

CADERNOS DO IME – Série Estatística

Universidade do Estado do Rio de Janeiro - UERJ
Rio de Janeiro - RJ - Brasil
ISSN 1413-9022 / v. 22, p. 01 - 15, 2007

COMPARAÇÃO ENTRE GENETIC FUZZY SYSTEM E NEURO FUZZY SYSTEM PARA SELEÇÃO DE POÇOS DE PETRÓLEO PARA FRATURAMENTO HIDRÁULICO

Antônio Orestes de Salvo Castro
PETROBRAS
UERJ
orestes@petrobras.com.br

Virgílio José Martins Ferreira Filho
UFRJ
virgilio@ufrj.br

Resumo

A operação de fraturamento hidráulico é muito utilizada para estimular a produção de poços de petróleo e na remoção de danos de formação. Para selecionar os poços candidatos a sofrerem esta operação, engenheiros utilizam estudos de reservatórios e análises de engenharia. Nos últimos anos, sistemas de inferência fuzzy tem atraído o interesse de pesquisadores desta área devido às características nebulosas das variáveis envolvidas neste processo de seleção. Este estudo compara a performance de um neuro fuzzy system e um genetic fuzzy system, aplicados à seleção de poços de petróleo para a operação de fraturamento hidráulico, com aquisição de conhecimento de uma base de dados para ajuste de suas funções de pertinência. Foram utilizando dados de treinamento e dados de validação idênticos nos dois sistemas e concluímos que, embora mais recente, o genetic fuzzy system obteve melhores resultados neste processo de seleção. Também concluímos que, devido à possibilidade de inclusão de restrições, o genetic fuzzy system resultou em funções de pertinência mais coerentes com o que se esperava dos valores lingüísticos das principais variáveis.

Palavras-chave: Engenharia de Petróleo, Fraturamento Hidráulico, Sistema Fuzzy, Algoritmo Genético.

1. Introdução

Atualmente, uma das mais importantes áreas de aplicação da teoria dos conjuntos fuzzy desenvolvida por Zadeh (1965) são os sistemas de inferência fuzzy (SIF), que, na verdade, são extensões dos sistemas clássicos com bases de conhecimentos, porém tendo os antecedentes e conseqüentes das regras “SE – ENTÃO” compostas por declarações fuzzy. No problema em questão, a seleção de poços para operação de fraturamento hidráulico, o conjunto de conhecimentos utilizado é melhor descrito na forma de uma composição difusa de variáveis lingüísticas. Os dados utilizados, como por exemplo, a permeabilidade da formação petrolífera, a viscosidade do óleo etc., são inferidos com base em amostras coletadas dos poços de petróleo perfurados, possuindo assim, uma incerteza inerente a este processo de inferência. Este ambiente difuso para selecionar os poços, embora envolva critérios técnicos e econômicos, propicia uma avaliação mais qualitativa voltada às características pessoais de quem está envolvido no processo decisório.

O SIF para seleção de poços para fraturamento hidráulico atua como um padrão operacional para esta seleção. Como todo padrão, é de fundamental importância que este se mantenha atualizado o que não é uma tarefa simples quando se trata de um SIF, pois necessitaria de um especialista para adquirir o conhecimento e inseri-lo sistema. Assim, uma sistemática computacional para mineração de conhecimento e ajustes do SIF é importante para mantê-lo operacional ao longo do tempo. Este trabalho apresenta os resultados comparativos da utilização de (1) uma sistemática baseada em algoritmos genéticos (AG) para atualizar as funções de pertinência deste SIF e uma sistemática baseada em redes neurais (RN) com a mesma finalidade.

2. Fraturamento Hidráulico

As operações de estimulação são largamente utilizadas na indústria petrolífera para ampliação do potencial produtivo de poços e formações portadoras de hidrocarbonetos. Estas operações aumentam a permeabilidade da formação através da indução de canais na rocha produtora ou pela remoção do dano de formação, o que facilita o fluxo dos fluidos a serem produzidos. Nem todos os poços são candidatos naturais a serem estimulados, devido as diferentes características que estes possuem. Mesmo dentro do mesmo campo petrolífero e dentro da mesma formação, serão

encontrados poços que devem e que não devem sofrer estas operações. O processo de seleção deve estar calçado em critérios técnicos e econômicos que podem ser trabalhosos caso sejam aplicados com os níveis de detalhes necessários. Um dos principais métodos de estimulação de poços utilizado na indústria do petróleo é o fraturamento hidráulico. Trata-se de uma operação que embora possa ser bastante lucrativa, se mal especificada, projetada ou conduzida, pode acarretar inclusive na perda do poço produtor.

Para alimentar o modelo, vários fatores devem ser considerados na seleção de poços e formações para a operação de fraturamento hidráulico. Foram identificados sete fatores como sendo preponderantes no processo de seleção, são eles: (1) nível de dano que a formação possui, Skin; (2) espessura da formação; (3) volume de óleo contido na formação; (4) gradiente de pressão estática; (5) condições mecânicas do poço; (6) permeabilidade da formação e (7) viscosidade do óleo.

Para identificar os poços candidatos às operações de fraturamento hidráulico foi efetuada uma classificação conforme um possível diagnóstico de um especialista que por ventura estivesse analisando o problema. Esta avaliação consiste em classificar os poços em quatro grupos conforme sua adequação ao fraturamento hidráulico: (1) Excelente candidato; (2) Bom candidato; (3) Possível candidato e (4) Não candidato.

O SIF é capaz de, baseado nos dados das 7 características de um poço de petróleo, classificá-lo em uma das 4 classes acima. Primeiramente os poços são posicionados ordem crescente de adequação, com o modelo gerando primeiramente valores negativos para os poços Não candidatos, valores entre 0 e 0,5 para os Possíveis candidatos, entre 0,5 e 0,75 para os bons candidatos e acima de 0,75 para os excelentes candidatos.

3. Sistema de Inferência Fuzzy (SIF)

A estrutura genérica de um SIF é composta de: (1) uma base de conhecimento (BC) que armazena o conhecimento disponível sobre o problema, na forma de regras fuzzy "SE-ENTÃO", (2) um dispositivo de fuzificação dos dados de entrada, um mecanismo de inferência e um dispositivo de defuzificação do resultado. A BC contém dois diferentes níveis de informação: (1) as funções de pertinência das variáveis lingüísticas e (2) as regras fuzzy de produção. Na forma geral, teríamos regras fuzzy do

tipo: SE X_1 é A_1 e X_n é A_n ENTÃO Y é B , onde X_i e Y são respectivamente inputs e outputs, e A_i e B são variáveis lingüísticas com conjuntos fuzzy associados, definindo assim, seu significado. Estas regras de produção representam a relação fuzzy entre A e B definidas em $U \times V$.

O modelo de SIF utilizado para retratar a seleção de poços para o fraturamento hidráulico é do tipo SUGENO, (TAKAGI & SUGENO,1985 e SUGENO & KANG, 1988). Neste tipo de SIF os antecedentes são compostos de variáveis lingüísticas e os conseqüentes são representados por funções das variáveis de entrada. Para o SIF do tipo Sugeno, normalmente a saída defuzzificada é composta pela avaliação de m regras e é obtida pela soma ponderada dos conseqüentes de cada regra acionada, Y_i , para $i = 1, \dots, m$ como descrito na equação 1.

$$\text{Valor defuzzificado} = \frac{\sum_{i=1}^m h_i \cdot Y_i}{\sum_{i=1}^m h_i} \quad (1)$$

onde cada $h_i = T(A_{i1}(x_1), \dots, A_{in}(x_n))$ é o grau de aderência entre o antecedente da i -ésima regra e a variável de entrada corrente do sistema $x_0 = (x_1, \dots, x_n)$. Porém, para este problema específico um novo procedimento de defuzzificação foi proposto com o objetivo de melhor retratar um valor defuzzificado para a seleção de poços para o fraturamento hidráulico. Isso se deveu ao fato de algumas situações representadas por valores extremos de algumas variáveis de entrada, implicarem na proibição sumária do poço ao fraturamento. Por exemplo, valores muito baixos da variável que retrata as condições mecânicas do poço impedem a operação e não podem ser compensados por valores convenientes de outras variáveis. Assim, um procedimento de restrições foi implementado ao processo convencional fazendo com que determinados valores impliquem diretamente em valores defuzzificados negativos, conforme a equação 2:

$$\text{Valor} = \begin{cases} -1 & \text{se } X_i \leq C_i \quad \forall i \\ \text{caso contrário} & \frac{\sum_{i=1}^m h_i \cdot Y_i}{\sum_{i=1}^m h_i} \end{cases} \quad (2)$$

3.1 Ajuste das Funções de Pertinência do SIF

As funções de pertinência do modelo de inferência fuzzy representam os parâmetros de entrada contendo os dados do conjunto poço / formação, que podem

variar de uma região petrolífera para outra. Estes parâmetros apresentam diferentes amplitudes nos seus valores para cada região petrolífera. Assim, embora uma regra de produção do tipo se o parâmetro P é alto então recomendação é R, possa ser aplicada de uma forma geral, a definição do que seja o valor lingüístico alto pode variar de forma substancial a depender da região petrolífera em que estamos aplicando o modelo. Assim, as funções de pertinência para um novo ambiente deveriam passar por outro processo de modelagem similar ao que foi utilizado para o estabelecimento de seus valores lingüístico para o SIF inicialmente modelado. Para evitar tal procedimento, tornando o modelo mais versátil, um processo de mineração de conhecimento a partir de dados de campos obtidos de operações de fraturamento hidráulico se fez necessário.

Foram comparados dois procedimentos para o desenvolvimento desta capacidade, um envolvendo a utilização de AG e outro baseado em RN, ambos atuaram no ajuste das funções de pertinência do SIF. Para detalhes da implementação do modelo de ajuste por AG, veja Castro e Ferreira (2003). Já na utilização de RN, foi escolhido o modelo ANFIS (Adaptative Nero Fuzzy Inferency System), pois este possui a capacidade de emular um SIF do tipo SUGENO através da utilização de redes neurais de base radial.

3.2 Dados para extração do conhecimento e validação

Para utilização neste estudo comparativo para ajuste das funções de pertinência do SIF, foi efetuada uma pesquisa no banco de dados corporativo utilizado para armazenar os dados dos poços produtores e selecionadas 110 operações de fraturamento efetuadas em diferentes poços de petróleo. Foram coletados os dados relativos aos valores dos 7 parâmetros de entrada utilizados no FIS e o valor do ganho de produção resultante da operação para identificar a ordenação que este poços deveriam apresentar, obedecendo o critério de ordem crescente de adequação. A esta massa de poços foram acrescentados os dados de mais 50 poços que não foram fraturados por não apresentarem características ideais para a operação de fraturamento. Nestes poços o valor do ganho de produção foi estipulado como sendo zero. Esta segunda massa de dados visava adicionar o conhecimento relativo aos poços no qual a operação não é recomendada. Desta massa de dados, um total de 100 (70 fraturados e 30 não fraturados) foram utilizados para definição das funções de pertinência com a utilização

dos AG. Outros 60 poços (40 fraturados e 20 não fraturados) foram separados para teste e validação do modelo gerado.

4. Genetic Fuzzy System

O genetic fuzzy systems ajusta o conhecimento embutido em um SIF, através da minimização do erro da saída do SIF ajustado e os resultados de um conjunto de treinamento utilizado para comparação. Este processo passa pela criação de material genético, geração de soluções iniciais, avaliação do erro por uma função de fitness, que será utilizada no processo de seleção para a determinação dos indivíduos mais adequados e que terão maior chance de reprodução. A esse processos é adicionado um processo eventual de mutação irá gerar novos indivíduos, ampliando o espaço de busca obrigando o procedimento a fugir de mínimos locais. Trata-se portanto, de um processo iterativo que terminará quando o erro atingir um valor aceitável. Neste processo é possível a inclusão de restrições, dentro da função de fitness, que se mostraram extremamente úteis, tanto para a redução do tempo de convergência quanto para manter o significado lingüístico das funções de pertinência dos conjuntos fuzzy.

4.1 Resultados do Genetic Fuzzy System

A tabela 1 apresenta os resultados extraídos após seis rodadas do modelo com AG. Na primeira coluna temos a descrição da variável de entrada, em seguida o seu valor antes da utilização dos AG para ajuste das funções de pertinência. As colunas numeradas de um a seis apresentam os valores obtidos em cada uma das rodadas do modelo. Os valores médios calculados, apresentados na coluna seguinte, foram utilizados para redesenhar as funções de pertinência. O desvio padrão e o coeficiente de variação apresentam a dispersão entre os valores obtidos em cada rodada. Podemos notar que o valor de número 3 de permeabilidade, o valor 6 de volume de óleo e o valor 3 de espessura da formação, apresentaram um elevado coeficiente de variação, não apresentando convergência.

São apresentadas na figura 1, as funções de pertinência antes do processo de ajuste pelos algoritmos genéticos (linha fina) e após o ajuste (linha mais escura). Os números ao lado dos valores lingüísticos fazem relação com a tabela 1 para que seus valores possam ser localizados nas figuras. Aqui podemos notar com mais clareza, que o valor "alta" da variável lingüística permeabilidade, o valor "muito alto" do volume de

óleo e o valor "muito alta" da espessura, conforme demonstrado pelo coeficiente de variação, realmente não apresentaram convergência. Este fato se deveu a não existência de valores destes parâmetros dentro destes intervalos nos poços utilizados para treinamento. Neste caso foi efetuada uma modificação no modelo, de forma a que, os valores ajustados que não apresentassem convergência, não substituíssem os valores antigos nas funções de pertinência do SIF.

Contudo, os ajustes apresentados pelo modelo, em sua maioria, foram bastante adequados e conseguiram convergência. O conjunto de 60 poços (40 fraturados e 20 não fraturados) separados para validação do modelo apresentou um erro considerado muito baixo, pois dos 40 poços fraturados apenas 13 poços ficaram fora de sua posição esperada, não gerando um erro posicional individual maior do que sete unidades. Para o conjunto de 20 poços não fraturados apenas um apresentou valor de adequação maior do zero (para estes poços eram esperado apenas valores negativos de adequação), porém este único poço apresentou valor foi muito próximo de zero [0,0023].

Tabela 1- Resultados obtidos com o Genetic Fuzzy System.

Variável Linguística	sem ajuste	ponto	Valores obtidos com as rodadas do modelo						média	desvio padrão	coefic. variação
			1	2	3	4	5	6			
skin	0	1	-1.70	-1.74	-1.71	-1.76	-1.74	-1.79	-1.740	0.0300	0.01724
(dano da form.)	2.5	2	3.15	3.21	3.17	3.18	3.18	3.19	3.1800	0.0183	0.00574
	6	3	8.76	8.59	8.61	8.52	8.54	8.5	8.5867	0.0863	0.01006
gradiente de pressão	0.25	1	0.231	0.203	0.207	0.214	0.214	0.205	0.2123	0.0093	0.04398
	0.50	2	0.418	0.420	0.431	0.411	0.413	0.427	0.4200	0.0071	0.01695
	0.65	3	0.589	0.595	0.592	0.597	0.591	0.594	0.5930	0.0026	0.00446
permeabilidade da formação	400	1	525	532	517	529	543	539	530.8	8.6104	0.01622
	1000	2	1232	1259	1274	1232	1295	1242	1255.7	23.099	0.01840
	2500	3	2711	3812	4932	5083	5229	6536	4717.2	1196.81	0.25371
condições mecânicas	0.35	1	0.354	0.361	0.359	0.341	0.349	0.348	0.3520	0.0068	0.01941
	0.52	2	0.551	0.498	0.502	0.509	0.511	0.499	0.5117	0.0182	0.03564
	0.75	3	0.712	0.719	0.727	0.718	0.721	0.741	0.7230	0.0092	0.01270
	0.90	4	0.919	0.923	0.917	0.921	0.965	0.916	0.9268	0.0172	0.01859
	viscosidade do óleo	20	1	0.020	0.019	0.021	0.024	0.021	0.023	0.0213	0.0017
	100	2	113	109	103	121	116	109	111.8	5.7276	0.05122
	370	3	391	396	389	401	394	390	393.5	4.1130	0.01045
	700	4	721	697	718	703	709	711	709.8	8.2141	0.01157
	volume de óleo	50	1	21.4	22.6	21.3	19.7	17.9	19.1	20.3	1.5839
	550	2	400	398	414	429	419	413	412.2	10.6680	0.02588
	630	3	605	619	612	607	601	618	610.3	6.6249	0.01085
	1100	4	1024	1043	1002	1007	1029	1036	1023.5	14.7281	0.01439
	1250	5	1196	1251	1163	1239	1236	1243	1221.3	31.4148	0.02572
	1750	6	1201	1958	1690	1342	1823	2196	1801.8	284.309	0.15779
	espessura da formação	10	1	12.9	14	10.4	13.7	13.6	12.3	12.8	1.2185
	23	2	21.7	22.5	18.6	19.9	20.1	17.8	20.1	1.6279	0.08099
	35	3	31.6	39.7	85.9	48.7	62.7	43.9	52.1	17.8307	0.34235

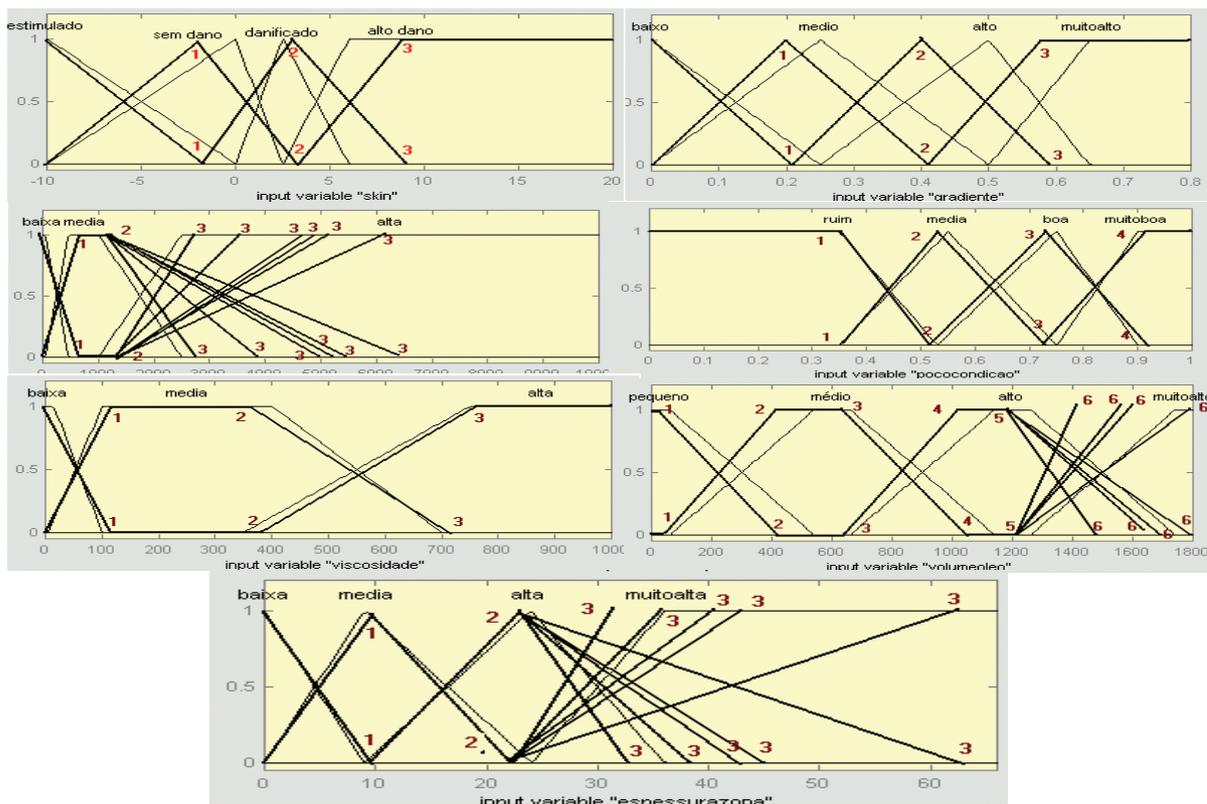


Figura 01 - Funções de pertinência ajustadas Tabela pelo Genetic Fuzzy System

5. O Neuro Fuzzy System - Modelo ANFIS

O procedimento ANFIS utilizado, automaticamente ajustou um FIS do tipo SUGENO. Foi utilizada pela aplicação uma estratégia híbrida de treinamento, formada pela conjugação do método dos mínimos quadrados e do gradiente descendente, gerando uma saída descrita pela combinação linear ponderada dos consequentes. Não existe uma teoria formal para a determinação da topologia da rede para uma dada aplicação, assim, foi utilizado o próprio FIS original desenvolvido pela modelagem efetuada através do conhecimento dos especialistas. Esse fator também foi importante, pois permite a comparação entre a performance do ANFIS e procedimentos utilizando AG desenvolvido neste trabalho, já que este modelo básico também foi utilizado no procedimento de ajustes das funções de pertinência com AG. A implementação foi efetuada em MATLAB utilizando a aplicação comercial ANFISEDIT do TOOLBOX e apresentou rápida convergência se comparado ao procedimento com AG e com um número relativamente pequeno de iterações. O erro apresentou rápida redução mostrando a eficiência da metodologia. Neste estudo foi despendido, em média, 110

minutos em uma CPU "Celeron 600" até que o erro atingisse valores inferiores a 1%. Este tempo foi considerado pequeno se comparado aos procedimentos tradicionais que utilizam redes neurais e mesmo se comparado ao procedimento concorrente com AG, que teve uma duração de 190 minutos na mesma CPU

5.1 Os resultados do ANFIS - Funções de pertinência das variáveis de entrada

As funções de pertinência das variáveis de entrada foram bastante alteradas pelo procedimento ANFIS. Neste procedimento não existem amarrações para as possibilidades de alteração das funções de pertinência, assim, essas alterações ocorreram de tal forma que os conjuntos fuzzy, na maioria dos casos, perderam a conexão com o seu valor lingüístico. A tabela 2 apresenta, para cada variável de entrada do modelo, os valores antes do ajuste e após o ajuste dos quatro pontos que formam os quatro vértices do número fuzzy trapezoidal de cada valor lingüístico. Como podemos observar os pontos 3 e 4, que representam os vértices superiores do trapézio dos números fuzzy após o ajuste, são iguais. Isso ocorreu, pois foi especificado no pacote MATLAB que implementa a ANFIS, que as essas funções seriam representadas por números triangulares.

Tabela 2 - Resultados obtidos com o Neuro Fuzzy System

variável	valor lingüístico	antes do ajuste				após o ajuste			
		1	2	3	4	1	2	3	4
gradiente	baixo	0	0	0	0,25	0	0	0	0,18
	médio	0	0,25	0,25	0,5	0,14	0,26	0,26	0,52
	alto	0,25	0,5	0,5	0,65	0	0,47	0,47	0,75
	muito alto	0,5	0,65	1,02	1,5	0,52	0,91	0,91	1,47
skin	estimulado	-10	-10	-10	0	-10	-10	-10	-2,4
	sem dano	-10	0	0	2,5	-10	-6,3	6,3	4,2
	danificado	0	2,5	2,5	7,5	-0,5	4,4	4,4	13,9
	alto dano	2,5	7,5	20	20	4,4	17,8	17,8	20
condições mecânicas	ruim	0	0	0,35	0,5	0	0	0	0,06
	média	0,35	0,5	0,5	0,75	0	0,07	0,07	0,28
	boa	0,5	0,75	0,75	0,9	0,1	0,45	0,45	0,84
	muito boa	0,75	0,9	1	1	0,31	0,9	0,9	1
permeabilidade	baixa	0	0	0	70	0	90	90	280
	média	0	70	150	250	0	295	295	563
	alta	100	250	10000	10000	284	9564	9564	12000
viscosidade	baixa	0	0	40	100	0	121	121	312
	média	0	100	380	700	0	507	507	1000
	alta	380	700	1000	1000	486	769	769	1000
espessura	baixa	0	0	5	10	0	0	0	9
	média	5	10	10	25	2	14	14	31
	alta	10	25	25	35	12	26	26	40
	muito alta	25	35	100	100	32	62	62	100
volume	pequeno	0	0	50	480	0	74	74	712
	médio	0	480	650	1100	0	954	954	2000
	alto	650	1100	1350	1680	608	113	113	1449
	muito alto	1350	1680	2000	2000	1379	1826	1826	2000

A figura 2 apresenta os conjuntos fuzzy das variáveis de entrada, antes e depois do ajuste em linhas contínuas e tracejadas respectivamente. Vários aspectos

interessantes podem ser observados, entre eles podemos ressaltar: (1) O conjunto fuzzy alto da variável lingüística gradiente se estende por quase todo range de valores, apresentando pouca pertinência na interseção com o conjunto baixo, englobando todo o conjunto médio e com significativa pertinência na interseção com o conjunto muito alto. Esta descrição para o comportamento deste conjunto foge totalmente a idéia que um especialista possui sobre um gradiente de valor lingüístico alto. (2) O mesmo acontece com o conjunto médio da variável viscosidade que engloba todo o range de valores. (3) Este mesmo fato pode ser também observado para o conjunto médio da variável volume de óleo.

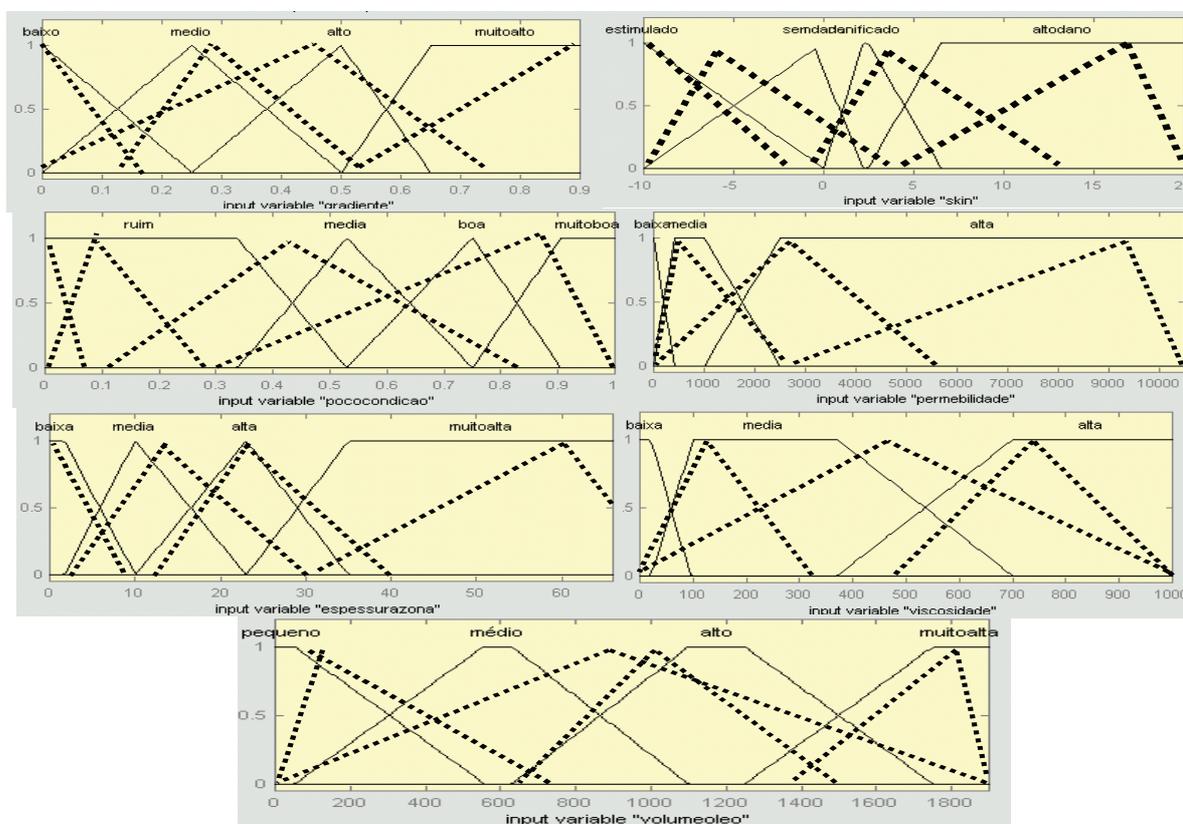


Figura 02 - Funções de pertinência ajustadas Tabela pelo Neuro Fuzzy System

5.2 Os resultados do ANFIS - A variável de Saída

Foi necessário aumentar a quantidade de valores lingüísticos da variável de saída (recomendação) de forma a que esta possuísse a mesma quantidade de valores que a quantidade de regras apresentada pelo FIS, passando de 4 para 29. Como valores lingüísticos adicionais se referiam aos quatro valores lingüísticos originais, estes foram inicializados com os valores numéricos correspondentes, ou seja, o valor adicional skin desaconselhável e gradiente desaconselhável como se referiam ao valor original

desaconselhável, foram inicializados com -1. Ao final do processo de treinamento um interessante resultado foi constatado. Os valores adicionais convergiram para montantes totalmente desvinculados de seus valores originais, tanto no que diz respeito ao valor quantitativo quanto ao valor relativo no que tange ao sinal. Isso implicou na completa perda de significado destes valores com a premissa utilizada na modelagem, que identificava como negativos as situações não recomendadas ao fraturamento hidráulico. Desta forma, fica impedida qualquer análise qualitativa individual dos parâmetros do SIF após o ajuste, pois estes apresentam apenas uma correlação matemática com os parâmetros de entrada. Assim, ao se submeter um poço ao SIF esta correlação matemática produzirá resultados satisfatórios, mas deve funcionar como caixa preta sem que se tente entender a lógica individual e cada valor numérico correspondentes aos valores lingüísticos.

6. Comparação entre a ordenação pelo Modelo AG e pelo Modelo ANFIS

Após o ajuste das funções de pertinência pelo procedimento ANFIS, o conjunto de composto de 60 poços de validação (40 fraturados e 20 não fraturados) foi apresentado ao SIF ajustado por ANFIS da mesma forma como efetuado quando do ajuste utilizando AG. A tabela 03 apresenta a ordenação efetuada pelo SIF ajustado pelos AG e logo abaixo a ordenação obtida pelo SIF após o ajuste utilizando o procedimento ANFIS. Em ambos os casos o erro foi calculado considerando apenas a diferença na ordenação esperada e a obtida. Para o conjunto de 20 poços não fraturados são esperados apenas valores negativos de adequação. Podemos notar que o quantitativo de poços que não obedeceu à ordenação esperada após o ajuste pelo procedimento ANFIS, (18 poços), foi superior ao apresentado quando do ajuste por AG (13 poços), porém o montante do erro foi menor. Enquanto o erro cometido pelo SIF ajustado por AG foi de 40 posições, o erro do SIF ajustado pelo procedimento ANFIS foi de 35 posições. Isso significa que, embora o SIF ajustado por AG tenha posicionado menos poços fora da posição esperada, quando o fez, os colocou mais distante destas posições que o SIF ajustado pelo procedimento ANFIS. Isso implica em uma performance similar para os dois procedimentos, no que diz respeito a este subconjunto (40 poços fraturados).

Tabela 03 – Comparação entre os erros na ordenação: Genetic Fuzzy System - Neuro Fuzzy System

Poço- posição esperada	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
posição do modelo AG	1	3	7	2	5	6	4	8	9	10	11	16	13	12	15	14	17	18	19	24
erro	0	1	4	2	0	0	3	0	0	0	0	4	0	2	0	2	0	0	0	4
posição do modelo ANFIS	2	6	1	3	5	4	7	8	9	11	10	12	13	14	15	16	17	20	19	21
erro	1	4	2	1	0	2	0	0	0	1	1	0	0	0	0	0	0	2	0	1
Poço- posição esperada	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40
posição do modelo AG	21	20	23	22	25	26	27	28	29	30	31	32	37	34	35	36	40	38	39	33
erro	0	2	0	2	0	0	0	0	0	0	0	0	4	0	0	0	3	0	0	7
posição do modelo ANFIS	18	27	24	22	24	26	23	28	29	30	31	32	34	35	33	36	37	38	39	40
erro	3	5	1	2	1	0	4	0	0	0	0	0	1	1	2	0	0	0	0	0

A tabela 04 apresenta os valores de Saída do SIF para os poços não fraturados do conjunto de validação. Ela mostra que, embora um grande número de poços tenha apresentado valores positivos, eles são bem próximos de zero, exceto pelo poço 13 que apresentou como valor de saída 0,1389, que é significativamente maior do que 0 para a análise em questão, colocando-o definitivamente na categoria dos poços possíveis de serem fraturados.

Tabela 04 – Valores de saída para os poços não recomendados - Neuro Fuzzy System

poço	Saída do SIF	poço	Saída do SIF
1	-0.0026	11	-0.6115
2	0.0077	12	0.0019
3	-0.0040	13	0.1389
4	-0.4379	14	-0.0002
5	-0.0662	15	-0.4225
6	0.0040	16	-0.0075
7	-0.0387	17	-0.1984
8	0.0060	18	-0.0088
9	-0.1062	19	0.0034
10	0.0021	20	-0.3079

Analisando mais profundamente este poço verificou-se que este apresentava sérios problemas mecânicos que impedem o seu fraturamento e que o valor de saída apresentado pelo SIF ajustado por AG havia sido -1, decorrente do procedimento de defuzzificação com restrições que está programado para apresentar um valor específico quando determinada situação se manifesta (veja equação 02), no caso a condição mecânica do poço com valor lingüístico RUIM. Outros dois poços estavam também nesta situação, o poço 11, que apresentou valor de saída -0.6115 e o poço 3, que apresentou valor de saída -0.0040. Nestes dois últimos casos, as demais condições apresentadas pelas variáveis de entrada não foram suficientemente favoráveis para compensar o problema mecânico, porém fica evidente que o procedimento de defuzzificação com restrições se mostrou importante devendo ser implantado no FIS após o ajuste efetuado pelo procedimento ANFIS.

7. Conclusões

A luz do caso analisado, apesar de tanto o neuro fuzzy system quanto o genetic fuzzy system terem apresentado bons resultados no que diz respeito ao ajuste das funções de pertinência do SIF modelado para selecionar poços de petróleo para o fraturamento hidráulico, algumas vantagens significativas foram encontradas no genetic fuzzy system, embora o neuro fuzzy system já seja uma técnica já consolidada, por exemplo:

No ANFIS, devido a ausência de restrições algumas funções de pertinência do SIF perderam a conexão com a lógica dos especialistas. De fato, o processo restritivo permitido pelos AG foram muito úteis, primeiramente mantendo a consistência geométrica dos conjuntos fuzzy, sendo inclusive ampliado durante o experimento, com a incorporação de restrições adicionais que efetivamente forçaram a manutenção da lógica lingüísticas das variáveis fuzzy. Apesar de não ter sido testado, acredita-se pela experiência adquirida no transcorrer deste trabalho, que sem este conjunto de restrições, o procedimento de ajuste das funções de pertinência utilizando os AG teria um desempenho similar ao ANFIS, isto é obtendo bons resultados, porém perdendo o significado lingüístico de algumas funções de pertinência.

Outra característica da implementação da ANFIS é que não foi possível a utilização do procedimento de defuzzificação com restrições desenvolvido especificamente para este tipo de SIF. No caso da metodologia que utiliza AG, o próprio SIF fazia parte da função de fitness, assim, não houve impedimento no que diz respeito a este processo de defuzzificação. Já no ANFIS não há como emular na rede neural o procedimento de defuzzificação com restrições. Assim, a flexibilidade proporcionada pelos AG permitiu que o processo de defuzzificação com restrições, importante para validação do sistema, fosse mantido durante o ajuste.

Referências

CASTRO, A. ; FERREIRA, V. (2003) Genetic Fuzzy System para Seleção de Poços de Petróleo para Fraturamento Hidráulico, **Anais... XXXV SOBRAPO-** Natal /RN.

SUGENO, M.; KANG, T. (1988). **Structure Identification of Fuzzy Model. Fuzzy Sets and Systems** 28(1), 15-33.

TAKAGI, T.; SUGENO, M. (1985). Fuzzy identification of Systems and its Applications to Modeling and Control. **IEEE Transactions on Systems, Man and Cybernetics** 15(1), 116-132.

ZADEH, L. (1965). Fuzzy Sets. **Information and Control** 8, 338-353.

COMPARISON OF GENETIC FUZZY SYSTEM AND NEURO FUZZY SYSTEM FOR THE SELECTION OF OIL WELLS FOR HYDRAULIC FRACTURING

Abstract

The hydraulic fracture operation is wide used to increase the oil wells production and to reduce formation damage. Reservoir studies and engineer analysis are made to select the wells for this kind of operation. As the reservoir parameters have some diffuses characteristics, Fuzzy Inference Systems (SIF) have been tested for this selection processes in the last few years. This paper compares the performance of a neuro fuzzy system and a genetic fuzzy system used for hydraulic Fracture well selection, with knowledge acquisition from an operational data base to set the SIF membership functions. The training data and the validation data used were the same for both systems. We concluded that, in despite of the genetic fuzzy system would be a younger process, it got better results than the neuro fuzzy system. Another conclusion was that, as the genetic fuzzy system can work with constraints, the membership functions setting kept the consistency of variables linguistic values.

Key-words: *Petroleum Engineering, Hydraulic Fracture, Fuzzy System, Genetic Algorithms.*