



Business Intelligence

PUC
RIO

FABRÍCIO NOGUEIRA DA SILVA

Detecção de Padrões de Produção que Antecipam o Fechamento de Poços de Petróleo

Monografia apresentada ao Departamento de Engenharia Elétrica da PUC/Rio
como parte dos requisitos para a obtenção do título de Especialização em
Business Intelligence

Orientador: Marley Maria Bernardes Rebuszi Vellasco
PhD

Rio de Janeiro
26 de Dezembro de 2011

RESUMO

As operações de poços produtores de óleo e gás são constantemente acompanhadas com informações acerca de seus potenciais e de suas produções em um determinado período. A perda de produção de um poço, produção inferior ao potencial, é registrada juntamente com um motivo referente à causa da mesma. Cada motivo de perda contém um conjunto de providências a serem tomadas para que o poço retorne à sua produção normal. O estado indesejável de um poço é quando o mesmo possui produção igual a zero, ou seja, poço fechado. O objetivo deste trabalho é desenvolver um modelo que aplique técnicas de inteligência computacional para identificação de padrões de operação de um poço que ocorrem antes do mesmo ser fechado por algum problema operacional. A detecção desses padrões poderia contribuir na previsão de fechamentos de poços, uma vez que se pode assumir que tais padrões podem se repetir no futuro. Como benefício direto deste modelo, ter-se-ia a possibilidade de antecipação de intervenções nos poços a fim de minimizar as perdas de produção.

ABSTRACT

The gas and oil well operations are constantly monitored with information about potential and production in a period. The production loss of a well, production less than its potential, is recorded with a reason related to its cause. Each loss reason has a set of steps to be followed aimed to put the well in its normal production. There is an unwelcome state of the well that is when the production is equal to zero, meaning a well closed. This work aims to develop a model in which applies computational intelligence techniques in order to identify operation patterns of an oil well that happen before its closing due to an operational problem. These patterns detection could contribute to oil well closing forecasts, since admit the patterns will happen again in future. As a result of this model, it would be possible to anticipate interventions in the wells for the purpose of reduce production loss.

Sumário

1. Introdução	6
1.1 Motivação	6
1.2 Objetivos do trabalho	10
1.3 Descrição do trabalho	11
1.4 Organização do trabalho	12
2. Descrição do problema	13
3. Metodologia.....	13
4. Arquitetura do sistema.....	17
5. Resultados.....	37
6. Conclusões e trabalhos futuros	43
7. Referências bibliográficas	43

Lista de figuras

Figura 1: Perspectiva de equipamentos existentes na extração e produção de petróleo em campo marítimo.	14
Figura 2: Equipamentos existentes na extração e produção de petróleo em campo terrestre.....	14
Figura 3: Gráfico de Produção X Tempo.....	15
Figura 4: Neurônio biológico.	18
Figura 5: Conexões sinápticas entre neurônios.	19
Figura 6: Variação do potencial de ação do neurônio.	20
Figura 7: Neurônio artificial.	21
Figura 8: Exemplo de rede feedforward de camada única.	24
Figura 9: Exemplo de rede feedforward de múltiplas camadas.	25
Figura 10: Exemplo de rede neural com retroalimentação.	26
Figura 11: Exemplo de rede com estrutura articulada.	26
Figura 12: Arquitetura do Sistema de Apoio a Decisão.	317
Figura 13: Rede neural configurada no software Weka.....	36
Figura 14: Rede neural de uma camada.	37
Figura 15: Rede neural de duas camadas.	38
Figura 16: Rede neural de duas camadas.	40

Lista de tabelas

Tabela 1: Instância de monitoramento de produção de um poço de petróleo. 34

1. Introdução

1.1 Motivação

O processo de produção de óleo e gás em instalações marítimas ou terrestres requer o uso de uma grande quantidade de equipamentos operando na extração, transporte, tratamento e armazenamento dos fluidos. Por conseguinte, a ausência de falhas em qualquer desses equipamentos é condição *sine qua non* para que a produção dos poços ocorra com normalidade. Um poço opera com normalidade quando sua taxa de produção equivale ao potencial do mesmo, ou seja, a produção do poço é a máxima possível. Já o potencial é determinado através de testes de produção, e indica a vazão máxima de extração de fluido do poço nas condições normais de operação dos equipamentos. A queda na produção de poços pode ser ocasionada por diversos motivos, desde falhas ou indisponibilidade de equipamentos, incrustações em dutos, condições marítimas e/ou ambientais até diminuição natural do potencial do poço.

Durante a operação dos poços, um monitoramento constante é realizado, atualizando-se informações sobre a produção dos mesmos. Tal monitoramento é essencial para se obter um conhecimento histórico do quanto cada poço produziu, da quantidade produzida por cada campo e até do valor de *royalties* a serem pagos. No processo de monitoramento, sempre que ocorre uma queda na produção, a mesma é registrada juntamente com um motivo que, por sua vez, relaciona-se com algum fator causador da perda. Conhecendo-se este fator, um conjunto de providências pode ser tomado para que o poço retorne à sua operação de normalidade. Estes dados são importantes para as unidades produtoras identificarem as principais causas de perda na produção e, conseqüentemente, empreenderem ações no sentido de eliminar ou mitigar as mesmas.

Dependendo do motivo, o poço pode ter suas operações completamente interrompidas, levando o mesmo a um estado de fechamento com perda, ou seja, possui uma produção igual a zero quando deveria estar produzindo. Este estado de poço fechado é o menos desejável no processo de extração de óleo e gás, uma vez que a sua ocorrência indica uma falha operacional, frequentemente grave. Como consequência, a perda de produção de um poço é

máxima durante o período em que o mesmo estiver fechado; o que compromete o seu saldo de produção. Neste caso, as intervenções devem ser feitas o quanto antes para que a produção seja retomada no menor intervalo de tempo possível.

Uma vez identificadas as causas de falhas que comprometem a operação plena de um poço, algumas providencias encaminhadas para solucioná-las podem implicar em mais custos para a companhia. Além do custo pela perda na produção em si, há o custo inerente à realização das ações de solvência às falhas, como por exemplo:

- Algum tempo será demandado para que as correções em equipamentos ou até mesmo substituições dos mesmos sejam feitas, principalmente se houver uma indisponibilidade para substituição imediata de algum equipamento;
- Equipes especializadas podem ter que se deslocar para os locais dos poços a fim de apurar com mais detalhes as causas de falhas, ou realizar intervenções que as solucionem;
- O próprio acesso ao poço pode ter um custo elevado, caso o mesmo esteja em instalações marítimas com lâmina d'água de grande profundidade.

Por esses e outros fatores percebe-se que quanto maior for o intervalo entre a identificação de uma falha e a solução da mesma, maior será a perda de produção e, portanto, menor o ganho da companhia.

A possibilidade de identificar falhas operacionais a partir da baixa na produção antes que as mesmas ocasionem em fechamento de poços seria relevante para a redução de custos. Enquanto que o método reativo, descrito até então, providencia a solução de falhas apenas quando o monitoramento registra o fechamento do poço, um método preditivo poderia dar início à intervenção de poços antes dos mesmos atingirem um estado de fechamento. A redução de custos fica evidente quando se considera que o tempo em que um poço ficaria fechado para realização de correção de falhas operacionais seria menor do que se a falha fosse identificada apenas após o fechamento do mesmo, por conseguinte o total da perda é reduzido.

Como mencionado anteriormente, a operação dos poços é monitorada constantemente e a ocorrência de qualquer queda na produção é registrada. Os motivos associados à queda de produção podem servir como indícios de que existe uma falha operacional nos poços. Através de análises dos dados dos motivos, pode-se tentar identificar padrões que indicam que uma sequência de motivos prediz um estado em que ocorrerá fechamento do poço. Alguns modelos

computacionais de previsão podem ser adotados como mecanismos que analisam os dados históricos, identificam os padrões e apontam indícios de fechamento de poços, assumindo-se que tais padrões irão se repetir no futuro. A técnica de redes neurais artificiais tem sido largamente utilizada para realização desse tipo de previsão.

Na área de petróleo e gás diversos trabalhos que envolvem previsão através de modelos computacionais já foram desenvolvidos. (Nguyen, et al. 2002) apresentaram a aplicação de um modelo de múltiplas redes neurais para estimar a produção futura de poços de petróleo baseado em dados de série histórica de produção mensal. Atualmente, várias técnicas de engenharia que requerem conhecimento especialista e dados de difícil obtenção são usadas para previsões de produção. Por comparação, um modelo de múltiplas redes neurais é confiável apenas para uma grande quantidade de dados históricos de produção. A motivação para o referido trabalho foi que engenheiros de reservatório realizam previsão de produção com base em resultados de análises de dados de perfilagem e pela experiência apoiada por programas de simulação numérica após o início da produção. Este processo pode ser tecnicamente difícil, demorado e caro em termos de custo laboratorial e computacional. Ao mesmo tempo, existe uma grande quantidade de dados de produção que é coletada e armazenada, mas dificilmente usada. Tais dados históricos podem ser utilizados para se construir um modelo pra previsão de produção. Entretanto, a precisão desse modelo pode ser comprometida quando usado para previsões de períodos mais longos. Com isso, ao invés de se usar o modelo comum, o trabalho propõe o uso de um modelo de múltiplas redes neurais para melhorar a precisão das previsões e reduzir sua complexidade. Um modelo de múltiplas redes neurais pode ser definido como várias redes neurais comuns trabalhando juntas para resolver um problema. Cada rede neural comum faz uma previsão para um período de tempo diferente.

Em outro trabalho, (Nguyen, et al. 2004) descreveram um Sistema de Apoio a Decisão que auxilia na previsão de produção de poços de petróleo. O sistema apresenta o melhor e pior cenário baseado em diferentes curvas de produção para que um especialista possa examinar e decidir qual modelo apresenta o melhor ajuste. A curva de produção de cada poço foi modelada matematicamente para que se tenham valores de produção baseados não somente em dados históricos. O trabalho ainda faz uma comparação entre modelos de estimação de curvas de produção e redes neurais; ambos utilizados no trabalho. A previsão de produção representa um papel importante na

determinação do valor dos poços de petróleo e gás. Porém, a precisão dos métodos de previsão empregados atualmente é questionável o que foi um incentivo para o trabalho realizar uma comparação entre as técnicas de estimação de curvas de produção e redes neurais. Para a técnica de estimação de curvas de produção, foi utilizado o método da Soma dos Erros Quadrados. Este método foi aplicado a equações para ajuste dos dados, que foram: linear, logarítmica, exponencial e harmônica. A outra técnica para ajuste de dados foi a de Redes Neurais com o uso do algoritmo Back Propagation.

Seguindo a mesma linha de previsão de produção de petróleo, (Weiss, et al. 2002) propuseram um trabalho que correlacionava dados de perfilagem de poços com as produções dos mesmos. Dados de diagramas de perfilagem foram classificados quanto a "bons" e "ruins" no que diz respeito à facilidade de interpretá-los a fim de adquirir conhecimento sobre a subsuperfície. O trabalho utilizou lógica fuzzy para classificar os perfis bons dos ruins e, em seguida, utilizou redes neurais para correlacionar os dados de perfilagem bons com a produção dos poços. A correlação resultante pôde ser usada para estimar a produção de petróleo de poços.

(Lackes, et al. 2009) propuseram um trabalho cujo objetivo foi desenvolver e implementar um instrumento de previsão para o preço de petróleo em períodos curtos, médios e longos (5, 20 e 60 dias respectivamente). O valor do petróleo é fortemente influenciado pelo contexto econômico, político e ambiental do planeta. Levando-se em conta esses fatores influenciadores, a motivação do referido trabalho foi de que ter uma noção com antecedência do valor do óleo é interessante para se estimular, ou não, a produção do mesmo. Devido a esse grande número de fatores complexos e diferentes que influenciam o preço do óleo, a técnica de redes neurais foi escolhida. Muitos dados relevantes para a previsão foram integrados à rede e vários modelos foram testados. Os dados foram compostos de aproximadamente 2000 registros correspondendo ao período entre 1999 a 2006. Como resultado do projeto, constatou-se que as redes neurais não atingiram bons resultados em previsões de curto prazo, mas apresentaram bons resultados em previsões de médio e longo prazo.

No desenvolvimento do referido trabalho, (Lackes, et al 2009) dividiram a previsão em duas fases, uma fase de configuração e uma fase de execução e manutenção. A primeira fase contou ainda com três subfases, a saber:

- a. Definição e modelagem: Nessa subfase foram definidos os dados de entrada para treinamento da rede e como seria a saída da rede

neural. Além disso, foram codificadas as regras, definida a topologia da rede bem como o neurônio.

- b. Treinamento: Divisão dos dados de entrada em 70% para conjunto de treinamento, 20% para conjunto de validação e prevenção de overfitting e 10% para conjunto de teste. Tendo feita a divisão, foi realizado o treinamento da rede e ajuste dos pesos. Os resultados obtidos nesta etapa podem levar a uma redefinição da rede neural.
- c. Teste: Nesta subfase foi definida a estratégia de teste e a realização do mesmo. Os resultados obtidos nesta etapa podem levar a uma necessidade de novo treinamento da rede neural.

Já a fase de execução e manutenção consistiu ainda em duas subfases, a saber:

- a. Operação/Execução: Após o treinamento da rede, a mesma é utilizada com dados de produção.
- b. Fase de manutenção: Foi definida uma subfase de manutenção para que a rede neural seja constantemente ajustada a fim de manter sua precisão na previsão.

Percebe-se pelos trabalhos apresentados que o uso de redes neurais é adequado para problemas que envolvem detecção de padrões e previsão. Por conta disso, a mesma técnica foi adotada para o desenvolvimento deste trabalho.

1.2 Objetivos do trabalho

Como mostrado na seção anterior, o monitoramento da produção de poços de petróleo e gás é acompanhado do registro de motivos quando ocorrem baixas de produção. Diante disso, o objetivo deste trabalho é propor um modelo de previsão que, a partir dos registros de motivos, possa identificar a iminência de fechamento de poços a fim de reduzir o tempo de permanência de um poço nesse estado e, conseqüentemente, reduzir a perda de produção.

Como método de detecção de padrões, foi escolhida a técnica de redes neurais que será alimentada com dados históricos de produção de poços no

intuito de identificar os padrões referentes à queda de produção e de fechamento de poços.

1.3 Descrição do trabalho

As seguintes etapas foram desenvolvidas neste trabalho: obtenção e classificação dos dados, definição de uma metodologia para identificar padrões de comportamento de estados de poços e realização de experimentos para validar a metodologia definida.

A primeira etapa consistiu em se definir um período para extração dos dados de produção. Em seguida, foi feita uma classificação nos dados de poços, classificando-os segundo alguns critérios. O primeiro critério de classificação foi quanto à instalação do poço: terrestre ou marítimo, uma vez que os equipamentos utilizados diferem de um ambiente pro outro. Além disso, as próprias características do ambiente podem influenciar na ocorrência de falhas, como por exemplo, a presença de altas pressões em ambiente marítimo e as intempéries do ambiente terrestre. Um segundo critério adotado foi quanto às características do fluido, como: BSW, teor de enxofre, teor de salinidade, teor de CO₂, teor de areia, etc. Tais características podem afetar a vida útil dos equipamentos que têm contato com o fluido na extração, transporte, tratamento e armazenamento. Como consequência, a necessidade de manutenção ou troca de equipamentos pode ser maior. Para simplificação do trabalho, o experimento realizado considerou apenas a localização do poço que, no caso, foi com um poço produtor de óleo localizado em campo marítimo. Os demais fatores foram desconsiderados no experimento.

A segunda etapa do trabalho foi a definição da metodologia para permitir que padrões de ocorrência de fechamento de poços fossem detectados. A metodologia baseia-se no treinamento de redes neurais a partir dos dados históricos de produção.

Para validar a proposta do trabalho, a terceira etapa consistiu da realização de testes usando a metodologia proposta sobre dados já existentes, mas não utilizados no treinamento da rede neural. Esta etapa foi importante para verificar se o nível de treinamento da rede foi adequado, ou se a rede ainda necessita de ajustes e novos treinamentos. No experimento, a fase de validação envolveu dois tipos de técnicas: a primeira foi com o uso de dados não utilizados no experimento e a segunda envolveu a técnica de validação cruzada.

1.4 Organização do trabalho

Esta monografia está dividida em quatro capítulos adicionais, descritos a seguir. O capítulo 2 descreve a importância do monitoramento da produção de poços de óleo e gás, bem como o problema da parada de produção que ocorre quando o poço permanece fechado por um período de tempo. O capítulo 3 fornece os conceitos básicos de redes neurais, que foi o método utilizado neste trabalho para detecção de padrões comportamentais na produção de poços e motor de previsão de paradas. O quarto capítulo apresenta a arquitetura proposta e os módulos envolvidos na mesma. O capítulo seguinte apresenta os resultados do experimento realizado para validar a solução proposta, conclui o trabalho e aponta alguns trabalhos futuros.

2. Descrição do problema

Durante os últimos anos, nenhum outro recurso natural teve um valor de mercado tão variável quanto o petróleo. Em tempo de calamidades ecológicas, instabilidades políticas, guerras no Afeganistão e Iraque, o “ouro negro” teve uma elevação caótica nos preços. Adicionalmente, esta elevação foi estimulada pelo aumento da demanda na China e Índia (Lackes, et al. 2009). Como a mais importante fonte de energia atualmente e propulsor econômico de muitas nações, o petróleo estabelece uma conexão entre diferentes países e grupos culturais como nenhum outro recurso (Zündorf, L. 2002). Porém, o custo de produção dessa fonte sofre diversos tipos de influência. Seja no contexto ambiental, influenciado pelos apelos das energias renováveis, passando pelo contexto político-econômico, instabilidade em regiões produtoras e consumidoras, ou pelo contexto geográfico, difícil localização do fluido, como aqueles encontrados em campos submarinos. Todos esses fatores devem ser contrapostos à demanda e ao preço de mercado para se decidir pela viabilidade da produção. Diante dessa característica fortemente variável de valor, uma produção de petróleo eficiente pode ser aquela que estabelece os menores custos no processo. Custos esses relacionados ao uso de equipamentos para extração de petróleo, estabilidade nas operações de produção (equipamentos operando sem problemas), ou mesmo soluções rápidas quando ocorrerem falhas na produção.

No Brasil, grande parte da produção de petróleo é proveniente de campos submarinos. No futuro, com a exploração da camada pré-sal, o país passará de décimo nono produtor mundial para o quinto maior (Rapoza, 2009). O difícil acesso aos campos de petróleo requer o uso de tecnologias avançadas que, algumas delas, ainda estão em desenvolvimento. O uso de plataformas semi-submersíveis, navios exploradores e produtores já representam um custo elevado no modelo de produção brasileiro e tendem a se estabelecer ainda mais com a exploração de petróleo na camada pré-sal. Porém, os altos custos de produção de petróleo não se limitam a campos submarinos. Campos terrestres também requerem o uso de uma diversidade de equipamentos utilizados tanto na extração, quanto transporte e armazenamento de óleo. Percebe-se uma grande influência na operação desses equipamentos para que a produção de óleo não seja afetada. Problemas em bombas de extração, incrustação de dutos, indisponibilidades de dispositivos de armazenamento de óleo e gás, são alguns

fatores que podem afetar a produção de petróleo. As figuras 01 e 02 ilustram a diversidade de equipamentos existentes na extração e produção de petróleo tanto em campos submarinos quanto em campos terrestres.




Figura 1: Perspectiva de equipamentos existentes na extração e produção de petróleo em campo marítimo.



Figura 2: Equipamentos existentes na extração e produção de petróleo em campo terrestre.

Um poço de petróleo para entrar em produção passará anteriormente por testes a fim de determinar diversos parâmetros, entre eles o potencial de produção do poço. Esse parâmetro diz respeito à vazão de óleo produzida em condições em que todos os equipamentos envolvidos na produção estejam operando perfeitamente. A existência de falhas em algum equipamento ocasionará a redução, ou mesmo, parada na produção de petróleo. O processo

de produção é constantemente monitorado para que qualquer falha ou mau funcionamento de equipamentos seja identificado. Conseqüentemente, o monitoramento visa a identificação de perdas na produção de petróleo.

Durante o monitoramento, a produção do poço é acompanhada e comparada com o valor do potencial. Quando o valor da produção é inferior ao do potencial verifica-se que pode existir algum mau funcionamento em algum equipamento envolvido na produção. Tal baixa é registrada juntamente com um motivo que justifique a queda de produção. A partir do motivo, providências são tomadas para que correções sejam feitas e a produção retorne ao nível adequado. Dependendo da falha, a produção pode ser igual a zero, ou seja, o poço permanece fechado por um período até que a falha de equipamentos seja corrigida. Tanto no caso da produção inferior ao potencial do poço quanto na produção igual a zero, ocorre perda no volume de petróleo produzido. Para ilustrar esse comportamento, a figura 03 descreve a produção de um poço hipotético durante o tempo. As linhas tracejadas indicam o volume de perda ocorrido no período em que a produção permaneceu abaixo do potencial. Percebe-se que a perda é máxima quando a produção é igual a zero.

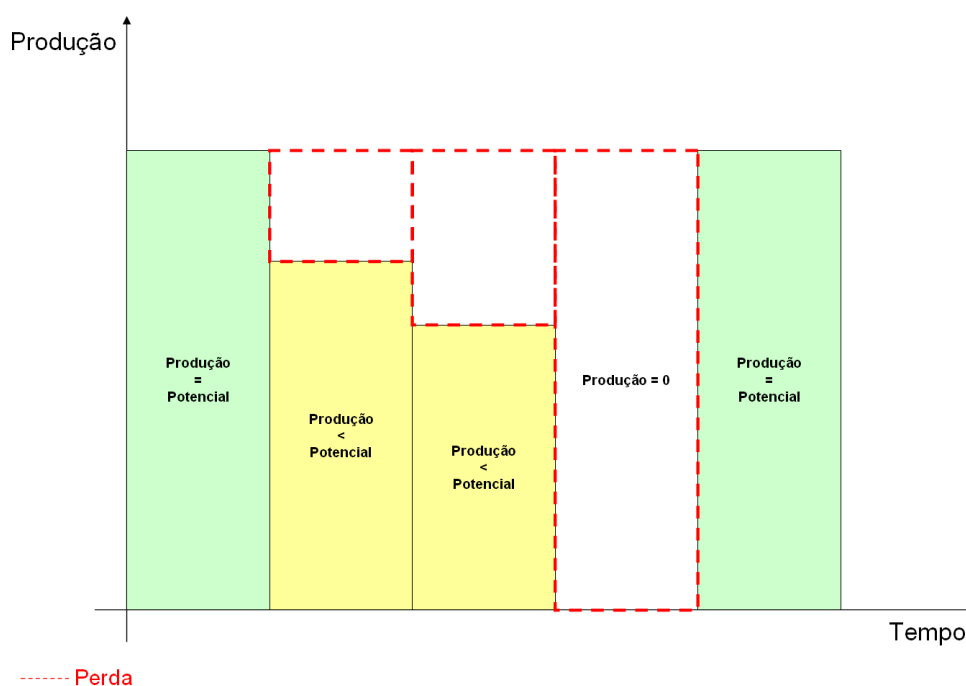


Figura 3: Gráfico de Produção X Tempo.

O comportamento da produção de petróleo ilustrado na figura 03 oscila e se prolonga no tempo durante todo o período de produção poço. Os estados em que ocorre perda na produção devem ser minimizados com a tomada de

providências para que o poço retorne o quanto antes ao estado de produção máxima, ou seja, produção igual ao potencial. O estado em que não ocorre produção é o menos desejado, pois maximiza a perda no período em que ocorre e geralmente está associado a uma falha grave no processo de produção. A existência de perdas na produção eleva os custos da produção, pois a receita proveniente do período em que houve a perda será menor do que se o poço estivesse operando normalmente.

Uma vez identificadas as causas de falhas que comprometem a operação plena de um poço, as providências encaminhadas para solucioná-las podem implicar em mais custos para a companhia. Além do custo pela perda na produção em si, há o custo inerente à realização das ações de solvência às falhas, como por exemplo:

- Algum tempo será demandado para que as correções em equipamentos ou até mesmo substituições dos mesmos sejam feitas, principalmente se houver uma indisponibilidade para substituição imediata de algum equipamento;
- Equipes especializadas podem ter que se deslocar para os locais dos poços a fim de apurar com mais detalhes as causas de falhas, ou realizar intervenções que as solucionem;
- O próprio acesso ao poço pode ter um custo elevado, caso o mesmo esteja em instalações marítimas com lâmina d'água de grande profundidade.

Por esses e outros fatores percebe-se que quanto maior for o intervalo entre a identificação de uma falha e a solução da mesma, maior será a perda de produção e, portanto, menor o ganho da companhia. Deste modo, se existirem padrões de produção do poço que antecedem o estado de poço fechado, será possível identificar a ocorrência desses padrões no futuro. Com isso, será possível perceber o fechamento do poço antes mesmo dele ocorrer efetivamente. Para a detecção dos padrões mencionados aqui, foi utilizada a técnica de redes neurais a partir de dados históricos de um poço produtor de óleo.

3. Metodologia

Redes neurais artificiais são modelos computacionais inspirados no sistema nervoso de seres vivos. Possuem a capacidade de aquisição e manutenção do conhecimento (baseado em informações) e podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões (Silva, 2010). Algumas características relevantes envolvidas com aplicação de redes neurais são:

- a. Adaptação por experiência: as adaptações dos parâmetros internos da rede, tipicamente seus pesos sinápticos, são ajustados a partir da apresentação sucessiva de exemplos (padrões, amostras, medidas) relacionados ao comportamento do processo, possibilitando a aquisição do conhecimento por experimentação;
- b. Capacidade de aprendizado por intermédio da aplicação de um método de treinamento, a rede consegue extrair o relacionamento existente entre as diversas variáveis que compõem a aplicação;
- c. Habilidade de generalização que após o processo de treinamento da rede, essa é capaz de generalizar o conhecimento adquirido, possibilitando estimar soluções que eram até então desconhecidas.

As redes neurais artificiais podem ser empregadas em diversos problemas relacionados às engenharias e ciências. As potenciais áreas de aplicabilidade podem ser enquadradas conforme se segue (Silva, 2010):

- a. Reconhecimento / classificação de padrões: o objetivo deste tipo de aplicação consiste de associar um padrão de entrada (amostra) para uma das classes previamente definidas, como acontece em reconhecimento de imagens, voz, escrita, etc. Neste caso, o problema a ser tratado possui um conjunto discreto e conhecido das possíveis saídas desejadas;
- b. Agrupamento de dados (*clustering*): o objetivo nesta circunstância consiste da identificação e detecção de similaridade e particularidades entre os diversos padrões de entrada a fim de

possibilitar seu agrupamento. Como exemplo, pode-se citar os problemas que envolvem identificação automática de classes e garimpagem de dados;

- c. Sistema de previsão: o objetivo consiste em estimar valores futuros de um processo levando-se em consideração diversas medidas prévias observadas em seu domínio. Entre as aplicações disponíveis enquadram-se a previsão de séries temporais, previsões de mercado financeiro, previsões climáticas, etc.

O processamento de informações no cérebro humano é regido por elementos processadores biológicos que operam em paralelo, tendo como objetivo a produção de ações apropriadas para cada uma de suas funcionalidades, tais como o pensar e o memorizar.

A célula elementar do sistema nervoso cerebral é o neurônio e seu papel se resume a conduzir impulsos (estímulos elétricos advindos de reações físico-químicas) sob determinadas condições de operação. Tal elemento biológico pode ser dividido em três partes principais, isto é, nos dendritos, no corpo celular (também conhecido como soma) e no axônio. A figura 04 ilustra um neurônio biológico.

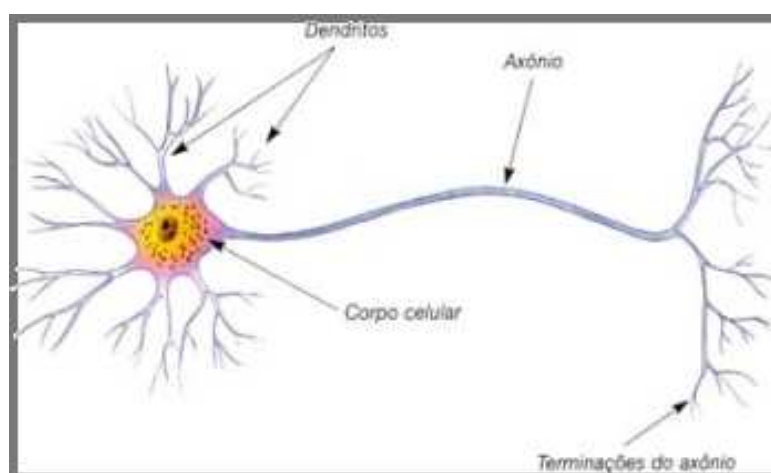


Figura 4: Neurônio biológico.

Os dendritos são constituídos por vários finos prolongamentos que formam a árvore dendrital. A principal função dos dendritos dos neurônios consiste de captar, de forma contínua, os estímulos vindos de diversos outros neurônios

(conectores) ou do próprio meio externo onde os mesmos podem estar em contato (neurônios sensitivos).

O corpo celular é incumbido de processar todas as informações advindas dos dendritos a fim de produzir um potencial de ativação que indicará se o neurônio poderá disparar um impulso elétrico ao longo de seu axônio. É também no corpo celular que se encontram as principais organelas citoplasmáticas (núcleo, mitocôndria, centríolo, etc) do neurônio.

O axônio é constituído por um único prolongamento, cuja missão é conduzir os impulsos elétricos para outros neurônios conectores ou para aqueles que se conectam diretamente com o tecido muscular (neurônios efetadores). A sua terminação é também constituída de ramificações denominadas terminações sinápticas.

As sinapses se configuram como as conexões que viabilizam a transferência de impulsos elétricos do axônio de um neurônio para os dendritos de outros, conforme ilustração mostrada na figura 05.



Figura 5: Conexões sinápticas entre neurônios.

Em suma, embora as atividades relacionadas aos neurônios biológicos pareçam inicialmente bem simples, tais elementos atuando em conjunto, são os principais responsáveis por todos os processamentos executados e gerenciados pelo cérebro humano. Estima-se que esta rede neural biológica, com características bem excêntricas, seja constituída por cerca de 100 bilhões de neurônios. Cada um destes é interligado por conexões sinápticas em média a outros 6000 neurônios, perfazendo-se então um total de 600 trilhões de sinapses (Shepherd, 1990).

No momento em que a célula nervosa é estimulada (despolarizada), além de um limiar de ativação (-55 mV), que é ocasionado pela variação de concentração interna de íons de sódio (Na⁺) e potássio (K⁺), há então o disparo de um impulso elétrico que será propagado ao longo de todo o seu axônio, cuja amplitude máxima alcançará o valor de 35 mV (Kandel et AL, 2000).




Figura 6: Variação do potencial de ação do neurônio.

Deve-se ressaltar que, independentemente dos tipos de neurônio (receptor, associativo ou motor), a amplitude de 35 mV, correspondente ao máximo valor de um potencial de ação é fixa e tende a ser rigorosamente atingida por todos eles quando estimulado, embora a duração deste sinal seja um parâmetro variante. Ao término do processo de excitação, como conseqüência, haverá a repolarização da membrana, isto é, o potencial de ação do neurônio retornará novamente ao seu patamar de potencial de repouso (-70 mV), conforme ilustrado na figura 06.

A estrutura das redes neurais artificiais foi desenvolvida a partir de modelos conhecidos de sistemas nervosos biológicos e do próprio cérebro humano. Os elementos computacionais ou unidades processadores denominadas neurônios artificiais, são modelos bem simplificados dos neurônios biológicos.

Tais modelos foram inspirados a partir da análise da geração e propagação de impulsos elétricos pela membrana celular dos neurônios (Hodgkin & Huxley, 1952).

Os neurônios artificiais utilizados nos modelos de redes neurais artificiais são não-lineares, fornecem saídas tipicamente contínuas, e realizam funções simples, como coletar os sinais existentes em suas entradas, agregá-los de acordo com sua função operacional e produzir uma resposta, levando em consideração sua função de ativação inerente.

O modelo de neurônio mais simples que engloba as principais características de uma rede neural biológica, isto é, paralelismo e alta

conectividade, foi proposto por (McCulloch & Pitts, 1943), sendo ainda o modelo mais utilizado nas diferentes arquiteturas de redes neurais artificiais.

Nessa representação, cada neurônio da rede pode ser implementado conforme mostra a figura 07. Os diversos sinais de entrada advindos do meio externo (aplicação) são espelhados pelo conjunto $\{x_1, x_2, x_3, \dots, x_n\}$, que são análogos aos impulsos elétricos externos captados pelos dendritos nos neurônio biológico.

As ponderações exercidas pelas junções sinápticas do modelo biológico são representadas no neurônio artificial pelo conjunto de pesos sinápticos $\{w_{x1}, w_{x2}, \dots, w_{xn}\}$. De forma análoga, a relevância de cada uma das entradas $\{x_i\}$ do neurônio é então executada por meio de suas multiplicações pelos respectivos pesos sinápticos $\{w_{xi}\}$, ponderando-se, portanto, todas as informações externas que chegam ao neurônio. Assim, torna-se possível verificar que a saída do corpo celular artificial, denotado por u , é a soma ponderada de suas entradas.




Figura 7: Neurônio artificial.

Assim, considerando a figura 07, verifica-se que o neurônio artificial é constituído de sete elementos básicos, ou seja:

- a) Sinais de entrada $\{x_1, x_2, \dots, x_n\}$: São sinais ou medidas advindas do meio externo e que representam os valores assumidos pelas variáveis de uma aplicação específica. Os sinais de entrada são usualmente normalizados visando incrementar a eficiência computacional dos algoritmos de aprendizagem;
- b) Pesos sinápticos: $\{w_{k1}, w_{k2}, \dots, w_{kn}\}$: São os valores que servirão para ponderar cada uma das variáveis de entrada da rede, permitindo-se quantificar as suas relevâncias em relação à funcionalidade do respectivo neurônio.

- c) Combinador linear $\{\Sigma\}$: Sua função é agregar todos os sinais de entrada que foram ponderados pelos respectivos pesos sinápticos a fim de produzir um valor de potencial de ativação;
- d) Limiar de ativação $\{b_k\}$: É uma variável que especifica qual será o patamar apropriado para que o resultado produzido pelo combinador linear possa gerar um valor de disparo em direção à saída do neurônio;
- e) Potencial de ativação $\{u\}$: É o resultado produzido pela diferença do valor produzido entre o combinador linear e o limiar de ativação. Se tal valor é positivo, ou seja, se $u \geq b_k$ então o neurônio produz um potencial excitatório; caso contrário, o potencial será inibitório;
- f) Função de ativação $\{g\}$: Seu objetivo é limitar a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela sua própria imagem funcional;
- g) Sinal de saída $\{y\}$: Consiste do valor final produzido pelo neurônio em relação a um determinado conjunto de sinais de entrada, podendo ser também utilizado por outros neurônios que estão sequencialmente interligados.

Pode-se resumir o funcionamento de um neurônio artificial por meio dos seguintes passos:

- Apresentação de um conjunto de valores que representam as variáveis de entrada do neurônio;
- Multiplicação de cada entrada do neurônio pelo seu respectivo peso sináptico;
- Obtenção do potencial de ativação produzido pela soma ponderada dos sinais de entrada, subtraindo-se o limiar de ativação;
- Aplicação de uma função de ativação apropriada, tendo-se como objetivo limitar a saída do neurônio;
- Compilação da saída a partir da aplicação da função de ativação neural em relação ao seu potencial de ativação.

A forma como os diversos neurônios artificiais são arranjados, ou dispostos, uns em relação aos outros define a arquitetura de uma rede neural artificial (RNA). Esses arranjos são essencialmente estruturados através do direcionamento das conexões sinápticas dos neurônios.

Já as diferentes formas de composições estruturais que uma rede neural pode assumir, considerando determinada arquitetura, definem a topologia da rede. Por exemplo, pode-se ter duas topologias pertencentes a uma mesma arquitetura, sendo que uma é composta de 10 neurônios e a outra é de 20 neurônios; ou ainda, uma constituída de neurônios com função de ativação logística, ao passo que os neurônios da outra assumem a tangente hiperbólica como função de ativação. Por outro lado, o treinamento de uma arquitetura específica consiste da aplicação de um conjunto de passos ordenados com o intuito de ajustar os pesos e os limiares de seus neurônios. Assim, tal processo de ajuste, conhecido como algoritmo de aprendizagem visa sintonizar a rede para que as suas respostas estejam próximas dos valores desejados.

Basicamente, uma rede neural artificial pode ser dividida em três partes, denominadas de camadas, as quais são nomeadas da seguinte forma:

- a) Camada de entrada: É a camada responsável pelo recebimento de informações (dados), sinais, características ou medições advindas do meio externo, sendo que tais entradas (amostras ou padrões) são geralmente normalizadas em relação às faixas de variações dinâmicas produzidas pelas funções de ativação. Esta normalização implica numa melhor precisão numérica frente às operações matemáticas realizadas pela rede.
- b) Camadas escondidas, intermediárias, ocultas ou invisíveis: São aquelas compostas de neurônios que possuem a responsabilidade de extrair as características associadas ao processo ou sistema a ser inferido. Quase todo o processamento interno da rede é realizado nessas camadas.
- c) Camada de saída: Esta camada é também constituída de neurônios, sendo responsável pela produção e apresentação dos resultados finais da rede, os quais são advindos dos processamentos efetuados pelos neurônios das camadas anteriores.

As principais arquiteturas de redes neurais artificiais, considerando a disposição de seus neurônios, assim como suas formas de interligação entre eles e a constituição de suas camadas, podem ser divididas em: redes

feedforward (alimentação à frente) de camada simples, redes *feedforward* de múltiplas camadas, redes recorrentes, e redes reticuladas.

Arquitetura *feedforward* de camada simples

Para este tipo de arquitetura de redes neurais artificiais, tem-se apenas uma camada de entrada e uma única camada de neurônios, que é a própria camada de saída. A figura 08 ilustra uma rede *feedforward* de camada simples composta de n entradas e m saídas.




Figura 8: Exemplo de rede *feedforward* de camada única.

O fluxo de informações segue sempre uma única direção (unidirecional), ou seja, da camada de entrada em direção à camada de saída. A partir ainda da análise da figura 08, observa-se então que a quantidade de saídas nas redes pertencentes à arquitetura sempre coincidirá com o número de neurônios. Essas redes são tipicamente empregadas em problemas envolvendo classificação de padrões e filtragem linear.

Arquitetura *feedforward* de múltiplas camadas

Diferentemente das redes pertencentes à arquitetura anterior, as redes *feedforward* de múltiplas camadas são constituídas pela presença de uma ou mais camadas de neurônios escondidos. São empregadas na solução de diversos tipos de problemas, tais como aqueles relacionados à aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica, ao controle de processos, etc.




Figura 9: Exemplo de rede *feedforward* de múltiplas camadas.

A figura 09 ilustra uma rede *feedforward* de múltiplas camadas formadas por uma camada de entrada composta de n sinais, duas camadas de neurônios escondidas constituídas respectivamente de n_1 e n_2 neurônios e, finalmente, uma camada de neurônios de saída composta de m neurônios representando os respectivos valores de saída da aplicação.

A partir ainda da figura 09 é possível abstrair que a quantidade de neurônios que compõem a primeira camada escondida é normalmente diferente do número de sinais que compõem a camada de entrada da rede. De fato, o número de camadas escondidas e seus respectivos neurônios constituintes dependem, sobretudo, do tipo e da complexidade do problema a ser mapeado pela rede, assim como da quantidade e da qualidade dos dados disponíveis sobre o problema. Entretanto, conforme acontece nas redes *feedforward* de camada simples, a quantidade de sinais de saída sempre coincidirá com o número de neurônios daquela respectiva camada.

Arquitetura recorrente ou realimentada

São redes em que as saídas dos neurônios são realimentadas como sinais de entrada para outros neurônios. A característica da realimentação qualifica tais redes para processamento dinâmico de informações, isto é, estas podem ser utilizadas em sistemas variantes em relação ao tempo, como previsão de séries temporais, otimização e identificação de sistemas, controle de processos, etc.

A figura 10 ilustra um exemplo de rede neural com realimentação, tendo-se um dos sinais da camada de saída retroalimentado à camada intermediária.




Figura 10: Exemplo de rede neural com retroalimentação.

Assim, por intermédio do processo de realimentação, as redes com este tipo de arquitetura produzem as saídas atuais levando-se também em consideração os valores das saídas anteriores.

Arquitetura em estrutura reticulada

As principais características de redes com estruturas reticuladas estão na consideração da disposição espacial dos neurônios visando propósitos de extração de características, ou seja, a localização espacial dos neurônios está diretamente relacionada com o processo de ajuste de seus pesos e limiares. Suas aplicações são bem diversificadas, tais como em problemas de agrupamento (*clustering*), reconhecimento de padrões, otimização de sistemas, grafos, etc.




Figura 11: Exemplo de rede com estrutura articulada.

Ainda a partir da figura 11, verifica-se que nesta tipologia de rede os diversos sinais de entrada são também inseridos em todos os neurônios da rede.

Processos de treinamento e aspectos de aprendizado

Um dos destaques mais relevantes das redes neurais artificiais está na capacidade de aprender a partir da apresentação de amostras (padrões) que exprimem o comportamento do sistema, sendo que, em seguida, após a rede ter aprendido o relacionamento entre as entradas e saídas, esta é capaz de generalizar soluções. A rede será então capaz de produzir uma saída próxima daquela esperada (desejada) a partir de quaisquer sinais inseridos em suas entradas.

Portanto, o processo de treinamento de uma rede neural consiste da aplicação de passos ordenados que sejam necessários para sintonização dos pesos sinápticos e limiares de seus neurônios, tendo-se como objetivo final a generalização de soluções a serem produzidas pelas suas saídas, cujas repostas são representativas do sistema físico em que estas estão mapeando.

O conjunto desses passos ordenados visando o treinamento da rede é denominado de algoritmo de aprendizagem. Ao longo de sua aplicação, a rede será então capaz de extrair características discriminantes do sistema a ser mapeado por intermédio de amostras que foram retiradas do seu contexto.

Normalmente, o conjunto total das amostras disponíveis sobre o comportamento do sistema é dividido em dois subconjuntos, os quais são denominados de subconjunto de treinamento e subconjunto de teste. O subconjunto de treinamento, composto aleatoriamente com cerca de 60% a 90% das amostras do conjunto total, será usado essencialmente no processo de aprendizado da rede. Já o subconjunto de teste, cuja composição está entre 10% a 40% do conjunto total de amostras, será utilizado para verificar se os aspectos referentes à generalização de soluções por parte da rede já estão em patamares aceitáveis, possibilitando assim a validação da topologia assumida. Contudo, o dimensionamento desses conjuntos deve também levar em consideração a caracterização estatística dos dados.

Durante o processo de treinamento de redes neurais artificiais, cada apresentação completa das amostras pertencentes ao subconjunto de treinamento, visando, sobretudo, o ajuste dos pesos sinápticos e limiares de seus neurônios, será denominada de época de treinamento.

Treinamento supervisionado

A estratégia de treinamento supervisionado consiste em se ter disponível, considerando cada amostra dos sinais de entrada, as respectivas saídas desejadas, ou seja, cada amostra de treinamento é composta pelos sinais de entradas e suas correspondentes saídas. Desta forma, há então a necessidade de se disponibilizar uma tabela de dados (entradas/saídas) representativa do processo, também conhecida por tabela atributos/valores, e que contemple inclusive o seu comportamento, pois é a partir de tais informações que as estruturas neurais formularão as “hipóteses” sobre aquilo a ser aprendido.

Neste caso, a aplicação do treinamento supervisionado depende apenas da disponibilidade desta tabela de atributos/valores, sendo que tudo se comporta como se houvesse um “professor” ensinando para a rede qual a resposta correta para cada amostra apresentada em suas entradas.

Os pesos sinápticos e limiares são então continuamente ajustados mediante a aplicação de ações comparativas, executadas pelo próprio algoritmo de aprendizagem, que supervisionam a defasagem entre as respostas produzidas pela rede em relação àquelas desejadas, sendo esta diferença usada no procedimento de ajuste. A rede será considerada treinada quando tal defasagem estiver dentro de valores aceitáveis, levando-se em consideração os propósitos de generalização de soluções.

Na realidade, o treinamento supervisionado é um caso típico de inferência indutiva pura, em que os parâmetros livres da rede são ajustados em função de se conhecer a priori quais são as saídas desejadas ao sistema investigado.

Treinamento não-supervisionado

Diferentemente do supervisionado, durante a aplicação de um algoritmo de aprendizado baseado em treinamento não-supervisionado inexitem as respectivas saídas desejadas.

Conseqüentemente, a própria rede tem a capacidade de se auto-organizar em relação às particularidades existentes entre os elementos componentes do conjunto total de amostras, identificando subconjuntos (*clusters*) que contenham similaridades. Os pesos sinápticos e limiares dos neurônios da rede são então ajustados pelo algoritmo de aprendizado de forma a refletir esta representação internamente dentro da própria rede.

Alternativamente, a quantidade máxima desses possíveis *clusters* pode ser especificada (*a priori*) pelo próprio projetista da rede, levando-se em consideração o seu conhecimento a respeito do problema a ser tratado.

Treinamento por reforço

Os métodos baseados em treinamento por reforço têm sido considerados uma variação das técnicas que utilizam treinamento supervisionado, as quais avaliam constantemente a defasagem de valor entre a resposta produzida pela rede em relação à respectiva saída desejada (Sutton & Barto, 1998 apud Silva, 2010). Os algoritmos de aprendizado utilizados no treinamento por reforço ajustam os parâmetros internos dos neurônios baseando-se em quaisquer informações quantitativas ou qualitativas advindas da interação com o sistema (ambiente) que está sendo mapeado, as quais são então utilizadas para medir o desempenho do aprendizado.

Frente a essas situações, o processo de treinamento da rede é realizado tipicamente por tentativa e erro, pois a única resposta disponível para uma determinada entrada é se esta é satisfatória ou não. Se for considerada satisfatória, incrementos nos pesos sinápticos e limiares são então gradualmente efetuados visando reforçar (recompensar) esta condição comportamental envolvida com o sistema.

Diversos algoritmos de aprendizado utilizados no treinamento com reforço são baseados em métodos estocásticos que selecionam probabilisticamente suas ações de ajustes, levando-se em conta um conjunto finito de possíveis situações, as quais são passíveis de serem recompensados frente às chances de se gerar resultados satisfatórios. No decorrer do processo de treinamento, as probabilidades associadas às ações de ajustes são ainda modificadas visando melhorar o desempenho da rede (Tsoukalas & Uhrig, 1997 apud Silva, 2010).

Aprendizagem usando lote de padrões (*off-line*)

Na aprendizagem usando lote de amostras (padrões), também denominada de aprendizagem *off-line* ou *batch*, os ajustes efetuados nos vetores de pesos das redes e em seus limiares só são efetivados após a apresentação de todo o conjunto de treinamento, pois cada passo de ajuste leva em consideração o total de desvios observados nas amostras de treinamento frente aos respectivos valores desejados para as suas saídas.

Assim, as redes que utilizam aprendizagem usando lote de padrões necessitam de pelo menos uma época de treinamento para se realizar um passo de ajuste em seus pesos e limiares. Portanto, todas as amostras de treinamento devem estar sempre disponíveis enquanto durar o processo de aprendizagem.

Aprendizagem usando padrão por padrão (*on-line*)

Para a aprendizagem usando padrão por padrão (*on-line*), ao contrário daquela por lote, os ajustes nos pesos e limiares das redes são efetuados após a apresentação de cada amostra de treinamento. Portanto, após a execução do passo de ajuste, a respectiva amostra pode ser descartada.

A aprendizagem *on-line* nesta configuração é normalmente utilizada quando o comportamento do sistema a ser mapeado varia de forma bastante rápida, sendo quase impraticável a adoção do aprendizado *off-line*, pois as amostras utilizadas em determinado instante podem não mais representar o comportamento do processo nos instantes posteriores.

Entretanto, como os padrões são apresentados um por vez, as ações de ajuste dos pesos e limiares são bem localizadas e pontuais, cujos reflexos remetem à determinada circunstância comportamental do sistema. Consequentemente, a rede apenas começará a fornecer respostas mais precisas após a apresentação de um número significativo de amostras.

4. Arquitetura do sistema

O sistema proposto neste trabalho tem como objetivo analisar o comportamento de produção de poços de petróleo e prever quando ocorrerá um evento de parada de poço. Como citado anteriormente, o estado em que um poço está sem produzir é o menos desejado por levar a uma maior perda de produção. A vantagem desse tipo de previsão é que o tomador de decisão pode solicitar providências antes mesmo que o poço seja fechado, além de se ter um acompanhamento mais apurado de sua produção.

Com isso, o sistema fará uso dos dados históricos referentes ao comportamento de produção de poços, buscará através da técnica de redes neurais a existência de padrões de comportamento que antecedem um estado de parada de poço, e então fará previsões de parada a partir dos novos comportamentos de produção existentes. As diversas funcionalidades foram divididas em módulos responsáveis pelo tratamento dos dados, armazenamento de dados históricos, detecção de padrões, alimentação de dados recentes, e interface com o usuário. A interação dos referidos módulos pode ser visualizada na figura abaixo no diagrama do Sistema de Apoio a Decisão (SAD).

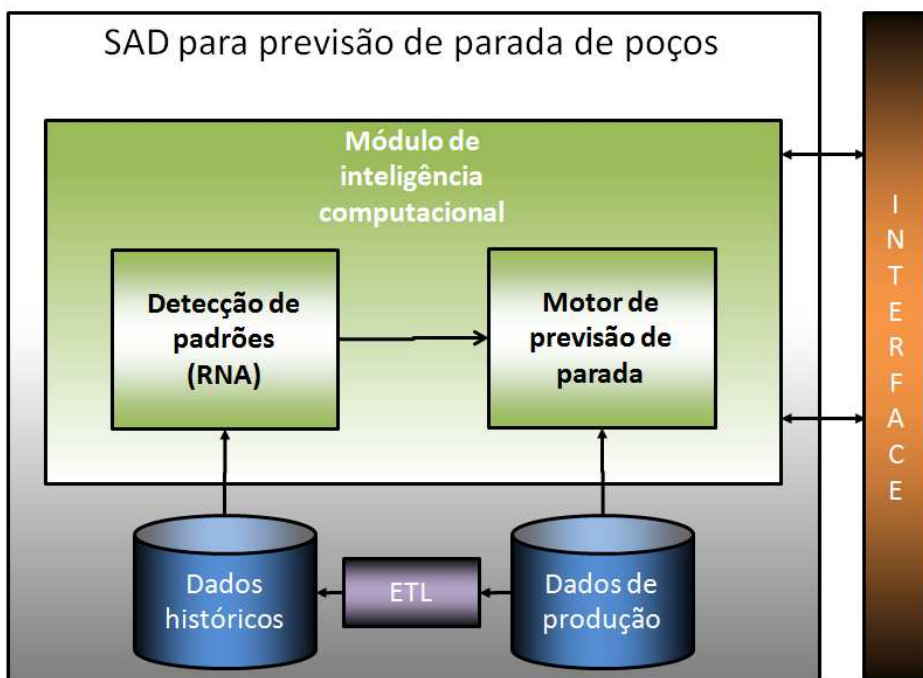


Figura 12: Arquitetura do Sistema de Apoio a Decisão.

Os dados transacionais de monitoramento da produção dos poços serão processados por um módulo de Extração, Transformação e Carga (ETL) que fará a limpeza e tratamento dos dados antes de serem armazenados numa base histórica. O processo de ETL é necessário, para que os dados sejam dispostos numa representação adequada para alimentar a rede neural. Após as atividades de ETL, os dados serão então armazenados na base histórica para então alimentar o Módulo de Inteligência Computacional.

Este módulo é responsável por executar as tarefas relacionadas à detecção dos padrões e exibição de alertas para os usuários do sistema. O submódulo de Detecção de Padrões, que fará uso da técnica de Redes Neurais Artificiais, irá periodicamente executar algoritmos sobre a base histórica para identificação de padrões que antecedem a parada de produção dos poços. Já o Motor de Previsão de Parada obterá os padrões detectados pelo submódulo anterior e fará uma análise da ocorrência desses padrões nos novos dados de monitoramento. Quando for identificada a ocorrência de padrões nos novos dados transacionais, o sistema poderá emitir alertas ao tomador de decisão alertando uma possível parada na produção do poço no futuro.

Já o módulo de Interface permitirá que o tomador de decisão acompanhe o comportamento da produção dos poços. Neste tipo de monitoramento, o sistema apontará os poços que tem probabilidade de parar a produção segundo alguma falha operacional. Na mesma interface, o tomador de decisão poderá ajustar o sistema informando se as previsões realizadas foram confirmadas. Dessa forma o sistema pode se auto-ajustar para que previsões mais acuradas sejam realizadas no futuro.

Para validar a arquitetura proposta neste trabalho, foi realizado um experimento que consistiu em definir uma rede neural para ser alimentada com dados do monitoramento da produção de um poço de petróleo. O experimento teve como objetivo simular o módulo de Detecção de Padrões da arquitetura proposta.

Os dados que alimentaram a rede neural definida no experimento foram obtidos do monitoramento de um poço de petróleo real localizado em campo marítimo. O período de monitoramento consistiu desde a entrada do poço em operação até a data em que este trabalho foi escrito (Outubro de 2011). Tal histórico, totalizando 4874 registros, é referente ao comportamento do poço durante 11 anos, uma vez que o mesmo entrou em produção no ano 2000. Os dados considerados desse histórico foram:

- a) Valor de potencial do poço: produção do poço em condições normais de operacionalidade, conforme descrito na seção 2.
- b) Produção do poço: produção real do poço no momento do monitoramento, conforme descrito na seção 2, a produção não necessariamente é igual ao potencial.
- c) Percentual de água e sedimentos: percentual de água e sedimentos contidos no volume de vazão do poço. Este dado foi considerado, pois se acreditou que essa característica pode afetar o volume de óleo produzido durante o tempo.
- d) Percentual de gás lift: percentual de gás de injeção contido no fluido produzido. Assim como o percentual de água e sedimentos, esse dado foi considerado porque se acreditou que essa característica pode afetar o volume de óleo produzido durante o tempo.
- e) Percentual de gás: percentual de gás contido no volume de vazão do poço. Assim como o percentual de água e sedimentos, esse dado foi considerado porque se acreditou que essa característica pode afetar o volume de óleo produzido durante o tempo.
- f) Motivo da perda de produção: O motivo que ocasionou a baixa de produção do poço. Essa baixa pode inclusive ser total, ou seja, quando o poço parou completamente. Nos dados transacionais o motivo está dividido em cinco informações:
 - a. Grupo do motivo: Categoria a qual o motivo da perda se enquadra, por exemplo: Energia;
 - b. Motivo: Motivo relacionado ao grupo que caracteriza a perda, por exemplo: Falha no gerador elétrico;
 - c. Sistema: Informa o sistema afetado pela falha, por exemplo: Distribuição de energia;
 - d. Componente: Informa um componente específico que tenha apresentado falha, por exemplo: Painel elétrico;
 - e. Causa: Informação que detalha a causa da falha, por exemplo: Curto-circuito;
 - f. Detalhe: Detalhamento do motivo.

Essas cinco informações compõem o motivo e foram categorizadas em dados numéricos, uma vez que na base transacional, tais informações são incluídas em categorias textuais. Os dados utilizados no

experimento apresentaram um total de 7 grupos de motivo, 37 motivos de perda, 30 sistemas, 30 componentes, 36 causas e 4 detalhes dispostos de maneira combinada entre as 4874 amostras utilizadas.

g) Providência: Providência solicitada para que a produção recupere a perda apresentada. Assim como no motivo, a providência está dividida em três informações:

- a. Grupo da providência: Categoria a qual a providencia da perda se enquadra, por exemplo: Manutenção;
- b. Providencia: Providência relacionada ao grupo que caracteriza a ação a ser tomada, por exemplo: Equipamento em reparo;
- c. Responsável: Setor responsável pela execução da providencia.

A tabela a seguir apresenta um extrato das amostras utilizadas para treinamento e validação da rede. Nesta tabela, os dados de motivo e providência já se apresentam categorizados numericamente:

Tabela 1: Instância de monitoramento de produção de um poço de petróleo.

Potencial	Produção	% sedimentos	%gás-lift	%gás	Grupo motivo	Motivo	Causa	Detalle	Sistema	Componente	Grupo providencia	Providencia	Responsável
2400	2400	0	45	90	0	0	0	0	0	0	0	0	0
2400	2220	0	45	95	3	19	11	0	4	8	2	5	15
2400	2270	0	45	95	3	17	3	0	29	15	4	5	11
2400	0	0	45	95	3	37	27	0	30	2	2	5	16
2400	1378	0	45	90	3	19	11	0	4	8	2	5	15
2400	2227	0	45	90	3	17	3	0	29	15	4	5	11
2400	2220	0	45	95	3	17	3	0	29	15	4	5	11
2400	2220	0	45	95	3	19	11	0	4	8	2	5	15
2400	2270	0	45	95	3	17	3	0	29	15	4	5	11
2400	0	0	45	95	3	37	27	0	30	2	2	5	16

O objetivo da rede neural utilizada no experimento é identificar os padrões de dados de produção do poço que antecedem o fechamento do mesmo. Com isso, o sistema de apoio a decisão proposto neste trabalho poderá alertar

quando tais padrões forem identificados no futuro. Arbitrariamente, os padrões que antecedem o fechamento de um poço foram definidos como os três registros anteriores ao registro que informa que o poço está fechado. Por exemplo, na tabela 1, os registros marcados em cinza representam padrões que antecedem o fechamento do poço. Nas 4874 amostras utilizadas no poço, diversos padrões antecedem os registros de poço com produção igual a zero. Assim, foi assumido, neste trabalho, que se esses padrões se repetirem no futuro ter-se-á indícios de que o poço irá fechar por algum problema operacional.

O experimento foi realizado utilizando-se o software de distribuição livre Weka (Hall, 2009). Utilizou-se então o algoritmo de treinamento supervisionado *Multilayer Perceptron*. Esse algoritmo permite configurar uma rede neural de camada única ou múltiplas camadas. Neste experimento, foram utilizadas diversas arquiteturas de rede neural utilizando-se o modo de treinamento supervisionado através das técnicas de validação cruzada e de amostras de teste. A primeira técnica consiste em dividir as amostras de entrada da rede em grupos, combiná-los várias vezes, utilizar um subconjunto dos grupos para treinar a rede e o subgrupo restante para validação. Já a segunda, consiste em separar anteriormente à execução do experimento, um conjunto de amostras para validar a rede neural após a fase de treinamento. Em ambas as técnicas o conjunto total de amostras foi apresentado à rede 500 vezes em cada treino, caracterizando 500 épocas. Cada amostra que alimentou a rede foi previamente classificada como antecedente a um estado de poço fechado e não antecedente a um estado de poço fechado. Conforme apresentado na tabela 1, as linhas marcadas em cinza representam amostras classificadas como antecedentes enquanto as linhas não marcadas representam amostras não antecedentes. A figura 13 ilustra uma das diversas arquiteturas de rede neural configurada no experimento e como os atributos das amostras alimentaram a rede.

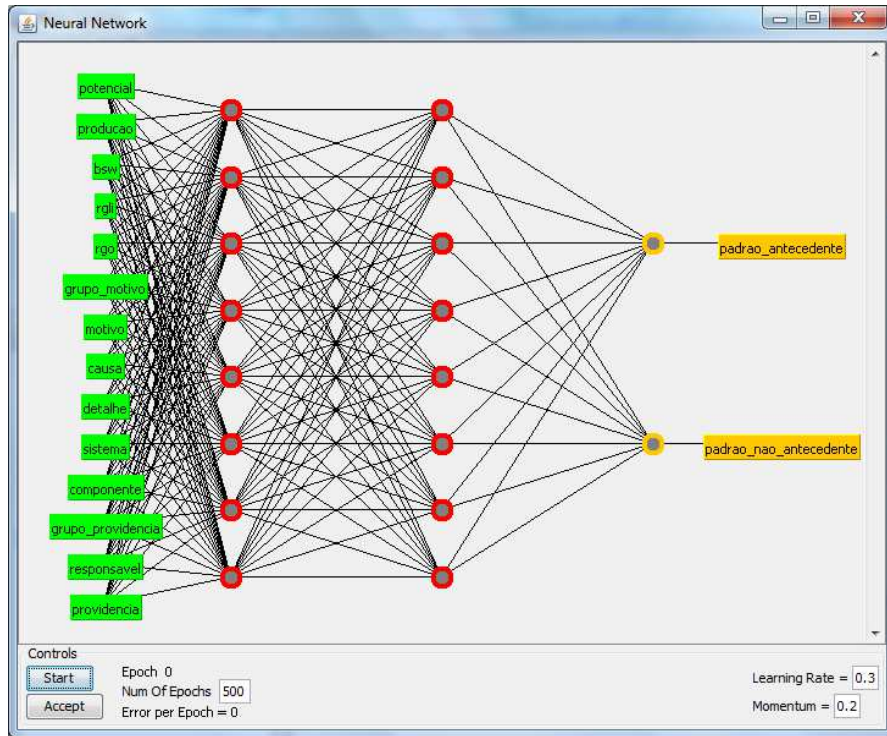


Figura 13: Rede neural configurada no software Weka.

5. Resultados

Conforme descrito na seção anterior o experimento foi executado em diferentes arquiteturas de rede neural. Porém os resultados apresentados em cada rede não tiveram variações consideráveis. Esta seção apresentará os resultados obtidos nas diferentes execuções.

- a) *Multilayer perceptron* de uma camada escondida com conjunto de dados de teste

Nesta configuração, a rede neural foi configurada com apenas uma camada as amostras foram divididas em dois grupos. Um grupo para treinamento da rede correspondendo a 80% do total de amostras e um grupo para validação da rede correspondendo a 20% do total das amostras.

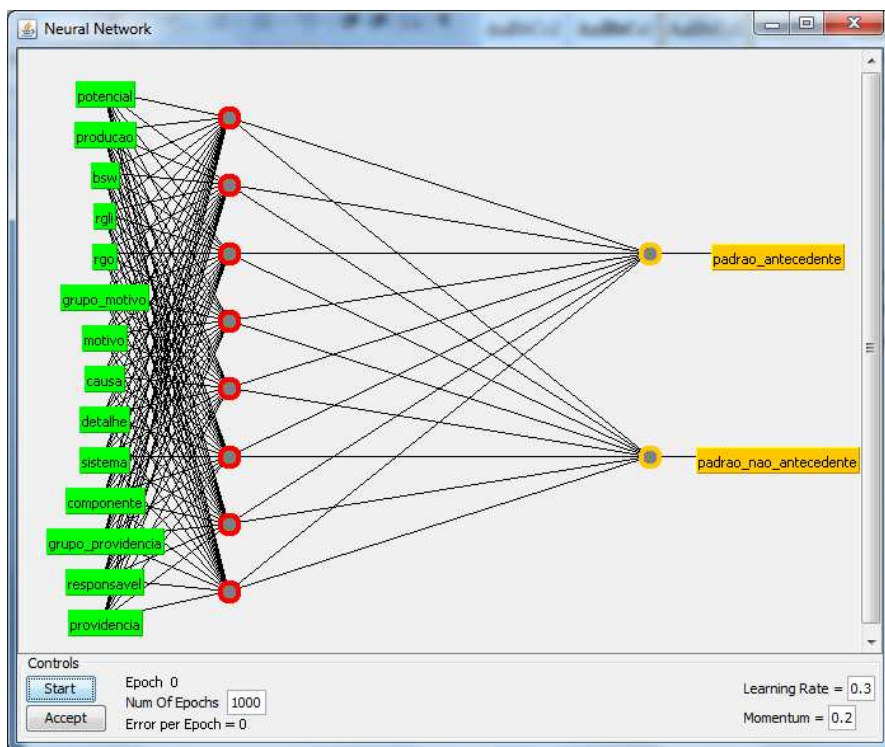


Figura 14: Rede neural de uma camada.

A rede apresentou um acerto de 55% na classificação das amostras como antecedente ou não antecedente a um estado de fechamento de

poço. Percebe-se pela matriz de confusão que a classificação apresentada não foi ideal:

	Padrão antecedente	Padrão não antecedente
Padrão antecedente	48	97
Padrão não antecedente	550	774

b) *Multilayer perceptron* de duas camadas escondidas com conjunto de dados de teste

Na tentativa de melhorar a classificação apresentada pela primeira topologia, alterou-se a rede para duas camadas com a segunda possuindo 14 neurônios, conforme visto na figura abaixo. O mesmo grupo para treinamento da rede correspondendo a 80% do total de amostras foi utilizado, bem como o grupo para validação da rede correspondendo a 20% do total das amostras.

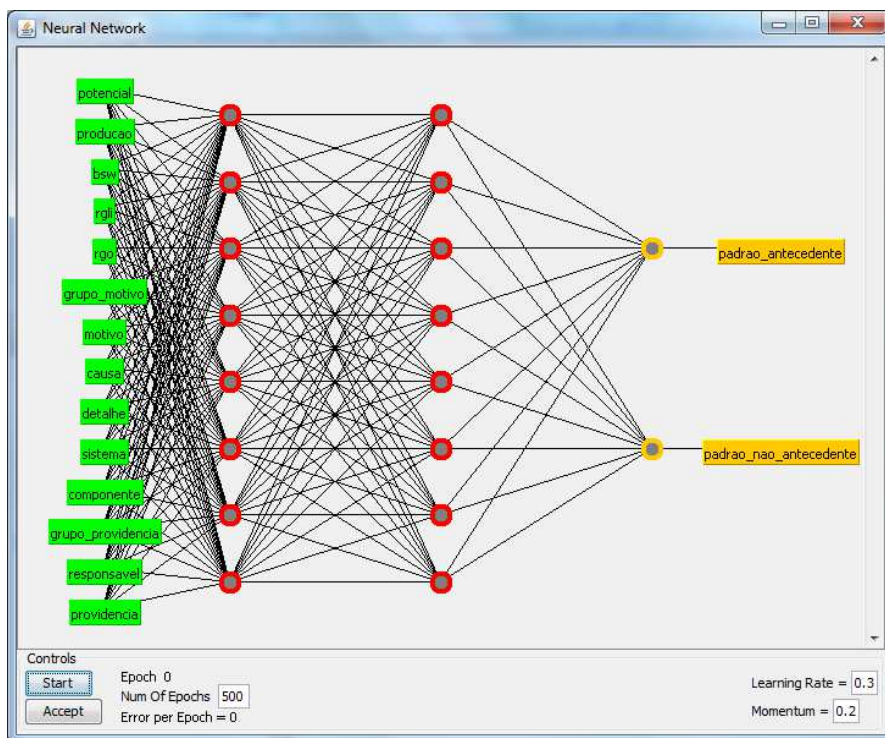


Figura 15: Rede neural de duas camadas.

Nesta arquitetura, houve uma piora na classificação da rede. O acerto da rede ficou na ordem de 43%, a tabela a seguir exibe a matriz de confusão dessa topologia.

	Padrão antecedente	Padrão não antecedente
Padrão antecedente	48	97
Padrão não antecedente	735	589

- c) *Multilayer perceptron* de duas camadas escondidas com conjunto de dados de teste

Nesta nova abordagem, a segunda camada teve o número de neurônios reduzido para apenas 2 neurônios no intuito de se avaliar o resultado. Assim como na topologia anterior, o mesmo grupo para treinamento da rede correspondendo a 80% do total de amostras foi utilizado, bem como o grupo para validação da rede correspondendo a 20% do total das amostras.

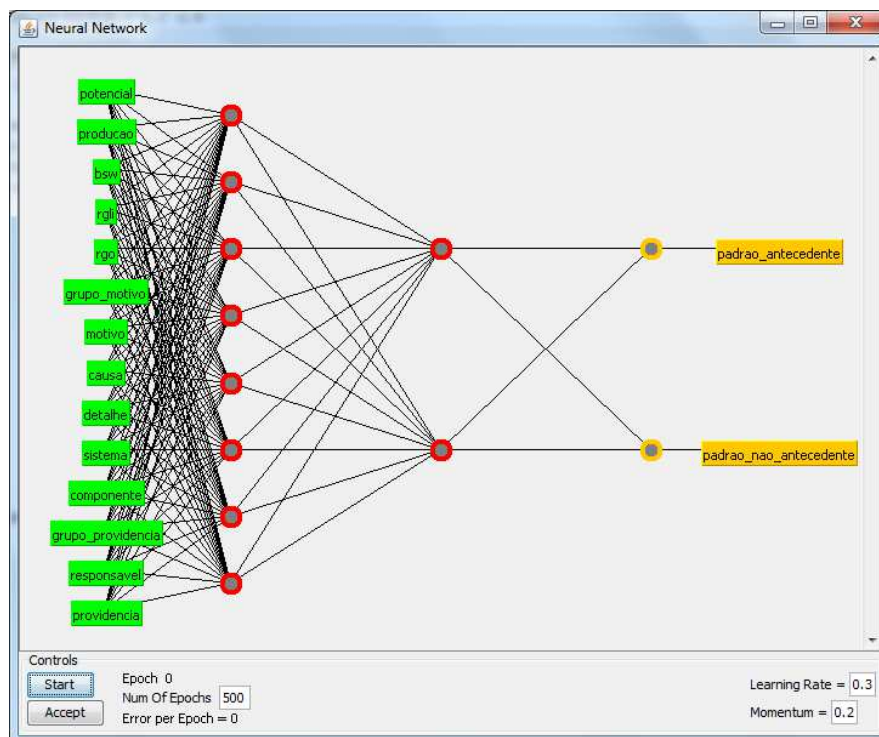


Figura 16: Rede neural de duas camadas.

Esta topologia apresentou praticamente o mesmo acerto da topologia anterior, ou seja, 43%. A tabela abaixo apresenta a matriz de confusão dessa topologia.

	Padrão antecedente	Padrão não antecedente
Padrão antecedente	65	80
Padrão não antecedente	759	565

d) *Multilayer perceptron* de uma camada escondida com validação cruzada

Após as análises descritas nas abordagens anteriores, partiu-se para a abordagem de execução da rede com validação cruzada, ou seja, o software Weka foi configurado para gerar 10 grupos de amostras, a partir do conjunto de amostra inicial. Desses 10 grupos, 9 deles são combinados e utilizados para treinamento da rede e um é utilizado para validação. Nessa primeira abordagem com a validação cruzada, utilizou-se a rede neural de apenas uma camada e o acerto na classificação foi

da ordem de 76%. Porém a matriz de confusão ainda não apresenta um bom nível de generalização, mas bem melhor do que nas abordagens que utilizaram um conjunto de dados de teste.

	Padrão antecedente	Padrão não antecedente
Padrão antecedente	156	876
Padrão não antecedente	159	3195

- e) *Multilayer perceptron* de duas camadas escondidas com validação cruzada

Essa topologia utilizou agora duas camadas de neurônios com validação cruzada e a segunda camada contendo 14 neurônios. O acerto da classificação manteve-se na ordem de 76%. Porém a matriz de confusão ainda não apresenta um bom nível de generalização, mas bem melhor do que nas abordagens que utilizaram um conjunto de dados de teste.

	Padrão antecedente	Padrão não antecedente
Padrão antecedente	59	973
Padrão não antecedente	84	3270

- f) *Multilayer perceptron* de duas camadas escondidas com validação cruzada

Essa abordagem alterou a topologia da rede para que apenas dois neurônios fizessem parte da segunda camada, porém a rede não sofreu alterações quanto à porcentagem de acerto, que se manteve em 76%. A matriz de confusão sofreu pouca alteração.

	Padrão antecedente	Padrão não antecedente
Padrão antecedente	57	975
Padrão não antecedente	73	3281

6. Conclusões e trabalhos futuros

O acompanhamento da produção de poços de petróleo é feito registrando-se os períodos em que os poços apresentam perda, ou seja, produzem aquém de seu potencial máximo. Um estado de perda de produção é normalmente caracterizado pela ocorrência de falhas em equipamentos utilizados na extração, tratamento ou estocagem do óleo. Os estados de perdas de produção podem ser definidos como perdas parciais, quando o poço está produzindo abaixo de seu potencial; ou como perdas totais, quando o poço está fechado sem produzir devido a uma falha operacional mais grave. Um estado de perda total é o mais indesejável por ocasionar a necessidade de uma intervenção mais séria no poço, pelo fato do recurso (petróleo) não ser extraído e conseqüentemente devido ao poço não gerar receita.

O registro das perdas no processo de monitoramento de produção de poços é feito informando-se o motivo que ocasionou a perda, bem como as providências a serem tomadas para que as falhas detectadas sejam mitigadas e o poço retorne a seu estado de produção normal. A partir dessa característica do processo de monitoramento, foi definida uma hipótese que consistiu em identificar padrões de registros de produção antecedentes aos estados de perda total. Assumiu-se então que tais padrões podem se repetir no futuro e dar indícios de que o poço irá entrar num estado de perda total. Dessa forma seria possível prever a ocorrência de fechamento de poços minimizando as despesas para reativação dos mesmos.

Com isso, foram obtidos dados de monitoramento de um poço de petróleo real com histórico de mais de 10 anos, desde quando o poço entrou em produção. Nesse histórico, foram escolhidos arbitrariamente os três registros anteriores a cada registro de perda total do poço como sendo os registros anteriores a um estado de fechamento. Após a identificação de todos os registros de estado de poço fechado e seus registros anteriores, foram utilizadas algumas arquiteturas de rede neural para que a identificação de padrões fosse feita. As redes neurais foram então treinadas com um conjunto de dados do histórico e então validadas com outro conjunto de dados a fim de se verificar sua capacidade de identificação dos padrões. Em seguida, foram analisados os resultados das redes, verificando-se o percentual de acerto das mesmas.

Verificou-se que mesmo variando-se as arquiteturas das redes neurais utilizadas no experimento a porcentagem de acerto da rede não sofreu alterações significativas. As alterações nessa porcentagem foram verificadas quando se alterou a abordagem da validação da rede. Os resultados foram melhores quando se realizou a validação cruzada.

Como trabalhos futuros, poderá ser feito um melhor tratamento prévio nos dados históricos do poço. Foi verificado que a curva de produção do poço apresentou uma tendência de queda. Isso sugere que durante o período de operação do poço as ocorrências de problemas em equipamentos podem ser influenciadas pelo tempo em que o poço está em operação. Ou seja, problemas operacionais no poço ocorridos recentemente podem ser bem diferentes de problemas operacionais que ocorreram nos primeiros períodos de operação. Com isso, os padrões de produção talvez sejam mais bem classificados quando se considera um período de produção do poço não tão longo quanto o utilizado neste trabalho.

Além disso, poder-se-á considerar a variação da porcentagem de água e sedimentos, e a porcentagem de gás como fatores que podem contribuir para a diferenciação de ocorrências de falhas. Isso quer dizer que o período em que um poço produz com pouca quantidade de água e sedimentos pode ter seu comportamento operacional de produção diferente do período em que o percentual de água e sedimentos seja maior. Conseqüentemente, a classificação dos padrões pode ser influenciada por essa variação. Nos dados utilizados no experimento, houve uma variação desses parâmetros por todo o período utilizado, o que pode ter afetado o rendimento não tão satisfatório do experimento. Como sugestão para trabalhos futuros, poder-se-á considerar a variação desses percentuais para que seja feita uma classificação prévia do período de produção de poços, para depois submeter os registros do período a uma rede neural em busca de padrões.

7. Referências bibliográficas

Nguyen, Hanh. H. Chan, Christine W. Wilson, Malcolm. **Prediction of Oil Well Production Using Multi-neural Networks**. Proceedings of the 2002 IEEE Canadian Conference on Electrical & Computer Engineering. pp 798-802, 2002.

Nguyen, Hanh H. Chan, Christine W. Monea, Michael. **A Decision Support System for Oil Production Prediction**. Canadian Conference on Electrical and Computer Engineering, May 2004, pp. 1397- 1400 Vol.3, 2-5.

Weiss, William W. Balch, Robert S. Stubbs, Bruce A. **How Artificial Intelligence Methods Can Forecast Oil Production**. SPE/DOE Improved Oil Recovery Symposium. Oklahoma. 13-17 April 2002.

Lackes, Richard. Börgermann, Chris. Dirkmorfeld, Matthias; **Forecasting the Price Development of Crude Oil with Artificial Networks**. International Work-Conference on Artificial Neural Networks (IWANN) 2009, Part II, LNCS 5518, pp. 248-255, 2009.

Zündorf, L. **Das System der internationalen Erdölindustrie**. Eine theoretische empirische Skizze, University of Lüneburg, Department of Economic and Social Sciences, work report no. 269, p. 1, 2002.

Rapoza, Kenneth. **Petrobras As Brazil's Moon Landing**. 29/9/2011 Forbes. Disponível em: <http://www.forbes.com/sites/kenrapoza/2011/09/29/petrobras-as-brazils-moon-landing/>. Acessado em: 01/10/2011.

Silva, Ivan Nunes. da. Spatti, Danilo H. Flauzino, Rogério **A. Redes Neurais Artificiais: para engenharia e ciências aplicadas**. São Paulo. Artliber, 2010.

Sheferd, G. M. **The synaptic organization of the brain**. Oxford University Press, Third edition, New York, USA, 1990.

Kandel, E. R. Schwartz, J. H. Jessel, T. M. **Principles of neural science**. McGraw-Hill, Fourth edition, New York, USA, 2000.

Hodgkin, A. L. Huxley, A. F. A **Quantitative Description of Membrane Current and its Application to Conduction and Excitation in Nerve**. Journal of Physiology, vol. 117, pp. 500-544, 1952.

McCulloch, W. S. Pitts, W. **A logical calculus of the ideas immanent in nervous activity**. Bulletin of Mathematical Biophysics, vol. 5, pp. 115-133, 1943.

Sutton, R. S., Barto, A. G. **Reinforcement learning: an introduction**. MIT Press, Cambridge, Massachusetts, USA, 1998.

Tsoukalas, L. H. Uhrig, R. E. **Fuzzy and neural approaches in engineering**. John Wiley, New York, USA, 1997.

Hall, Mark. Frank, Eibe. Holmes , Geoffre. Pfahringer , Bernhard. Reutemann, Peter. Witten, Ian H. **The WEKA Data Mining Software: An Update**; SIGKDD Explorations, Volume 11, Issue 1, 2009.