

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO



Allan do Amaral de Oliveira

SELEÇÃO DE POÇOS PARA OPERAÇÕES DE
ESTIMULAÇÃO UTILIZANDO INTELIGÊNCIA ARTIFICIAL.



Escola Politécnica
Centro de Tecnologia
Universidade Federal do Rio de Janeiro
Rio de Janeiro, 2012



SELEÇÃO DE POÇOS PARA OPERAÇÕES DE ESTIMULAÇÃO UTILIZANDO INTELIGÊNCIA ARTIFICIAL.

Allan do Amaral de Oliveira

Projeto de Graduação apresentado ao Curso de Engenharia do Petróleo da Escola Politécnica, Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Engenheiro.

Orientador: Vírgilio José Martins Ferreira Filho, Dr.

Rio de Janeiro
Julho de 2012

SELEÇÃO DE POÇOS PARA OPERAÇÕES DE ESTIMULAÇÃO UTILIZANDO INTELIGÊNCIA ARTIFICIAL.

Allan do Amaral de Oliveira

PROJETO DE GRADUAÇÃO APRESENTADO AO CURSO DE ENGENHARIA DE PETRÓLEO DA ESCOLA POLITÉCNICA, UNIVERSIDADE FEDERAL DO RIO DE JANEIRO, COMO PARTE DOS REQUISITOS NECESSÁRIOS À OBTENÇÃO DO TÍTULO DE ENGENHEIRO DE PETRÓLEO.

Examinado por:

Prof. Virgílio José Martins Ferreira Filho, D. Sc
(Orientador)

Prof. Paulo Couto, Dr. Eng.

Eng. Paula Castineira

RIO DE JANEIRO, RJ – BRASIL

JULHO DE 2012

Oliveira, Allan do Amaral de

Seleção de Poços para a Operação de Estimulação
Utilizando Inteligência Artificial/ Allan do Amaral de Oliveira
– Rio de Janeiro: UFRJ/ Escola Politécnica, 2012.

X, 88 p.: il.; 29,7 cm.

Orientador: Virgílio José Martins Ferreira Filho

Projeto de Graduação – UFRJ/ Escola Politécnica/

Curso de Engenharia do Petróleo, 2012.

Referencias Bibliográficas: p. 86-88.

1. Seleção de Poços para Estimulação 2. Fraturamento
Hidráulico 3. Inteligência Artificial 4. Estudo de Caso.
5. Estudo Prospectivo.

I. Martins Ferreira Filho, Virgílio. II. Universidade Federal do
Rio de Janeiro, Escola Politécnica, Curso de Engenharia
do Petróleo. III. Título.

DEDICATÓRIA

À minha irmã e melhor amiga Aline, por todo amor e companheirismo ao longo de toda minha vida.

Ao meu avô Jorge, por ser meu exemplo de vida e grande pai.

Ao meu pai Ronaldo, por todo apoio e incentivo

À minha tia Eliana, por minha base educacional e todos os cuidados

À minha mãe Marilucia e avó Helena, guias espirituais nesta caminhada

E à toda minha família, namorada e amigos da UFRJ, GPI, EAC, EJC, SSOG entre outros, pelo carinho, paciência e ajuda !

AGRADECIMENTOS

Gostaria de agradecer primeiramente a Deus por mais esse sucesso alcançado.

À UFRJ em especial ao curso de engenharia de petróleo, todos seus professores e funcionários.

Ao professor Virgílio, pelos ensinamentos, orientação e paciência.

À minha família, por ser a minha base.

Obrigado !

*“É preciso força pra sonhar e perceber
que a estrada vai, além do que se vê”*

Resumo do Projeto de Graduação apresentado à Escola Politécnica/ UFRJ como parte dos requisitos necessários para a obtenção do grau de Engenheiro de Petróleo.

SELEÇÃO DE POÇOS PARA OPERAÇÕES DE ESTIMULAÇÃO UTILIZANDO INTELIGÊNCIA ARTIFICIAL.

Allan do Amaral de Oliveira

Julho de 2012

Orientador: Virgílio José Martins Ferreira Filho

Curso: Engenharia de Petróleo

Operações de estimulação são práticas comumente empregadas na indústria petrolífera de forma a possibilitar o aumento ou manutenção da produção de campos de óleo e gás. A seleção dos poços candidatos a sofrer tal operação assim como o planejamento da mesma é realizada com base em estudos de reservatórios, softwares de simulação e na experiência adquirida por especialistas da área ao longo de suas vidas.

Devido à característica subjetiva das variáveis envolvidas neste processo de escolha e execução, profissionais do setor tem se interessado cada vez mais por sistemas inteligentes que possam servir de apoio à tomada de decisão em diversos aspectos da operação.

Desta forma, o objetivo deste trabalho é, com base em uma revisão bibliográfica de assuntos ligados a estimulação de poços e técnicas de inteligência artificial, apresentar através de estudos de caso e prospectivo uma metodologia de

seleção de poços para operações de estimulação utilizando os paradigmas inteligentes Redes Neurais Artificiais, Algoritmos Genéticos e Lógica Fuzzy, concluindo através de seus resultados as vantagens, desvantagens e aplicação presente e futura da técnica desenvolvida por pesquisadores norte americanos no início dos anos 2000.

Palavras-chave: Seleção de poços, Estimulação, Redes Neurais Artificiais, Algoritmos Genéticos e Lógica Fuzzy.

Abstract of Undergraduate Project presented to POLI/UFRJ as a partial fulfillment of the requirements for the degree of Petroleum Engineer.

WELL SELECTION FOR STIMULATION OPERATIONS USING ARTIFICIAL INTELLIGENCE

Allan do Amaral de Oliveira

July, 2012

Advisor: Virgílio José Martins Ferreira Filho

Course: Petroleum Engineering

Stimulation operations are practices commonly used in the oil and gas industry in order to increase or maintain the productivity of wells. The candidate selection to perform these kind of operations, as well as its planning is done based on reservoirs studies, simulation software and on the experience acquired by experts in the area throughout their lives.

Due to the subjective character of the variables involved in this process of choosing and implementing, professionals have been increasingly interested in intelligent systems that can serve to support decision making in many aspects of the operation.

Thus, the main objective of this paper is, based on a literature review of subjects as stimulation operations and artificial intelligences techniques to present through case and prospective studies a methodology of well candidates selection for stimulation operations using intelligent paradigms such as Artificial Neural Networks,

Genetic Algorithms and Fuzzy Logic, concluding with its results, the advantages, disadvantages and the present and future of the application of the technique, developed by U.S. researchers in the early 2000s

Keywords: Well Selection, Stimulation, Neural Networks, Genetic Algorithms and Fuzzy Logic

SUMÁRIO

1	INTRODUÇÃO.....	1
1.1	OBJETIVO.....	2
1.2	METODOLOGIA/TEORIA.....	2
1.2.1	Operações de estimulação e o Fraturamento Hidráulico	2
1.2.2	A seleção de poços para estimulação	5
1.2.3	Sistemas Híbridos Inteligentes	5
1.2.4	Trabalho proposto	6
2	MÉTODOS DE ESTIMULAÇÃO: FRATURAMENTO HIDRAULICO	8
2.1	MÉTODOS DE ESTIMULAÇÃO	8
2.2	FRATURAMENTO HIDRÁULICO	9
2.2.1	Histórico da Operação	9
2.2.2	A operação de Fraturamento Hidráulico	11
2.2.3	Objetivos do Fraturamento	12
2.2.4	Seleção de poços para fraturamento hidráulico	14
2.2.5	Planejamento da operação.....	18
3	TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL	29
3.1	REDES NEURAIS ARTIFICIAIS.....	30
3.1.1	Histórico de Redes Neurais Artificiais	30
3.1.2	As Redes Neurais Artificiais (RNA).....	31
3.1.3	Redes Neurais Feed-forward	35
3.1.4	Treinamento de RNA's	37
3.1.5	O algoritmo <i>backpropagation</i>	38
3.2	ALGORITMOS GENÉTICOS.....	41
3.2.1	Os Algoritmos Genéticos	41
3.2.2	Mecanismos de um Algoritmo Genético.....	43

3.2.3	Parâmetros Genéticos	47
3.3	LÓGICA FUZZY	49
3.3.1	Histórico da técnica	49
3.3.2	Teoria de Conjuntos Fuzzy	50
4	SELEÇÃO DE POÇOS PARA REESTIMULAÇÃO ATRAVÉS DO TÉCNICAS INTELIGENTES - ESTUDO DE CASO	63
4.1	DESCRIÇÃO	63
4.1.1	INTRODUÇÃO	63
4.1.2	O Uso da Inteligência Artificial na Seleção de Poços Candidatos para Reestimulação.	65
4.1.3	Estudo de Caso: Formação Frontier, Bacia de Green Rlver.	70
4.1.4	Resultados	76
4.1.5	Conclusão do estudo	78
4.2	ANÁLISE CRÍTICA DO ESTUDO DE CASO	78
5	ESTUDO PROSPECTIVO	80
6	CONCLUSÃO	84
7	REFERÊNCIAS BIBLIOGRÁFICAS	86

LISTA DE FIGURAS

Figura 2.1 :Primeiro fraturamento experimental no campo de Huguton, Kansas, EUA (1947)	10
Figura 2.2: Evolução de publicações sobre fraturamento na base One Petro.	11
Figura 2.4: Composição básica dos fluidos de Fraturamento.....	20
Figura 2.5: Exemplo de propante cerâmico.....	23
Figura 2.6: Diagrama 3-D de tensões principais.	24
Figura 2.7: Corte de um poço vertical demonstrando a atuação das tensões horizontais e direção de propagação de fratura.	25
Figura 2.8: Diagrama tensão x profundidade	26
Figura 2.9: Representação de um poço canhoneado.....	27
Figura 2.10: Gráfico pressão x tempo na operação de fraturamento.....	28
Figura 3.1: Estrutura de um neurônio humano	31
Figura 3.2: Estrutura básica de uma rede neural artificial	32
Figura 3.3: Estrutura básica de um neurônio artificial.....	33
Figura 3.4: Função de ativação Logsig	34
Figura 3.5: Função de ativação tansig	34
Figura 3.6: Função de ativação tansig	35
Figura 3.7: Esquema das camadas de uma rede neural	36
Figura 3.8: Operação do algoritmo backpropagation.....	38
Figura 3.9: Backpropagation	40
Figura 3.10: Cromossomo de 5 genes	44
Figura 3.11: Cruzamento simples	45
Figura 3.12: Cruzamento duplo.....	46
Figura 3.13: Operador de inversão	47
Figura 3.14: Operador de mutação	47
Figura 3.15: Operações tradicionais na teoria de conjuntos clássica	49
Figura 3.16: Comparação entre funções do tipo booleana e fuzzy.....	52
Figura 3.17: Funções de pertinência da variável linguística temperatura	54
Figura 3.18: Geometria das funções de pertinência.....	54
Figura 3.19: União de conjuntos fuzzy	55
Figura 3.20: Interseção de conjuntos fuzzy	55
Figura 3.21: Complemento de conjuntos fuzzy	56
Figura 3.22 : Ciclo Fuzzy	58

Figura 3.23: Procedimentos de defuzzificação.....	62
Figura 4.1: Fluxograma da metodologia desenvolvida	65
Figura 4.2: Categorias de dados para implementação da metodologia.....	67
4.3: Ilustração da rede neural criada para modelagem do problema.....	68
Figura 4.4: Localização da Bacia de Green River	71
Figura 4.5: Correlação dos dados de treinamento	72
Figura 4.6: Correlação dos dados de validação	72
Figura 4.7: Importância relativa de cada categoria.....	73
Figura 4.8: Regras Fuzzy e suas qualificações.....	75
Figura 4.9: Qualificação das verdades fuzzy.....	75
Figura 4.10: Resultados do tratamento para o poço GRB 45-12.....	76
Figura 4.11: Resultados do tratamento para o poço GRB 27-14.....	77
Figura 4.12: Resultados do tratamento para o poço NLB 57-33.....	77

1 INTRODUÇÃO

Operações de estimulação são amplamente difundidas na indústria petrolífera para elevação do potencial produtivo de poços e formações portadoras de hidrocarbonetos. Estas operações atuam no aumento da produtividade ou injetividade de uma dada formação através da indução de canais na rocha reservatório ou pela remoção do dano, facilitando o fluxo dos fluidos a serem produzidos.

Devido às diferentes características de cada formação ou projeto, nem todos os poços são candidatos naturais a serem estimulados. Mesmo dentro do mesmo campo petrolífero, serão encontrados poços que devem ou não sofrer este tipo de operação,. Entre as operação de intervenção mais utilizadas pode-se citar as de fraturamento hidráulico, lavagem ácida e fraturamento ácido.

O processo de seleção de poços para estimulação envolve a análise de diferentes parâmetros e depende fortemente de recursos tecnológicos como simuladores e também da experiência de especialistas do setor. Uma interpretação deficiente dos parâmetros de poço, ou uma falha de planejamento da operação podem ocasionar graves consequências à produção de um campo, podendo resultar inclusive na perda de poços ou em graves acidentes.

Desta forma, embora as operações de estimulação sejam frequentemente praticadas, o problema de seleção mostra-se ainda relevante e ganha cada vez mais importância no cenário atual. Este destaque deve-se principalmente ao desenvolvimento da exploração de campo de gás natural produzidos de formações de baixíssima permeabilidade (menor que 1 mD) conhecidos como campos de *tight gás*, recurso apontado como potencial provedor de hidrocarbonetos para a crescente demanda por gás natural por todo mundo. Nestes campos as operações de estimulação são essenciais para se conseguir níveis econômicos de produtividade.

1.1 OBJETIVO

O objetivo deste trabalho é a apresentação e análise de uma metodologia de auxílio à tomada de decisão para seleção de poços candidatos a estimulação. Esta metodologia, desenvolvida por pesquisadores norte-americanos no ano de 2000, busca através da aplicação conjunta de técnicas computacionais inteligentes, a obtenção de uma maior eficiência operacional, redução de custos e a criação de um mecanismo para manutenção de experiências profissionais adquiridas com o passar do tempo em operações deste tipo.

1.2 METODOLOGIA/TEORIA

1.2.1 OPERAÇÕES DE ESTIMULAÇÃO E O FRATURAMENTO HIDRÁULICO

Um dos principais métodos de estimulação de poços utilizado atualmente, e tema de estudo neste trabalho, é o fraturamento hidráulico. Esta operação consiste na aplicação de um diferencial de pressão acima da resistência mecânica da formação, provocando a sua quebra, ou fratura. Logo em seguida é realizado o bombeio de um volume de fluido especificado a alta vazão para propagar os canais formados e injeção de um agente de sustentação com pressão superior a do fechamento das fraturas.



Figura 1.1: Plantas de fraturamento onshore e offshore

(www.halliburton.com e www.slb.com)

Devido ao seu grande índice de sucesso e retorno financeiro, tratamentos de fraturamento hidráulico são usualmente praticados logo após a fase de perfuração de poços quando constatada a baixa transmissibilidade da zona de interesse.

Após sofrer a primeira operação, poços que apresentam um declínio de produtividade a níveis abaixo do economicamente viável podem ser refraturados a fim de se garantir a continuidade de sua operação.

Em grandes campos de gás, o fraturamento representa uma das principais operações praticadas e, ao longo do tempo, grande volume de dados e significativos conhecimentos puderam ser adquiridos (Popa, Wood, Cassidy, 2011).

Fraturar, ou refraturar, uma formação com sucesso ainda se mostra um desafio aos engenheiros. Significativas pesquisas e trabalhos foram conduzidos na última década utilizando técnicas de inteligência artificial a fim de se mapear os dados existentes e construir sistemas preditivos que possam maximizar os resultados de uma determinada operação.

Ao considerar um tratamento de fraturamento hidráulico, quatro etapas fundamentais devem ser bem projetadas (Popa, Wood, Cassidy, 2011):

- Seleção de poços candidatos
- Design do tratamento
- Planejamento da operação
- Execução do trabalho em campo.

Cada uma dessas etapas possui importância equivalente, e atenção individual apropriada deve ser prestada a fim de se realizar um trabalho eficiente.

Na primeira etapa: seleção de candidatos, engenheiros e operadores buscam pelos poços ideais que, quando fraturados, possam aumentar de forma significativa a produtividade de seu campo.

Um considerável volume de trabalhos e pesquisas foi dedicado a esta área utilizando diferentes técnicas como estatística, modelos analíticos, simulação e computação inteligente. Uma revisão bibliográfica deste assunto, através de autores como Shelley (“Artificial Neural Network Enhanced Completions Improve Well Economics”, Shelley, R. F, 1999), Reeves (“Fracture-Stimulation Technology for Gas-Storage Wells”, S. R. Reeves, 1998) e Mohaghegh (“Candidate Selection for Stimulation of Gas Storage Wells Using Available Data With Neural Networks and Genetic Algorithms”, Mohaghegh, S., Platon, V., Ameri, S., 1998), aponta que técnicas de Inteligência artificial e *data mining* têm fornecido grande taxa de sucesso quando aplicadas a seleção de poços para estimulação ou reestimulação.

A segunda fase consiste no design do tratamento de fraturamento, quando são definidas as características de projeto que resultarão em um maior ganho econômico de produção.

Usualmente esta fase é conduzida por engenheiros através do uso de simuladores ou técnicas de soft computing. Um significativo número de softwares está disponível no mercado para realização deste trabalho, e como exemplo pode-se citar os pacotes *FracPro* (<http://www.carboceramics.com/fracpropt-software/>), *FracCADE* (http://www.slb.com/~media/Files/sand_control/product_sheets/software/fraccade_frac_design_software_ps.ashx) e *M Frac* (<http://www.mfrac.com/mfrac.html>).

Esses programas utilizam como parâmetros de entrada propriedades da formação e de fluidos, volume/tipo de agente propante e suas taxas de bombeio para calcular a geometria e condutividade das fraturas e, através de um processo de tentativa e erro, modificando parâmetros de tratamento como volumes de fluido e sólidos, e taxas de bombeio, busca atingir o design ideal específico para o poço selecionado.

Este método pode demandar um significativo tempo de engenharia, que pode variar desde algumas horas até mesmo a um dia completo, resultando muitas vezes em uma única solução gerada. Em contraste aos simuladores e modelos analíticos, técnicas de inteligência artificial podem oferecer novas abordagens com resultados confiáveis obtidos em menores espaços de tempo.

A terceira etapa diz respeito ao planejamento da operação e envolve a identificação de equipamentos e ferramentas, a aquisição ou aluguel de materiais necessários, planejamento logístico e preparo da locação.

Finalmente, a última fase, e provavelmente a mais crítica é a execução da operação. Esta ocorre na locação do poço e está sujeita a diferentes possibilidades de fracasso dada a imprevisibilidade da execução prática do trabalho.

1.2.2 A SELEÇÃO DE POÇOS PARA ESTIMULAÇÃO

A seleção de candidatos a estimulação não se baseia apenas no potencial ganho produtivo de um determinado poço, deve-se também garantir que esse aumento seja sustentável, justificável economicamente e não acompanhado de um aumento do volume de água ou gás (nos casos de campos de óleo).

Na prática, a maior parte dos tratamentos de fraturamento é conduzida em poços selecionados através de pouco ou nenhum envolvimento de bases científicas e princípios de engenharia. Em sua maioria, candidatos selecionados apresentam baixa performance e o tratamento aplicado baseia-se em uma combinação de práticas já consagradas (Martin, Economides, 2010)

De fato, em muitos casos a experiência profissional é capaz de solucionar o problema e proporcionar resultados satisfatórios, porém esta situação não é garantida e muitas vezes os tratamentos aplicados poderiam apresentar maior rendimento.

A seleção de potenciais candidatos a sofrer este tipo de intervenção não garante o sucesso da mesma. Diversos parâmetros relacionados ao planejamento da operação como design da fratura e seleção de fluidos terão impacto direto nos resultados obtidos.

1.2.3 SISTEMAS HÍBRIDOS INTELIGENTES

Devido à característica nebulosa das variáveis envolvidas no processo de escolha, profissionais da área tem se interessado cada vez mais por sistemas inteligentes que possam servir de apoio à tomada de decisão em diversos aspectos da operação, o que inclui desde a seleção de poços candidatos até a determinação de

parâmetros técnicos da intervenção, de forma a se obter resultados ótimos em termos de aumento de produtividade e menor mobilização de recursos.

Nas últimas duas décadas, uma significativa atividade na área de computação inteligente com foco em paradigmas como Redes Neurais Artificiais, Algoritmos Genéticos e Lógica Fuzzy pode ser observada, aplicada a resolução de problemas complexos de engenharia de forma eficiente (Popa, Wood, Cassidy, 2011)

Redes Neurais Artificiais (RNA) constituem-se em um paradigma computacional baseado no modelo biológico do cérebro humano. São técnicas computacionais que apresentam um modelo inspirado na estrutura neural e que adquirem conhecimento através da experiência, já os Algoritmos Genéticos são algoritmos de otimização global, baseados nos mecanismos de seleção natural e da genética, e a Lógica Fuzzy (Nebulosa) é a lógica que suporta os modos de raciocínio que são aproximados ao invés de exatos, são técnicas para o tratamento de informações qualitativas.

Alguns trabalhos se concentraram na integração de dois ou mais desses paradigmas gerando os conhecidos sistemas híbridos. O poder desses sistemas se apóia no fato de que estas técnicas possuem caráter complementar, contribuindo com sua força individual para geração de uma solução ao problema em questão.

1.2.4 TRABALHO PROPOSTO

Neste trabalho, de forma a prover a base teórica para apresentação da metodologia em estudo, inicialmente é realizada uma revisão bibliográfica dos temas abordados. Desta forma, divididos em dois capítulos, são explanados conceitos sobre métodos de estimulação, com destaque para o tratamento de fraturamento hidráulico, e os paradigmas inteligentes Redes Neurais Artificiais, Lógica Fuzzy e Algoritmos Genéticos.

Em seguida, através do artigo "*Development of an Intelligent Systems Approach for Restimulation Candidate Selection*" (Mohaghegh, Hills e Reeves, 2000) a proposta para seleção inteligente de poços para reestimulação criada por Shahab Mohaghegh, Scott Reeves e David Hill, é então apresentada e suas premissas e resultados discutidos em uma análise crítica elaborada com base na pesquisa realizada para esta monografia.

Por fim, fechando este trabalho, é realizado um estudo prospectivo para aplicação prática da técnica apresentada, utilizando seus resultados como base para discussão de suas vantagens, limitações e utilização futura.

2 MÉTODOS DE ESTIMULAÇÃO: FRATURAMENTO HIDRÁULICO

2.1 MÉTODOS DE ESTIMULAÇÃO

A estimulação de poços tem como objetivo aumentar a produtividade ou a injetividade de poços de petróleo e gás, pelo aumento do fator de recuperação do campo ou pela antecipação da produção e corrigir algum tipo dano causado no poço.

Estes tipos de tratamento podem ser altamente eficazes se bem projetados e executados. Entre estes métodos destacam-se tratamentos como:

- Acidificação de matriz:

Técnica de estimulação utilizada para remoção de dano e/ou aumento de permeabilidade em regiões localizadas a poucos metros ao redor do poço. Consiste no bombeio de uma solução ácida na formação, a fim de dissolver parte dos minerais presentes na sua composição mineralógica, aumentando ou recuperando a permeabilidade da formação ao redor do poço.

- Fraturamento hidráulico:

Consiste na injeção de um fluido (fraturante) na formação, sob uma pressão suficientemente alta para causar a ruptura da rocha. Simultaneamente ao bombeio de fluidos é realizada a injeção de um material granular (agente de sustentação), responsável pela manutenção da fratura gerada, criando então canais de alta permeabilidade, por onde ocorrerá o escoamento de hidrocarbonetos.

- **Fraturamento ácido:**

Composto pela conjugação das duas técnicas já citadas, neste tratamento, uma solução ácida é injetada na formação, sob pressão acima da de ruptura da formação, originando então uma fratura. A condutividade da fratura é obtida por meio da reação do ácido com a rocha, criando canalizações irregulares, que permanecerão abertas após o fechamento da mesma.

Operações de estimulação podem ser praticadas uma ou mais vezes em um mesmo poço dependendo do seu comportamento após a realização do primeiro tratamento.

Esta prática conhecida como reestimulação, consiste basicamente repetição das técnicas citadas anteriormente e servirá nesta monografia como tema de estudo de caso com foco no tratamento de fraturamento hidráulico.

2.2 FRATURAMENTO HIDRÁULICO

2.2.1 HISTÓRICO DA OPERAÇÃO

A operação de fraturamento hidráulico tem sido realizada desde os primórdios da Indústria do petróleo. Sua primeira realização experimental data de 1947, em um poço de gás operado pela companhia Stanolind Oil. no campo de Hugoton, em Grant County, Kansas, EUA. (Holditch, 2007)

Em 17 de Março de 1949, a empresa Howco (Halliburton Oil Well Cementing Company), detentora exclusiva da patente da então nova tecnologia, executou as duas primeiras operações comerciais de fraturamento hidráulico. Utilizando uma mistura de óleo cru e gasolina com a adição de 100 a 150 lbm (45.3 a 67.9 kg) de areia, os primeiros tratamentos foram realizados ao custo médio de US 950,00.

Neste primeiro ano, um total de 332 poços foram estimulados, com um aumento de produção médio de 75%.



Figura 2.1 :Primeiro fraturamento experimental no campo de Hugoton, EUA (1947)
(Holditch, 2007)

Com o passar dos anos a comunidade científica dedicou-se ao desenvolvimento da técnica que, devido à evolução de modelos matemáticos, fluidos, materiais e equipamentos, tornou-se prática comum na indústria e hoje destaca-se como um dos mais eficazes métodos de estimulação praticados (Thomas, 2001), proporcionando a abertura do horizonte exploratório especialmente no que tange reservatórios de gás natural.

Desde sua primeira execução comercial em 1949, estima-se que perto de 2,5 milhões de operações de fraturamento já tenham sido executadas por todo mundo e que aproximadamente 60% dos poços perfurados atualmente sofram este tipo de tratamento. (Shahab, 2000)

O fraturamento atrai interesse não só por elevar a produtividade dos poços, mas também por proporcionar o aumento de reservas tornando viável a exploração de novos campos – só nos Estados Unidos o crescimento nas reservas de óleo pode ter sido de pelo menos 30% e nas de gás natural, 90%. (Holditch, 2007)

Conforme demonstrado na figura 2.2, as pesquisas na área de fraturamento ainda apresentam forte crescimento, evidenciando assim os esforços para o desenvolvimento da técnica que embora já amplamente difundida, se mal especificada ou executada, pode resultar também em grandes prejuízos e até mesmo na perda de poços.




Figura 2.2: Evolução de publicações sobre fraturamento na base One Petro.

Como importante justificativa para a manutenção do alto crescimento nas pesquisas sobre fraturamento, pode-se citar a exploração de campos de *shale* e *tight gas*. Apontados como fontes potenciais para a crescente demanda mundial por gás natural (Krauss, 2009), esses reservatórios apresentam baixíssima permeabilidade ($< 0.1\text{md}$), sendo desta forma, primordial a execução de tratamentos de estimulação.

2.2.2 A OPERAÇÃO DE FRATURAMENTO HIDRÁULICO

O fraturamento hidráulico é um processo no qual um elevado diferencial de pressão, provocado pelo bombeio de um fluido de fraturamento, é aplicado contra a rocha-reservatório até a sua ruptura. A fratura, que é iniciada no poço, se propaga através da formação pelo bombeio de certo volume de fluido, acima da pressão de fraturamento.

Para que a fratura criada não se feche ao cessar o diferencial de pressão, um agente de sustentação, à base de areia ou outros compostos, é bombeado junto ao fluido de fraturamento. Desta forma são criados caminhos preferenciais de elevada

condutividade que facilitarão o fluxo de fluidos do reservatório para o poço, ou vice-versa (Orestes, 2005).




Figura 2.3: Esquema ilustrativo da operação de fraturamento em um campo terrestre (Orestes, 2010)

Existem também os fraturamentos ácidos que dispensam a utilização do agente de sustentação, nestas operações, a ação do ácido provoca o surgimento de canais de alta permeabilidade mesmo após a retirada da pressão imposta pela bombeio de fluido.

2.2.3 OBJETIVOS DO FRATURAMENTO

Tratamentos de fraturamento hidráulico são praticados na maioria dos casos com o objetivo principal de elevar o índice de produtividade de um poço produtor ou a taxa de injeção de poços injetores.

O Índice de Produtividade (IP) define a taxa a qual hidrocarbonetos podem ser produzidos dado um determinado diferencial de pressão entre o reservatório e o poço, e é definido pela equação 2.1:

$$IP = \frac{q}{P_e - P_w} \quad (2.1)$$

Onde:

q = vazão

P_e= Pressão estática (ou média) do reservatório

P_w= Pressão de fluxo do poço

De forma similar, o índice de injetividade se refere à taxa que um fluido pode ser injetado em um poço sob o mesmo diferencial de pressão.

Existem diversas aplicações para o fraturamento hidráulico, podem-se citar algumas como:

- Aumento da área de drenagem ou o contato entre a formação e o poço;
- Aumento da vazão de hidrocarbonetos produzidos de reservatórios de baixa permeabilidade ou de poços danificados;
- Conexão de fraturas naturais;
- Redução da queda de pressão ao redor do poço a fim de minimizar a produção de areia ou minimizar problemas como a deposição de asfaltenos e parafinas
- Facilitação da alocação de areia em *gravel-packings*
- Conexão da extensão vertical de um reservatório em poços direcionais e horizontais.

Desta forma, o fraturamento poderá agir permitindo, facilitando ou ainda acelerando a produção de hidrocarbonetos presentes no reservatório.

Em diversos casos, especialmente em formações de baixa permeabilidade, reservatórios danificados, ou poços horizontais em reservatórios com diferentes camadas litológicas, a produção do poço pode ser impossibilitada sem a realização de uma operação de fraturamento planejada e executada com sucesso, desta forma, o engenheiro responsável pela viabilidade de poços deste tipo deve projetar o tratamento ótimo e então garantir em campo o sucesso da operação.

2.2.4 SELEÇÃO DE POÇOS PARA FRATURAMENTO HIDRÁULICO

O sucesso ou fracasso de uma operação de fraturamento estão diretamente atrelados à qualidade dos poços candidatos selecionados.

Para se escolher o melhor candidato a uma estimulação, deve-se levar em consideração múltiplas variáveis. Entre os parâmetros de maior influência para este tipo de operação pode-se destacar: permeabilidade, distribuição de tensão in-situ, viscosidade dos fluidos contidos no reservatório, fator de dano à formação, pressão do reservatório, profundidade do reservatório e condições mecânicas do poço (Orestes, 2005)

É dito um reservatório de baixa permeabilidade aquele que apresenta uma alta resistência ao fluxo de fluidos. Em muitas formações, processos químicos e/ ou físicos podem alterar as propriedades das rochas de um reservatório através do tempo geológico. Algumas vezes esses processos diagênicos restringem os poros das rochas reduzindo então a capacidade de fluidos se movimentarem.

Rochas de baixa permeabilidade normalmente são potenciais candidatas a processos de estimulação por fraturamento hidráulico.

Além da permeabilidade, uma rocha de um reservatório pode ser danificada quando o poço é perfurado ou quando o revestimento é assentado e cimentado.

O fator de dano ou *skin* se refere ao quanto a formação ao redor de um poço está obstruída (ou estimulada). Como causa de obstrução pode-se citar a invasão de fluidos de completação e ou perfuração à formação exposta ao poço alterando os poros e a conexão entre os mesmos, ou também os danos gerados pelo disparo de cargas para o canhoneio.

Quando os poros estão obstruídos, a permeabilidade é reduzida e o fluxo nesta região do reservatório pode ser substancialmente reduzido. Danos podem ser especialmente severos em reservatórios naturalmente fraturados. Para se estimular reservatórios danificados, uma fratura curta e de alta condutividade é a solução ideal.

Os melhores poços candidatos geralmente são os que apresentam volumes substanciais de hidrocarbonetos e necessitam aumentar seu índice de produtividade. Esses reservatórios apresentam grande espessura na zona portadora de hidrocarbonetos, pressões médias à elevadas, barreiras de tensão *in situ* a fim de se conter o crescimento vertical da fratura e também uma zona de baixa permeabilidade ou danificada.

Poços em geral não candidatos são os que apresentam pequeno volume de hidrocarbonetos *in place*, de baixa pressão, de baixo raio de influência.

Reservatórios de permeabilidade extremamente baixa podem não produzir vazões de hidrocarbonetos economicamente viáveis, mesmo após a estimulação sendo assim esses poços podem não ser bons candidatos (Sergina, 2003).

Frequentemente, as principais limitações para seleção de candidatos não estão atreladas a aspectos técnicos do reservatório e desempenho da fratura. Diferentes aspectos podem causar a rejeição de um intervalo ou poço à operação de fraturamento, algumas dessas razões são citadas abaixo (Martin, Economides, 2010)

1. Proximidade a Contatos Água-óleo/gás:

Em geral, fraturar uma zona de aquífero pode causar danos substanciais ao desempenho do poço pós-tratamento. A indústria apresenta diversos casos como estes que por razões óbvias na maioria das vezes não são publicados.

Existem sistemas capazes de mitigar os efeitos da penetração em zonas de água agindo através da incorporação de agentes modificadores de permeabilidade aos fluidos de fraturamento (dos Santos et al., 2005, Mahajan et al., 2006 apud Martin, Economides, 2010) ou do uso de sistemas de propantes capazes de manter aberto preferencialmente o topo da fratura (dos Santos et al., 2009 apud Martin, Economides, 2010)

2. Proximidade de zonas de gás (produção de óleo):

Em reservatórios de óleo, fraturas podem facilmente penetrar em zonas superiores de gás como inferiores de água. A principal diferença no caso de zonas de gás é que poucas medidas mitigadoras podem ser adotadas.

3. Limitações quanto as pressões de completação.

Invariavelmente o fraturamento requer pressões significante maiores que as experimentadas pela completação durante ciclos normais de produção ou fechamento.

Além de checar as limitações de pressões na tubulação do poço (revestimento e coluna), atenção particular deve ser dada a equipamentos de poço como mandris de *gas lift*, válvulas de segurança, camisas deslizantes, e aparelhos para controle de fluxo.

Outra limitação se encontra nos obturadores ou *packers*. Pressão adicional no interior da completção pode resultar em forças verticais ascendente aplicadas ao *packer*, e o engenheiro deve se certificar que o mesmo não será desassentado ou se moverá para cima.

Muitos desses problemas podem ser mitigados através da aplicação de pressão no anular, reduzindo então o diferencial de pressão entre o interior da coluna e o anular.

4. Contração da coluna:

Dois fatores poderão causar a diminuição do comprimento da coluna: pressão adicional e resfriamento causado pelo fluido de fraturamento, relativamente frio. O engenheiro deve garantir que este fato não cause tensões acima da suportada pela coluna ou *packer*.

5. Limitações da pressão de cabeça de poço:

Muitos poços produtores podem não suportar as pressões necessárias ao fraturamento. Desta forma, é prática comum a utilização de ferramentas de isolamento de cabeça de poço (*treesavers*) ou substituir a cabeça de poço por uma árvore de fraturamento. Ambas as opções contribuem com tempo e custos a operação.

6. Tubulações de baixa qualidade:

Tubulações que apresentam danos causados por erosão, corrosão ou efeitos mecânicos podem impossibilitar a realização de um tratamento, dada sua incapacidade de suportar o acréscimo de tensões. Presentes na coluna de intervenção tubos danificados podem ser substituídos facilmente a um custo adicional de workover, já a remoção de revestimentos danificados é muito mais complexa e custosa.

7. Cimentação de baixa qualidade:

A cimentação é necessária ao isolamento de uma determinada zona a fim de se garantir que a fratura tenha início nos canhoneados e não em outro local. Desta forma, deve-se garantir o isolamento das zonas superiores e inferiores à zona de interesse, afim de que a operação ocorra de maneira efetiva e segura.

8. Impossibilidade de recuperação, reciclagem ou descarte de fluidos de tratamento:

A recuperação de fluidos de tratamento é uma parte vital do processo, e pode impactar diretamente a sua execução caso não exista a possibilidade de recuperá-lo e descartá-lo.

9. Sensitividade da formação aos fluidos de tratamento:

Muitas formações são sensíveis aos fluidos à base água e algumas (especialmente formações portadoras de gás seco) a qualquer tipo de fluido. Existem sistemas capazes de mitigar esses problemas, porém usualmente eles ocasionarão um aumento substancial dos custos do tratamento, principalmente caso uma infraestrutura ideal não exista na locação do poço.

10. Isolamento de zona:

Idealmente, tratamentos de fraturamento devem ser executados através de intervalos individuais canhoneados, ou seções de poço aberto de comprimento limitado. Na maioria dos casos, este isolamento é relativamente fácil de se garantir principalmente quando o poço é novo, porém, para os já existentes, algum tipo de intervenção pode se fazer necessária.

11. Impossibilidade de se executar intervenções:

A maioria dos poços requer algum tipo de intervenção antes da operação de fraturamento. É muito raro encontrar um poço já existente que possua uma estratégia de completação e canhoneado condizente a operação de fraturamento a ser

executada. Caso esta operação de adaptação não seja possível, devido, por exemplo, a limitação de estruturas *offshore*, o poço pode não sofrer o tratamento.

12. Falta de infra-estrutura para o fraturamento:

Sem a existência de uma infraestrutura básica incluindo tanques, fornecimento de água, serviços de recuperação e descarte de fluidos, sondas de workover, equipamento de *well testing*, fornecedores de propantes, unidades de arame, N₂ e CO₂, flexitubo entre outros não é possível a execução de uma operação de fraturamento.

Os custos associados a esta disponibilização dependendo do local do poço e do mercado podem tornar a operação inviável.

13. Localização do poço:

Alguns poços são mais fáceis e conseqüentemente mais baratos de se tratar do que outros. Poços *offshore* ou de difícil acesso em terra multiplicam os custos de uma operação.

14. Poços de Alta Pressão ou Temperatura:

Nestes casos, cuidados especiais devem ser tomados e equipamentos mais resistentes devem ser utilizados. Deve-se atentar também a disponibilidade ou existência de materiais fluidos ou propantes capazes de suportar essas condições.

2.2.5 PLANEJAMENTO DA OPERAÇÃO

Uma vez efetuada a seleção do melhor candidato, é iniciado então o planejamento da operação a ser realizada.

O planejamento de uma operação de fraturamento hidráulico é uma etapa crítica e de significativa demanda de tempo durante o processo de estimulação. Esta

envolve a coleta de dados para simulação, escolha de fluidos, agentes de sustentação e análises mecânicas da formação, itens melhor discutidos nas seções a seguir.

2.2.5.1 Coleta de dados

A coleta de dados para alimentar os simuladores de reservatório e de fratura é uma das fases mais importantes durante o planejamento de uma operação de fraturamento.

Este conjunto de dados pode ser dividido em dois grupos: Os que podem ser controlados pelo engenheiro e aqueles os quais não se tem muita informação e que por isso devem ser estimados ou inferidos.

No primeiro grupo se enquadram informações como características da completação, volume de tratamento, volume de propante, taxa de injeção, viscosidade do fluido de fraturamento, aditivos contra perda de fluido, tipo de agente propante etc. Já no segundo grupo enquadram-se parâmetros como profundidade de formação, permeabilidade da rocha, tensões *in-situ* na zona de interesse e camadas adjacentes e espessura do reservatório.

Esses dados poderão ser inferidos através de perfilagens, amostragens e testes de formação ou estimados através de poços de correlação.

2.2.5.2 Fluidos de Fraturamento

Fluidos de fraturamento são utilizados com o objetivo de transmitir o diferencial de pressão necessário para ocasionar a quebra da formação e, após isso, possibilitar a manutenção da abertura dos canais criados, através da alocação do agente propante no interior da rocha reservatório.

Com o intuito de diminuir a sua perda para a formação rochosa, o fluido age também formando uma espécie de reboco nas faces da fratura ao mesmo tempo em que, permite minimizar o dano (redução da permeabilidade) no pacote do agente de sustentação e faces da fratura.

Outra característica que o fluido de fraturamento deve apresentar está relacionada à sua viscosidade, esta deve ser baixa na coluna para reduzir a perda de carga, porém alta durante a propagação e fechamento da fratura para evitar a decantação do agente de sustentação.

Nesta última etapa, a viscosidade deverá ser rapidamente reduzida para facilitar a limpeza do reservatório.

Em virtude da variedade de poços existente, os fluidos de fraturamento devem se adequar às diversas condições de poço, como: temperatura, permeabilidade, composição mineralógica e pressão de poros.

Os primeiros fluidos de fraturamento utilizados usados eram à base óleo (1948), já na década de 50 surgiram os primeiros fluidos de base água espessados com goma guar, tornando-se muito populares até os dias de hoje, quando 70% das operações utilizam este tipo de fluido, ou similares à base de hidroxipropilguar.

Desta forma, a composição básica dos fluidos de fraturamento em geral é apresentada na figura 2.4, e tem seus componentes descritos na tabela 2.1. (Economides, 2010)




Figura 2.4: Composição básica dos fluidos de Fraturamento

(<http://www.hydraulicfracturing.com/Fracturing-Ingredients/Pages/information.aspx>)

Tabela 2.1: Componentes dos Fluidos de Fraturamento

Fluidos de Fraturamento		
Produto	Objetivo	Resultados no poço
Água e areia ~ 98%		
Água	Expandir a fratura e é responsável pelo transporte do agente propante.	Uma menor parcela da água permanece na formação enquanto o restante é produzido junto com os fluidos da formação
Areia (propante)	Possibilita que as fraturas permaneçam abertas e oferecem um caminho de alta permeabilidade para o fluxo de hidrocarbonetos da formação	Permanece no interior das fraturas introduzidas na formação
Outros aditivos ~ 2%		
Ácidos	Ajuda na dissolução de minerais e na indução de fraturas na rocha reservatório	Reage com minerais presentes na formação produzindo sal, água e dióxido de carbono neutralizado
Agente antibactericida	Elimina bactérias presentes na água, impedindo assim que estas produzam subprodutos corrosivos	Reage com microorganismos que possam estar presentes no fluido de tratamento ou na formação.
Quebrador	Possibilita o retardamento da quebra do gel de fraturamento	Na formação, reage com o <i>crosslynker</i> e gel possibilitando que o fluido de tratamento flua de volta ao poço e superfície. Esta reação produz amônia e sais sulfurosos, que retornam à superfície junto à água.
Estabilizador de argilas	Previne o inchamento da argila presente na formação	Reage com a argila presente na formação através de troca iônica Sódio-Potássio. Esta reação resulta na formação de cloreto de sódio, que retorna à superfície junto à água produzida.

Inibidor de Corrosão	Previne a corrosão de equipamentos metálicos presentes no poço	Liga-se a superfícies metálicas, como tubos ou ferramentas de fundo de poço. Qualquer produto restante é quebrado e consumido por microorganismos ou retornam à superfície junto à água produzida.
<i>Crosslinker</i>	Mantém a viscosidade do fluido de tratamento mesmo com o aumento da temperatura.	Combinado ao quebrador na formação forma sais que retornam a superfície junto à água.
Redutor de Fricção	Lubrifica a água de forma a minimizar a perda de carga.	Permanece na formação onde na presença de elevadas temperaturas e através da exposição ao quebrador pode ser consumido por microorganismos.
Agente gelificante	Torna a água mais viscosa de forma a possibilitar o carreamento do cascalho.	Mantém a viscosidade do fluido de tratamento até que o quebrador se torne ativo.
Controlador de Ferro	Previne contra a precipitação de metais nos tubos.	Reage com minerais da formação criando sais, dióxido de carbono e água
Agente de ajuste de pH	Mantém a efetividade de outros componentes como crosslinkers.	Reage com agentes ácidos no fluido de tratamento de forma a manter um pH neutro . Esta reação resulta em sais, água e dióxido de carbono.
Inibidor de incrustação	Previne contra a deposição de incrustações em equipamentos de fundo de poço e superfície.	Liga-se aos equipamentos de fundo de poço não permitindo o depósito de incrustações
Surfactante	Usado para elevar a viscosidade do fluido de fraturamento	Mantém a viscosidade do fluido de tratamento elevada até que o quebrador se torne ativo.

2.2.5.3 Propantes

Propantes, ou agentes de sustentação, são materiais, que impedem o fechamento das fraturas quando a injeção do fluido de fraturamento é interrompida, após o término do tratamento.

Estes sólidos devem apresentar resistência mecânica suficiente para resistirem às pressões internas impostas pelas rochas ao mesmo tempo em que devem possuir moderada densidade, de forma a não comprometer o seu processo de injeção na fratura (Barreto, 2010)

Além disso, devem reunir condições de não refluir para o poço, o que viria a provocar uma série de transtornos como o entupimento de bombas, contaminação do meio ambiente por partículas impregnadas de hidrocarbonetos, entre outros.

Como exemplos desses materiais, podemos encontrar: grãos de areia, areias tratadas com resina, cerâmica ou outras partículas.



Figura 2.5: Exemplo de propante cerâmico

(<http://www.made-in-china.com/showroom/topperchemicals/product-list/catalog-1.html>)

2.2.5.4 Mecânica do fraturamento

Rochas localizadas em subsolo encontram-se submetidas a um campo de tensões resultantes de diversos fatores. Consideram-se dois tipos de forças que atuam nos corpos geológicos: Forças de corpo (ou de volume) e forças de contato (ou superfície). (Teixeira *et. al*, 2010)

As forças de volume atuam sobre a massa de um corpo como um todo, a exemplo das forças gravitacional e eletromagnética, já as de contato atuam tracionando ou comprimindo o corpo rochoso ao longo de superfícies imaginárias.

As forças de contato são resultantes de fatores como a pressão litostática/hidrostatica e temperatura podendo ser divididas em 3 direções principais como mostrado na figura 2.6




Figura 2.6: Diagrama 3-D de tensões principais (Yew, 2008)

Onde, σ_1 representa a tensão vertical, σ_2 , a tensão horizontal mínima e σ_3 a máxima. Essas tensões são normalmente compressivas, anisotrópicas e não homogêneas, desta forma, os esforços compressivos na rocha não apresentam os mesmos valores e tem sua magnitude alterada de acordo com a direção.

A magnitude e direção das tensões principais são de grande importância no planejamento de uma operação, pois controlam a pressão necessária para criar e propagar uma fratura, sua forma e extensão, direção (horizontal, vertical ou inclinado),

e as tensões responsáveis por comprimir ou expulsar os agentes propantes durante a produção do poço.

A resistência natural de uma determinada formação está associada a sua estrutura, processo de compactação e cimentação, desta forma, somadas às tensões de contato defini-se o conjunto de forças responsáveis por manter a rocha unida.

Uma fratura hidráulicamente induzida é propagada perpendicularmente ao plano da menor tensão principal. Em formações rasas, a menor tensão é a resultante da sobrecarga, logo a fratura induzida será vertical. Fraturas horizontais são usualmente observadas em profundidades de até aproximadamente 300 metros (Holditch, 2007). Em reservatórios mais profundos a sobrecarga provocará a maior tensão, logo a fratura gerada é vertical.




Figura 2.7: Corte de um poço vertical demonstrando a atuação das tensões horizontais e direção de propagação de fratura. (Yew, 2008)

Para que se possa saber a orientação da fratura induzida deve-se estudar as tensões que a rocha reservatório está submetida analisando diagramas de tensões *versus* profundidade como o da figura 2.8

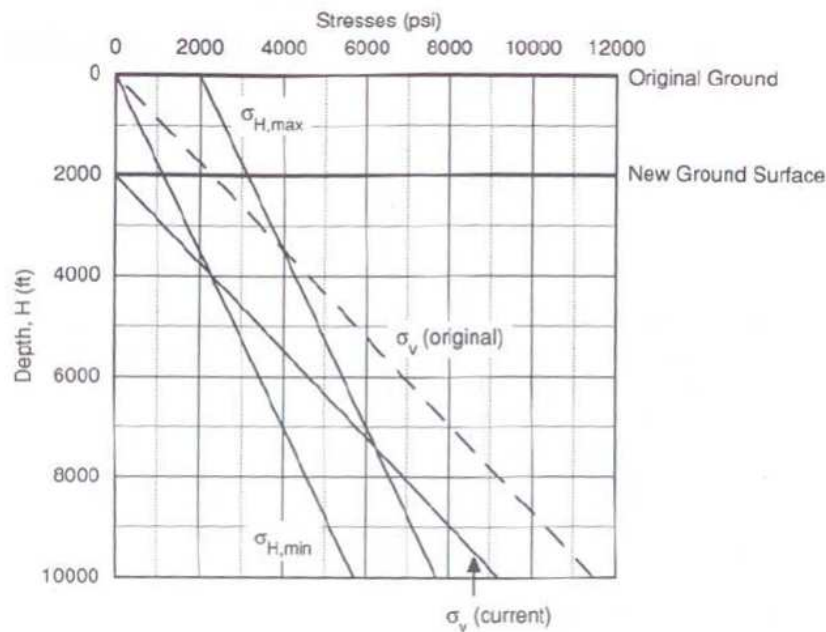


Figura 2.8: Diagrama tensão x profundidade (Yew, 2008)

A direção de propagação da fratura dependerá do azimuth das tensões principais, este fato torna-se especialmente crítico em poços desviados ou horizontais. Devido à ação de tensões cisalhantes não planares, a fratura hidraulicamente induzida pode estar em ângulo com o eixo do poço, podendo girar e se desviar durante os estágios iniciais de propagação, para alinhar seu plano perpendicular à mínima tensão, desta forma a abertura da fratura pode ser limitada ou fraturas múltiplas ao longo do poço podem ser produzidas (Yew, 2008)

A maioria dos poços candidatos a um fraturamento é revestida. Para se fraturar um poço revestido, ele é inicialmente canhoneado por meio de cargas moldadas de forma a se obter uma série de orifícios perfurados dispostos em forma de espiral ao longo da superfície do poço.

Os canhoneios possuem um espaçamento típico de 4 a 6 polegadas e um ângulo de fase de 60 a 120 graus conforme mostrado na figura 2.9. Quando o poço é pressurizado, os canhoneios na (ou próximos da) direção da máxima tensão horizontal *in situ* – σ_{max} - são os primeiros a serem fraturados.




Figura 2.9: Representação de um poço canhoneado (Yew, 2008)

2.2.5.5 Pressões no fraturamento

A operação de fraturamento hidráulico tem início com a pressurização do poço através do bombeio de fluidos. O aumento da pressão nos poros da rocha ocasiona uma tensão interna na formação de mesma magnitude em todas as direções. Quando esta tensão se torna mais elevada que a menor tensão que mantém a rocha coesa – σ_{\min} - tem-se então o surgimento de uma fratura perpendicular ao plano desta menor tensão (Yew, 2008).

A figura 2.10 exemplifica um típico registro de pressão de fundo (pressão medida no interior do poço, próximo a entrada da fratura). Pode-se observar que o diferencial de pressão aplicado primeiramente ultrapassa a pressão de poros do reservatório, e então supera a tensão compressiva alojada na parede do poço, causando uma tração em sua superfície. Quando a tensão superficial supera a resistência à tração da rocha, a fratura é então iniciada. A fratura se propaga hidraulicamente pelo reservatório conforme o bombeio é mantido, e, ao mesmo tempo, parte do fluido de fraturamento é perdido para o meio rochoso circundante por filtração.

É importante observar que a fratura é mantida pela diferença entre a pressão líquida (pressão do fluido menos a pressão do reservatório) e a tensão horizontal

mínima efetiva, enquanto que a taxa de filtração pela superfície da fratura é causada somente pela pressão líquida.




Figura 2.10: Gráfico pressão x tempo na operação de fraturamento (Yew, 2008)

A máxima pressão atingida no início do tratamento é pressão inicial de quebra P_b . Esta pressão tende a cair quando a fratura se inicia na superfície do poço. O trecho praticamente constante da curva de pressão é a pressão de propagação P_{prog} . Esta pressão é responsável pela propagação da fratura hidráulica pelo reservatório. Uma vez cessado o bombeio, a pressão cai subitamente, e continua a decrescer vagarosamente até a pressão do reservatório. O ponto de transição é chamado de pressão instantânea, Psi, ou ISIP (*Instantaneus Shut-In Pressure*).

Neste ponto o fluxo de fluido pela fratura cessa, e não há, portanto perda de carga ocasionada pelo mesmo. Contudo, ele continua a filtrar pela superfície da fratura até que sua pressão entre em equilíbrio com a tensão mínima *in-situ* resultando no seu fechamento.

3 TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL

Inteligência virtual diz respeito a uma coleção de novas ferramentas analíticas que buscam imitar a vida (Zaruda, Marks e Robinson, 1994). Técnicas de inteligência artificial possuem a habilidade de aprender ou lidar com novas situações. Redes neurais artificiais, Algoritmos Genéticos e Lógica Fuzzy são alguns dos principais paradigmas classificados como inteligência artificial.

Essas técnicas possuem um ou mais atributos de razão, como generalização, descoberta, associação e abstração e, nas últimas décadas, se consolidaram como recursos de auxílio à resolução de problemas anteriormente classificados como de difícil ou impossível resolução (Mohaghegh, 2000)

Segundo Russell et al (2004) e Guerrero et al (2002), as técnicas de inteligência artificial têm três características principais que as diferenciam dos outros métodos:

1. A busca; explora as distintas possibilidades em problemas onde os passos a seguir não são claramente definidos.

2. O emprego do conhecimento; permite explorar a estrutura e relações do domínio à que pertence o problema, e a redução do número de possibilidades por considerar, tal como fazemos os humanos.

3. A Abstração; proporciona a maneira de generalizar para os passos intrinsecamente similares

A tendência hoje em dia é a integração dessas técnicas entre si e com técnicas convencionais, como análises estatísticas.

Paradigmas inteligentes encontram-se difundidos em diversas áreas de conhecimento e estão consolidados comercialmente em diferentes produtos e setores da economia. Estão presentes em campos como medicina diagnóstica, detecção de fraudes em sistemas de cartões de crédito, aprovação de empréstimos bancários, sistemas de navegação automáticos entre outros.

Na indústria do petróleo, essas ferramentas são utilizadas para resolver problemas como análise de pressão transiente, interpretação de perfis, caracterização de reservatórios e seleção de poços para estimulação

3.1 REDES NEURAIS ARTIFICIAIS

3.1.1 HISTÓRICO DE REDES NEURAIS ARTIFICIAIS

Pesquisas na área de Redes Neurais Artificiais, também conhecidas sob a sigla RNA, remetem à década de 40, publicadas pela primeira vez em um artigo da autoria de Mc Colloch e Pitts (1943), (Mohaghegh, 2000).

Em 1957, Roseblatt desenvolveu uma rede simples, composta por única camada de neurônios com pesos sinápticos e bias ajustáveis chamada *perceptron*. Ele provou que, dadas classes linearmente separadas, um *perceptron* poderia, em um número finito de tentativas de treinamento, desenvolver um vetor peso capaz de separar essas classes (um problema de reconhecimento de padrões).

Aproximadamente no mesmo período Bernard Wildrow e Marcian Woff desenvolveram uma rede de características similares chamada *ADALINE* (*ADaptive LINear Elements* – Elementos lineares adaptativos)

Conforme o desenvolvimento das pesquisas, percebeu-se que cálculos elementares não poderiam ser resolvidos por *perceptrons* de uma única camada, desta forma, iniciava-se o estudo de estruturas mais robustas, acreditando-se que estas poderiam superar as limitações de *perceptrons* simples.

Entretanto, devido às dificuldades em desenvolver algoritmos de aprendizado que possibilitassem a resolução de problemas complexos, a comunidade científica deixou o paradigma das redes neurais de lado durante algumas décadas.

Este recesso durou até quando, no começo dos anos 80, motivados por pesquisas promissoras desenvolvidas por John Hopfield (1982), coincidentes com o surgimento de novos algoritmos de aprendizado, como o *backpropagation* em 1986 por Rumelhart, Hinton and Williams, as pesquisas sobre RNAs foram retomadas.

3.1.2 AS REDES NEURAIS ARTIFICIAIS (RNA)

Redes Neurais são modelos matemáticos que se assemelham às estruturas neurais biológicas e tem capacidade computacional adquirida por meio de aprendizado utilizando exemplos (Haikin, 1994, apud Orestes, 2005).

Por possuírem certas características de desempenho similares a do sistema nervoso animal, para melhor entender o funcionamento desses sistemas de processamento de informações, define-se a estrutura celular biológica antes de se oferecer uma definição detalhada do recurso computacional.

Todos os organismos vivos são feitos de células. A estrutura básica do sistema nervoso humano são unidades celulares denominadas neurônios.

Um neurônio típico possui um corpo celular (onde o núcleo é encontrado), dendritos, e um axônio conforme mostrado na figura 3.1




Figura 3.1: Estrutura de um neurônio humano

(adaptado de <http://muitasescleroses.files.wordpress.com/2011/09/90118467.jpg>)

Informações sob a forma de pulsos eletroquímicos entram na célula através dos dendritos. Dependendo da natureza deste input, o neurônio será ativado de forma

excitada ou inibida, produzindo então, um sinal de saída que viajará através do axônio, conectando-se a outro neurônio.

O local onde a terminação do axônio de um neurônio entra em grande proximidade com o dendrito de outro, possibilitando a passagem de impulsos eletroquímicos, é denominado Sinapse.

Estima-se que o cérebro humano contenha a ordem de 10 a 500 bilhões de neurônios. Esses neurônios são divididos em módulos, cada um contendo aproximadamente 500 redes neurais com aproximadamente 100.000 neurônios conectados a centenas ou milhares de outros mais (Rumelhart, McClelland, 1986)

Essa arquitetura é a força principal por trás de comportamentos que apesar de muitas vezes parecerem naturais, analisados mais a fundo mostram-se extremamente complexos. Simples tarefas como agarrar uma bola, beber um copo de água ou caminhar por um mercado, requerem cálculos de coordenadas de alta precisão que até mesmo computadores sofisticados não conseguem reproduzir.

Este fato torna-se especialmente mais interessante sabendo-se que neurônios cerebrais possuem tempos de resposta de 10 a 100 milissegundos, enquanto o de um típico chip de computadores desktop é medido em nano segundos.

Apesar de um milhão de vezes mais devagar que um computador de mesa, o cérebro humano pode desenvolver diversas tarefas à velocidade muito mais elevada devido à sua massiva arquitetura paralela.

Redes Neurais Artificiais (RNA) são sistemas de processamento de informações considerados aproximações grosseiras ou simulações simplificadas deste processo biológico e tem sua estrutura básica demonstrada na figura 3.2




Figura 3.2: Estrutura básica de uma rede neural artificial

(<http://www.cerebromente.org.br/n05/tecnologia/rna.htm>)

Elas foram desenvolvidas como generalização de modelos matemáticos da cognição humana ou biologia neural com base nas seguintes suposições:

- O processamento de informações ocorre em estruturas simples chamadas neurônios (elemento de processamento)
- Sinais são passados entre neurônios através de links de conexão
- Cada conexão tem um peso associado, que em uma típica rede neural, multiplica o sinal sendo transmitido.
- Cada neurônio aplica uma função de ativação (geralmente não linear) ao sinal de entrada a fim de se determinar o sinal de saída.

Na figura 3.3 é representado o esquema de um neurônio artificial, elemento básico de processamento da rede. O neurônio apresenta como entrada o vetor $X = \{x_1, x_2, \dots, x_n\}$ de dimensão n , e correspondente a este, um vetor de pesos $W = \{w_1, w_2, \dots, w_n\}$.

A ponderação das entradas x_i pelos pesos w_i somada a um peso independente b gera uma saída linear de acordo com a equação 3.1:

$$u = \sum x_i w_i + b \quad (3.1)$$

A saída Y do neurônio, denominada saída de ativação, é obtida pela aplicação de uma função $f(\cdot)$ à saída linear u , indicada por $Y = f(u)$.




Figura 3.3: Estrutura básica de um neurônio artificial (Orestes, 2004)

A função $f(.)$ é chamada de função de ativação do neurônio e pode assumir várias formas. Três tipos de funções de ativação usualmente utilizadas em redes neurais artificiais podem ser destacados (Demuth et al, 2008 apud Pitchon, 2008):

a) Logarítmica Sigmóide (logsig):

Seu valor de saída está compreendido no intervalo $[0; 1]$ e é representada pelo gráfico na figura 3.4.




Figura 3.4: Função de ativação Logsig (Demuth *et al.*, 2008 abud Pitchon, 2009).

b) Tangente Sigmóide (tansig):

Seu valor de saída está compreendido entre $[-1; 1]$ e seu gráfico é apresentado na figura 3.5.




Figura 3.5: Função de ativação tansig (Demuth *et al.*, 2008 abud Pitchon, 2009).

c) Puramente Linear (purelin):

Seu valor de saída é igual ao de entrada.




Figura 3.6: Função de ativação tansig (Demuth *et al.*, 2008 abud Pitchon, 2009).

Uma RNA apresenta uma coleção de neurônios dispostos em uma formação específica. É esta associação de neurônios que determina a capacidade da rede em desempenhar determinadas tarefas como a resolução de problemas de regressão, classificação, aproximação, otimização ou predição.

Nesta trabalho são destacadas as redes do tipo *Feed-forward*, ou de alimentação direta, as quais são apresentadas no item seguinte.

3.1.3 REDES NEURAIIS *FEED-FOWARD*

Nas redes de alimentação direta os neurônios encontram-se agrupados em camadas. Uma rede de múltiplas camadas usualmente é constituída por uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída. Não há troca de informações entre neurônios da mesma camada e não há realimentação na rede.

Na camada inicial cada neurônio recebe um valor proveniente do vetor de entrada (*inputs*), desta forma, o número de neurônios nesta, representará a quantidade de parâmetros que estão sendo apresentados à rede.

Em seguida o sinal é transmitido para as camadas intermediárias, ou escondidas, que são responsáveis, primariamente, pela extração de características e por coordenar atividades como classificação e reconhecimento de padrões.

Durante a passagem por estas camadas, os sinais de entrada são multiplicados pelos seus pesos e somados ao peso independente. A função de ativação e o número de neurônios empregados são parâmetros definidos pelo programador.

Por fim, na saída, os neurônios recebem os sinais da última camada escondida, resultando então em um vetor de resultados (*outputs*) de um ou mais elementos.

O desenho esquemático das camadas de uma rede neural pode ser observado na figura 3.7




Figura 3.7: Esquema das camadas de uma rede neural (Orestes, 2004)

3.1.4 TREINAMENTO DE RNA'S

O aprendizado da RNA é realizado através de sua exposição a um grande número de exemplos do caso estudado. Atrelando um conjunto de dados a um algoritmo de treinamento, a rede trabalhará iterativamente a fim de ajustar os pesos w existentes entre suas camadas, desta forma, à medida que interage com o meio externo, a rede busca a obtenção de resultados aceitáveis para o fim o qual esta foi projetada.

Uma das formas de classificações mais populares de redes-neurais é a baseada nos métodos de treinamento, que podem ser divididos em dois subgrupos: supervisionado e não supervisionado.

Redes Neurais de aprendizado não supervisionado, também conhecidas como mapas auto organizáveis, são algoritmos de clusterização e classificação. Elas recebem este nome, pois nenhum *feedback* é fornecido à rede. Sua utilização na indústria de óleo e gás é focada na interpretação de perfis e identificação litológica.

No aprendizado supervisionado pares de treinamento são fornecidos à rede que, com o auxílio de supervisores externos, monitorarão a resposta resultante de cada entrada, avaliando a diferença entre a saída da rede e a resposta esperada. Este fato não ocorre no aprendizado não supervisionado, quando não existem saídas esperadas para efeito de comparação.

A fase de treinamento de uma RNA é uma etapa crítica visto que se mal executada pode resultar no super treinamento da rede, fenômeno também conhecido na literatura como memorização. Esta ocorre quando a rede perde sua capacidade de generalização de resultados devido à repetição demasiada de sua rotina de aprendizado.

O primeiro modelo desenvolvido aplicando-se o conceito de aprendizado foi o *Perceptron* Simples, porém a solução de problemas mais complexos envolveria o treinamento de redes de múltiplas camadas. Neste sentido foram propostos diversos métodos, porém entre os existentes, o *backpropagation*, ou retropropagação, é um dos mais utilizados.

3.1.5 O ALGORITMO *BACKPROPAGATION*

Durante o treinamento com o algoritmo backpropagation, a rede opera em uma seqüência de dois passos demonstrados na figura 3.8.

Primeiro, um padrão é apresentado à camada de entrada. A atividade resultante flui através das camadas da rede, até que uma resposta seja encontrada. No segundo passo a saída obtida é comparada a saída desejada para um padrão particular. Caso esta não esteja correta, o erro é calculado, e então retro propagado a partir da camada de saída até a camada de entrada.

Desta forma os pesos das conexões internas vão sendo modificados até que, através da repetição desta rotina, a função desempenho erro seja minimizada (Carvalho, 2000).

A retro propagação é realizada através do cálculo das derivadas parciais do erro de saída em relação a cada um dos pesos da rede.




Figura 3.8: Operação do algoritmo backpropagation

Diversos algoritmos foram criados com o objetivo de realizar o ajuste ótimo das conexões de uma rede, muitos deles inspirados na regra de Delta para RNAs com apenas uma camada (*Perceptron*).

Na regra Delta, a atualização dos pesos é obtida seguindo a direção contrária ao gradiente do erro e pode ser descrita como:

$$\Delta W_{ij}(n) = -\gamma \frac{\partial E}{\partial W_{ij}} \quad (3.2)$$

Onde γ é uma constante de proporcionalidade denominada taxa de aprendizado e $\frac{\partial E}{\partial W_{ij}}$ é a derivada parcial do erro E em relação ao peso da conexão do neurônio j para o neurônio i.

O algoritmo *backpropagation* é uma extensão do método do gradiente para o treinamento supervisionado de redes de múltiplas camadas.

Para uma rede de duas camadas, a equação de ajuste na iteração (n+1) dos pesos da última camada é dada por:

$$wO_{ij}(n+1) = wO_{ij}(n) + \gamma e(n) f'(u_j(n)) x_i(n) \quad (3.3)$$

(Braga, Carvalho et al., 2000)

Onde $f'(u_j(n))$ é a derivada da função de ativação do neurônio j em relação a sua saída linear $u_j(n)$ e $x_i(n)$ é a saída do neurônio i da camada intermediária e γ é a taxa de aprendizado.

Para a camada intermediária, a equação de ajuste na iteração n+1 assume a seguinte forma:

$$wI_{ij}(n+1) = wI_{ij}(n) + \gamma f_j'(u_j(n)) \sum e(n) x_i(n) f'(u_j(n)) w_{ji}(n) x_i(n) \quad (3.4)$$

Onde o I se refere aos neurônios da camada intermediária e o termo $\sum e(n) x_i(n) f'(u_j(n)) w_{ji}(n) x_i(n)$ é uma estimativa do erro do neurônio j da camada intermediária utilizando o erro da camada de saída conforme a figura 3.9.

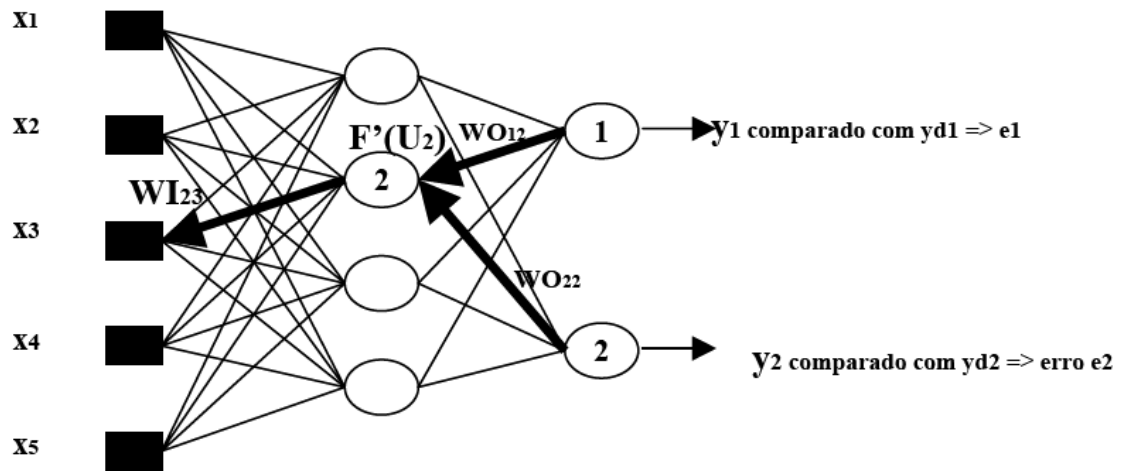


Figura 3.9: Backpropagation

Desta forma, o ajuste do peso WI_{23} será:

$$\Delta wi_{23} = \gamma F'_j(u_2) (wO_{12} e_1 f'_j(u_1) + (wO_{22} e_2 f'_j(u_2))) \quad (3.5)$$

Esta equação representa a propagação dos erros e_1 e e_2 das saídas, que serão utilizados no ajuste de um peso da camada intermediária. Este procedimento se repete até que os valores encontrados estejam dentro de limites aceitáveis ou até que o tempo programado para o treinamento se esgote.

3.2 ALGORITMOS GENÉTICOS

Computação evolucionária, como outras técnicas virtuais inteligentes, foram desenvolvidas com base em elementos da natureza e tem como objetivo a busca ótima de soluções para um determinado problema, através da tentativa de recriação do processo evolucionário, utilizando algoritmos e instruções computacionais.

Desde meados da década de 60, um conjunto de novas ferramentas analíticas de otimização inteligente foram desenvolvidas baseadas na teoria evolucionária de Darwin. O termo computação evolucionária generaliza grande parte dessas ferramentas e compreende técnicas como programação evolucionária, Algoritmos Genéticos, Estratégias de Evolução, entre outras, cada uma com seu diferente objetivo (Mohaghegh, 2000).

Hoje em dia, os Algoritmos genéticos são utilizados em áreas distintas como a de projeto de engenharia, otimização na área financeira, comportamento de processos baseados em análise de dados, entre outras (Orestes, 2005).

Como outras técnicas de busca heurística, os resultados obtidos podem não resultar sempre na solução ótima, porém esta se mostra de fácil implementação e alta eficiência ao lidar com parâmetros discretos.

Na indústria do petróleo a técnica vem sendo empregada para solução de problemas como:

- Otimização de estruturas em plataformas offshore;
- Roteamento de sondas;
- Otimização da operação de malhas de gasodutos;
- Otimização de programas de revestimentos de poços;
- Programas de produção.

3.2.1 OS ALGORITMOS GENÉTICOS

A teoria de Darwin de sobrevivência das espécies (1859), junto à de seleção de Weismann e genética de Mendel, servem de argumentos para a universalmente aceita Teoria da Evolução.

De acordo com Mohagheh (2000), na natureza o processo evolucionário ocorre quando as quatro seguintes condições são satisfeitas:

- Um indivíduo tem a capacidade de se reproduzir;
- Existe uma população destes indivíduos auto-reprodutores;
- Existe certa variedade entre estes indivíduos auto-reprodutores;
- Essa variedade está associada a diferenças na capacidade de sobrevivência em um dado meio ambiente.

Organismos se desenvolvem à medida em que se adaptam à ambientes dinâmicos. A aptidão de um determinado indivíduo é definida como o grau de adaptação a um meio específico. Esta capacidade do organismo determinará quanto tempo ele sobreviverá e a chance do mesmo transferir suas características para uma geração futura.

Na evolução biológica, somente os vencedores sobrevivem e dão continuidade ao processo evolutivo. Acredita-se que caso o organismo sobreviva através da adaptação ao seu meio, este seja mais preparado e possua características ideais.

Estas características são codificadas através de seus genes e podem ser transmitidas para sua prole através da hereditariedade, desta forma, quanto maior o nível de adaptação de um indivíduo, maior suas chances de sobrevivência e reprodução.

Inteligência e Evolução estão intimamente conectadas. Inteligência é definida como a capacidade de um sistema de adaptar o seu comportamento a fim de se atingir objetivos específicos dentro de uma faixa de ambientes (Fogel, 1995 apud Mohagheh, 2000).

Imitando o processo evolutivo através do uso de algoritmos computacionais, pesquisadores tentam reproduzir a inteligência associada com a capacidade de resolução de problemas dos processos evolutivos.

Como na vida real, este tipo de adaptação contínua pode gerar organismos muito robustos. O processo se estende através de diversas “gerações”, com a propagação dos melhores genes à medida que novos indivíduos são criados. O resultado em geral, é uma boa solução para o problema em estudo.

Na simulação computacional do processo evolutivo, operadores genéticos realizam a transferência de genes de geração para geração. Estes operadores (cruzamento, inversão e mutação) são as ferramentas primárias para a criação de novos indivíduos a partir das características de organismos mais adaptados da população de origem.

Através da ciclagem destes operadores, obtém-se uma surpreendentemente poderosa ferramenta capaz de preservar o equilíbrio crítico necessário a busca inteligente: O equilíbrio entre exploração (tomando vantagem de informações já obtidas) e exploração (buscando novas áreas de solução).

Apesar de simplório pelo ponto de vista biológico, estes algoritmos são suficientemente complexos para fornecer poderosos mecanismos de busca.

3.2.2 MECANISMOS DE UM ALGORITMO GENÉTICO

De acordo com Mohagheg (2000), o processo de otimização genética pode ser dividido nos seguintes passos:

- I. Geração de uma população inicial
- II. Avaliação da aptidão de cada indivíduo desta população
- III. Ranqueamento destes indivíduos com base em seu nível de aptidão
- IV. Seleção dos indivíduos melhor desenvolvidos para criação de uma nova população
- V. Utilização de operadores genéticos, como *crossovers*, inversão e mutação para geração da nova população
- VI. Continuar o processo através da repetição do passo 2 até que o objetivo seja satisfeito.

I. Geração de uma população inicial

A população inicial é usualmente gerada utilizando processos aleatórios cobrindo todo universo do problema. Isto irá garantir uma grande variedade no conjunto de genes.

Cada problema é então codificado através de uma coleção de genes (cromossomo), cada um representando um parâmetro no problema.

Em algoritmos genéticos clássicos, um vetor de 0s e 1s representa cada gene, desta forma, um cromossomo é um extenso vetor binário que inclui todos os parâmetros que compõe um indivíduo.

A figura 3.10 exemplifica um típico cromossomo de 5 genes. Este cromossomo foi gerado para a resolução de um problema codificado para busca da solução ideal utilizando 5 parâmetros.




Figura 3.10: Cromossomo de 5 genes (Mohagheg, 2010)

II. Avaliação da aptidão dos indivíduos da população

A aptidão de cada indivíduo é determinada através de uma função objetivo. Dado um cromossomo, a função de avaliação consiste em associar um valor numérico de "adaptação", no qual se supõe que seja proporcional a "utilidade" ou "habilidade" do indivíduo representado.

A meta da otimização é usualmente encontrar o máximo ou mínimo da função avaliação. Exemplos desse processo incluem, por exemplo, a minimização de um erro para um problema que deve convergir para um valor alvo ou a maximização de uma determinada variável de interesse.

III. Ranqueamento dos indivíduos da população com base no nível de aptidão

Uma vez avaliada a aptidão de cada indivíduo, os mesmos podem ser então ranqueados. Após esta etapa, chega-se ao momento de selecionar os progenitores responsáveis pela próxima população.

O processo de seleção atribui uma maior probabilidade de reprodução para o indivíduo melhor posicionado no ranking, decrescendo gradativamente de acordo com a posição dos seguintes.

IV. Seleção dos indivíduos melhor desenvolvidos para criação de uma nova população

Existem diversos métodos para se selecionar os melhores cromossomos, como por exemplo, Seleção da Roleta Giratória, Seleção de Boltzman, Seleção por Torneio, Seleção por Classificação, Seleção de Estado Seguro entre outras.

Em resumo, de acordo com as probabilidades definidas através do ranqueamento, cromossomos de maior nível de adaptação apresentarão maiores chances de serem selecionados e utilizados na criação de uma nova geração.

V. Utilização de operadores genéticos

Após o fim da etapa de seleção, operadores genéticos como de cruzamento, inversão e mutação são incorporados a fim de gerar a nova população. O processo evolutivo de sobrevivência ocorre na etapa de seleção e reprodução. Quanto melhor avaliado um indivíduo, maior a sua chance de reproduzir e passar seus genes para a próxima geração.




Figura 3.11: Cruzamento simples (Mohagheg, 2010)

No cruzamento, os indivíduos pais são primeiramente selecionados e então um ponto de quebra aleatório nos cromossomos é definido. Ambos os pais irão se partir no local definido e suas partes separadas trocarão de lugar. Este processo produz dois novos indivíduos. Um par de pais pode se quebrar em mais de um local em ocasiões diferentes para produzir mais de um par de filhos. A figura 3.11 exemplifica um processo simples de *crossover*.

Existem outros tipos de cruzamento além do simples, como cruzamento duplo e randômico. Nos cruzamentos duplos, cada pai se divide em dois locais diferentes, e as partes divididas são trocadas. No randômico, pais podem se dividir em diversos locais. A figura 3.12 exemplifica um *crossover* duplo.




Figura 3.12: Cruzamento duplo (Mohagheg, 2010)

Como mencionado anteriormente, existem outros dois operadores genéticos além dos de cruzamento. Os de inversão e os de mutação. Em ambos os casos a prole é gerada a partir de apenas um indivíduo.

Os operadores de inversão trocam todos os valores 0 em 1 e vice versa, para a criação de um novo indivíduo. O operador de mutação escolhe um local aleatório no vetor binário trocando o valor de um ou mais bits específicos.

A probabilidade de inversão ou mutação é muito menor que a de *crossover*. As figuras 3.13 e 3.14 trazem esquemas dos processos.



Figura 3.13: Operador de inversão(Mohagheg, 2010)




Figura 3.14: Operador de mutação (Mohagheg, 2010)

VI. Ciclo e término do processo

Uma vez gerada a nova população, a avaliação dos indivíduos através da função objetivo é então repetida e o processo entra em um ciclo com a repetição das etapas já praticadas.

Durante a primeira geração, o individuo de melhor aptidão é salvo como solução ótima do problema. Nas seguintes, o individuo mais desenvolvido é comparado ao individuo ótimo e, caso tenha nível de aptidão maior, toma o seu lugar. A convergência da solução pode ser avaliada através de diferentes critérios como erro mínimo, número de gerações e aptidão total da geração.

O procedimento explanado neste capítulo diz respeito ao processo clássico de Algoritmos Genéticos. Muitas variações deste processo existem.

3.2.3 PARÂMETROS GENÉTICOS

Ao se realizar uma otimização através de Algoritmos Genéticos, para que esta possa atingir seu objetivo de forma efetiva, se faz necessário o conhecimento da influência de seus parâmetros no resultado obtido (Orestes, 2000). Desta forma estes

podem ser estabelecidos conforme as necessidades do problema e dos recursos disponíveis.

Tamanho da População:

O tamanho da população afeta diretamente o desempenho global e a eficiência dos Algoritmos Genéticos. Deve-se buscar o equilíbrio ideal do número de indivíduos gerados, uma vez que populações pequenas podem apresentar uma reduzida cobertura do espaço de busca podendo convergir prematuramente para mínimos locais, ao mesmo tempo em que populações muito grandes representam um maior esforço computacional e possivelmente maior tempo de análise.

Taxa de Cruzamento:

Quanto maior a taxa de cruzamento, mais rapidamente novas estruturas serão introduzidas na população. Caso esta seja muito elevada, estruturas com boa aptidão poderão ser perdidas uma vez que a maior parte da população será substituída, porém com valores muito baixos, o algoritmo pode apresentar uma convergência muito lenta.

Taxa de Mutação:

Deve-se buscar um valor médio para a taxa de mutação a fim de possibilitar que se alcance qualquer ponto no espaço de busca. Valores baixos podem resultar na estagnação de uma dada posição em um valor local, já uma taxa muito alta torna a busca essencialmente aleatória.

Intervalo de Geração:

Tem por objetivo controlar a porcentagem da população que será substituída durante a próxima geração. Com um valor alto, a maior parte da população será substituída, podendo ainda ocorrer perda de estruturas de alta aptidão. Com um valor baixo, o algoritmo pode tornar-se muito lento

3.3 LÓGICA FUZZY

3.3.1 HISTÓRICO DA TÉCNICA

A ciência de hoje é baseada na lógica crisp de Aristóteles fundada há mais de 2000 anos atrás. Nesta forma de pensamento o mundo é visto de forma bivalente, como preto ou branco, sim ou não e 0 ou 1.

A teoria de conjuntos desenvolvida no século XIX na Alemanha pelo matemático Cantor foi baseada na lógica de Aristóteles e define os conjuntos como coleções de objetos distintos e bem definidos.

A figura 3.15 é um simples exemplo da teoria de conjuntos de Cantor, e suas operações comuns, como complemento, interseção e união.




Figura 3.15: Operações tradicionais na teoria de conjuntos clássica (Mohagheg, 2010)

O primeiro trabalho a abordar lógica vaga, de autoria do filósofo americano Charles S. Pierce, data do início do século XX, nesta mesma época alguns matemáticos e filósofos como Polish, Lukasiewicz e Black dedicaram-se ao estudo de lógicas de valores múltiplos e conjuntos vagos. (Mohagheg, 2000)

Esses cientistas foram os principais responsáveis pela construção dos fundamentos onde a lógica fuzzy, ou difusa, foi mais tarde desenvolvida.

Finalmente em 1965, Lofti Zadeh, conhecido como pai da Lógica Fuzzy, publicou o artigo “Fuzzy Sets” considerado um marco na história dos conjuntos difusos. (Mohagheg, 2000)

Ele desenvolveu diversos conceitos chave, oferecendo uma base compreensiva para aplicação da teoria em problemas científicos e de engenharia.

Esta base incluiu as operações clássicas de conjuntos fuzzy e as chamadas funções de pertinência, as quais compreendem todas as ferramentas matemáticas necessárias para aplicação da teoria de conjuntos fuzzy a problemas reais.

Por seu caráter não exato, a lógica fuzzy teve grandes dificuldades de aceitação pela comunidade científica ocidental ainda na década de 70, e possivelmente devido à características culturais, se desenvolveu mais rapidamente no oriente, em países como o Japão (Mc Neill, Freiburger, 1993)

Enquanto a lógica fuzzy era atacada nos Estados Unidos, grupos japoneses construíram uma indústria bilionária ao redor desta tecnologia.

Hoje, os japoneses detêm mais de 2000 patentes relacionadas à este tipo de ciência. Eles utilizaram esta tecnologia no desenvolvimento de eletrodomésticos como lava-louças ou aspiradores de pó, máquinas de arroz, fornos microondas, câmeras digitais e carros.

3.3.2 TEORIA DE CONJUNTOS FUZZY

Os processos humanos de pensamento, raciocínio e tomada de decisão não são exatos. Usamos palavras vagas e imprecisas para expor nossas idéias e nos comunicarmos.

Existe uma contradição entre o processo impreciso de pensamento humano e a lógica científica exata, essa contradição fez surgir abordagens não práticas do uso de computadores assistindo humanos no processo de tomada de decisão e pode ser apontada como principal razão para que sistemas tradicionais de inteligência artificial

ou sistemas baseado em regras (também conhecidos com “*expert systems*”) não tenham obtido sucesso.

Essencialmente, a lógica fuzzy fornece os meios para a computação através de palavras. Usando a lógica fuzzy, especialistas não necessitam resumir seu conhecimento a uma linguagem que máquinas ou computadores possam compreender.

Esta é capaz de prover meios de representação de incertezas resultantes tanto da natureza aleatória de eventos quanto da imprecisão ou ambigüidade da informação disponível sobre o problema que se deseja resolver.

Em processos aleatórios, os resultados de um evento, entre diversas possibilidades, é estritamente o resultado de uma probabilidade. Quando a incerteza é um produto de eventos aleatórios, a teoria da probabilidade é a ferramenta apropriada a ser utilizada. Observações e medições podem ser usadas para solucionar este tipo de incertezas. Por exemplo, quando uma moeda é jogada para o alto, nada mais que incertezas aleatórias ou estatísticas permanecem.

A maioria das incertezas, especialmente quando se lida com sistemas complexos, são resultado da falta de informação, imprecisão, falta de habilidade em realizar medidas adequadas, falta de conhecimento ou do caráter vago das variáveis

A teoria de conjuntos fuzzy, através de seus conjuntos e controladores nebulosos, é uma boa ferramenta para lidar com modelos matemáticos sujeitos à este tipo de imprecisão.

Em conjuntos exatos, um determinado objeto pertence ou não a um conjunto. Na lógica fuzzy tudo é uma questão de grau de associação, desta forma um objeto pertence a um determinado conjunto em certo nível, trocando o conceito de verdadeiro ou falso por conceito parcial destes resultados.

Um controlador nebuloso é um sistema a base de regras de produção do tipo Se (premissa) Então (conclusão), que definem ações de controle em função das diversas faixas de valores que as variáveis de estado do problema podem assumir.

Essas faixas, usualmente mal definidas, de valores são modeladas por conjuntos nebulosos denominados de termos linguísticos.

A maior dificuldade na criação de sistemas nebulosos em geral, e de controladores nebulosos em particular encontra-se na definição dos termos linguísticos e das regras.

3.3.2.1 Conceitos básicos da teoria dos conjuntos nebulosos

Um conjunto nebuloso A do universo de discurso Ω é definido por uma função de pertinência $\mu_A : \Omega \rightarrow [0,1]$.

Essa função associa a cada elemento x de Ω o grau $\mu_A(x)$, com o qual x pertence a A . A função de pertinência $\mu_A(x)$ indica o grau de compatibilidade entre x e o conceito expresso por A :

- $\mu_A(x) = 1$ indica que x é completamente compatível com A ;
- $\mu_A(x) = 0$ indica que x é completamente incompatível com A ;
- $0 < \mu_A(x) < 1$ indica que x é parcialmente compatível com A , com grau $\mu_A(x)$.




Figura 3.16: Comparação entre funções do tipo booleana e fuzzy (Pitchon, 2009)

Como representado na figura 3.16, Um conjunto A da teoria dos conjuntos clássica pode ser visto como um conjunto nebuloso específico, denominado usualmente de “crisp”, para o qual $\mu_A : \Omega \rightarrow \{0,1\}$, ou seja, a pertinência é do tipo booleana, e não gradual como para os conjuntos nebulosos.

A cardinalidade de um conjunto nebuloso A é expressa como:

- Para Ω discreto:

$$|A| = \sum \mu_A(x) \quad (3.6)$$

- Para Ω contínuo:

$$|A| = \int \mu_A(x) \quad (3.7)$$

Definimos o suporte de \tilde{A} como o conjunto de todos os pontos x em X tais que $\mu(A) > 0$. Um conjunto fuzzy é normal se o seu centro não é vazio, ou seja, existe sempre um ponto $x \in X$ tal que $\mu(A) = 1$. Define-se corte α ou um conjunto de cortes α , de um conjunto fuzzy A, com um conjunto $A_\alpha = \{x \mid \mu(A) \geq \alpha\}$.

3.3.2.2 Variáveis Linguísticas

As variáveis lingüísticas são aquelas que seus valores não são expressos por números, mas por palavras ou sentenças em linguagem natural (Orestes, 2005).

Uma variável lingüística como temperatura poderá assumir valores lingüísticos como alta, baixa e moderada, que expressem as sensações e não um valor determinado que só possa ser obtido através de instrumentos.

A figura 3.17 ilustra um exemplo de descrição lingüística da variável temperatura de um determinado processo:

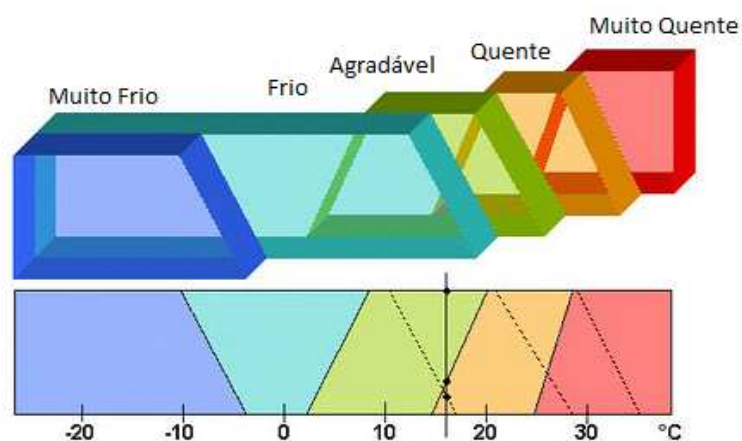


Figura 3.17: Funções de pertinência da variável linguística temperatura

(<http://siadmoments.blogspot.com.br/2007/11/blog-post.html>)

3.3.2.3 Funções de pertinência fuzzy

Cada conjunto fuzzy é caracterizado pela sua função de pertinência, geralmente são representados por $\mu(x)$. É através delas que serão determinadas o quanto um determinado elemento pertence ao conjunto (ZIMMERMAN, 1991). De acordo com sua aplicação ou a maneira de representar em um determinado contexto existem diferentes tipos de funções de pertinência.

Existem diferentes tipos de função de pertinência, diferenciados quanto a sua geometria, entre elas pode-se citar as triangulares, trapezoidais, Gaussianas, Cauchy e Sigmóides.

Triangular	Retangular	Trapezoidal	Gaussiana	Sigmóide

Figura 3.18: Geometria das funções de pertinência

3.3.2.4 Operações em Conjuntos Nebulosos

As operações de conjuntos fuzzy são similares às dos conjuntos “crisp”, e compreende as operações de interseção, união, negação, entre outras.

A seguir são demonstradas as principais operações com conjuntos fuzzy:

- **União**

Equivalente ao operador *OU* da lógica Booleana, a função de pertinência da união de dois conjuntos fuzzy A e B com funções de pertinência $\mu_a(x)$ e $\mu_b(x)$ respectivamente é definida como sendo o máximo destas funções.




Figura 3.19: União de conjuntos fuzzy (Orestes, 2005)

- **Interseção**

Equivalente ao operador *E* da lógica Booleana, considerando-se os mesmos conjuntos fuzzy A e B com funções de pertinência μ_a e μ_b respectivamente é definida como sendo o mínimo destas funções.




Figura 3.20: Interseção de conjuntos fuzzy (Orestes, 2005)

- **Complemento**

A função de pertinência do complemento de um conjunto fuzzy A com função de pertinência μ_A é definida como:

$$\mu_{\bar{A}} = 1 - \mu_A$$




Figura 3.21: Complemento de conjuntos fuzzy (Orestes, 2005)

Algumas propriedades de conjuntos fuzzy são similares as dos conjuntos crisp, dentre elas podemos citar:

- **Associatividade:** $(A \cap B) \cap C = A \cap (B \cap C)$
 $(A \cup B) \cup C = A \cup (B \cup C)$
- **Comutatividade:** $A \cap B = B \cap A$
 $A \cup B = B \cup A$
- **Distributividade:** $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$
 $A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$

3.3.2.5 Base de Conhecimento e raciocínio fuzzy

A base de conhecimento é constituída por uma base de dados submetida a uma base de regras, de maneira a definir a estratégia de controle e as suas metas.

Na base de dados ficam armazenadas as definições sobre discretização e normalização dos universos de discurso, e as definições das funções de pertinência dos termos nebulosos.

O raciocínio fuzzy pode se dividir em três itens independentes: valores verdade, operadores e procedimentos de raciocínio. Os valores verdade, resultantes das funções de pertinência, são definidos pelas variáveis lingüísticas associadas aos seus respectivos conjuntos fuzzy, os operadores permitem a união das variáveis lingüísticas para formação de regras. Como procedimento de raciocínio pode-se utilizar o exemplo abaixo:

Se temperatura é alta e pressão alta Então perigo é grande.

Temos assim:

- Variáveis Lingüísticas: Temperatura, pressão e nível de perigo.
- Conjuntos fuzzy: alta, grande
- Operadores da regra: se, e, então

Estas regras, juntamente com os dados de entrada, são processados pelo procedimento de inferência, o qual interpreta as ações de controle de acordo com o estado do sistema, aplicando o operador de implicação.

Em um dado controlador nebuloso, é importante que existam tantas regras quantas forem necessárias para mapear totalmente as combinações dos termos das variáveis, isto é, que a base seja completa, garantindo que exista sempre ao menos uma regra a ser disparada para qualquer entrada. Também é essencial a consistência,

onde procura-se evitar a possibilidade de contradições e a interação entre as regras, gerenciada pela função de implicação de modo a contornar a situação de ciclo.

3.3.2.6 Processamento Fuzzy

O processamento fuzzy é composto de por três etapas que são a fuzzificação, a inferência e a defuzzificação. Estas três etapas fecham um ciclo que permitem a resolução de muitos problemas e que são bastante utilizados em sistemas de controle.

O esquema da figura 3.22 ilustra as etapas deste ciclo

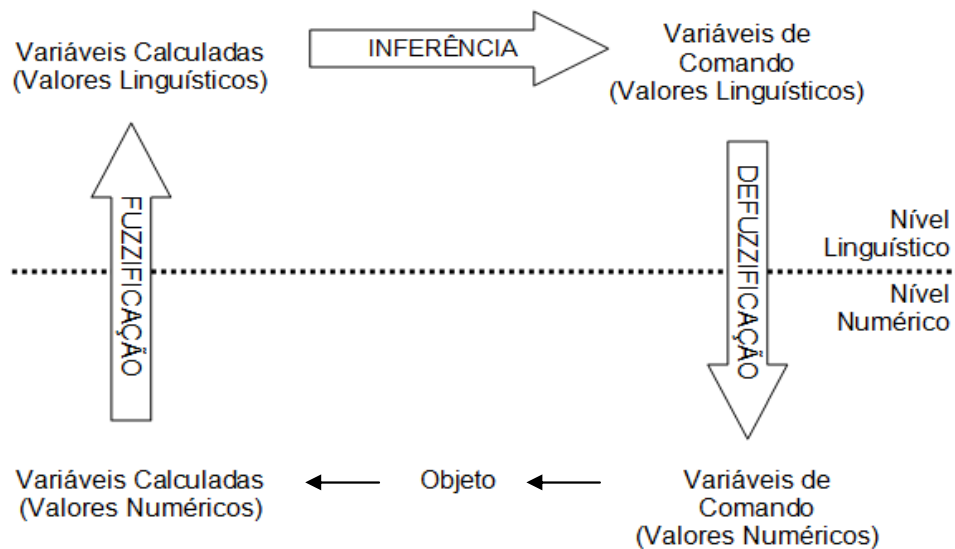



Figura 3.22 : Ciclo Fuzzy


1. Fuzzificação:

Nesta etapa será realizada a transformações dos valores de entrada crisp em conjuntos fuzzy através da utilização das variáveis lingüísticas e suas funções de pertinência, formando então os conjuntos fuzzy.

Desta forma uma variável como velocidade que pela lógica clássica poderia ser classificada da seguinte forma:



Após a fuzzificação poderia adquirir a seguinte estrutura:



2. Sistema de inferência :

De acordo com Sandri e Correa (1999), o procedimento de inferência consiste na:

1. Verificação do grau de compatibilidade entre os fatos e as cláusulas nas premissas das regras;
2. Determinação do grau de compatibilidade global da premissa de cada regra;

3. Determinação do valor da conclusão, em função do grau de compatibilidade da regra com os dados e a ação de controle constante na conclusão (precisa ou não);
4. Agregação dos valores obtidos como conclusão nas várias regras, obtendo-se uma ação de controle global.

O modelo clássico de inferência funciona da seguinte maneira:

Passo 1: Dada uma variável de estado x_i , definida no universo X_i , a realização de x_i é definida como o valor $x_i^* \in X_i$, que esta assume em X_i em um determinado momento;

Passo 2: A *compatibilidade* da premissa i de uma regra j com x_i^* , ou seja, a compatibilidade de x_i^* , $1 \leq i \leq n$, com A_{ij} da regra R_j , $1 \leq j \leq m$, é definida por:

$$\alpha_{ij} = \mu_{A_{ij}}(x_i^*), \quad 1 \leq i \leq n, \quad 1 \leq j \leq m \quad (3.9)$$

Passo 3: Com as premissas de uma dada regra avaliadas, a compatibilidade global α_j da regra R_j , $1 \leq j \leq m$, com os x_i^* é determinada com uma t-norma T :

$$\alpha_j = T(\alpha_{1j}, \dots, \alpha_{nj}), \quad 1 \leq j \leq m \quad (3.10)$$

Passo 4: O α_j assim obtido é relacionado com o respectivo conjunto nebuloso C_j do conseqüente da regra R_j , dando origem a um conjunto C'_j , $1 \leq j \leq m$, através de um operador com implicação I :

$$\mu_{C'_j} = I(\alpha_j, \mu_{C_j}(y)) \quad (3.11)$$

Passo 5: Um operador ∇ faz a agregação das contribuições das várias regras acionadas C'_j num único conjunto nebuloso C' :

$$\mu_{C'}(y) = \nabla(\mu_{C'_1}(y), \dots, \mu_{C'_m}(y)), \forall y \in Y \quad (3.12)$$

Um operador ∇ é usualmente um t-conorma, quando o operador de implicação I é uma t-norma, e uma t-norma em caso contrário.

Os tipos de controladores nebulosos encontrados na literatura são os modelos clássicos, compreendendo o modelo de Mandani e o de Larsen, e os modelos de de interpolação, compreendendo o modelo de Takige-Sugeno e o de Tsukamoto.

3.3.2.7 Procedimento de “Defuzzificação”

A defuzzificação é o procedimento responsável pelo tratamento do conjunto resultante da união das regras acionadas durante o processamento fuzzy afim de se obter uma saída que possa ser utilizada de forma prática para tomada de decisão.

Este processo é definido como a conversão de uma quantidade fuzzy em uma quantidade precisa na forma de um valor escalar unitário.

Existem vários procedimentos de defuzzificação, onde podemos citar:

- **Valor de maior pertinência:** cujo valor crisp de x resultante da defuzzificação é representado pelo de maior pertinência. [$\mu(x) \geq \mu(x)$ para todo $x \in X$]

- **Valor da média ponderada:** Este procedimento é mais apropriado para funções agregadas simétricas. É avaliado pela ponderação dos máximos de cada conjunto que compõe a agregação.

- **Centróide ou centro de gravidade do conjunto fuzzy:** A coordenada x do centro de gravidade da figura formada pelo conjunto fuzzy agregado é o valor defuzzificado capaz de representar toda a análise efetuada até então. [$\mu(x) = \int \mu(x) \cdot x \, dx / \int \mu(x) \, dx$]

- **Média da máxima pertinência:** Este método é utilizado quando a máxima pertinência não possui um único valor.

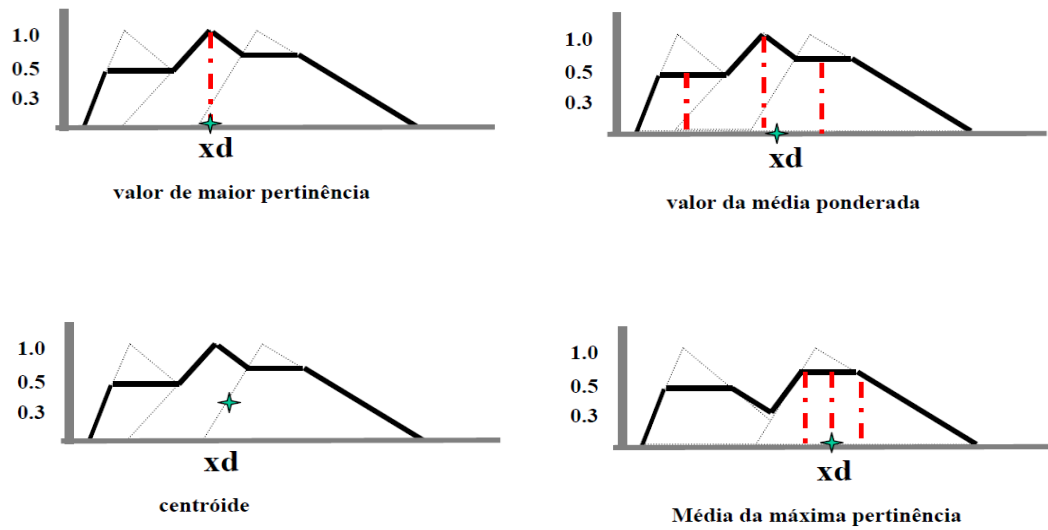


Figura 3.23: Procedimentos de defuzzificação (Orestes, 2005)

4 SELEÇÃO DE POÇOS PARA REESTIMULAÇÃO ATRAVÉS DO USO DE TÉCNICAS INTELIGENTES - ESTUDO DE CASO

4.1 DESCRIÇÃO

A metodologia de seleção de poços para estimulação bem como o estudo de caso realizado foram retirados do paper SPE 59767 “*Development of an Intelligent Systems Approach for Restimulation Candidate Selection*” de autoria de Shahab Mohaghegh, Scott Reeves e David Hill. (Mohaghegh, Reeves e Hill, 2000)

Neste trabalho, publicado no ano de 2000, é apresentado o resultado da pesquisa de uma metodologia de seleção de poços para reestimulação com base nas técnicas de inteligência artificial Redes Neurais Artificiais, Algoritmos Genéticos e Lógica Fuzzy.

A efetividade desta metodologia é então analisada através de um estudo de caso realizado em um campo de gás na bacia de *Green River*, nos Estados Unidos e apresentado a seguir.

4.1.1 INTRODUÇÃO

Em 1996, o instituto americano “*Gas Research Institute*” (GRI) realizou um estudo para investigar o potencial do aumento de produção gerado através de tratamentos de reestimulação nos Estados Unidos. Os resultados da pesquisa indicaram que apesar do alto potencial da prática (mais de 1 trilhão de pés cúbicos em 5 anos somente para a região do país) as dificuldades na realização de tarefas como seleção de candidatos, diagnóstico de problema e seleção/design/ implementação de tratamentos de estimulação de forma técnica e economicamente efetiva ainda eram significativas.

Dada à falta de tecnologia na área de reestimulação e a escassez de mão de obra especializada no planejamento e execução da operação, o Instituto iniciou um projeto

de pesquisa e desenvolvimento em 1998 com diversos objetivos, entre eles pode-se citar:

- 1) Desenvolvimento de uma metodologia eficiente e de baixo custo para seleção de poços candidatos a operação;
- 2) Identificação e investigação dos mecanismos responsáveis pela baixa performance de poços;
- 3) Desenvolver e testar técnicas de reestimulação específicas para causas de baixa produtividade de poços.

Atendendo ao primeiro dos objetivos citados, uma metodologia integrada dividida em quatro principais etapas foi desenvolvida para selecionar candidatos potenciais a reestimulação de forma confiável e economicamente viável.

Primeiramente, uma sofisticada abordagem estatística é utilizada para identificar tanto diferenças óbvias como sutis na performance dos poços, provendo assim idéias iniciais de potenciais candidatos.

Em um segundo momento técnicas de inteligências artificial (um híbrido de redes neurais artificiais, algoritmos genéticos e lógica fuzzy) são utilizadas de forma a reconhecer padrões ao relacionar resultados de tratamento já executados à características do reservatório, geologia, completação e estimulação dos poços em estudo.

Através dessas informações, variáveis controláveis e de influência no processo podem ser identificadas e utilizadas na busca pelas possíveis causas de baixa produtividade e dar início então a fase inicial de planejamento da operação a ser realizada. Em seguida, métodos de engenharia como curvas-tipo podem ser utilizados para ranquear os possíveis candidatos a operação oferecendo uma indicação relativa da qualidade do reservatório e eficiência da completação.

Finalmente poços de alto potencial são individualmente analisados para verificação de sua integridade mecânica, pressão do reservatório e outras informações de histórico do poço que possam não terem sido abordadas durante as etapas anteriormente citadas. Por fim, a viabilidade econômica do tratamento é avaliada finalizando o processo.

No artigo em estudo, são apresentadas as técnicas utilizadas na segunda etapa do processo, nomeadas de *O Uso da Inteligência Artificial na Seleção de Poços Candidatos para Reestimulação*.

Uma vez já explanados os conceitos básicos sobre cada uma das técnicas de inteligência artificial citadas, como também da operação de estimulação por fraturamento hidráulico, apresenta-se em seguida a metodologia presente no artigo como também o estudo de caso realizado

4.1.2 O USO DA INTELIGÊNCIA ARTIFICIAL NA SELEÇÃO DE POÇOS CANDIDATOS PARA REESTIMULAÇÃO.

Nesta seção é apresentada a metodologia de seleção de poços pra reestimulação desenvolvida no trabalho e aplicada em uma formação na região americana de *Rocky Mountains* a fim de se demonstrar sua aplicabilidade em campo.

A figura 4.1 é um Fluxograma representativo do processo desenvolvido e também serve de base para explicação da função de cada recurso inteligente.

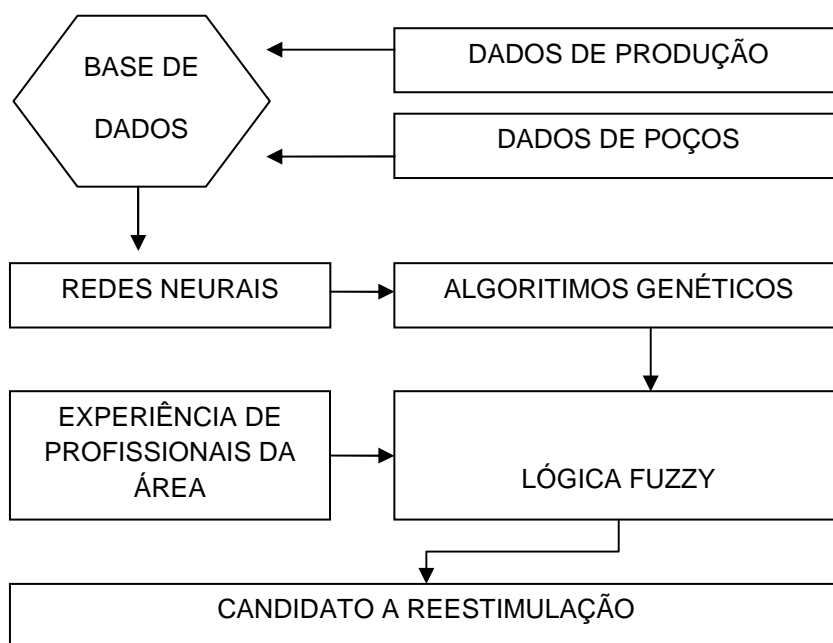


Figura 4.1: Fluxograma da metodologia desenvolvida

- Dados de Pesquisa

Três etapas são adotadas para seleção de candidatos a reestimulação utilizando inteligência artificial, antes do início do processo, porém, um conjunto de dados que inclua todas as informações relevantes definidas para a realização da operação em um determinado campo deve ser compilado.

Esses dados, que podem ser encontrados em arquivos de poços ou banco de dados, devem conter quatro categorias principais de informações. A primeira, diz respeito a informações gerais de cada poço, como por exemplo, coordenadas de localização, profundidade, data de início de produção entre outras.

A segunda categoria se refere à qualidade do reservatório, incluindo dados como de porosidade, *net pay*, saturação, permeabilidade (se disponível) e indicadores de pressões. Caso o reservatório possua diferentes camadas, se faz necessário possuir esse tipo de informação para cada uma das zonas de interesse.

O terceiro grupo de informações engloba dados relacionados ao projeto do tratamento. Enquadram-se nesta categoria dados de tipo e volume de propante e fluido de fraturamento a serem utilizados, densidade das cargas de canhoneado, número de zonas e camadas envolvidas em cada trabalho de fraturamento.

Por fim, a última categoria diz respeito principalmente aos dados de produção. Estes são utilizados para o cálculo da produção acumulada em 5 anos de cada poço, parâmetro esse, que correlacionado aos citados nas outras categorias, oferecerá subsídio para a criação de um modelo capaz de prever o resultado de operações ainda não realizadas. Na figura 4.2 um quadro resumo das categorias e seus dados é apresentado.

<p>CATEGORIA 1</p> <p>Características dos Poços:</p> <p>Localização</p> <p>Profundidade</p> <p>Início da Produção</p> <p>...</p>	<p>CATEGORIA 2</p> <p>Dados de Reservatório:</p> <p>Porosidade</p> <p><i>Net Pay</i></p> <p>Permeabilidade</p> <p>Dados de Pressões</p>
<p>CATEGORIA 3</p> <p>Dados do Tratamento:</p> <p>Tipo e Volume de Propante</p> <p>Tipo e Volume de fluido de fraturamento</p>	<p>CATEGORIA 4</p> <p>Dados do Produção:</p> <p>Produção acumulada no período de 5 anos após a realização do tratamento</p>


Figura 4.2: Categorias de dados para implementação da metodologia

- Aplicação da Metodologia

Uma vez compilado o conjunto de dados, a próxima etapa envolve a aplicação dos recursos inteligentes.

O processo é iniciado através do uso de Redes Neurais Artificiais, estas são utilizadas a fim de se construir um modelo representativo da performance de um poço em um determinado reservatório de estudo.

O conjunto de dados definido é utilizado então como pares *input-output* para o treinamento da rede, servindo as três primeiras categorias – informações dos poços, qualidade do reservatório e dados de simulação - como dados de entrada e a última – histórico de produção - como de saída.



4.3: Ilustração da rede neural criada para modelagem do problema

Dada a grande complexidade em realizar esta modelagem através de técnicas convencionais, como a modelagem matemática, redes neurais podem servir como valioso artifício na identificação de possíveis correlações entre parâmetros de poço, reservatório, dados de tratamento e do resultado da interação dessas características no ganho de produção alcançado após a realização da operação.

Uma vez implementado um modelo neural razoavelmente acurado e representativo do processo para a formação em estudo, análises adicionais podem ser então realizadas.

Estas análises podem incluir, por exemplo, o uso do modelo para teste de hipóteses de comportamento do poço face à mudanças em parâmetros de tratamento, auxiliando assim na identificação das melhores práticas a serem aplicadas em campo.

Este tipo de estudo leva à segunda etapa da metodologia. Em posse de um modelo representativo para a formação em estudo, como utilizar este recurso na

identificação dos poços com maiores potenciais para sofrer o tratamento de estimulação?

Uma vez que as Redes Neurais são capazes de identificar as melhores práticas a serem adotadas em campo, diferentes tipos de tratamento de fraturamento hidráulico podem ser testados a fim de se verificar qual a melhor forma de tratamento para um poço em um determinado momento. O grau de distanciamento do tratamento ideal é traduzido na perda de oportunidade de produção, que pode ser utilizado como indicador do potencial para reestimulação.

Para executar esta parte da análise são utilizados os Algoritmos Genéticos, com isso, as redes neurais desenvolvidas na primeira etapa do processo servem agora como função de pertinência para as rotinas dos Algoritmos Genéticos.

O processo de aferição da perda de oportunidade de produção funcionará então da seguinte maneira:

O modelo neural desenvolvido na primeira seção da metodologia é capaz de prover uma saída (Produção acumulada em 5 anos) baseado nos dados de entrada da rede (informações dos poços, qualidade do reservatório e dados de simulação do tratamento).

Entre os dados de entrada citados, somente os parâmetros relativos ao design do tratamento de estimulação podem ser controlados, dados de poço e reservatório estão fora do poder de controle do engenheiro.

Desta forma os Algoritmos Genéticos são utilizados na busca inteligente pela combinação de parâmetros controláveis do tratamento que possam resultar em uma produção ótima. A diferença entre o resultado alcançado através do modelo, e a previsão de produção do poço sem a realização do tratamento é interpretada como o ganho de produção potencial caso seja realizada a estimulação.

Esta análise conclui a segunda parte da metodologia, porém a seleção do candidato não é baseada inteiramente nos resultados fornecidos pelos Algoritmos Genéticos.

O terceiro e último passo para seleção do candidato a reestimulação incorpora ao processo um sistema Fuzzy de suporte à decisão.

Os sistemas especialistas Fuzzy usarão nesta etapa as informações fornecidas pelas redes neurais e algoritmos genéticos. Eles conjugam o resultado obtido nas duas primeiras etapas às informações provenientes da experiência profissional de especialistas da área, muitas vezes com experiência de anos no campo estudado. Desta forma a seleção não é feita baseada apenas em recursos computacionais e matemáticos, mas também humanos.

O sistemas de inferência Fuzzy são capazes de incorporar a linguagem natural ao processamento de informações. Esta capacidade pode fornecer grande ganho de eficiência especialmente quando de posse de informações imprecisas para tomada de decisões.

Uma regra típica em sistemas de inferência fuzzy que pode auxiliar o profissional a ranquear candidatos a reestimulação pode ser expressa como a seguir:

“Se o poço mostra um *grande potencial* de aumento na produção acumulada em 5 anos, **E** uma *pressão de reservatório moderada*, **E** apresenta um *baixo volume de propante* para o net pay completado, **Então** o poço é um *bom candidato a reestimulação*.”

Um valor verdade é associado a cada regra no sistema fuzzy desenvolvido para esta metodologia. O processo de tomada de decisão utilizando sub-conjuntos fuzzy e valores verdade relativos como regras, oferece as bases para utilização do raciocínio aproximado na tomada de decisões.

Esse processo é conhecido como um dos mais robustos métodos no desenvolvimento de sistemas de inferência de alto nível em diversas indústrias.

4.1.3 ESTUDO DE CASO: FORMAÇÃO *FRONTIER*, BACIA DE *GREEN RIVER*.

Nesta seção a metodologia proposta é aplicada a formação Frontier na bacia de Green River, localizada na parte oeste dos Estados Unidos entre os estados de Utah, Colorado e Wyoming.



Figura 4.4: Localização da Bacia de Green River (Mohaghegh, Reeves e Hill, 2000)

Como primeira etapa do processo, redes neurais artificiais são utilizadas na construção do modelo representativo do desempenho dos poços da bacia em estudo através da correlação entre dados de entrada e saída esperada. No caso, servem como dados de entrada à rede parâmetros de localização, reservatório, completação e fraturamento e de saída, a produção acumulada em 5 anos após o tratamento.

Tabela 4.1: Parâmetros utilizados como input na análise através de Redes Neurais Artificiais

Categoria	Parâmetro de Input	Comentários
Localização	X	Coordenadas X do poço (leste-oeste)
	Y	Coordenadas Y do poço (norte-sul)
	KB	Elevação do Kelly Buching
Reservatório	Permeabilidade	Obtido através de análise de curva tipo
	Área drenada	Obtido através de análise de curva tipo
	Volume de Gás in place	Obtido através do cálculo: Porosidade x Saturação de Gás x Net Pay
Completção	Altura total completada	Altura completada de todas as zonas
	Número total de canhoneados	Número total de disparos efetivos
	Data da completação	Data em que o poço foi completado
	Número de zonas	Número de zonas completadas
Fraturamento	Número de fraturamentos	Um poço pode sofrer mais de 7 tratamentos de fraturamento
	Tipo de Fluido	Base Óleo gelificado, não gelificado, gel linear...
	Volume de Fluido	Volume total de fluido bombeado
	Volume de Propante	Volume total de propante bombeado

Através da análise da figura 4.4 pode-se observar que o conjunto de dados utilizados para treinamento da rede apresentam um coeficiente de correlação de 0.96, já a figura 4.5 demonstra que os dados utilizados para verificação apresentam coeficiente de correlação de 0.72




Figura 4.5: Correlação dos dados de treinamento (Mohaghegh, Reeves e Hill, 2000)




Figura 4.6: Correlação dos dados de validação (Mohaghegh, Reeves e Hill, 2000)

Neste artigo também foi realizada uma análise estatística de sensibilidade, não tratada em detalhes neste trabalho, para identificação dos parâmetros de maior influência no conjunto de dados possuído.

Os resultados desta análise podem ser observados na figura 4.6




Figura 4.7: Importância relativa de cada categoria (Mohaghegh, Reeves e Hill, 2000)

Nesta figura são demonstradas as 4 categorias de dados de entrada, sendo as de maior influência as que possuem o menor fator de R^2 , destacam-se os dados de reservatório, seguido dos de completção e estimulação, como os parâmetros mais relevantes à modelagem.

Deve-se notar que entre todos os parâmetros envolvidos nesta análise somente os últimos três relativos à estimulação (ver tabela 1) são considerados como variáveis controláveis.

Este fato leva à segunda etapa da análise que envolve então a otimização dos parâmetros de estimulação através de Algoritmos genéticos.

Nesta etapa os três parâmetros citados (Tipo de fluido de tratamento, Volume total de Fluido de tratamento e volume de propante utilizado) são utilizados no processo de otimização.

Utilizando o modelo de rede desenvolvido na primeira etapa da análise como função de pertinência da modelagem evolutiva, o algoritmo busca possíveis combinações desses três parâmetros e tenta encontrar a resultante na maior produção acumulada.

Esse processo é então repetido para cada poço individualmente e os resultados obtidos considerados como o potencial produtivo do poço então utilizado na próxima etapa do processo.

A terceira etapa é realizada através da criação de um sistema composto por 3 inputs e 1 output. Os inputs incluem o ganho potencial de produção resultante da modelagem inteligente, o parâmetro “Fraturas por Zona” e Pressão, variáveis estas levantadas por engenheiros experientes da área.

O parâmetros fraturas por zona demonstram o quando a formação já foi fraturada em diferentes partes ao longo do poço (número de fraturas dividido pelo número de zonas). O parâmetro pressão, devido à falta de precisão em que os dados foram adquiridos também é tratado aqui como dado vago.

Desta forma esses parâmetros de entrada foram então classificados em sub-conjuntos fuzzy de acordo com as variáveis linguísticas baixo, moderado e alto.

O dado de saída é o grau de aconselhamento de determinado poço à operação, definidos aqui pelas variáveis linguísticas:

- 1) O poço é candidato (sim)
- 2) O poço talvez seja candidato (talvez)
- 3) O poço não é candidato (não)

O sistema de inferência inclui 27 regras qualificadas através dos três sub-conjuntos. A figura 4.8 demonstra a instituição dessas regras:

		Pressão			Pressão			Pressão		
		Baixa			Média			Alta		
Fraturas/Zona	Médio Baixo	Não <small>V</small>	Talvez <small>RV</small>	Talvez <small>RV</small>	Talvez <small>V</small>	Sim <small>RV</small>	Sim <small>RV</small>	Sim <small>V</small>	Sim <small>MV</small>	Sim <small>MV</small>
	Alto	Não <small>MV</small>	Não <small>V</small>	Talvez <small>RV</small>	Não <small>RV</small>	Talvez <small>V</small>	Sim <small>RV</small>	Talvez <small>MV</small>	Sim <small>V</small>	Sim <small>MV</small>
		Não <small>MV</small>	Não <small>MV</small>	Não <small>V</small>	Talvez <small>RV</small>	Não <small>RV</small>	Talvez <small>V</small>	Talvez <small>MV</small>	Talvez <small>MV</small>	Sim <small>V</small>
		Baixa	Média	Alta	Baixa	Média	Alta	Baixa	Média	Alta
		Potencial Produtivo Acum. (5 anos)			Potencial Produtivo Acum. (5 anos)			Potencial Produtivo Acum. (5 anos)		

Figura 4.8: Regras Fuzzy e suas qualificações (Mohaghegh, Reeves e Hill, 2000)

Na figura 4.9 demonstra-se a qualificação das funções verdade utilizadas no raciocínio aproximado implementado no sistema fuzzy. Como pode-se observar cada regra pode ser qualificada como verdadeira, razoavelmente verdadeira ou muito verdadeira.

Razão Aproximada	
Qualificações das Regras	
Razoavelmente Verdadeira	RV
Verdadeira	V
Muito Verdadeira	MV




Figura 4.9: Qualificação das verdades fuzzy (Mohaghegh, Reeves e Hill, 2000)

Desta forma utilizando a metodologia discutida todos os poços disponíveis para estudo foram processados e qualificados.

4.1.4 RESULTADOS

Após a qualificação dos poços foram selecionados 3 poços para reestimulação e validação do modelo.

Os poços citados foram denominados GRB 45-12, GRB 27-14 e NLB 57-23. A tabela 8.2 demonstra suas qualificações, obtidas através da análise proposta.

Tabela 4.2: Classificação dos poços após a aplicação da metodologia

Poços Candidatos	Ranking utilizando a metodologia proposta
GRB 45-12	20
GRB 27-14	112
GRB 57-33	Sem dados de pressão
Poços analisados	123

Já as figuras 4.9, 4.10 e 4.11 demonstram os resultados preliminares de campo da reestimulação realizada.




Figura 4.10: Resultados do tratamento para o poço GRB 45-12 (Mohaghegh, Reeves e Hill, 2000)




Figura 4.11: Resultados do tratamento para o poço GRB 27-14 (Mohaghegh, Reeves e Hill, 2000)




Figura 4.12: Resultados do tratamento para o poço NLB 57-33 (Mohaghegh, Reeves e Hill, 2000)

4.1.5 CONCLUSÃO DO ESTUDO

Como pode-se observar através da análise dos gráficos comparativos entre a produção prevista e a concretizada, o poço de maior qualificação, obtido através da metodologia proposta, foi o único a obter ganho de produção através da reestimulação, validando então o estudo desenvolvido.

Vale ressaltar que o objetivo desta metodologia não é prever o ganho de produção através da operação em um determinado poço, mas sim oferecer artifícios para comparação entre os mesmos e selecionar o de maior potencial.

4.2 ANÁLISE CRÍTICA DO ESTUDO DE CASO

Através da análise da aplicação da metodologia proposta ao estudo de caso apresentado pode-se observar que resultados satisfatórios foram encontrados. Desta forma, publicado há um pouco mais que uma década, o presente trabalho, junto a outros artigos similares em sua maioria de autoria de Shahab Mohaghed, se destaca como referencia do uso de técnicas inteligentes híbridas na resolução de problemas ligados a indústria do petróleo.

Porém através de um estudo bibliográfico paralelo pode-se realizar algumas considerações a cerca do estudo apresentado e de algumas de suas restrições. Essas observações podem ser divididas em duas categorias. A primeira diz respeito a limitações inerentes a própria técnica de computação artificial, já a segunda a parâmetros de projeto e metodologia.

Em relação a primeira categoria pode-se discutir o volume e variedade de dados utilizados. Para se garantir resultados coerentes e robustos deve-se contar com um vasto conjunto de dados contendo os parâmetros de influência ao processo. Além de numeroso, o conjunto de dados deve ser bem variado englobando as diferentes características que uma formação ou projeto pode possuir.

Desta forma além da dificuldade em atingir-se a abrangência ideal do conjunto de dados é muito complicado garantir a confiabilidade dos mesmos, uma vez que erros de medição e mudanças durante a execução da operação não são retratadas em arquivos de planejamento de onde muitas vezes os dados são retirados. No artigo estudado pouco é falado sobre o conjunto de dados a fim de se garantir a abrangência e confiabilidade dos mesmos.

Adicionalmente, mesmo em posse de dados efetivos, a análise através das técnicas expostas fica muitas vezes restrita ao ambiente de onde o conjunto de dados foi coletado, podendo ser aplicada apenas a formações de características muito parecidas e mesmo assim sem garantia de sucesso.

Seguindo para segunda categoria de fatores, discute-se a seleção dos parâmetros de influência utilizados para a modelagem do problema e conseqüente seleção de poços candidatos. Embora tenha sido realizado em estudo paralelo sobre a influencia dos inputs utilizados, muitos parâmetros relevantes a operação destacados através de revisão bibliográfica não são levados em consideração.

Por fim, e talvez se tratando do aspecto mais grave levantado, a metodologia de seleção é fundamentalmente baseada em parâmetros de reservatório ou de design de projeto.

Fatores muitas vezes não mensuráveis através de índices numéricos como proximidade a zonas portadoras de água, condições mecânicas do poço e equipamentos de completação, barreiras geográficas entre outros evidenciados na literatura e citados ao longo do texto, são deixados de lado.

Este fato poderia resultar na limitação dos resultados obtidos através do estudo que, caso aplicados na pratica poderiam apresentar resultados muito diferentes do simulado podendo resultar na inviabilidade da operação e muitas vezes em grandes prejuízos.

5 ESTUDO PROSPECTIVO

Com base na metodologia apresentada, foi realizado um estudo com objetivo de implementação de um modelo neural para a seleção de poços para a operação de fraturamento hidráulico. Através da criação e treinamento de uma RNA, buscou-se estimar o ganho de produção obtido após a realização de um tratamento de estimulação em um determinado poço e assim, dentro de um grupo de potenciais candidatos de um mesmo campo, identificar os mais indicados a este tipo de intervenção.

Desta forma, o objetivo da rede não seria prever a produção de determinado poço após a realização do tratamento, mas sim identificar dentro de um grupo, os candidatos com maior potencial de ganho de produção percentual.

Como explanado anteriormente, o sucesso da modelagem por redes neurais depende diretamente da quantidade, qualidade e variedade dos dados utilizados para sua implementação. O conjunto de informações de campo utilizados neste estudo foi retirado do artigo “*Productivity of Frac Stimulations in German Rotliegend: Theoretical Consideration and Pratical Results*” de autoria de M. Khoeler (Khoeler, 2005) e é composto por parâmetros obtidos de 18 poços fraturados em arenitos na Alemanha, retratando suas condições de reservatório e fluxo antes e depois da operação de estimulação.

Entre os parâmetros presentes no artigo encontram-se dados de:

- Permeabilidade
- Espessura do zona produtora
- Vazão de gás
- Pressão de Fundo de poço
- Raio do poço
- Raio efetivo
- Asa da fratura
- Dano a Formação
- IP

Como o objetivo da rede é a previsão de produção após a realização de uma operação de fraturamento, os parâmetros foram então divididos entre dois grupos: *inputs* e *outputs*.

O primeiro grupo, com parâmetros de influência selecionados através da revisão bibliográfica realizada e disponíveis no banco de dados possuído, diz respeito as informações de poço, reservatório e operação, já o segundo, relacionado ao resultado da operação, retrata o ganho de produção obtido. A tabela 5.1 resume as principais características da RNA.

Tabela 5.1: Características da RNA

Objetivo	Previsão do aumento da produtividade de poços após a operação de fraturamento hidráulico
Parâmetros de entrada	Espessura da zona produtora, permeabilidade, diferencial de pressões no fundo do poço, raio do poço, raio efetivo do poço, dano à formação, produção.
Parâmetros de saída	Produção pós operação

Uma vez definidos os dados de entrada e saída a serem utilizados, através do programa MATLAB, foram criados então diferentes modelos neurais para relacionamento dos parâmetros de estudo.

As redes criadas diferenciam-se umas das outras basicamente de acordo com o seu número de camadas, neurônios, divisão dos dados para treinamento e verificação, épocas e algoritmo de treinamento, e são avaliadas através do erro calculado entre os resultados fornecidos e os esperados.

No presente estudo, buscou-se a rede de melhores características através de um processo de tentativa e erro, modificando os parâmetros de construção da RNA. Após diversas tentativas, a rede que obteve os melhores resultados, foi a que apresentou as seguintes características e divisão de dados:

Tabela 5.2: Dados da rede selecionada

Número de neurônios na camada de entrada	7
Número de camadas escondidas	3
Algoritmo de treinamento	<i>Backpropagation</i>
Épocas de treinamento	5000

Tabela 5.3: Divisão dos dados

Parâmetros de entrada								Parâmetros de saída
Poço	h (m)	k (mD)	dP (bar)	Vazão de gás (m3/h) pré-frac	rw (m)	re (m)	dano	Vazão de gás (m3/h) pós-frac
1	16.8	10.18	64.6	19300	0.0635	1000	0.3	25000
2	12	0.95	505.4	7000	0.0635	1000	8.4	20000
3	17.9	0.67	240.1	15000	0.0635	1000	-2.9	24000
4	21.6	0.43	246.3	9900	0.0635	1000	-3.2	23850
5	17.7	0.18	445.8	5000	0.0743	1000	-0.5	10000
6	17.5	2.48	34	9000	0.0746	1000	-3.7	25000
7	15.2	8.15	73.6	14500	0.0635	1000	5.5	20100
8	25.8	0.97	100	8760	0.0889	1000	-3	13000
9	14.6	0.97	260.3	9190	0.0635	1000	-2.1	19640
10	9.8	10.77	180.6	30000	0.0635	1000	2.3	21500
11	17.9	0.64	187	6000	0.0889	1000	-3.5	5000
12	21.9	3.43	151.8	30000	0.0635	1000	-0.2	15000
13	26.1	13.61	59.6	20190	0.0635	1000	0	31000
14	12.5	0.77	225	7450	0.0635	1000	-2.4	14600
15	73.5	0.03	182.7	1000	0.065	1000	0.5	2300
16	113.8	0.64	48.8	14850	0.075	1000	-1.7	22000
17	18.2	2.08	169.6	15000	0.0635	1000	0.5	9300
18	106.7	0.005	290	500	0.075	1000	0.1	2000

Treinamento	Validação
-------------	-----------

Do conjunto de dados de 18 poços, informações de 16 deles (1 à 16) foram utilizadas para o treinamento da rede, enquanto 2 (17 e 18) para a validação da rede obtida. Após a modelagem de algumas redes neurais, são apresentados na Tabela 5.4 os melhores resultados obtidos.

Tabela 5.4: Tabela de Resultados

	17	18
Vazão de gás (m ³ /h) pós-frac REAL	9300	2000
Vazão de gás (m ³ /h) pós-frac SIMULADO	9619	2300
ERRO	3%	15%

Devido às características aleatórias presentes na geração de uma rede (inicialização dos pesos), e utilizando os parâmetros apresentados na tabela 5.2, foram gerados alguns modelos de redes neurais de forma a encontrar o que melhor simulasse o processo.

A rede de melhor ajuste foi a que apresentou os resultados exibidos na tabela 5.4. O resultado apresentado pode ser considerado satisfatório dado os erros de 3% e 15% encontrados, indicando que apesar da pouca quantidade e variedade dos dados de treinamento a metodologia foi capaz de fornecer resultados coerentes.

Porém para que a efetividade da rede criada possa ser comprovada, se faz necessário um conjunto de dados mais extenso e variado, desta forma, sem poder garantir a confiabilidade da previsão, e devido à dificuldade de obtenção de dados para modelagem a parte prática da pesquisa em questão não obteve resultados finais conclusivos.

6 CONCLUSÃO

Através do trabalho realizado constata-se que embora operações de fraturamento hidráulico sejam fortemente difundidas na indústria de petróleo e gás, o seu desenvolvimento ainda é tema de destaque em pesquisas em diferentes áreas da engenharia e, impulsionado pela forte exploração e desenvolvimento de campos de tight e shale gás, motivo de debates sobre os impactos de sua realização.

A utilização de técnicas de computação inteligentes no planejamento e execução de operações é uma tendência observada não apenas em tratamentos de estimulação, mas em diversas outras áreas da indústria como interpretação geológica, Perfuração e Reservatórios, consolidando-se como importante recurso computacional utilizado de forma a maximizar resultados, reduzir custos e apoiar a tomada de decisão.

O estudo apresentado, junto a outros diversos trabalhos já publicados, ratifica o potencial do uso da computação inteligente aplicada a operações de estimulação e ressalta as vantagens da metodologia de seleção inteligente principalmente em relação aos seguintes aspectos:

- ✓ Rapidez para realização da análise dos candidatos potenciais;
- ✓ Redução de custos através da escolha de poços e parâmetros operacionais ótimos da operação;
- ✓ Preservação do conhecimento adquirido através da experiência de profissionais da área;

Este trabalho cumpre ainda seus objetivos ao identificar limitações da técnica, algumas delas inclusive vivenciadas no estudo prospectivo realizado, podendo citar como exemplo:

- A necessidade de dados de campo de boa qualidade e em grande volume de forma a possibilitar a construção de redes neurais robustas para simulação da operação

- O baixo poder de generalização da metodologia quando esta é aplicada a um campo específico.
- Alguns aspectos do design das ferramentas inteligentes como, por exemplo, o número de neurônios utilizados em uma Rede não possui modelos matemáticos que determinem sua especificação ideal, ficando esta determinação a cargo da experiência de cada profissional e dos relatos observados na literatura.

Desta forma conclui-se este trabalho, ressaltando o potencial da técnica de seleção inteligente de poços para estimulação, que apesar de suas limitações, apresenta ainda grande capacidade de desenvolvimento dada à contínua evolução dos recursos computacionais, dos conhecimentos e dados na área de estimulação e dos desafios enfrentados hoje em dia na exploração de campos não convencionais de óleo e gás.

Como próximos passos deve-se considerar a busca por um conjunto de dados mais extensos e variados, seja provenientes de casos reais ou simulados computacionalmente, para que uma vez garantida uma boa modelagem através das RNA's, a pesquisa possa ser expandida e a metodologia desenvolvida aplicando as técnicas de Algoritmos Genéticos e Lógica Fuzzy estudadas.

7 REFERÊNCIAS BIBLIOGRÁFICAS

- BARRETO, M. A.: Caracterização de materiais para garantir a condutividade de fraturas hidráulicamente induzidas em poços de petróleo e gás, Rio de Janeiro (2010)
- BRAGA, A. CARVALHO, F. LUDEMIR, B.: Redes Neurais Artificiais: Teoria e Aplicações, Livros Técnicos e Científicos, Rio de Janeiro (2000)
- CASTRO, ANTONIO ORESTES SALVO: “Seleção de Poços de Petróleo para Operação de Fraturamento Hidráulico: uma Abordagem Comparativa entre Sistemas Fuzzy-genético e Neuro-Fuzzy”, Rio de Janeiro, UFRJ (2004)
- DEMUTH, H.; BEALE, M.; HAGAN, M. : Neural Network Toolbox™ 6 User's Guide. The MathWorks, 2008. Disponível em: <http://www.mathworks.com/access/helpdesk/help/pdf_doc/nnet/nnet.pdf>. Acesso em: 3 de dezembro de 2008.
- DOS SANTOS J.A.C.M., CUNHA R.A., DE MELO R.C.B, Aboud, R.S., PEDROSA, H.A. E MARCHI, F.A.: “Inverted-Convection Proppant Transport for Effective Conformance Fracturing”, SPE 109585, SPEPO, 187-193, (2009).
- DOS SANTOS J.A.C.M., DE MELO R.C.B. E DI LULLO, G.: “Case History Evaluation of RPMs on Conform Fracturing Applications”, SPE 94352 (2005).
- FOGEL D. B.: Evolutionary Computation, Toward a New Philosophy of Machine Intelligence, IEEE Press, Piscataway, New Jersey (1995)
- HAYKIN, S.: Neural Networks – A Comprehensive Foundation. Prentice-Hall, NY. (1994)
- HOLDITCH, STEPHEN A. :Petroleum Engineering Handbook, Volume IV, Capítulo 8, Society of Petroleum Engineers (2007)
- KRAUSS, C.: New way to tap gas may expand global supplies, New York Times (2009)
- KOEHLER, M.: “Productivity of Frac Stimulations in the German Rotliegend: Theoretical Consideration and Practical Results”, *SPE Europe EAGE Annual Conference*, Madrid (2005)

MAHAJAN M., RAUF N., GILMORE T. E MAYLANA A.: "Water Control and Fracturing: A Reality", SPE 101019 (2006)

MARTIN E ECONOMIDES: "Best Practices for Candidate Selection, Design and Evaluation of Hydraulic Fracture Treatments", *SPE Production and Operations Conference and Exhibition*, Tunis, Tunisia (2010)

MC CULLOCH, W. S. AND PITTS, W.: "a Logical Calculus of Ideas Immanent in Nervous Activity" *Bull. Mathematical Biophysics* (1943) 5, 115

MC NEILL, D. AND FREIBERGER, P.: *Fuzzy Logic*, Simon & Schuster, New York City (1993)

MOHAGHEGH, S.: Virtual-Intelligence Applications in Petroleum Engineering: Part 1 – Artificial Neural Networks. *Journal of Petroleum Technology* [S.I.], v. 52, n. 9, p. 8, (2000)

MOHAGHEGH, S.: Virtual-Intelligence Applications in Petroleum Engineering: Part 2— Evolutionary Computing. *Journal of Petroleum Technology* [S.I.], v. 52, n. 10, p. 40-46, (2000)

MOHAGHEGH, S.: Virtual-Intelligence Applications in Petroleum Engineering: Part 3— Fuzzy Logic. *Journal of Petroleum Technology* [S.I.], v. 52, n. 11, p. 82-87, (2000)

MOHAGHEGH, S.: "Candidate Selection for Stimulation of Gas Storage Wells Using Available Data With Neural Networks and Genetic Algorithms", *SPE Eastern Regional Meeting, Pittsburgh, Pennsylvania*, USA (1998).

MOHAGHEGH, HILLS E REEVES: Development of an Intelligent Systems Approach for Restimulation Candidate Selection, *SPE/CERI Gas Technology Symposium*, Calgary, Alberta, Canada (2000)

POPA, WOOD E CASSIDY.: "Application of Case-Based Reasoning for Well Fracturing Planning and Execution" *SPE Western North American Region Meeting*, 7-11, Anchorage, Alaska, USA (2011)

REEVES, S. R.: "Fracture-Stimulation Technology for Gas-Storage Wells", *Journal of Petroleum Technology*, Volume 50, Number 2, USA (1998)

ROSEMBLATT, F: "The Perceptron Probabilistic Model for Information Storage and Organization of the Brain" *Psychol. Rev.* (1958) 65, 386

RUMELHART, D.E e MC CLELLAND, J.L.: Parallel Distributed Processing, Exploration in the Microstructure of Cognition foundations, MIT press, Cambridge, Massashusetts (1986)

SHELLEY, R. F., GRIESER, W. V.: "Artificial Neural Network Enhanced Completions Improve Well Economics", *SPE Hydrocarbon Economics and Evaluation Symposium*, Dallas, Texas, EUA (1999)

TEIXEIRA, TOLEDO, FAIRCHILD E TAIOLI: Decifrando a Terra, São Paulo, Oficina de Textos, 2000.

THOMAS, J. E. ET AL: Fundamentos de engenharia de petroleo, Rio de Janeiro (2001)

YEW, C.H.: Mecanica do Fraturamento Hidraulico, E-papers (2008)

ZARUDA, JM MARKS, R.J E ROBINSON, C.J.: Computational Inteligenc, Imitating Life, IEEE Press, Piscaway, New Jersey (1994)