



2º CONGRESSO BRASILEIRO DE P&D EM PETRÓLEO & GÁS

PREDIÇÃO DO DESGASTE DE BROCAS UTILIZANDO REDES NEURAIIS

Luis Fernando Pozas, Guilherme Bittencourt

Departamento de Automação e Sistemas, Universidade Federal de Santa Catarina,
88040-900-Florianópolis-SC, {lfpozas, gb}@das.ufsc.br

Resumo – A operação de perfuração de poços é a segunda fase na busca do petróleo e se dá em locais previamente determinados por pesquisas geológicas e geofísicas. Ela consiste basicamente na manobra de uma sonda de perfuração por um técnico altamente especializado, o sondador. A sonda por sua vez possui em sua extremidade inferior uma broca, que é a responsável por abrir caminho na rocha seja por trituração, por acunhamento seguido de arrancamento, ou ainda, por raspagem. O desgaste da broca se dá em função de diversos fatores como velocidade de rotação, taxa de penetração, tipo de formação sendo perfurada, etc.

Por outro lado, sabe-se que as redes neurais são ótimas ferramentas de representação de conhecimento e são capazes de lidar com sistemas não-lineares, possuindo a capacidade de prever a evolução de um dado modelo matemático. Assim, propõe-se o desenvolvimento de um sistema baseado em redes neurais, que seja capaz de inferir o nível de desgaste da broca e relatá-lo ao sondador durante as operações de perfuração.

Palavras-Chave: petróleo; perfuração de poços; redes neurais; simulador de perfuração;

Abstract – Drilling operations take place after the exploration operations chooses the region to begin the search for oil. Basically it consists in driving the drill stem downward the hole by the expert driller, which tries to do it as fast and safe as possible. There is a drill bit attached to the lower extremity of the drill stem which is responsible for digging the hole. Drill bit wear is affected by factors such as rotation speed, rate of penetration, rock properties, etc.

On the other hand, it is a well-established fact that neural networks have a very good performance in the execution of the following tasks: knowledge representation and non-linear systems modeling. The proposal of this work is to develop a neural network based system that infers bit wear and report it to the expert driller during the drilling operation.

Keywords: oil; drilling wells; drill bits; neural network; drilling well simulator;

1. Introdução

A perfuração é a segunda fase na busca do petróleo e consiste basicamente na perfuração de um poço mediante o uso de uma sonda de perfuração. Geralmente, esta atividade é realizada por empresas terceirizadas que cobram por seus serviços a quantia de US\$200.000,00 - custo diário médio de sondas de perfuração marítimas para águas profundas - e operam em locais previamente determinados pelas pesquisas Geológicas e Geofísicas.

A sonda é composta por uma torre, que serve como base de apoio e sustentação, e pela coluna de perfuração que se apóia na torre. A coluna é formada por vários tubos conectados entre si. Na extremidade inferior da coluna encontra-se a broca, que abre caminho nas camadas subterrâneas seja por ação de tritamento, acunhamento seguido de arrancamento, ou raspagem, e na extremidade superior estão conectados os equipamentos que têm a função de transmitir torque à coluna e de imprimir peso sobre a broca. É nesta extremidade também que há a injeção do fluido de perfuração. O fluido é um dos elementos de maior importância na atividade de perfuração pois dele dependem a limpeza das brocas, a retirada dos cascalhos do fundo do poço, a manutenção de uma pressão hidrostática ideal no fundo do poço e o estudo geológico da rocha que está sendo perfurada.

A sonda de perfuração é manobrada por um técnico altamente especializado conhecido como sondador (ou expert driller), que através do controle de variáveis como o peso sobre a broca, a vazão e a pressão do fluido de perfuração, o torque aplicado, a velocidade de rotação, e outras, tenta garantir que a perfuração se dê da maneira mais econômica e segura possível. Para tanto, um grande número de dispositivos de telemetria o auxilia nesta tarefa.

No entanto, apesar do grande auxílio destes dispositivos, muitos acidentes ocorrem durante a perfuração. Algumas vezes são causados por inexperiência do sondador (caso raro), outras tantas por fatalidades, e um grande número de vezes por distração ou cansaço do sondador. Nunca é demais lembrar que estes operadores estão sujeitos a rotinas estafantes de trabalho, com turnos de 12 horas, algumas vezes 15 dias por mês embarcados, trabalhando em locais de alta periculosidade. Nestas condições sabe-se que os seres humanos tornam-se mais propensos a cometer erros.

Por outro lado, sabe-se que as redes neurais são ótimas ferramentas de representação de conhecimento, são capazes de lidar com sistemas não-lineares e possuem capacidade de prever a ocorrência de eventos com uma certa antecedência. Justamente por estas características elas têm sido bastante utilizadas no setor de petróleo & gás em pesquisas como análise da evolução de poços (ZHONG), pesquisas geológicas (WANG) e análise de desgaste de brocas (BILGESU). E, ao contrário dos métodos analíticos tradicionais aonde um modelo matemático do problema precisa ser desenvolvido, as redes neurais exigem apenas a apresentação de pares entrada/saída do sistema em questão durante a fase de aprendizado para que estejam aptas a realizar as tarefas para as quais foram designadas.

Na fase de treinamento da rede, serão utilizados dados provenientes de um simulador de perfuração de poços. Durante a perfuração o sondador não possui nenhuma informação sobre o estado de desgaste da broca, informação esta que somente pode ser obtida com a retirada total da coluna do poço e observação direta da peça. A disponibilidade desta informação poderia auxiliar o sondador na diagnose de algum evento inesperado, na manobra da sonda ou ainda na otimização da perfuração.

O objetivo deste trabalho é observar o desempenho de algumas configurações de redes neurais na previsão de desgaste de brocas em perfurações de formações rochosas uniformes. Uma vez avaliadas, será necessário fazer a validação das mesmas através de ensaios de campo. Posteriormente, estas redes poderão ser integradas em um equipamento capaz de prever o desgaste de brocas em formações rochosas compostas.

O presente trabalho se organizará da seguinte maneira: Na seção 2, uma breve introdução às redes neurais será apresentada; na seção 3, a metodologia do trabalho será descrita; na seção 4 os resultados obtidos serão apresentados; na seção 5 uma conclusão sobre os resultados obtidos, na seção 6 os agradecimentos e na seção 7 as referências.

2. Fundamentos de Redes Neurais Artificiais

O reconhecimento de que o cérebro humano trabalha de maneira completamente diferente do que um computador digital tem motivado a pesquisa em redes neurais (RN's). O cérebro é um sistema de processamento de informações altamente complexo, paralelo e não linear, que tem a capacidade de organizar seus elementos estruturais, conhecidos como neurônios, de tal forma que se torne capaz de realizar algumas computações muitas vezes mais rápido do que alguns computadores digitais de hoje em dia. Por exemplo, uma tarefa de reconhecimento visual. O cérebro continuamente faz representações do meio ambiente em que está imerso interagindo em questões de décimos de segundos. A realização de tarefas muito mais simples do que esta pode levar horas em computadores convencionais.

De acordo com [HAYKIN], em sua forma mais geral, uma rede neural é uma máquina que é projetada para modelar a forma em que o cérebro realiza uma determinada tarefa. A rede normalmente é implementada através do uso de componentes eletrônicos ou de simulações em softwares. Para alcançar uma boa performance as RN's efetuam uma intensa interconexão entre seus elementos de processamento, os chamados 'neurônios'.

Um neurônio é a unidade fundamental de processamento de informações da rede neural. A figura 1 apresenta um diagrama em blocos de um neurônio. Nele pode-se perceber:

- Um conjunto de sinapses ou conexões, cada qual caracterizada por apresentar um peso ou força própria. Especificamente, um sinal x_j aplicado na entrada de uma sinapse j multiplicado pelo peso sináptico w_j ;
- Um somador para somar todos os sinais de entrada já multiplicados pelos seus respectivos pesos;
- Uma função de ativação para limitar a amplitude da saída do neurônio. Ela também é conhecida como função de compressão por 'comprimir' a faixa de amplitude permissível para o sinal de saída a um valor finito.




Fig.1 – Elemento básico de processamento: neurônio

O procedimento utilizado para realizar o processo de aprendizado é chamado de algoritmo de aprendizado, cuja função é modificar os pesos sinápticos da rede, organizadamente, de maneira que se possa dizer que a rede 'absorveu' aquele conhecimento. O aprendizado é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo guiado por estímulos provenientes do ambiente no qual está inserido. Esta definição implica na seguinte seqüência de eventos:

- Receber estímulos do ambiente;
- Submeter-se à mudanças em seus parâmetros como resultado destes estímulos;
- Responder ao ambiente de maneira diferente devido à esta adaptação;

Ainda de acordo com [HAYKIN], uma tarefa fundamental de uma RN é construir um modelo do mundo na qual está inserida e mantê-lo suficientemente consistente com o mundo real, de maneira que as metas específicas da aplicação de interesse sejam alcançadas.

3. Metodologia

Utilizou-se o toolbox nntool integrante do software MathWorks Matlab 6.1 para implementar as redes neurais. As simulações de perfurações foram feitas no simulador MaxSimul PayZone J. Este simulador apresenta a opção de análise do desgaste da broca, o que nos permite obter dados sobre o estado da broca durante toda a perfuração. Todas as tarefas foram executadas em um computador Pentium4 com 1.4GHz e 256MB de RAM.

O seguinte procedimento foi adotado: durante a fase de treinamento, estimulou-se a rede com dados provenientes de uma perfuração aonde uma litologia uniforme foi perfurada por uma broca até que esta atingisse seu desgaste total. Esta perfuração foi efetuada mantendo-se fixos os valores de peso na broca, vazão do fluido de perfuração, e velocidade de rotação e monitorando o valor do torque na coluna e a taxa de penetração a cada minuto.

O procedimento foi então repetido para outras combinações dos valores do peso na broca, vazão do fluido de perfuração, e velocidade de rotação. Na tabela 1 estão indicadas as combinações de valores que foram utilizados em cada perfuração. Uma vez obtidos os dados sobre o desgaste da broca para todas as perfurações, estes foram apresentados às redes. Na tabela 1 estão indicadas também as combinações de valores utilizadas nas perfurações que foram utilizadas para averiguar a capacidade de aprendizado e de generalização da rede.

Quanto às redes, foram avaliadas três configurações diferentes para se verificar qual se adapta melhor ao problema proposto. Todas são do tipo *Feed-Forward Back-Propagation* e possuem cinco entradas, sendo elas o peso na broca, a velocidade de rotação, a vazão da lama de perfuração, o torque medido na coluna e a taxa de penetração. Em sua saída são apresentados os valores instantâneos de desgaste da broca.

Tabela 1 – Valores de WOB, RPM e GPM utilizados durante as perfurações.

	WOB (em £ x1000)	RPM	GPM
Treinamento	10	100	900
	30	100	900
	50	100	900
	70	100	900
	90	100	900
	50	20	900
	50	80	900
	50	150	900
	50	220	900
	50	280	900
	50	100	200
	50	100	410
	50	100	610
	50	100	1000
Aprendizado	50	100	900
Generalização	70	180	700

4. Resultados

Inicialmente foram feitas simulações com uma broca do tipo *Milled Tooth*, com diâmetro de $12 \frac{1}{4}$ " , dentes de tamanho médio e três bicos injetores em uma litologia do tipo *Hard Sand*. Foram utilizadas três configurações diferentes de redes. A rede que será aqui denominada R5-2 possui uma camada de entrada com cinco neurônios, uma camada de saída com dois neurônios configurados com função de ativação puramente linear, e não possui camadas ocultas. A rede aqui denominada R5-10-2 possui uma camada de entrada com cinco neurônios, uma camada oculta com dez neurônios configurados com função de ativação tangente sigmóide, e uma camada de saída com dois neurônios configurados com função de ativação puramente linear. A rede aqui denominada R5-10-10-2 possui uma camada de entrada com cinco neurônios, duas camadas ocultas com dez neurônios cada configurados com função de ativação tangente sigmóide, e uma camada de saída com dois neurônios configurados com função de ativação puramente linear.

De acordo com [HAYKIN], para fazer uma avaliação mais precisa sobre o andamento do processo de treinamento de uma rede neural é necessário que a mesma seja avaliada quanto à sua capacidade de aprendizado, ou seja, se o mapeamento de entrada/saída apresenta um erro médio quadrático pequeno, e à sua capacidade de generalização, ou seja, se a resposta da rede a padrões de entrada que não fazem parte do conjunto de treinamento apresenta um erro médio quadrático pequeno. O erro médio quadrático é definido na equação 1:

$$\xi = \frac{\sqrt{\sum_{x=1}^N (D(x) - Y(x))^2}}{N} \quad (1)$$

aonde $D(x)$ é o vetor resposta desejada , $Y(x)$ é o vetor resposta na saída da rede e N é a dimensão dos vetores D e Y .

Na tabela 2 estão indicados, para cada configuração de rede, o erro médio quadrático de aprendizado e o erro médio quadrático de generalização após cada ciclo de treinamento, aonde ciclo de treinamento se refere à apresentação dos dados de perfurações 2800 vezes à rede neural. Estão indicados também o tempo gasto pelo computador em cada ciclo de treinamento.

Tabela 2 – Erro quadrático médio de treinamento e de generalização

R5-2			
Ciclo de treinamento	Erro de Aprendizado	Erro de Generalização	Tempo Decorrido (min)
1	0,0145	0,0403	12,90
2	0,0076	0,0178	16,28
3	0,0047	0,0100	17,24

R5-10-2			
Ciclo de treinamento	Erro de Aprendizado	Erro de Generalização	Tempo Decorrido (min)
1	0,0023	0,0269	15,82
2	0,0034	0,0026	16,35
3	0,0032	0,0021	17,08

R5-10-10-2			
Ciclo de treinamento	Erro de Aprendizado	Erro de Generalização	Tempo Decorrido (min)
1	0,0048	0,0082	15,70
2	0,0027	0,0096	15,80
3	0,0022	0,0057	16,17

Observando os resultados obtidos com as redes neurais, em um primeiro momento poderíamos optar por escolher a rede R5-10-2 porque esta é a que apresenta o menor erro de aprendizado após o primeiro ciclo de treinamento. No entanto, ela não generaliza muito bem e há de se levar em conta também que conforme as redes são submetidas a novos ciclos, percebe-se que o erro de aprendizado da R5-10-2 aumenta enquanto que o erro da R5-10-10-2 diminui progressivamente até tornar-se o menor de todos. Por outro lado, a rede R5-10-2 generaliza melhor do que a rede R5-10-10-2. Resumindo, poderíamos dizer que a rede R5-2 generaliza melhor, enquanto a rede R5-10-10-2 é mais precisa.

Já a rede R5-2 é a que apresenta o pior desempenho de todas pois possui os maiores erros de aprendizado e de generalização. Por outro lado, pelo critério de tempo total gasto no treinamento ela apresenta a vantagem de possuir o menor custo computacional dentre todas. No entanto, a diferença de tempo entre todas as redes é muito pequeno para que esta rede seja considerada a melhor escolha.

Assim, por ser a que melhor generaliza e não possuir um erro de aprendizado tão elevado elegeu-se a R5-10-2 como a de melhor desempenho na tarefa de previsão de desgaste de brocas.

5. Conclusões

O objetivo do presente trabalho é estudar o desempenho de algumas configurações de redes na tarefa de avaliar o desgaste de brocas e sugerir uma metodologia para que essa tarefa possa ser alcançada. Os resultados apontam que seguindo nossa metodologia é possível desenvolver uma ferramenta baseada em redes neurais para inferir o desgaste de uma broca.

Em um primeiro momento, os dados obtidos na seção anterior indicam erros de treinamento numa faixa entre 0.22% e 0.47% e de generalização numa faixa entre 0.21% e 0.57% após 3 ciclos de treinamento. São valores de erro bastante baixos, e tudo indica que tendem a ser menores com mais ciclos de treinamento. Isso quer dizer que as redes aqui testadas foram capazes de indicar o desgaste de uma broca quando informadas sobre os valores de peso na broca, velocidade de rotação, vazão do fluido de perfuração, o torque na coluna e a taxa de penetração. No entanto ressalta-se que maiores informações devem ser obtidas através da repetição da metodologia em outros tipos de litologia e com outras brocas para que uma conclusão mais precisa possa ser obtida.

Antes da implementação da ferramenta, será necessário fazer com estas redes uma validação através de ensaios de campo. Se as redes apresentarem desempenho satisfatório, sugere-se fazer uma simulação em uma formação rochosa composta por duas litologias diferentes e avaliar se a rede consegue inferir o desgaste da broca corretamente apesar da mudança de litologia.

6. Agradecimentos

Gostaria de agradecer às seguintes instituições:

- ANP;
- Departamento de Automação e Sistemas – Universidade Federal de Santa Catarina;
- FEESC;
- MaxSimul.

7. Referências

A.MURRAY, A.F.STRONACH E P.F.A.MACCONNEL – The Applications of Advanced Computing Techniques to Oil and Gas Facility Optimisation – Offshore Europe Conference – Aberdeen, Escócia – Setembro/1999.

- ZHONG HE, LINYU YANG, JOHN YEN E CHING WU – Neural-Network approach to predict well performance using available field data – SPE Western Regional Meeting – Bakersfield, EUA – Março/2001.
- L. WANG, P.M. WONG E S.A.R. SHIBILI – A´nan oilfield: Use of geological quantification, neural networks and Geostatistics – SPE Reservoir Eval. & Eng., vol. 2, nº. 6, Dezembro 1999.
- H.L. BILGESU, U. ALTMIS, S. AMERI, S. MOHAGHEGH E K. AMINIAN – A New Approach to Predict Bit Life Based on Tooth or Bearing Failures – SPE Eastern Regional Meeting – Pittsburgh, EUA – Novembro/1998.
- S. HAYKIN – Neural Networks – A Comprehensive Foundation – Prentice Hall – 2ª Ed - NY, 1993.
- MATHWORKS - Toolbox nntool – Manual do Matlab 6.1
- MAXSIMUL - PayzoneJ Drilling Simulator – California, USA