

# 1º Congresso Brasileiro de Redes Neurais

Escola Federal de Engenharia de Itajuba  
Itajuba, 24 a 27 de outubro de 1994

## Sistema Inteligente para Problemas de Gas-Lift

Antonio R. Patrício, DEPRO/PETROBRÁS  
Armando F. Rocha, UNICAMP  
Celso K. Morooka, UNICAMP

### RESUMO

A produção de óleo e gas natural é muito sensível à perturbações no poço e/ou no processo. Identificação de problemas em poços de gas-lift e na planta de processo envolve também raciocínio simbólico, uma vez que as cartas de gas de superfície e os históricos de funcionamento do processo provêm vários dados considerados importantes, mas não todos requeridos para a tomada de decisão. Uma variedade de problemas de poço e planta pode ocorrer com o sistema de gas-lift. Redes neurais foram usadas para desenvolvimento do SEPLANT, um sistema especialista cujo objetivo é fornecer suporte ao controle inteligente das operações de gas-lift e de seu correspondente processo, servindo de ferramenta para os operadores nas tomadas de decisões em situações de contingência, de forma a evitar problemas e perdas de produção.

### INTRODUÇÃO

Na exploração de campos de produção de óleo e gas natural, a vida útil dos poços e do processo pode ser considerada segundo as três seguintes fases (Homem, 1991):

- período quando a produção somente aumenta, até alcançar seus valores máximos. Durante esta fase,

o reservatório tem pressão suficiente para trazer óleo até a planta de processo na superfície;

- período quando a pressão do reservatório começa a declinar, sendo então necessário o uso de elevação artificial para manter a produção do reservatório;
- período quando os sistemas de injeção de água e/ou gas natural começam a operar, dependendo dos resultados dos estudos e do comportamento da performance do reservatório.

A principal etapa da seleção de um sistema de elevação artificial é a previsão da vazão esperada para cada método analisado. Esta vazão pode ser determinada pelo traçado das curvas de IPR e OPR, que representam a habilidade de produção de fluidos dos poços. Estas curvas relacionam a pressão disponível do reservatório com a vazão e a pressão requeridas na entrada do tubing, para elevar o líquido até a superfície e são usadas também para estimar qual o aumento desta vazão para um dado método de elevação artificial.

A tecnologia de elevação por gas-lift vem evoluindo ao longo dos últimos anos, desde o início dos trabalhos pioneiros no começo da década de 1950. Este método de elevação situa-se em segundo lugar logo após o bombeio mecânico, com base no número de instalações no mundo (Hasan e Kabir, 1993). Um sistema de gas-lift tipo simples, é composto de tubing, válvulas de gas-lift, mandris, packer, separador, compressor e instrumentação. O

gas é comprimido na superfície e injetado no tubing através das válvulas de gas-lift, para aerar a coluna de líquido que está sendo produzida, reduzindo assim a pressão de fundo em fluxo permitindo uma produção maior de líquido. Avanço rápido tem sido observado no projeto dos vários tipos de instalações otimizadas de processo, em particular as otimizações que tornam esta técnica mais atrativa, principalmente para poços marítimos.

Variáveis como razão gas-líquido, vazão de gas produzido e injetado, pressões de revestimento e de tubing, e as cartas de gas de superfície (registradores) são peças importantes para operação de gas-lift.

O sistema de gas-lift tem operação mais complexa que o sistema de surgência natural pois a razão gas-líquido é variável. O conhecimento preciso do volume de gas injetado não é uma informação confiável para o controle de processo, porque este volume depende da pressão na profundidade de injeção.

Problemas como malfuncionamento de válvulas (poços e processo), vazamento de mandril, e outras condições anormais de processo, pode ocorrer com este sistema (Brown, 1980).

A identificação de problemas em sistema de gas-lift envolve também raciocínio simbólico, desde que a instrumentação convencional e as cartas de gas de superfície fornecem várias informações importantes, mas não todas requeridas para a tomada de decisão (Patricio, 1992).

Técnicas de inteligência artificial estão emergindo como ferramentas adequadas para suporte à tomada de decisão na indústria do petróleo. Qualquer sistema inteligente especialmente projetado para supervisionar e controlar as atividades de gerenciamento da produção de poços e funcionamento do processo, deve ser capaz de executar o monitoramento inteligente usando o conhecimento de especialistas (Alegre et al., 1993). O objetivo deste trabalho é apresentar o SEPLANT, um sistema inteligente hierárquico, para ajuda ao engenheiro na operação de poços de gas-lift. Uma vez estabelecido o diagnóstico, as redes neurais podem também indicar a ação correta a ser tomada para manter as condições especificadas do gas-lift.

## O NEURÔNIO ARTIFICIAL

Recentemente, grandes progressos foram denotados na neurociência e na ciência da computação renovando o interesse em redes neurais, como arquiteturas de uso potencial na resolução de problemas. Redes neurais são circuitos dinâmicos compostos de camadas de neurônios altamente interconectadas. Elas são únicas, devido sua habilidade em aprender com a experiência, como fazem as pessoas (Garcia e Whitman, 1992). Por exemplo, elas podem ser indicadas, com exibições repetidas, a reconhecer problemas de gas-lift e de seu processo correspondente. Muitos tipos de redes neurais têm sido propostas na literatura. Aqui o neurônio formal introduzido por Rocha, 1992 é usado devido sua simplicidade e sua utilização efetiva em vários domínios tais como reconhecimento de padrão, e um certo número de aplicações petrolíferas.

(Rocha, 1992) propôs, no sentido de aumentar a capacidade de processamento do neurônio artificial, um novo modelo formal incluindo algumas propriedades emprestadas pelas redes Petri no neurônio original de Mc Culloch-Pitts. Este novo tipo de neurônio tem também a vantagem de descrever o conhecimento recente sobre a fisiologia da sinapse descoberta por biólogos. Foi mostrado (Fig. 1) que a transmissão dos neurônios pré e pós-sinápticos envolve a liberação específica de mensagens químicas pré-sinápticas chamadas transmissores (t) para ligar moléculas pós-sinápticas definidas chamadas receptores (r). Esta ligação tr ativa por sua vez, algumas outras moléculas pós-sinápticas chamadas controladores (c), cujo propósito é exercitar alguma ação de economia neuronal. Em outras palavras, a ativação de uma sinapse resulta em transações do tipo:

$$t + r \text{ ---} > c \text{ ---} > \text{ação} \quad (1a)$$




Fig. 1 O Neurônio Simbólico

A quantidade  $a(i,c)$  de controladores ativados pela  $i$ -ésima sinapse de um neurônio  $n_j$ , depende:

- 1b) da quantidade de  $a(i,r)$  de receptores  $r$  disponíveis no local pós-sináptico;
- 1c) da quantidade  $a(i,t)$  de transmissores  $t$  liberados no terminal pré-sináptico, e;
- 1d) da afinidade química  $\mu(t,r)$  entre as moléculas pós-sinápticas  $t$  e  $r$ .

Agora:

- 2a) se  $A(i,t)$  é a quantidade total de transmissores  $t$  armazenados no local pré-sináptico e;
- 2b) se  $A(i,r)$  é a quantidade total de receptores armazenados pela célula pós sináptica, então;
- 2c) o peso  $w_i$  da sinapse é calculado como:

$$w_i = A(i,t) \rho A(i,r) \lambda \mu(t,r)$$

onde  $\rho$  e  $\lambda$  são em geral,  $t$ -normas.

Nesta condição, o volume atual  $a(i,t)$  de transmissores liberados na  $i$ -ésima sinapse pode ser calculada como:

$$a(i,t) = s_j * w_i \tag{3a}$$

onde  $*$  é, em geral, uma  $t$ -norma e o volume  $a(i,c)$  de controladores ativados pela ligação  $t/r$  pode ser assumida como:

$$a(i,c) = g(a(i,t)) \tag{3b}$$

no caso,  $g$  é a função identidade:

$$a(i,c) = s_j * w_i \tag{3c}$$

se  $m$  fontes  $s_j$  provêm a informação de entrada de um neurônio  $n_j$  com relevância  $r_j$  cada, então sua saída  $s_j$  é obtida como:

$$a = \sum_{i=1}^n s_i * w_i \tag{4a}$$

$$s_j = f(a) \tag{4b}$$

onde  $s_j$  é uma função da média ponderada de suas entradas  $s_j$ . A função  $f$  é em geral uma função booleana tal que:

$$1 \text{ if } a > \alpha \tag{4c}$$

$$s_j = 0 \text{ otherwise}$$

mas ela pode ser definida como qualquer função de filtro. A relevância  $w_i$  é o peso da conexão (sinapse) entre o neurônio pré-sináptico (fonte de informação)  $i$  e o neurônio pós-sináptico  $n_j$  (meio de processamento). Procedimentos de aprendizagem ("backpropagation" é o mais famoso entre eles) mudam os pesos sinápticos de acordo com o sucesso (recompensa) ou falha (punição) de  $n_j$  para fornecer a solução do problema em estudo. nesta condição,  $w_i$  é uma medida de incerteza estatística da contribuição de  $s_j$  para a solução do problema.

Os neurônios são organizados em camadas para formar redes especializadas em resolução particularmente de problemas complexos. Os neurônios (sensoriais) da camada de entrada são indicados para comparar o valor atual de variáveis específicas  $v$  de conhecimento protípico  $v'$  sobre o comportamento destas variáveis, assim  $s_j$  provê uma medida de incerteza do "matching"  $v \cong v'$ . Os neurônios das camadas intermediárias mediam e filtram as informações de entradas, equações 4a. a 4c. Estas operações provaram ser equivalentes aos cálculos envolvidos na resolução de sentença do tipo (Yager, 1990; Rocha, 1992) :

se  $Q$  (relevância  $X_s$  é  $A$  é verdade) então  $y$  é  $B$  (5)

Onde  $Q$  é um quantificador linguístico como a maioria de, se  $X$  de  $N$  e assim por diante.

Nesta condição a rede neural especializada (Fig. 2) é composta de :

- 1. nodos de evidências: são os nodos situados no nível mais baixo da rede. Eles representam os

dados que suportam as decisões nesta aplicação.

2.nodos intermediários: representam diferentes agregações de evidências usadas pelo especialista em seu raciocínio.

3.nodos de hipóteses : são os nodos situados no nível mais alto da rede e representam as hipóteses de diagnósticos levadas em consideração.

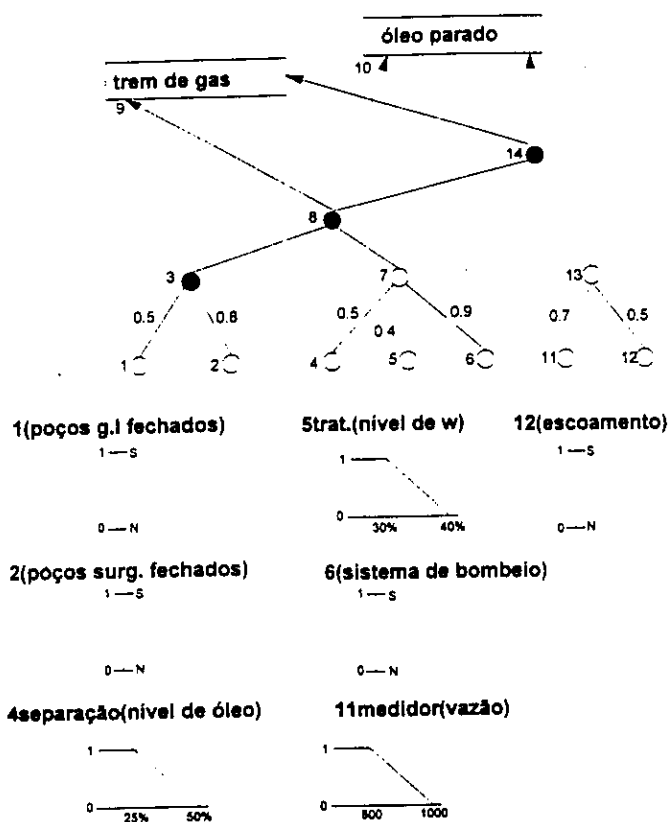


Fig. 2 Rede Neural

**REDES NEURAIS**

O conhecimento que o especialista adquire enquanto vivencia os problemas de seu domínio de especialização, é guardado em seu cérebro por uma troca de conectividade entre neurônios, e pelos neurônios especializados em executar operações definidas e cálculos lógicos selecionados (Rocha and Yager, 1992; Rocha, 1992). Devido a isto, o

conhecimento do especialista pode ser representado como uma rede de conhecimento composta por um conjunto de redes interconectadas. cada rede codifica o raciocínio procedural usado pra suporte da tomada de decisão sobre os problemas do domínio.

Redes neurais foram construídas para imitar o raciocínio do especialista usado no controle do gas-lift e seu processo, sob condições operacionais definidas. Este conhecimento é representado como um conjunto de redes neurais relativo aos casos especificados do domínio que interessa ao engenheiro de campo. Todas as redes neurais são montadas para identificar problemas definidos de gas-lift e ajudar o engenheiro na tomada de decisão sobre a ação de controle requerida para manter a operação normal.

Cada rede neural é composta de um conjunto de nodos terminais chamados evidências (nodos 1,2,4,5,6,11 e 12 na Fig. 2), cuja tarefa é avaliar as condições requeridas para prover decisões operacionais. Estes nodos terminais contêm conhecimento prototípico sobre valores de variáveis controláveis que suportam tomadas de decisões operacionais especificadas ( gráficos de funções da Fig. 2). Os valores atuais destas variáveis são "matched" contra o conhecimento prototípico e determinam o grau de ativação do nodo terminal correspondente. Este grau de ativação representa a confiança dos dados contra a evidência prototípica requerida para a tomada de decisão.

Os resultados terminais são "clustered" em nodos não terminais chamados nodos associativos (3,7 e 13 da Fig. 2), de acordo com a conectividade assumida pelo especialista para a rede neural. Este grau de ativação de cada associação de neurônio é obtida como uma operação de t-normas de suas saídas. Esta entrada depende da ativação e da relevância dos nodos terminais que chegam. Relevâncias (.5..8,.. na Fig. 2) é associada ao peso da rede sinaptica, e mede a importância de cada peça de informação como suporte para a tomada de decisão. O produto é a operação de intersecção mais comum (t-norma) usada para combinar relevância e confiança.

Os nodos de decisão (8 e 14 na Fig. 2) são usados pelo especialista para orientar a navegação das redes neurais. Neurônios de decisão levam a vantagem de

filtrar propriedades de seus terminais para dirigir ao fluxo de informação de nodos de redes diferentes. Por exemplo, os neurônios 8 e 14 da Fig. 2 tanto podem transferir o foco da hipótese para "óleo parado" como proceder a investigação da hipótese "trem de gas" pedindo outras informações.

### O CONHECIMENTO CONECCIONISTA

(Leão and Rocha, 1990) introduziram uma técnica de aquisição e representação do tipo de conhecimento coneccionista. Esta técnica foi largamente comprovada por (Machado et al., 1990 e Rocha, 1992). A seguir, estão as principais etapas de obtenção do conhecimento do especialista segundo esta técnica:

- . é solicitada ao especialista uma lista de problemas do domínio e;
- . para cada problema do domínio, é requerido ao especialista uma lista de dados prototípicos de suporte e para ordenar esta lista segundo a sequência temporal, cada peça da informação deve ser obtida em condições reais.

Esta lista ordenada é considerada um conjunto de nodos sensoriais (neurônios 1,2,4,5,6,11 e 12 da Fig. 2) da rede de conhecimento correspondente. Devido a isto é solicitada ao especialista:

- . unir os nodos terminais (sensoriais) da rede da mesma forma que ele combina informações de suporte para sua tomada de decisão. Em fazendo isto, o especialista cria o número de neurônios associativos (neurônios 3,7,13 e 8 e 14 da Fig.2) necessário para imitar na prática o "clustering" de dados de suporte, até esses neurônios associativos representarem alternativas possíveis para tomadas de decisões (por exemplo "trem de gas" na Fig.2).

Uma vez descrito o gráfico e obtida a estrutura da rede neural, o especialista:

- . deve fornecer o peso de cada arco do grafo. Estes pesos representam a relevância (.5..8 .....na Fig2) e cada peça de informação tem o suporte do raciocínio do especialista.
- . deve prover o conhecimento prototípico usado para "matching" na camada de entrada. Este conhecimento é, em geral, codificado pelas funções de "matching" definindo conceitos tais

como alto, baixo, médio, pressão de sucção, temperatura alta e outros (Zadeh, 1975);

- . deve descrever as regras (t ou s-normas) usadas para combinar informações nos neurônios de associação/decisão e;
- . deve definir os limiares lógicos operacionais a serem desempenhados por cada neurônio associativo. Estas operações descrevem as condições que cada tomada de decisão deve obedecer e o fornecimento das regras para navegar cada rede.

### RACIOCINANDO SOBRE O GAS-LIFT E O PROCESSO

Algumas das decisões que devem ser tomadas durante a operação do processo são baseadas nas cartas de gas de superfície e complementadas pelos resultados da produção de óleo. Desde que as cartas de gas de superfície não fornecem todas as informações requeridas para controle do processo e dos poços, muitos outros índices de performance tais como previsões de pressão e temperatura na profundidade de injeção de gas e a vazão de óleo produzido, são usados pelo engenheiro para dar suporte a sua tomada de decisão final. Embora estes índices sejam obtidos como resultados de cálculos definidos usando medidas numéricas de condições da elevação artificial, eles são usualmente referidos como expressões qualificadas de alto, médio, pressão baixa, temperatura, vazão, em muitos exemplos.

Estas informações são continuamente obtidas das instalações do processo e dos poços por meio de sensores eletrônicos, que enviam sinal ao módulo escritório central da última variável adquirida ou requerendo ao usuário o fornecimento do mesmo.

Informações como pressão alta de operação, baixo volume de injeção de gas, vazão de produção média, baixa razão gas-líquido, alta temperatura, são usadas aqui tanto como nodos disparadores como evidências complementares para tomada de decisão do especialista. Uma vez ativados os disparadores, um módulo supervisor atua na rede neural correspondente, e outras informações são obtidas dos sensores ou do usuário para suporte da decisão.

## VALIDAÇÃO

Para testar a proficiência do SEPLANT, os sintomas resultantes de 35 falhas do processo e dos poços de gas-lift foram apresentadas ao sistema de redes neurais. Durante esta fase, todos os valores de saída foram precisamente classificados dentro de segundos para correção das falhas, resultados estes confirmados pelo uso de dados de campo (cartas de gas de superfície). A tabela 1 mostra a curva média (um dos casos é simulação) para a ação da rede neural em problemas simples.

A tabela 1 lista dados de treinamento e reais de 4 casos envolvidos. As colunas da mesma representam sequencialmente da esquerda para a direita: números médios de nodos de evidências nos grafos de conhecimento, dos casos teóricos (01) e concretos (03) envolvidos.

Tabela 1 Resultados da Simulação

GRAFO	CASO T.	CASO # 1	CASO # 2	CASO # 3
POÇOS DE GAS-LIFT FECHADOS	SIM E NÃO	SIM	SIM	SIM
POÇOS SURGENTES FECHADOS	SIM E NÃO	TODOS OU ALGUNS	TODOS OU ALGUNS	TODOS OU ALGUNS
SEPARAÇÃO DE O/G/W (NÍVEL %)	45	ATÉ 60	ATÉ 50	ATÉ 50
TRATAMENTO DE ÓLEO (NÍVEL %)	40	20 NO MÁXIMO	20 NO MÁXIMO	20 NO MÁXIMO
SISTEMA DE BOMBEIO	PARADO	PARADO	PARADO	PARADO

Na série seguinte de simulações, um conjunto de sintomas foi apresentado ao SEPLANT para determinar sua habilidade em executar tarefas generalizadas. Esta capacidade foi examinada

introduzindo sintomas de entrada de dois e três malfuncionamentos de poços e processos respectivamente. O caso acima mencionado desperta interesse pois o diagnóstico de falhas múltiplas é difícil de estabelecer usando métodos tradicionais de análise de problemas.

As condições de campo do SEPLANT foram testadas com corridas de vários casos simulados quais sejam um modelo teórico e três casos de campo reais, que validaram a estrutura desenvolvida para construção do SEPLANT.

As redes neurais foram capazes de aprender a associação correta entre evidências e malfuncionamentos de processo e poços. Foram capazes também de diagnosticar múltiplas condições de falhas.

## CONCLUSÕES

O SEPLANT simplifica a diagnose de problemas e sumariza relatórios de fácil entendimento. Problemas de superfície (processo e poços) e de fundo (poços) são reconhecidos e importantes parâmetros de produção são calculados.

O SEPLANT minimiza a participação requerida do especialista na diagnose do problema mas não elimina a necessidade do mesmo. O SEPLANT está sendo usado como uma ferramenta de treinamento para o pessoal de projeto e operação. Com este sistema, os usuários podem aprender previamente problemas não familiares do gas-lift (poços e processo) e preverem soluções para estes problemas.

Os resultados obtidos através das simulações dos casos teórico e reais mostraram que a teoria de redes neurais simbólicas codifica e absorve o raciocínio dos especialistas envolvidos na engenharia de análise de sistemas de gas-lift.

A estratégia de operação do SEPLANT pode aumentar a possibilidade de sucessos técnico e econômico da implementação e manuseio inteligentes de poços e processos de gas-lift.

## REFERENCES

- Alegre L., Morooka C. K. and Rocha A. F. - Intelligent Approach of Rod Pumping Problems. SPE Petroleum Computer Conference, pg. 249- 255, (1993).

- Brown K. - Artificial Lift Methods - vol. I - USA(1977)
- Garcia G. and Whitman W. W. - Inversion of a Lateral Log Using Neural Networks, SPE Petroleum Computer Conference, pg 295 - 304, (1992)
- Hasan A. R. and Kabir C. S. - Predicting Fluid Temperature Profiles in Gas-Lift Wells, SPE Petroleum Technology Co, pg 673 - 682, (1993)
- Homem F. C. - Offshore Power Generation Reliability and Availability - Msc. Thesis, Cranfield Institute, London (1991)
- Leão B. and Rocha A. F. - Proposed Methodology for Knowledge Acquisition: A Study on Congenital Heart Disease Diagnosis, Methods Information Medicine - (1990)
- Machado R. J. and Rocha A.F. - Calculating the Mean knowledge Representation from Multiple Experts In: Fedrizzi & Kacprzyck. Multiperson Decision Making Models Using Fuzzy Sets and Possibility Theory, Kluwer Academic Publishers - (1990)
- Patricio A. R. - Sistema Especialista para Apoio à Operação de Plantas Marítimas de Produção - Msc. Thesis, Unicamp - (1992)
- Rocha A. F. - Neural Nets: A Theory for Brains and Machines. Lecture Notes in Artificial Intelligence - Springer Verlag, vol. 638 - (1992)
- Rocha A. F. and Yager R. R. - Neural Nets and Fuzzy Logic, in: Kandel and Langholz (eds), Intelligent Hybrid Systems, CRC Press, pg 13 - 27 (1992)
- Zadeh L. - The concept of A Linguistic Variable and its Application to Approximate Reasoning. Information Sciences, pg 199 - 301 (1975)

