

8.1. Conclusões

A caracterização de reservatórios representa um problema de especial interesse para a exploração e produção na indústria de petróleo e, portanto é preciso desenvolver metodologias que permitam a inferência de propriedades geológicas em um campo de petróleo, sobre tudo em regiões sem poços perfurados. Neste aspecto o estudo dos dados sísmicos e a extração de informação a partir deles se torna fundamental para a construção de modelos geológicos 3D. Nesta dissertação foi utilizado o algoritmo de programação genética multi-gene para estudar as relações existentes entre os dados sísmicos e as propriedades de reservatório, permitindo assim obter uma estimativa que integre os valores dos perfis de poço, com aqueles provenientes de levantamentos sísmicos migrados processados. Devido a esta integração, a ambiguidade da sísmica é reduzida e os valores mais precisos dos perfis de poços são espalhados ao reservatório completo.

O fluxo de trabalho abordado nesta pesquisa tem por objetivo a estimação da porosidade neutrônica como uma propriedade densa no reservatório. A abordagem utilizada foi separada em duas etapas principais: estimativas nos poços e no reservatório completo. Em ambos os casos, foram desenvolvidos casos de estudo baseados no campo Namorado.

A primeira parte da linha de trabalho concentrou-se na estimativa do perfil de poço sônico nos poços onde não houvesse sido registrado este perfil. O algoritmo de PG conseguiu representar por meio de uma expressão simbólica explícita a relação entre o perfil sônico e outros perfis de poço. Os resultados da aproximação foram comparados com redes neurais, para ter um ponto de validação. PG obteve resultados eficientes em termos do erro MAPE, inclusive superiores que os obtidos por RN. Os erros médios foram 5.44% e 5.82% para os dois métodos respectivamente. Demonstrando assim que PG é uma alternativa

viável para estimar perfis ausentes, devido a sua capacidade de representar relações não lineares.

Para o caso das estimativas no reservatório 3D, foi realizado um processo de inversão sísmica utilizando inversão genética, a partir de dados sísmicos originais e perfis de impedância acústica. O processo de inversão genética apresenta vantagens com respeito a outros processos de inversão sísmica, já que precisa de um número reduzido de variáveis de entrada, não requer de um especialista e o tempo de processamento é baixo. A eficiência deste método foi evidenciada na estimação, com um erro MAPE meio inferior a 10% e um coeficiente de correlação médio superior a 70%.

Por último, a estimativa da porosidade neutrônica foi realizada por meio de um conjunto previamente selecionado de atributos sísmicos e a impedância acústica invertida como a principal variável de entrada. Este processo foi abordado de duas maneiras diferentes, inicialmente foi aplicada PG ao reservatório completo, obtendo uma expressão global para estimar a porosidade. Os resultados de PG, neste caso foram satisfatórios em termos do erro MAPE e do erro médio, permitindo uma estimação completa da propriedade geológica. O método de PG atingiu um erro médio de 2.83 e um erro MAPE de 15.5%, enquanto que os mesmos erros para RN foram de 3.79 e 20.8%. A comparação com RN permitiu avaliar o desempenho de PG, demonstrando os benefícios que este algoritmo pode brindar à caracterização de reservatórios.

Em seguida, para obter expressões específicas seguindo as características geológicas do campo, foi realizado um agrupamento do reservatório, em três electrofácies. PG foi aplicado a cada *cluster* para construir três soluções explícitas diferentes, para aproximar a porosidade neutrônica, que dependem da zona geológica. Os resultados mostraram uma porcentagem de melhoria nos erros médios (18.5% MAPE e 8% Erro médio) evidenciando o alto desempenho deste método de regressão simbólica e o benefício alcançado ao *clusterizar* o campo de petróleo.

Com o propósito de determinar o efeito na solução da quantidade de poços utilizados no conjunto de treinamento, realizou-se uma análise de sensibilidade dividida em dois experimentos. O primeiro consta de três testes com 10 poços, o segundo de três testes de 5 poços. A mesma metodologia foi utilizada em cada teste e os resultados foram comparados. Estes apresentam um aumento leve nos

erros para o primeiro teste e um aumento maior para o segundo teste. Esta análise evidenciou a possibilidade de diminuir os dados de entrada sem afetar consideravelmente a estimativa da porosidade.

Finalmente, é importante destacar que PG fornece como solução uma expressão explícita, que pode ser diretamente utilizada em outros sistemas de análise sísmica ou como alternativa inicial de solução para depois refiná-la.

8.2. Trabalhos Futuros

A partir de este trabalho são destacadas as seguintes oportunidades de trabalhos futuros:

- Determinar outras propriedades geológicas 3D importantes na área de exploração e produção de petróleo, como a permeabilidade e a saturação de água, utilizando o algoritmo de PG.
- Estudar e implementar uma alternativa baseada em PG para realizar a inversão sísmica. Esta deve estar fortemente baseada na localização geográfica e utilizar sub-regiões sísmicas para minimizar o ruído e aproveitar a maior quantidade de informação.
- Desenvolver funções personalizadas que sirvam como operadores básicos para a construção da função explícita resultante do algoritmo de PG, que sejam capazes de aumentar a frequência da sísmica e melhorar as estimações. Isto devido a que a baixa frequência dos dados sísmicos limita a frequência da resposta de um modelo que utilize variáveis derivadas da sísmica como única entrada.

Referências Bibliográficas

AZEVEDO, L. e PEREIRA, G. R. 2009. *Seismic attributes in hydrocarbon reservoirs characterization*. Universidade de Aveiro : Master Dissertation, 2009.

BANCHS, R. E. e MICHELENA, R. J. 2002. *From 3D seismic attributes to pseudo-well-log volumes using neural networks: Practical considerations*. s.l. : The Leading Edge, 2002. pp. 996-1001. Vol. 21(10).

BARCLAY, F., et al. 2008. *Seismic inversion: Reading between the lines*. s.l. : Oilfield Review, 2008. pp. 42-63. Vol. 20(1).

BARNES, A. E. 2001. *Seismic attributes in your facies*. [ed.] CSEG Recorder. 2001. pp. 41-47. Vol. 26.7.

BISASO, I. 2011. *CALIBRATION OF SEISMIC AND WELL DATA: Towards Improved Quantitative Seismic Reservoir Characterisation of the*. s.l. : University of Bergen, Dissertação de Mestrado, 2011.

BISHOP, C. M. 1995. *Neural networks for pattern recognition*. s.l. : Oxford university press, 1995.

BIZZI, L. A., et al. 2003. *Geologia, Tectônica e Recursos Minerais do Brasil: texto, mapas & SIG*. Brasília : CPRM – Serviço Geológico do Brasil, 2003.

BROWN, A. 1996. *Seismic attributes and their classification*. s.l. : The leading edge, 1996. pp. 1090-1090. Vol. 15.10.

—. 2001. *Understanding seismic attributes*. s.l. : Geophysics, 2001. pp. 47-48. Vol. 66.1.

BURKE, E., et al. 2009. *Exploring hyper-heuristic methodologies with genetic programming*. s.l. : In Computational intelligence, Springer Berlin Heidelberg, 2009. pp. 177-201.

CALDERON, J. E. e CASTAGNA, J. 2007. *Porosity and lithologic estimation using rock physics and multi-attribute transforms in Balcon Field, Colombia*. s.l. : The leading edge, 2007. pp. 142-150. Vol. 26.2.

CHAGAS, E. S., RUSSO, S. L. e SIMON, V. H. 2010. Estimativa da perfilagem em poços de petróleo utilizando a estatística multivariada. s.l. : Simpósio Nacional de Probabilidade em estatística, São Paulo 19, 2010.

CHOPRA, S. e MARKFURT, K. J. 2005. Seismic attributes—A historical perspective. s.l. : Geophysics, 2005, Vol. 70.5, pp. 3SO-28SO.

- CHOPRA, S. e MARKFURT, K. 2006. *Seismic Attributes—a promising aid for geologic prediction*. s.l. : CSEG Recorder, 2006. pp. 110-120. Vol. 31.
- CRAIN, E. R. 2015. *Crain's Petrophysical Handbook*. *Crain's Petrophysical Handbook*. [Online] 05 de 2015. <https://www.spec2000.net/01-index.htm>.
- DA COSTA, F. T. 2013. *Modelagem Geoestatística do Campo de Namorado na*. [ed.] Dissertação de Mestrado. s.l. : Universidade Federal Fluminense, 2013.
- DAVIES, D. L. e BOULDIN, D. W. 1979. *A cluster separation measure*. s.l. : Pattern Analysis and Machine Intelligence, IEEE Transactions, 1979. pp. 224-227. Vol. 2.
- DEAN, O., REYNOLDS, A. C. e LIU, N. 2008. *Inverse theory for petroleum reservoir characterization and history matching*. s.l. : Cambridge University Press, 2008.
- DORRINGTON, K. P. e CURTIS, A. L. 2004. *Genetic-algorithm/neural-network approach to seismic attribute selection for well-log prediction*. s.l. : Geophysics, 2004. pp. 212-221. Vol. 69.1.
- DOYEN, P. M. 1988. *Porosity from seismic data: A geostatistical approach*. s.l. : Geophysics, 1988. pp. 1263-1275. Vol. 53(10).
- DOYEN, P. M., et al. 1997. *Reconciling data at seismic and well log scales in 3-D earth modelling*. s.l. : In SPE Annual Technical Conference and Exhibition. Society of Petroleum Engineers, 1997.
- DREYFUS, G. 2005. *Neural networks: methodology and applications*. s.l. : Springer Science & Business Media, 2005.
- EVANS, B, J e H., DRAGOSET W. 1997. *A handbook for seismic data acquisition in exploration*. s.l. : Society of exploration geophysicists, 1997.
- FALLAH-MEHDIPOUR, E., HADDAD, O. B. e MARIÑO, M. A. 2012. *Real-time operation of reservoir system by genetic programming*. s.l. : Water resources management, 2012. pp. 4091-4103. Vol. 26(14).
- HAMPSON, D. P, SCHUELKE, J. S. e QUIREIN, J. A. 2001. *Use of multiattribute transforms to predict log properties from seismic data*. s.l. : Geophysics SEG, 2001. pp. 220-236. Vol. 66.1.
- HAYKIN, S. 2009. *Neural networks and learning machines*. s.l. : Upper Saddle River: Pearson Education, 2009. Vol. 3.
- HORNE, B. G. 1993. *Progress in supervised neural networks*. [ed.] IEEE. 1993. pp. 8-39. Vol. 10(1).
- IKELLE, L.T. e AMUNDEN, L. 2005. *Introduction to petroleum seismology*. Tulsa : Society of Exploration Geophysicists, 2005.
- ISAAKS, E. H. e SRIVASTAVA, R. M. 1989. *An introduction to applied geostatistics*. 1989.

JAIN, A. K. 2010. *Data clustering: 50 years beyond K-means*. s.l. : Pattern recognition letters, 2010. pp. 651-666. Vol. 31(8).

JARVIS, K. 2006. *Integrating well and seismic data for reservoir characterization: Risks and rewards*. s.l. : ASEG Extended Abstracts, 2006. pp. 1-4. Vol. 2006(1).

KAYDANI, H., MOHEBBI, A. e EFTEKHARI, M. 2014. *Permeability estimation in heterogeneous oil reservoirs by multi-gene genetic programming algorithm*. s.l. : Journal of Petroleum Science and Engineering, 2014. pp. 201-206. Vol. 123.

KOZA, J. R. 1992. *Genetic programming: on the programming of computers by means of natural selection*. s.l. : MIT press, 1992. Vol. 1.

KUMAR, B. e KISHORE, M. 2006. *Electrofacies Classification—A Critical Approach*. Kolkata : In 6th International Conference & Exposition on Petroleum Geophysics, 2006. pp. 822-825.

KURODA, M. C., et al. 2012. *Electrofacies characterization using self-organizing maps*. s.l. : Revista Brasileira de Geofísica, 2012. Vol. 30(3).

LATIMER, R. B., DAVIDSON, R. e VAN RIEL, P. 2000. *An interpreter's guide to understanding and working with seismic-derived acoustic impedance data*. s.l. : The leading edge, 2000. pp. 242-256. Vol. 19(3).

LEIPHART, D. J., e H., BRUCE S. 2001. *Comparison of linear regression and a probabilistic neural network to predict porosity from 3-D seismic attributes in Lower Brushy Canyon channeled sandstones, southeast New Mexico*. s.l. : Geophysics SEG, 2001. Vol. 66.5.

LEITE, E. P. e VIDAL, A. C. 2011. *3D porosity prediction from seismic inversion and neural networks*. s.l. : Computers & Geosciences, 2011. pp. 1174-1180. Vol. 37(8).

LEITE, M., CARRASQUILLE, A. e SILVA, J. D. 2008. *Simulação do perfil sônico a partir dos perfis de raios gama e de resistividade em poços da Bacia de Campos*. s.l. : Revista Brasileira de Geofísica, 2008, Vol. 26(2), pp. 141-151.

MEILA, M. 2006. *The uniqueness of a good optimum for k-means*. s.l. : Proceedings of the 23rd international conference on Machine learning, ACM, 2006. pp. 625-632.

MENESES, S. X. e ADAMS, T. 1990. *Ocorrência de resistividades anômalas no Campo de Namorado, Bacia de Campos*. s.l. : Boletim de Geociências da PETROBRÁS, 1990. Vol. 4. 183-188.

MOHAGHEGH, S. e S. AMERI, S. 1995. *Artificial neural network as a valuable tool for petroleum engineers*. 1995.

MOHAGHEGH, S. 2005. *Recent developments in application of artificial intelligence in petroleum engineering*. 2005. pp. 86-91.

NEVES, F. A., MOHAMMAD S. Z. e B., STEPHEN W. 2004. *Detection of potential fractures and small faults using seismic attributes*. s.l. : The Leading Edge, 2004. pp. 903-906. Vol. 23.9.

OLDENBURG, D. W., SCHEUER, T. e LEVY, S. 1983. *Recovery of the acoustic impedance from reflection seismograms*. s.l. : Geophysics, 1983. pp. 1318-1337. Vol. 48(10).

PACHECO, M.A. e VELLASCO, M. M. 2009. *Intelligent systems in oil field development under uncertainty*. s.l. : Springer, 2009. Vol. 183.

PENDREL, J. 2006. *Seismic inversion—a critical tool in reservoir characterization*. s.l. : Scandinavian oil-gas magazine, 2006. pp. 19-22. Vol. 5(6).

POLI, R., et al. 2008. *A field guide to genetic programming*. s.l. : Lulu.com, 2008.

RANDEN, T. et al. 2000. *Three-dimensional texture attributes for seismic data analysis*. 70th Annual International Meeting. s.l. : Society of Exploration Geophysics Expanded Abstracts, 2000.

RAVENNE, C., et al. 2000. *Quantification of facies relationships via proportion curves*. [ed.] In Geostatistics Rio 2000. s.l. : Springer Netherlands, 2000. pp. 19-39.

RUSSELL, B. H. 1988. *Introduction to seismic inversion methods*. s.l. : Society of Exploration Geophysicists, 1988. Vol. 2.

SAGGAF, M. M. e NEBRIJA, L. 2003. *Estimation of missing logs by regularized neural networks*. s.l. : AAPG bulletin, 2003. pp. 1377-1389. Vol. 87(8).

SCHLUMBERGER. [Online]
<http://www.glossary.oilfield.slb.com/en/Terms.aspx?LookIn=term%20name&filter=NMO>.

—. 2007. *Interpreter's Guide to Seismic Attributes*. 2007, p. 115.

—. 2010. *Petrel Seismic-to-Simulation Software Manual*. s.l. : Schlumberger, 2010. p. 1279.

SCHULTZ, P. S., et al. 1994. *Seismic-guided estimation of log properties (Part 1: A data-driven interpretation methodology)*. s.l. : The Leading Edge, 1994. pp. 305-310. Vol. 13(5).

SEARSON, D., LEAHY, D. e WILLIS, M. 2010. *GPTIPS: an open source genetic programming toolbox for multigene symbolic regression*. s.l. : Proceedings of the International multiconference of engineers and computer scientists, 2010. pp. 77-80. Vol. 1.

SERRA, O. 1984. *Fundamentals of well-log interpretation*. Amsterdam : Elsevier, 1984. Vol. 1.

- SRIVASTAVA, R. M. 1992. *Reservoir characterization with probability field simulation*. s.l. : In SPE Annual Technical Conference and Exhibition. Society of Petroleum Engineers, 1992.
- TANER, M. T. 1997. *Seismic trace attributes and their projected use in prediction of rocks properties and seismic facies*. s.l. : Rock Solid Images, 1997.
- TANER, M. T., et al. 1994. *Seismic attributes revisited*. s.l. : SEG, 1994.
- TANG, H., TOOMEY, N. e MEDDAUGH, S. 2011. *Using an artificial-neural-network method to predict carbonate well log facies successfully*. 2011.
- THOMAS, J. E. 2001. *Fundamentos de engenharia de petróleo*. s.l. : Interciência, 2001.
- TIWARY, D. K., et al. 2009. *Comparison of seismic upscaling methods: From sonic to seismic*. s.l. : Geophysics, 2009. pp. WA3-WA14. Vol. 74(2).
- VEEKEN, P. C., et al. 2009. *Nonlinear multitrace genetic inversion applied on seismic data across the Shtokman field, offshore northern Russia*. s.l. : Geophysics, 2009. pp. WCD49-WCD59. Vol. 74(6).
- VIDAL, A. C., et al. 2007. *Modelagem geoestatística 3D da impedância acústica para a caracterização do Campo de Namorado*. s.l. : Revista brasileira de geofísica, 2007. pp. 295-305. Vol. 25(3).
- WATANABE, S., et al. 2013. *Streamline-Based Time Lapse Seismic Data Integration Incorporating Pressure and Saturation Effects*. s.l. : In SPE Annual Technical Conference and Exhibition. Society of Petroleum Engineers, 2013.
- WEST, B. P., et al. 2002. *Interactive seismic facies classification using textural attributes and neural networks*. s.l. : The Leading Edge, 2002. pp. 1042-1049. Vol. 21.10.
- YILMAZ, O. 2001. *Seismic Data Analysis: Processing, inversion, and interpretation of seismic data*. Tulsa : Society of Exploration Geophysicists, 2001, Vol. 2.
- YILMAZ, O. 2001. *Seismic Data Analysis: Processing, inversion, and interpretation of seismic data*. Tulsa : Society of Exploration Geophysicists, 2001. Vol. 1.
- YU, T., WILKINSON, D. e CASTELLINI, A. 2007. *Applying genetic programming to reservoir history matching problem*. [ed.] Springer US. s.l. : In Genetic Programming Theory and Practice IV, 2007. pp. 187-201.
- . 2008. *Constructing reservoir flow simulator proxies using genetic programming for history matching and production forecast uncertainty analysis*. s.l. : Journal of Artificial Evolution and Applications, 2008. Vol. 2.

Apêndice

Na seguinte tabela são apresentados os perfis de poço disponíveis para cada um dos poços do campo de Namorado.

POÇO	INTERVALO (m)	GR	ILD	DT	RHOB	NPHI
3NA 0001A RJS	2950,0 - 3200,0	x	x	x	x	x
3NA 0002 RJS	2975,0 - 3200,0	x	x	x	x	x
3NA 0003 RJS	3100,0 - 3210,0	x	x	x	x	
3NA 0003D RJS	3150,0 - 3325,0	x	x	x	x	x
3NA 0004 RJS	2950,0 - 3150,0	x	x	x	x	x
3NA 0005A RJS	2900,0 - 3100,0	x	x	x	x	x
3NA 0006D RJS	3250,0 - 3520,0	x	x	x		
7NA 0007 RJS	3025,0 - 3275,0	x	x	x	x	x
7NA 0008D RJS	3200,0 - 3470,0	x	x	x	x	x
7NA 0009D RJS	3300,0 - 3550,0	x	x	x	x	x
7NA 0010D RJS	3270,0 - 3530,0	x	x	x	x	
7NA 0011A RJS	3000,0 - 3200,0	x	x	x	x	x
7NA 0012 RJS	2970,0 - 3175,0	x	x	x	x	x
7NA 0013A RJS	2950,0 - 3125,0	x	x	x	x	
8NA 0014D RJS	3475,0 - 3700,0	x	x	x	x	
7NA 0015D RJS	3400,0 - 3650,0	x	x	x	x	
7NA 0016D RJS	3425,0 - 3600,0	x	x	x	x	
3NA 0017A RJS	3125,0 - 3340,0	x	x	x	x	x
8NA 0018D RJS	3240,0 - 3450,0	x	x	x	x	
8NA 0020D RJS	3420,0 - 3700,0	x	x	x	x	
3NA 0021B RJS	2930,0 - 3140,0	x	x	x	x	x
8NA 0022 RJS	3140,0 - 3270,0	x	x	x	x	
8NA 0023D RJS	3210,0 - 3430,0	x	x	x	x	
7NA 0024D RJS	3600,0 - 3875,0	x	x	x	x	
7NA 0025D RJS	3160,0 - 3430,0	x	x	x	x	
7NA 0026D RJS	3420,0 - 3570,0	x	x	x	x	
8NA 0027D RJS	3680,0 - 3950,0	x	x	x	x	
7NA 0028D RJS	3520,0 - 3747,0	x	x	x	x	
7NA 0029D RJS	3420,0 - 3600,0	x	x	x	x	
7NA 0030D RJS	3360,0 - 3630,0	x	x	x	x	
7NA 0031D RJS	3070,0 - 3330,0	x	x	x	x	
8NA 0032D RJS	3320,0 - 3550,0	x	x	x	x	
8NA 0033D RJS	3700,0 - 3950,0	x	x	x	x	
7NA 0034D RJS	3150,0 - 3400,0	x	x	x	x	
7NA 0035D RJS	3600,0 - 3860,0	x	x	x	x	
7NA 0036D RJS	3690,0 - 3970,0	x	x	x	x	
7NA 0037D RJS	3170,0 - 3400,0	x	x	x	x	x

7NA 0038D RJS	3075,0 - 3340,0	x	x	x	x	
8NA 0039D RJS	3200,0 - 3530,0	x	x	x	x	
7NA 0040D RJS	3050,0 - 3310,0	x	x	x	x	
7NA 0041D RJS	3400,0 - 3725,0	x	x	x	x	
7NA 0042D RJS	3340,0 - 3610,0	x	x	x	x	
7NA 0043D RJS	3180,0 - 3380,0	x	x	x	x	
7NA 0044D RJS	3150,0 - 3400,0	x	x	x	x	
7NA 0045D RJS	3240,0 - 3410,0	x	x	x	x	
7NA 0046D RJS	3600,0 - 3790,0	x	x	x	x	
7NA 0047D RJS	3135,0 - 3380,0	x	x	x	x	
7NA 0048D RJS	3040,0 - 3240,0	x	x	x	x	
7NA 0049D RJS	3200,0 - 3500,0	x	x	x	x	
7NA 0050D RJS	3300,0 - 3530,0	x	x	x	x	
7NA 0051D RJS	3580,0 - 3840,0	x	x	x	x	
7NA 0052D RJS	3150,0 - 3360,0	x	x	x	x	
7NA 0053D RJS	3050,0 - 3270,0	x	x	x	x	
1RJS 0019 RJ	2900,0 - 3120,0	x	x	x	x	x
4RJS 0042 RJ	3000,0 - 3215,0	x	x	x	x	x
4RJS 0234 RJ	3150,0 - 3352,0	x	x	x	x	x