

Rede neural artificial aplicada à estimativa da pressão de poros de uma formação rochosa

Artificial neural network applied to the pore pressure estimation of a rocky formation

Marianna Rezende de Moraes Mendonça¹ , Bruna Silveira Teixeira¹ , Giovane Quadrelli¹ ,
Ricardo Franciss¹ 

¹Universidade Católica de Petrópolis – UCP, Rua Barão do Amazonas, 124, Centro, CEP: 25685-100, Petrópolis, RJ, BR
(marianna.oilengineer@gmail.com; brunasilveira@gmail.com; giovane.quadrelli@ucp.br; ricardo.franciss@ucp.br)

Recebido em 16 de outubro de 2019; aceito em 14 de abril de 2021

Resumo

O projeto de perfuração de poço é uma das principais etapas de engenharia e tem o objetivo de evitar problemas como *kicks*, instabilidade de poços, *blowouts* e perda de circulação, que representam os principais causadores de danos ambientais, prejuízos econômicos e até perdas humanas, especialmente críticos quando se trata de perfurações ultraprofundas. Usualmente, métodos matemáticos, empíricos e medidos em campo são usados na estimativa da pressão de poros, porém não se pode dizer que esses têm exatidão nos valores encontrados, pois dependem de como o instrumento ou o analista leem determinada medição. Por esse motivo, métodos como as redes neurais artificiais (RNAs) foram estudados, a fim de encontrar valores de pressões com margem de erro cada vez menor. Além de serem muito mais rápidas e precisas do que os métodos convencionais, as RNAs são sistemas computacionais adaptativos inspirados no cérebro humano, que adquirem conhecimento por meio de experiência. Com isso, um estudo de caso foi realizado a fim de criar, treinar e utilizar uma RNA a partir de dados de perfilagem do poço estudado, além de informações como profundidade e densidade das formações rochosas. A proposta é estimar a pressão de poros usando essa inteligência artificial e comparar os resultados obtidos entre o método convencional de Eaton e a RNA criada, com o intuito de mostrar que os resultados com essa nova tecnologia atingem os menores valores de erro.

Palavras-chave: Inteligência artificial; Perfuração; Método de Eaton.

Abstract

Well planning is one of the most important steps of drilling engineering to avoid problems such as kicks, well instability, blowouts, and lost circulation, which represents the main causes of environmental damage, economic loss, and human loss included. These damages are especially critical when it comes to ultra-deepwater drilling. Usually, to estimate pore pressure, methods based on historical experience, mathematical statistical, empirical, and field-measured are used. However, accuracy on each method is a challenge for improvement, as they depend on how the instrument or petrophysics analysts reads the particular measurement. Therefore, methods such as artificial neural network (ANN) are studied, aiming to find values of formation pressures with lesser margin of error. Besides being a faster and more accurate method than the conventional ones, the ANN is an adaptive computer system inspired by the human brain itself, that acquires knowledge with experience. The outline is to use this artificial intelligence to estimate pore pressure. Therewith, a case study was performed to create, train, and implement ANN from data logs of the well studied, besides depth and density of rock formation information. The proposal is to estimate pore pressure using this artificial intelligence technique and compare the obtained results between the Eaton conventional method and the created ANN, in order to prove that the results using this new technique reach smaller errors.

Keywords: Artificial intelligence; Drilling; Eaton Method.

INTRODUÇÃO

O presente artigo tem como principal enfoque a aplicação de uma nova tecnologia para a estimativa da pressão de poros de formações rochosas, com o intuito principal de manter a estabilidade do poço. Segundo Souza (2011), o Brasil tem se destacado mundialmente devido aos sucessos em perfurações de poços de petróleo em lâminas d'água (LDA) profunda e ultraprofunda. Quando se trata de perfuração ultraprofunda, o desafio é ainda maior, pois, na medida em que a LDA fica mais profunda, a camada rochosa a ser perfurada e a pressão no interior da rocha aumentam gradativamente, devido aos pesos sobrepostos, designada pressão litostática ou pressão de confinamento. De acordo com Teixeira et al. (2000), a intensidade da pressão litostática é função da coluna de rochas sobrejacente e da densidade dessas rochas.

Um dos principais motivos de aumento de tempo e custo na perfuração está ligado diretamente a problemas de instabilidade de poços. Logo, determinar as geopressões é essencial para analisar a estabilidade do poço. Fazer uma boa estimativa da pressão de poros da formação, além de aumentar a segurança, reduz o tempo de perfuração. Normalmente ela é calculada a partir de modelos matemáticos baseados em perfis elétricos ou a partir de dados do perfil sônico. É importante ressaltar que tais medições só são feitas em rochas argilosas, ou seja, isso diminui a possibilidade de estimativa em outros modelos rochosos. Além disso, é comum haver erros nas medições das propriedades físicas da rocha, bem como dificuldades na determinação de qual tipo de mecanismo de geração de pressão de poros que aquela porção rochosa apresenta.

É imprescindível destacar que a pressão de poros é um dos fatores mais importantes na indústria do petróleo, principalmente no auxílio da perfuração. As metodologias de estimativa direta dessa geopressão atualmente utilizadas dependem diretamente do profissional responsável, sendo esse encarregado de construir e avaliar a curva de compactação normal e, conseqüentemente, a pressão de poros da formação rochosa. Por serem metodologias dependentes da avaliação de profissionais qualificados, a resposta não é imediata, aumentando, muitas vezes, o custo da operação e podendo levar a erros extremos, como o ocorrido no Golfo do México, em 2010, na plataforma *Deepwater Horizon*. Com o intuito de acelerar o processo de perfuração e evitar a instabilidade do poço, e conseqüentemente danos ao meio ambiente e à vida humana, novas tecnologias vêm sendo estudadas, conforme Ribeiro (2006), Cai et al. (2018), Scheid et al. (2020), dentre outros autores, a fim de melhorar a medição dessa geopressão e evitar futuros erros, pois, uma vez perfurado o poço, caso haja algum problema na formação, o prejuízo será ainda maior.

Silva et al. (2015) recomendam a abordagem de redes neurais a problemas com grandes quantidades de informações

e de alta complexidade, características comuns à área de petróleo, justificando a necessidade de experiência e reconhecimento de padrões. Neste estudo, foi criada uma rede neural artificial (RNA) com uma base de dados relativamente pequena, a qual fornecia dados de perfilagem do poço estudado, além de informações de profundidade e densidade das formações rochosas. A RNA foi criada e treinada com o intuito principal de estimar a pressão de poros. O foco principal deste trabalho foi estimar essa relevante geopressão, a qualquer profundidade, abrindo o campo para essa área tão importante.

GEOMECÂNICA DO PETRÓLEO

Mecânica das rochas

A geomecânica do petróleo estuda o comportamento mecânico das rochas, levando em consideração as propriedades físicas delas, para fins de análise de problemas relacionados à estabilidade de poços de petróleo. Segundo Oliveira et al. (2016), esse estudo se faz necessário desde a prospecção até a produção de hidrocarbonetos. Durante a perfuração de um poço de petróleo, a rocha é exposta a diferentes carregamentos externos que acabam alterando o estado de tensões originais da formação. Em particular, a mecânica das rochas se preocupa com o comportamento de formações rochosas quando estão submetidas às perturbações causadas pela escavação.

Propriedades como a tensão e a pressão no interior da rocha são essenciais para estabelecer critérios que evitem tanto a geração de pressões anormais na rocha quanto a instabilidade do poço. Além disso, estimar, com coerência, os valores de densidade e perfil sônico das formações faz com que o cálculo dessas pressões/tensões internas seja bem aplicado.

Dentre as principais tensões que a rocha sofre ao longo de sua vida estão a tensão de sobrecarga e a tensão efetiva. A primeira é a tensão exercida por todo o material, tanto fluido quanto sólido, devido ao peso próprio das rochas. Matematicamente falando, a tensão de sobrecarga, a uma dada profundidade, é o somatório do peso de todas as camadas sobrepostas a esse elemento, sendo definida pela Equação 1.

$$\sigma_V = \int_0^D \rho g dD \quad (1)$$

Em que:

σ_V = tensão de sobrecarga;

ρ = massa específica ou “densidade” das camadas sobrepostas;

g = constante gravitacional;

D = profundidade desejada;

dD = variação de profundidade.

Observando-se a Equação 1, a tensão de sobrecarga é definida por três parâmetros, os quais somente a densidade não é predeterminada. Métodos como análise de testemunhos e perfil densidade são bastante utilizados na indústria atualmente. Os testemunhos são amostras reais de rocha de subsuperfície que proporcionam medição pontual da densidade. Já o perfil densidade é um dos métodos mais importantes que estimam a massa específica das formações rochosas. Essa metodologia registra a densidade eletrônica da rocha a partir da emissão e da captação de raios gama. É importante ressaltar que, em densas formações rochosas, os raios gama perdem energia e, por isso, não conseguem ser aplicados. Nesses casos, é usada a correlação de Bellotti.

Segundo Vasconcelos (2014), a correlação proposta por Bellotti estima a densidade usando o tempo de trânsito da matriz da rocha, a densidade do fluido no interior dos poros e o tempo de trânsito medido pelo perfil sônico.

Outro tipo de correlação utilizada para estimar a densidade das rochas é a de Gardner. Por ser uma correlação simples e confiável, é o método mais usado na indústria do petróleo para a estimativa das densidades das formações. Essa também relaciona a densidade com o tempo de trânsito (Equação 2) ou com a velocidade do som (Equação 3), como mostram as equações a seguir:

$$\rho_b = a \left(\frac{10^6}{\Delta t} \right)^b \quad (2)$$

$$\rho_b = a(V)^b \quad (3)$$

Em que:

ρ_b = densidade total da formação em g/cm³;

Δt = tempo de trânsito em μ s/ft;

V = a velocidade do som em ft/s;

a = constante empírica (valor usual igual a 0,23);

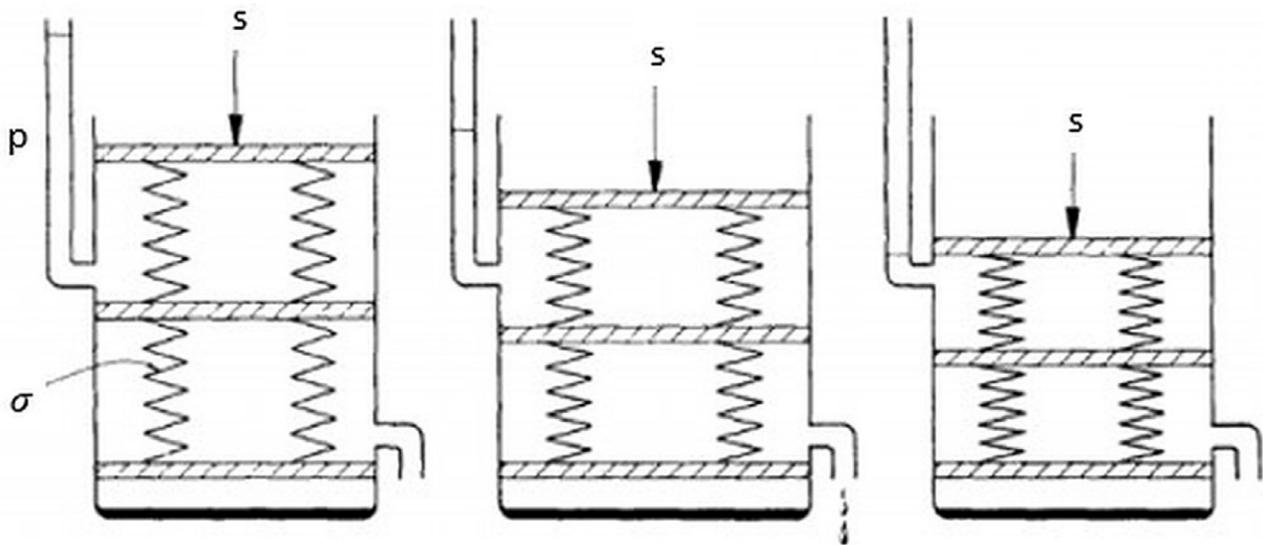
b = expoente empírico (valor usual igual a 0,25).

Os parâmetros a e b foram estimados a partir de testes laboratoriais e observações de dados de campo no Golfo do México para diversos tipos de rochas (Gardner, 1974 *apud* Vasconcelos, 2014). Rocha e Azevedo (2009) ressaltam que a correlação de Gardner é conhecida por estimar a densidade de formações em ambientes *offshore*. Logo, os resultados encontrados devem ser corrigidos por meio da calibração das constantes, utilizando-se perfil de densidade disponível em análise.

Outra tensão extremamente importante é a efetiva. Terzaghi (1943 *apud* Hottmann e Johnson, 1965) propõe um experimento para explicar a origem da teoria da compactação de formações argilosas saturadas com água. A Figura 1 simula o aumento da sobrecarga sobre os grãos da rocha, que são representados pelas molas, e sobre o fluido contido no interior dos poros. Nas mangueiras laterais, esse fluido tende a escapar, na medida em que a tensão vertical vai aumentando, a fim de aliviar a pressão. Com isso, Terzaghi chegou à relação seguinte (Equação 4):

$$P_{poros} = \sigma_{sobrecarga} - \sigma_{efetiva} \quad (4)$$

A Equação 4 relaciona a pressão de poros com as demais tensões anteriormente exemplificadas. Muitas vezes



Fonte: Hottmann e Johnson (1965).

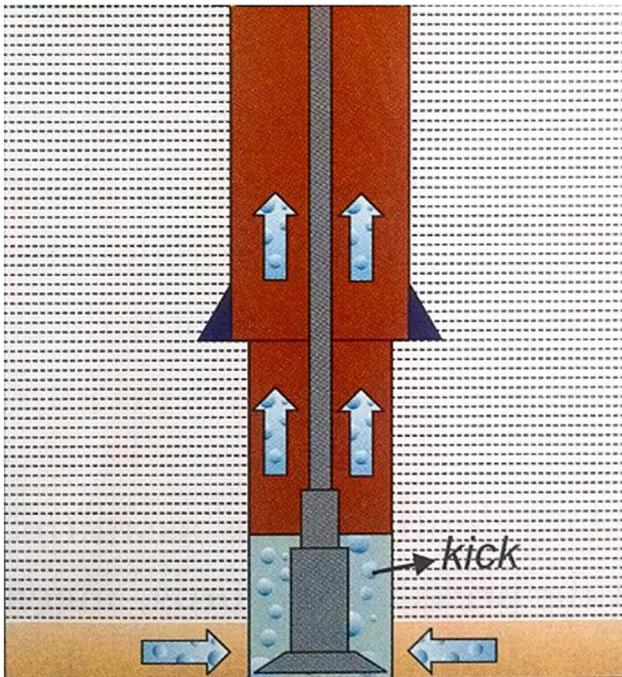
Figura 1. Experimento de Terzaghi.

referenciada como pressão da formação, a pressão de poros pode ser determinada como a pressão do fluido contido nos espaços entre grãos da rocha, também conhecido como espaço poroso. É de extrema importância estudá-la, pois é ela quem estabelece o peso do fluido a ser usado durante a perfuração, o qual será responsável pela pressão dentro do poço.

O tipo de formação rochosa, segundo Domingues (2016), influencia muito quando se trata de perfuração de um poço de petróleo, pois, dependendo das propriedades da rocha, e juntamente com a pressão de poros, pode acarretar em diferentes consequências, como *kick* ou aprisionamento da coluna. Diante de formações permeáveis, caso a pressão de poros se torne maior do que a pressão dentro do poço, poderá ocorrer influxo do fluido da formação para o poço, denominado *kick* (Rocha e Azevedo, 2009, p. 114) (Figura 2).

Como o *kick* é um fluxo indesejado de fluido, a perfuração deve ser interrompida para que haja controle. Isso, além de resultar em grande prejuízo econômico, pode também ocasionar um grande impacto ambiental se chegar à superfície (*blowout*), colocando em risco, além do meio ambiente, a vida.

Quando se trata de formações com baixa permeabilidade e a pressão de poros ainda for maior do que a pressão dentro do poço, pode acontecer o seu desmoronamento, deixando, muitas vezes, a coluna aprisionada. Por outro lado, sendo o peso do fluido de perfuração muito maior do que a pressão de poros, pode ocorrer de a formação fraturar e haver perda de fluido de perfuração para o poço.



Fonte: Rocha e Azevedo (2009).

Figura 2. Kick em um poço de óleo e gás.

Para o cálculo da pressão de poros, consideremos um fragmento de rocha composto por grãos sólidos e poros cheios de líquidos, selados por uma placa rígida sob tensão atuando em sua superfície externa, chamada de tensão real ou de sobrecarga, como mostra a Figura 3. De acordo com Aadnoy e Looyeh (2014), essa tensão é absorvida tanto pelos grãos da rocha quanto pelo fluido, ignorando as tensões locais que agem em cada grão. Por esse motivo, é evidente que a tensão efetiva, também conhecida como tensão média suportada pelos grãos da rocha, é menor que a tensão de sobrecarga. A diferença é a pressão de poros, como demonstrado anteriormente na Equação 4.

MÉTODOS CONVENCIONAIS PARA ESTIMAR A PRESSÃO DE POROS

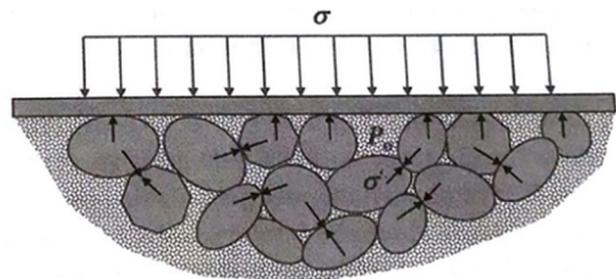
No processo de planejamento de um poço, a estimativa da pressão de poros é fundamental, especialmente durante a perfuração de poços mais profundos — *onshore* ou *offshore* —, em que podem existir maiores pressões de poros.

São usados métodos diretos e indiretos para determinar o gradiente da pressão de poros. O método direto nada mais é do que uma abordagem experimental e é realizado em formações permeáveis. Já o método indireto se baseia em modelos analíticos e é efetuado em folhelhos.

Método direto

Neste, as medições obtidas são assumidas como verdade absoluta e, em vez de apresentar uma curva de pressão de poros ao longo do poço, as medições diretas apresentam resultados pontuais. Os testes mais comuns para medições de pressão de poros na indústria são: Teste de Formação, *Repeated Formation Test* (RFT), e *Formation Pressure While Drilling* (FPWD).

O Teste de Formação é feito após a perfuração do poço e equivale a uma completação provisória. Além de ser um método com muitas manobras, incluindo as colunas de



Fonte: Aadnoy e Looyeh (2014).

Figura 3. Material rochoso poroso selado com uma placa rígida.

perfuração e teste, é também demorado, podendo levar horas ou até dias. Por esses motivos, não é a melhor opção para um profissional estimar a pressão de poros. Já o RFT é um aperfeiçoamento do Teste de Formação, o qual é realizado após a perfuração com o poço ainda aberto, ou seja, sem revestimento. O fato de ser feito com um cabo reduz o tempo da operação. A ferramenta tem um sistema de válvulas e câmaras, o que possibilita o registro das pressões estáticas, além de obter pequenas amostras de fluido. Após a perfuração do poço, os resultados encontrados para ambas as medições servem para confirmar, ou não, a estimativa da pressão de poros já realizada. Tais resultados são de grande utilidade para outros poços presentes na mesma área.

O FPWD é realizado em tempo real durante a perfuração do poço, utilizando um conjunto de sensores acima da broca, no entanto, é um método mais caro do que o RFT (Santos et al., 2015).

Método indireto

Os métodos indiretos usam técnicas de análise de tensão para estimar o gradiente de pressão de poros. Um ponto importante a destacar é que todos os métodos indiretos foram desenvolvidos para prática em folhelhos, que, por serem formações argilosas e de baixa permeabilidade, são bastante influenciadas pela subcompactação.

Em 1957, Hubbert e Willis introduziram o método, o qual presumia que a fratura ocorre quando a pressão do fluido utilizado exerce a soma da tensão efetiva mínima e a pressão de poros da formação. Dez anos após essa descoberta, em 1967, Matthews e Kelly desenvolveram um método um pouco mais preciso, o qual poderia ser aplicado em formações de rochas brandas, que são encontradas no Golfo do México e no norte do Mar do Norte. No ano seguinte, em 1968, Pennebaker aprimorou, usando dados sísmicos, o que Matthews e Kelly haviam desenvolvido. Ele constatou que a idade geológica interferia no valor do gradiente de pressão de sobrecarga e, com isso, desenvolveu um conjunto de curvas relacionando o gradiente com a profundidade.

De acordo com Laredo e Fontoura (2007), Eaton é um dos métodos mais usados na indústria do petróleo atualmente e será discutido a seguir.

Método de Eaton

Neste método, a pressão de poros a certa profundidade é função: da pressão de sobrecarga, da pressão normal de poros, da razão entre o valor do parâmetro observado e do valor da linha de tendência de compactação normal, bem como do expoente escolhido. Tal expoente está diretamente relacionado à área que está em estudo e ao parâmetro utilizado. Por exemplo, de acordo com Eaton (1975), os valores

do expoente (em específico nos poços do Golfo do México), para o perfil de resistividade e perfil sônico, são de 1,2 e 3, respectivamente. Esse é considerado o método mais utilizado na indústria para predição indireta do gradiente de pressão de poros e é regido pelas Equações 5 e 6.

Resistividade:

$$G_P = G_{OV} - \left[(G_{OV} - G_N) \left(\frac{R_O}{R_N} \right)^{1,2} \right] \quad (5)$$

Tempo de trânsito:

$$G_P = G_{OV} - \left[(G_{OV} - G_N) \left(\frac{\Delta t_N}{\Delta t_o} \right)^3 \right] \quad (6)$$

Em que:

G_P = gradiente de pressão de poros em lb/gal;

G_N = gradiente normal de pressão de poros em lb/gal;

G_{OV} = gradiente de sobrecarga em lb/gal;

Δt_o = tempo de trânsito observado;

Δt_N = valor da reta normal para o tempo de trânsito;

R_O = resistividade observada;

R_N = valor da reta normal para a curva de resistividade.

É importante lembrar que, quando se trata de gradiente, há relação com a profundidade.

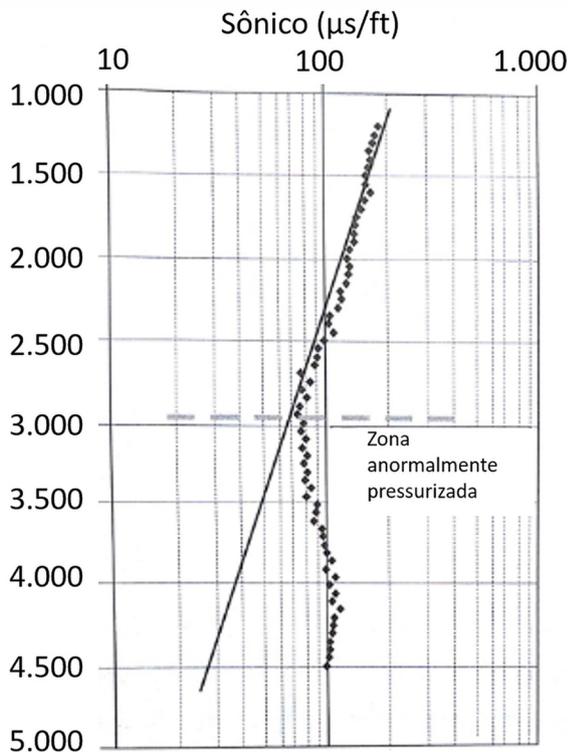
Os valores ditos “normais”, apresentados pelo índice N , que são observados nas Equações 5 e 6, são obtidos na linha de tendência, também chamada de curva de compactação normal, por isso o traçado dessa reta é o passo fundamental para que esse método tenha êxito. Já os valores descritos como “observados” (0) são os verificados nos perfis. A Figura 4 apresenta um exemplo de linha de tendência para um perfil sônico.

É importante mencionar o que significa a expressão “sônico”. Essa também é conhecida como tempo de trânsito e nada mais é do que o tempo que o som demora para se propaga no interior da rocha. Quanto maior a velocidade do som na formação, menor é o tempo de propagação. Por isso, pode-se dizer que o tempo gasto por uma onda na superfície sólida da rocha é bem menor do que na superfície líquida ou gasosa.

A vantagem de se usar o perfil sônico no cálculo da estimativa da pressão de poros é que o tempo de trânsito tem relação direta com a porosidade da rocha, pois, na medida em que a porosidade diminui com a profundidade, o tempo de trânsito também diminui.

Curva de compactação normal

A curva de compactação normal, também conhecida como *trend*, tem o intuito de avaliar as pressões anormais associadas ao processo de compactação e, com isso, identificar o trecho em que a compactação ocorrida foi normal.



Fonte: Rocha e Azevedo (2009).

Figura 4. Curva de tendência para um perfil sônico.

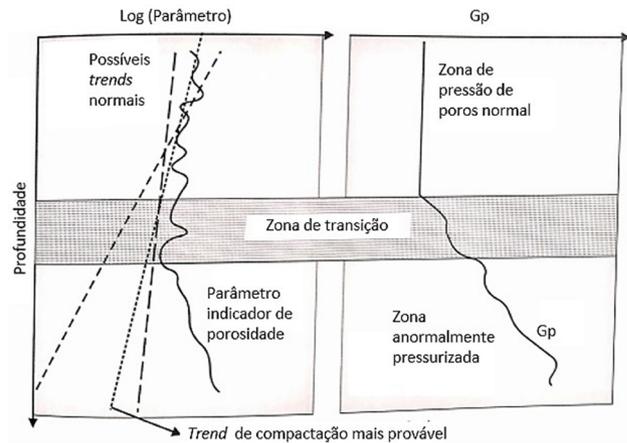
Como visto, a compactação está diretamente ligada à diminuição da porosidade da rocha com o aumento da profundidade, logo, a curva de tendência deve apresentar esse tipo de comportamento. No geral, as rochas normalmente compactadas são encontradas nos trechos superiores do poço, pois as formações mais rasas são as mais recentes e, portanto, têm maior probabilidade de estarem normalmente pressurizadas (Rocha e Azevedo, 2009).

O traçado dessa linha é uma etapa muito importante na estimativa da pressão de poros, pois podem existir diversas maneiras de se traçar a reta. Isso varia de acordo com a interpretação de cada profissional, como ilustra a Figura 5.

REDES NEURAIS ARTIFICIAIS

Como visto, os métodos convencionais de estimativa da pressão de poros são dependentes da avaliação do profissional e da maneira que a linha de tendência será desenhada. Por esses motivos, é de extrema importância estudar um novo método para a determinação da pressão de poros, de modo que a experiência do profissional não interfira diretamente nos resultados obtidos.

O trabalho das RNAs tem sido motivado desde que foi descoberto que o cérebro humano processa informações



Fonte: Rocha e Azevedo (2009).

Figura 5. Exemplos de possíveis curvas de tendência de compactação normal.

de forma inteiramente diferente do computador digital convencional. As RNAs são sistemas de computação adaptativos inspirados no arranjo neural de organismos inteligentes que ganham conhecimento por meio de experiência. Na sua forma mais geral, uma rede neural é uma máquina que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse (Haykin, 2001). O cérebro humano tem enorme competência de processar informações e, a partir dessa análise, estudos são realizados com o intuito de reproduzir as reações do cérebro em máquinas.

Principais características das RNAs

Segundo Silva et al. (2010), as características mais importantes relacionadas à aplicação das RNAs são:

- Adaptação por experiência: as adaptações dos pesos sinápticos são realizadas a partir da apresentação contínua de exemplos relacionados ao comportamento do processo, o que possibilita à rede adquirir conhecimento por meio de experimentos;
- Capacidade de aprendizado: a partir da aplicação de um determinado método de treinamento, a rede consegue aprender sobre as diversas variáveis que a compõem;
- Habilidade de generalização: após o processo de aprendizado, a rede está habilitada a generalizar os dados adquiridos, possibilitando estimar respostas que antes eram uma incógnita;
- Organização de dados: a rede consegue realizar sua organização interna agrupando padrões que apresentam características em comum;
- Tolerância a falhas: o fato de a rede ter elevado nível de interconexões (sinapses) entre os neurônios torna o sistema tolerante a falhas;

- Armazenamento distribuído: o conhecimento adquirido de determinado processo dentro de uma arquitetura neural é simbolizado de forma distribuída entre as conexões de seus neurônios;
- Facilidade de prototipagem: geralmente, a implementação da rede neural não é complicada. Tudo depende da especificidade da aplicação. Após o processo de treinamento, os resultados são usualmente obtidos por operações matemáticas.

Neurônio biológico

Em 1911, o espanhol Ramón y Cajál introduziu a ideia de que os neurônios pertenciam à estrutura do cérebro, por isso, entendê-lo se tornou mais fácil. Pode-se dizer que o processamento de informações do cérebro humano é administrado por elementos biológicos que têm como objetivo a produção de ações adequadas para cada uma de suas funções, tais como pensar e memorizar. Estima-se que um ser humano tenha cerca de 10 bilhões de neurônios e 60 trilhões de sinapses ou conexões, que interagem entre si, armazenando e tomando decisões adequadas a partir das informações recebidas.

O sistema nervoso é composto por um conjunto bastante complexo de neurônios, que são responsáveis por conduzir impulsos sob determinadas condições de operação, ou seja, o funcionamento e o comportamento do corpo humano. Um neurônio é formado por um corpo celular com diversas ramificações, conhecidas como dendritos, que são um conjunto de terminais de entrada, e pelos axônios, que são longos terminais de saída.

Os dendritos são formados por inúmeros finos segmentos que formam a árvore dendrital. Sua principal função consiste em receber os estímulos vindos de diversos neurônios.

O axônio é constituído por um único terminal, que tem o dever de conduzir os impulsos para outros neurônios. O seu prolongamento é composto de ramificações conhecidas como terminações sinápticas.

Os neurônios se comunicam por meio das sinapses, em que os impulsos nervosos são transmitidos entre elas. Tais conexões transferem os impulsos do axônio de um neurônio para os dendritos de outros.

Modelo artificial de um neurônio

O arranjo das RNAs foi elaborado com base na arquitetura cerebral humana. Ele é composto por várias unidades de processamento, ou seja, neurônios, cujo funcionamento é bastante simples. Essas unidades geralmente são conectadas por canais de comunicação que estão relacionados a determinado peso.

Os neurônios artificiais aplicados nos modelos de redes neurais são, na maioria das vezes, não lineares, normalmente

geram saídas contínuas, podendo ser também binárias, e coletam sinais presentes em suas entradas, agregando-os de acordo com sua função. Além disso, eles apresentam um valor de saída, ou seja, uma resposta, levando em consideração a função de ativação. O modelo artificial é mostrado na Figura 6.

Pode-se observar, na Figura 6, que os sinais (x_j) são apresentados à entrada a partir das sinapses (j) que estão conectadas a um neurônio (k). Cada sinapse é multiplicada por um peso (w_{kj}), que pondera os dados de entrada, a fim de indicar a sua influência na saída da unidade. É importante notar o modo como são escritos os índices dos pesos sinápticos. O primeiro está atribuído ao neurônio em questão e o segundo, à sinapse à qual o peso se refere.

Um somador (Σ) ou (u_k) é utilizado para somar os sinais de entrada (já ponderados pelos pesos sinápticos), e a função de ativação (Φ) para restringir a amplitude dos sinais na saída. A função de ativação molda a forma como o neurônio responde ao nível de excitação, limitando e definindo a saída da rede neural. Existem vários tipos de função de ativação. Os três mais básicos são: limiar, linear e sigmoide. A escolha do tipo varia de acordo com o objetivo do projeto.

O modelo neural da Figura 6 inclui o bias (b_k), o qual tem a função de aumentar ou diminuir a entrada líquida da função de ativação. Entre o somador e a função de ativação, existe o potencial de ativação (v_k). Tal componente é o resultado obtido pela diferença do valor produzido pelo somador menos o valor do bias. Se tal valor encontrado for positivo, então, pode-se dizer que o neurônio produz um sinal excitatório, caso contrário, o potencial será inibitório.

Em termos matemáticos, pode-se dizer que um neurônio (k) escreve o seguinte par de Equações 7 e 8 para os sinais de entrada e saída, respectivamente.

$$u_k = \sum_{j=1}^m w_{kj}x_j + b_k \quad (7)$$

$$y_k = \Phi(u_k) \quad (8)$$

Em que:

x_j = sinais de entrada;

w_{kj} = peso sináptico;

b_k = bias;

Φ = função de ativação;

u_k = somador dos sinais de entrada;

y_k = sinal de saída.

Arquitetura da rede neural

A maneira como os neurônios artificiais podem ser associados é uma importante característica que estabelece o tipo de arquitetura das RNAs. Uma rede neural pode ter uma ou várias camadas. As principais arquiteturas, levando-se em conta os neurônios e os modos a serem conectados, podem

ser divididas em: redes diretas (*Feedforward*) ou redes recorrentes (*Feedback*), sendo a primeira a mais utilizada atualmente.

Como dito, a arquitetura neural é geralmente organizada em camadas, as quais são classificadas em três grupos, como mostra a Figura 7.

Na camada de entrada, os neurônios recebem sinais de excitação, ou seja, é o local em que os dados de entrada são apresentados à rede. Na camada intermediária ou oculta, acontece a maior parte do processamento. Nessa camada, os neurônios têm a função de extrair as características associadas ao processo. Já a camada de saída é o local em que

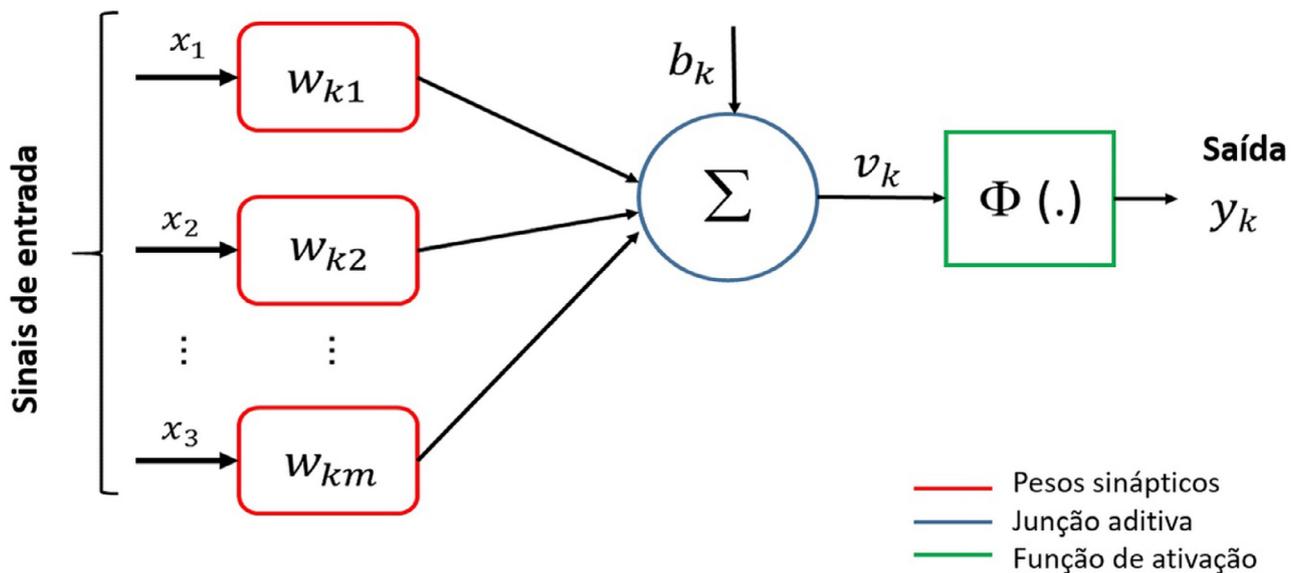


Figura 6. Modelo artificial de um neurônio biológico.

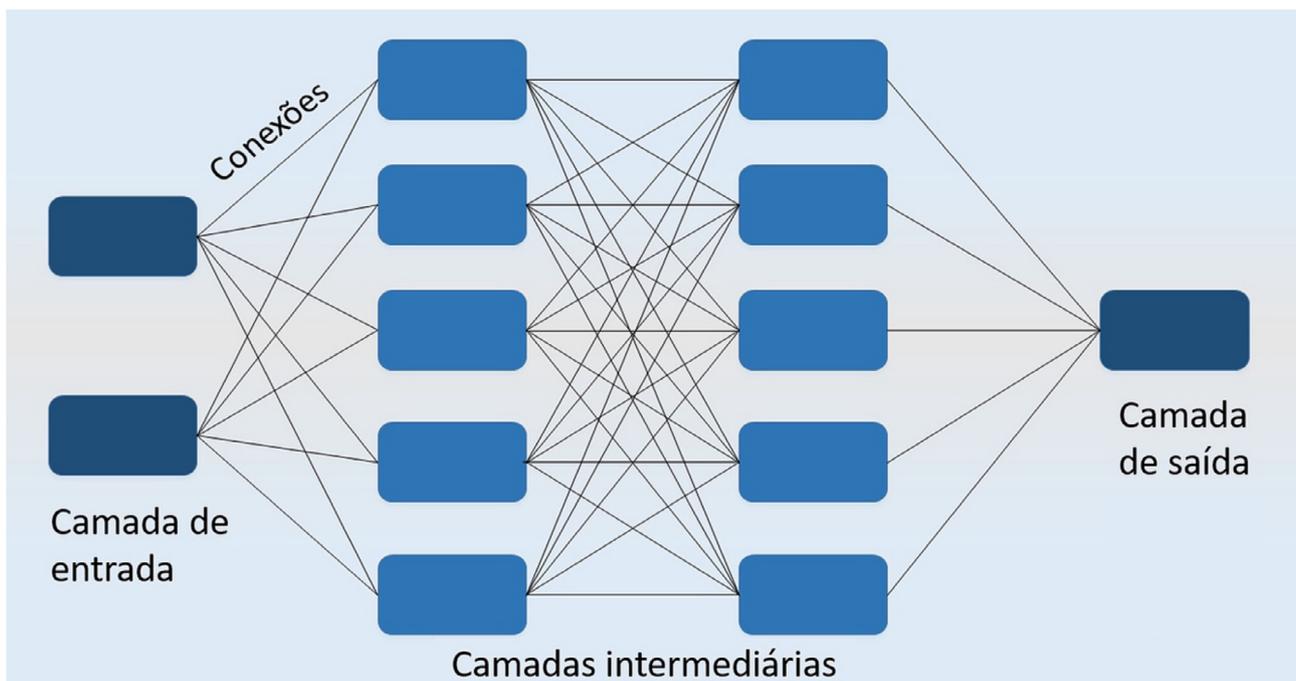


Figura 7. Arquitetura em camadas da rede neural.

o resultado é concluído e apresentado. Basicamente, itens como a quantidade de neurônios e as camadas intermediárias, que compõem a estrutura de uma rede neural, estão sempre sujeitos a alterações. Tudo depende da necessidade de aplicação da rede.

Processo de aprendizagem

O ponto primordial para uma rede neural é a habilidade de aprender a partir da apresentação de padrões e, em seguida, se tornar capaz de generalizar soluções e produzir uma saída a mais próxima possível da desejada. Além disso, ela é capaz de melhorar o seu desempenho por meio da aprendizagem.

O conhecimento é adquirido por intermédio de um processo iterativo de ajustes, aplicado aos pesos sinápticos, que são modificáveis de acordo com o algoritmo de aprendizado. Segundo Silva et al. (2010), o conjunto total de amostras de dados é dividido em dois subconjuntos, denominados de subconjunto de treinamento e subconjunto de teste. O primeiro é constituído por aproximadamente de 60 a 90% das amostras do conjunto total e será usado no processo de aprendizado da rede. Já o subconjunto de teste é composto por cerca de 10 a 40% do conjunto total de amostras e será aplicado para certificar que as soluções por parte da rede já estão em patamares aceitáveis. Tal análise possibilita a validação da topologia assumida.

Aprendizado supervisionado

Para que este tipo de aprendizado funcione, é preciso ter o conhecimento prévio de exemplos entrada-saída, conhecidos como “professor”. Tendo tal conhecimento dos dados, a rede deve ser treinada e, com o auxílio de um instrutor, é verificado o quanto ela está próxima de uma solução aceitável, podendo-se ajustar os pesos entre os neurônios, de modo a encontrar uma diferença mínima entre as saídas desejadas. Os pesos terão os seus valores iniciais definidos aleatoriamente e serão atualizados por meio do algoritmo de aprendizagem, na próxima repetição.

Os pesos sinápticos são muito importantes e precisam ser dosados de maneira correta. Os valores atribuídos aos pesos dependem da complexidade do problema. Quando acontece de a rede ser pouco treinada, os valores designados aos pesos podem não ser suficientes para que a rede possa gerar uma saída estatisticamente aceitável, e então acontece o *underfitting*. Porém, quando acontece de a rede ser treinada excessivamente, pode acontecer o *overfitting*.

O treinamento é considerado completo quando a rede alcança certo nível de desempenho. Quando a aprendizagem não é mais necessária, os pesos são praticamente fixados para a aplicação. Em seguida, é importante averiguar o que a rede pode fazer com os dados que ainda não foram apresentados. Se o resultado de saída do sistema não for estatisticamente

satisfatório para esse novo conjunto de dados, chamado subconjunto de teste (anteriormente exemplificado), pressupõe-se que o treinamento ainda não foi o bastante.

Esse tipo de verificação serve para assegurar que a rede não apenas memorizou um conjunto de dados como também aprendeu padrões envolvidos na aplicação. É importante ressaltar que, às vezes, o problema não está na arquitetura da rede, e sim envolvido com a má qualidade dos dados usados para o treinamento.

Aprendizado não supervisionado

Diferentemente da aprendizagem supervisionada, a não supervisionada não é auxiliada por um professor, ou seja, não há exemplos da função a ser aprendida pela rede. Ela funciona da seguinte maneira: a rede se auto-organiza distinguindo padrões diferentes e similares, ou seja, é usado um esquema de exemplos de coisas semelhantes para que a rede responda de modo similar. Neste artigo, não serão discutidos os tipos de aprendizado não supervisionado, pois não foram de utilidade para o desenvolvimento do projeto.

O aprendizado Backpropagation

O aprendizado *backpropagation*, ou retropropagação, é um dos algoritmos de treinamento mais usados no mundo e é utilizado para treinar redes com multicamadas, ou seja, na topologia da RNA há uma ou mais camadas intermediárias, o que torna o treinamento mais complexo. A Figura 8 é uma ilustração básica desse algoritmo.

Por fazer parte do aprendizado supervisionado, para dar início ao treinamento, é preciso que já sejam conhecidos tanto os valores de entrada quanto os de saída da rede. Durante o treinamento, a rede opera em uma sequência de dois passos. Primeiro, um padrão é apresentado à camada de entrada da rede. A atividade resultante flui, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, a saída obtida é comparada à saída desejada, ou seja, comparada com o valor do “professor”. Se tal saída não estiver correta, o erro é calculado e, então, retropropagado a partir da camada de saída até a camada de entrada, atualizando os pesos sinápticos. Entretanto, cada elemento da camada intermediária recebe apenas uma porção do sinal de erro total. A rede estará funcionando corretamente quando for encontrado o conjunto de pesos que irão satisfazer determinado problema. Na medida em que ocorre a retropropagação, os pesos sinápticos vão se atualizando de modo que o valor de saída convirja com o valor desejado.

O erro de cada peso é definido pela Equação 9 e o erro total, ou índice de desempenho, pela Equação 10.

$$e_k(n) = d_k(n) - y_k(n) \quad (9)$$

$$E(n) = \frac{1}{2} e_k^2(n) \quad (10)$$

Em que:

e_k = sinal de erro;

d_k = resposta desejada;

y_k = sinal de saída;

E = índice de desempenho;

n = tempo de um processo iterativo envolvido no ajuste de pesos sinápticos;

k = neurônio.

MATLAB

O Matrix Laboratory (MATLAB) é um *software* interativo de fácil aprendizagem, no qual vetores e matrizes são a base das iterações. É muito importante que os elementos e as operações sejam bem entendidos pelo programa, para que se obtenha o melhor que o MATLAB pode oferecer. Além disso, versões mais novas do *software* dispõem, em sua biblioteca, de diversas ferramentas, chamadas “*toolboxes*”, para determinadas aplicações como: redes neurais, lógica fuzzy, processamento de sinais, entre outros. A linguagem permite, também, que o usuário consiga escrever sua própria biblioteca, incorporando novas funções ao programa.

Neural Network Toolbox

No caso deste artigo, a *toolbox* utilizada foi a interface gráfica Neural Network Toolbox (NNTool). Essa ferramenta tem a capacidade de projetar, treinar e visualizar as RNAs.

ESTUDO DE CASO

O problema tratado foi retirado do livro “Projeto de Poços de Petróleo”, de Rocha e Azevedo (2009, p. 191). A obra aborda um poço perfurado a uma LDA de 1.000 m de profundidade e tem como dados os valores do perfil sônico desde a profundidade de 1.200 até 4.500 m. A Tabela 1 é a representação de alguns valores fornecidos pelo livro e medidos em campo, e no Apêndice A é possível visualizar todos os dados usados no problema proposto, como, por exemplo: profundidade, densidade, sônico e gradiente de sobrecarga, além de cálculos complementares, como a tensão de sobrecarga (usada diretamente na determinação do gradiente de sobrecarga).

O objetivo do problema é determinar a curva de compactação normal e, por conseguinte, a estimativa do gradiente de pressão de poros. De acordo com a Equação 1, anteriormente descrita, foi calculado o gradiente de sobrecarga. A reta de compactação normal, também conhecida como *trend*, foi calculada a partir dos valores do perfil sônico fornecidos

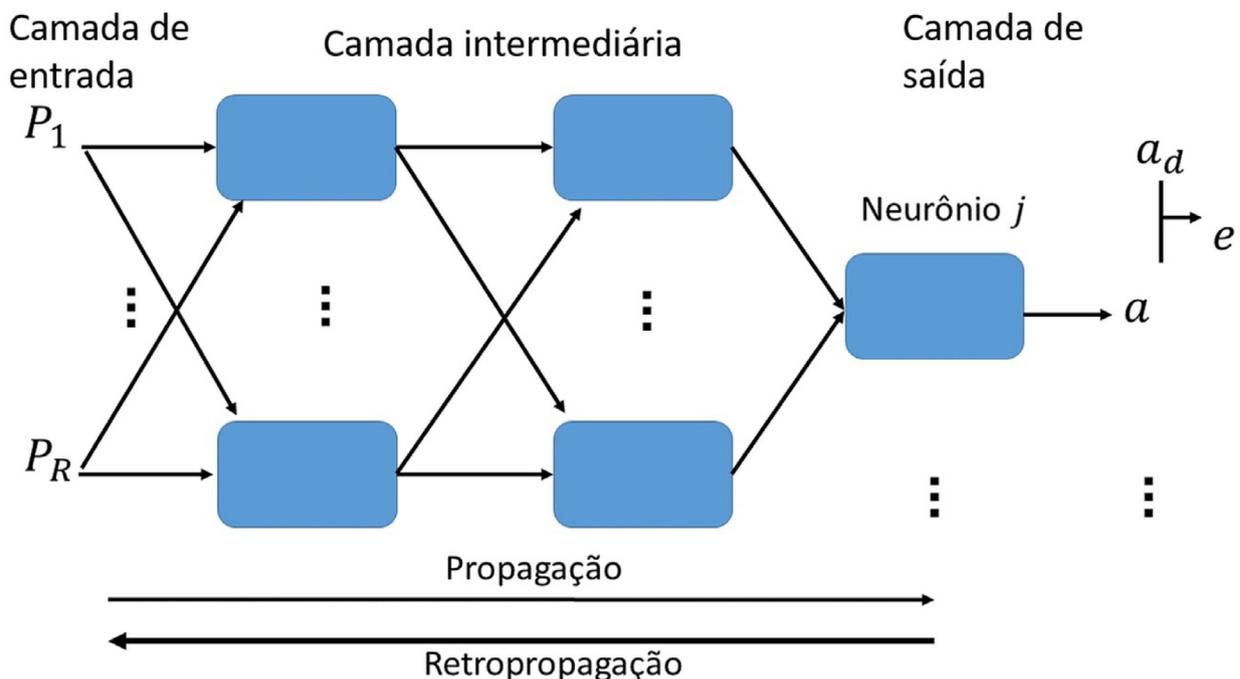


Figura 8. Representação do algoritmo *backpropagation*.

pelo problema. No Apêndice B é apresentada a curva calculada. Em seguida, foi usada a fórmula de Eaton, com base no sônico, para o cálculo do gradiente de pressão de poros.

Sabe-se que, para que haja boa estimativa da pressão de poros, é necessário um bom traçado da linha de tendência, mas, como visto, o traçado depende do ponto de vista do profissional que o analisa. Como a pressão de poros é muito importante para a indústria do petróleo, novas tecnologias estão sendo estudadas, a fim de encontrar um melhor método para estimá-la. No caso deste artigo, foi criada uma RNA que pudesse estimar tanto essa quanto outras pressões de poros a qualquer profundidade dentro de um mesmo campo petrolífero.

Os dados de entrada apresentados à rede neural criada foram: profundidade, densidade da formação, perfil sônico e gradiente de sobrecarga. É muito importante se lembrar de que, para que a mesma rede seja usada para problemas diferentes, novos dados devem ser apresentados a ela.

Na janela da interface gráfica “nntool” foram apresentadas as Matrizes 1 e 2, que nada mais são do que os dados de entrada (*inputs*) e os dados-alvo — valores calculados convencionalmente — (*target*), respectivamente.

$$\begin{pmatrix} 1200 & 1250 & 1300 & \dots & 4500 \\ 2,03 & 2,05 & 2,06 & \dots & 2,31 \\ 165 & 158 & 155 & \dots & 99 \\ 9,95 & 10,24 & 10,51 & \dots & 16,33 \end{pmatrix}_{4 \times 67} \quad (1)$$

$$(8,6 \quad 8,53 \quad 8,54 \quad \dots \quad 15)_{1 \times 67} \quad (2)$$

Na primeira matriz, as linhas representam os parâmetros de entrada, sendo eles: profundidade, densidade, perfil sônico e gradiente de sobrecarga, respectivamente. Já na segunda matriz, como o valor desejado é apenas o gradiente de pressão de poros, ela apresenta apenas uma linha. Vale destacar que há 67 registros em profundidade para os quatro

Tabela 1. Registo da profundidade (m) e do tempo de trânsito (μs/ft).

Profundidade (m)	Delta T (μs/ft)
1.200	165
1.250	158
1.300	155
1.350	148
1.400	149
1.450	145
1.500	142
1.550	141
1.600	149
1.650	140
1.700	138

Fonte: Adaptado de Rocha e Azevedo (2009).

parâmetros de entrada e para a saída desejada. É importante ressaltar, também, que, para que haja bom resultado no treinamento de uma RNA, é muito importante que exista boa qualidade e quantidade de dados para que a inteligência aprenda de maneira eficaz e precisa.

A rede foi criada com quatro camadas de entrada, uma intermediária e uma de saída. Foram feitos vários testes alterando apenas a quantidade de camadas e neurônios, e a rede que chegou à saída mais próxima da desejada foi a que continha uma camada intermediária, com 15 neurônios. A Figura 9 apresenta o modelo generalizado da RNA criada.

Como se sabe, uma das principais características das RNAs é a capacidade de aprendizado, então, tendo a rede arquitetada, a próxima etapa é o treinamento. Nesta, o programa roda de acordo com o algoritmo de aprendizagem predeterminado, no caso deste artigo, o *backpropagation*. O importante dessa etapa é verificar os gráficos de performance e desempenho, pois são eles que irão dizer ao programador o quão perto da resposta-alvo a resposta gerada pela rede criada e treinada está.

Quando o treinamento é encerrado, pode-se observar o gráfico de performance (Figura 10), que relaciona o treinamento, a validação e o teste, com o “*the best*”, ou seja, com o melhor resultado de validação, segundo a rede. No gráfico, no eixo das ordenadas, é apresentado o valor do erro e no eixo das abscissas, o valor da época, que nada mais é do a quantidade de vezes que o conjunto total de amostras passou pelo treinamento.

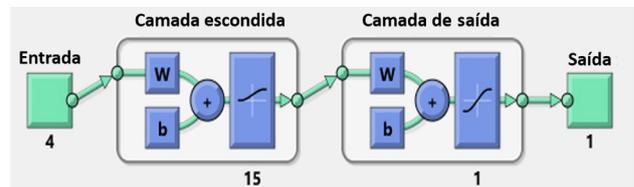


Figura 9. Modelo generalizado da rede neural do problema.

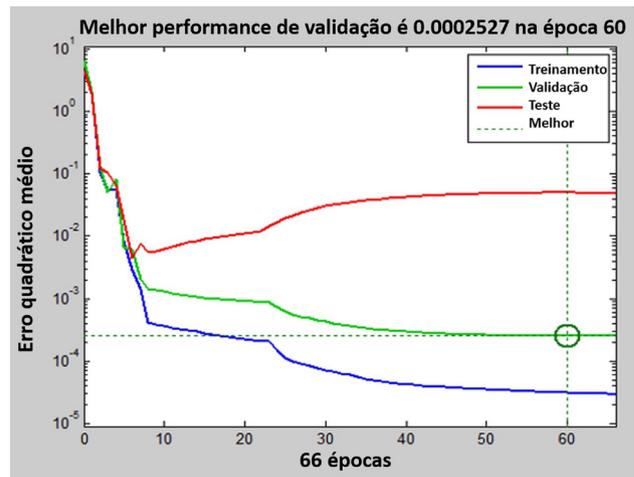


Figura 10. Gráfico de performance.

Como visto, o conjunto de dados para treinamento da rede é dividido em dois subconjuntos, sendo essa divisão feita pela própria interface gráfica, de forma aleatória. Ambos os subconjuntos podem ser visualizados na Figura 10, sendo a curva azul de treinamento e a curva vermelha de teste. Já a curva verde é um acréscimo do MATLAB e é chamada de validação. Esta, também conhecida como “validação cruzada”, demonstra ao programador se a rede neural está mantendo ou perdendo sua capacidade de generalização. A época, destacada na figura, remete àquela que teve a menor porcentagem de erro de toda a fase de treinamento. Nesse caso, os pesos sinápticos são memorizados para, em seguida, serem usados na próxima etapa do processo: inserir novos dados.

Além disso, a rede permite avaliar, separadamente, cada um dos itens descritos. Cada item é avaliado de acordo com um índice “R”, que varia de 0 a 1. Quanto mais próximo do valor unitário, melhor é o resultado. Se $R = 1$, pode-se dizer que há relação exata entre a saída e o alvo. Caso contrário, se “R” é próximo de zero, então não existe nenhuma relação linear entre o *output* e o *target*.

A Figura 11 representa o gráfico (gradiente de pressão de poros \times profundidade) após o treinamento feito, e pode-se observar que a aprendizagem foi quase perfeita e que as saídas geradas pela rede são compatíveis com a saída desejada. De acordo com os resultados apresentados, foi calculado o erro percentual entre o gradiente de pressão de poros gerado pela rede e o calculado convencionalmente. Numericamente falando, esse erro foi de apenas 0,2%.

Por fim, se a rede não obtiver resultado preciso, uma nova tentativa de treinamento pode ser feita, mas vale ressaltar que, a cada treinamento, os parâmetros da rede mudam e, com isso, pode ser que novas soluções sejam apresentadas. Uma segunda opção para tentar chegar a um valor aceitável é aumentar o número de neurônios da camada oculta, pois, assim, a rede terá mais flexibilidade. Uma última e terceira opção seria tentar outros tipos de funções de treinamento ou tentar usar dados adicionais, que poderão deixar a rede mais propensa a produzir novos dados.

Após criada e bem treinada, a RNA já tem a capacidade de apresentar ao programador dados de um diferente problema, com isso, a próxima e última etapa é inserir novos dados nessa RNA. O Apêndice C apresenta os novos dados de entrada da rede, mantendo os quatro parâmetros de entrada, sendo eles: profundidade, densidade, sônico e gradiente de sobrecarga. A ideia principal é fazer com que a RNA forneça um novo dado de saída, que, neste caso, é o gradiente de pressão de poros. Vale ressaltar que, caso esses “novos dados de entrada” tenham outros parâmetros, a rede deve ser retreinada de acordo com esses novos dados históricos, sem precisar mudar sua arquitetura.

Para isso, na janela de comandos, declaram-se os novos *inputs*, ou seja, novas matrizes com os dados de entrada de um diferente poço. Em seguida, ainda na janela de comandos, digita-se a Equação 11, que relaciona a rede treinada com esses novos dados. Os valores de y serão os novos dados de saída calculados pela RNA.

$$y = \text{network}(x) \quad (11)$$

Em que:

x = novos dados de entrada;

y = novos dados de saída;

network = rede neural criada e treinada.

Com os dados gerados, foram calculados, de maneira convencional, os valores do gradiente de pressão de poros, para que pudessem ser comparados aos valores que a RNA gerou. É importante destacar que não há a necessidade de calcular o gradiente de pressão de poros de maneira convencional — usando Eaton — para calcular os novos valores da RNA. Isso se faz somente para treinar a rede, e não para inserir novos dados nela. Neste caso, os autores escolheram calculá-la com o intuito de comparação dos resultados, para que pudesse ser gerado o erro percentual médio entre os valores que foram apresentados pela rede neural e

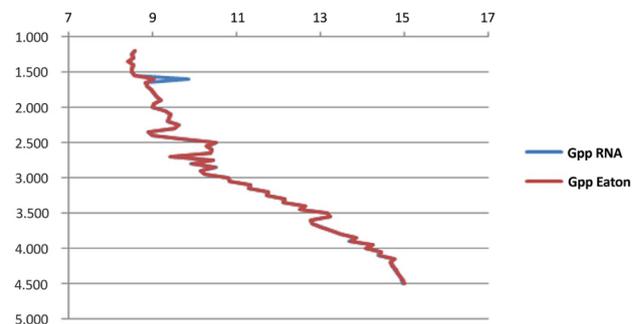


Figura 11. Comparação dos dados calculados e gerados pela RNA após a fase de treinamento.

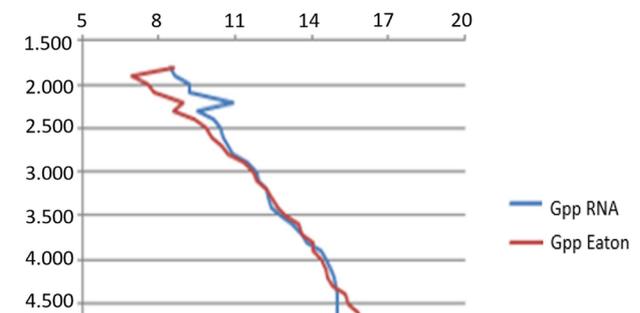


Figura 12. Comparação dos novos dados calculados e gerados pela RNA.

os calculados convencionalmente. Na Figura 12 é apresentado um gráfico comparativo desses valores.

Uma importante observação a ser feita é que a diferença entre os resultados obtidos na rede neural e os calculados, usando Eaton, se dá devido a dois possíveis motivos. O primeiro é referente ao traçado da curva de tendência. Como já foi dito, para calcular a pressão de poros convencionalmente, é necessário que seja traçada a linha de tendência, e que tal curva é dependente da experiência de quem a traça, pois, caso contrário, poderia gerar erros significativos. O outro possível motivo se dá pelo fato de existir um erro, por menor que seja, na fase de treinamento da rede. Somados tais desvios, o valor do erro percentual calculado no último caso, da Figura 12, foi de apenas 5%.

Com isso, pode-se dizer que o assunto discutido ao longo deste artigo foi de grande valia. Estudar e implementar uma RNA para problemas cotidianos pode poupar tanto tempo quanto dinheiro, trazendo maior produtividade e lucro para a indústria do petróleo.

CONCLUSÕES

Com as crescentes pesquisas e possibilidades de perfuração em poços cada vez mais profundos, o estudo das geopressões se tornou muito importante, a fim de evitar perdas materiais, ecológicas e financeiras.

Como visto, a pressão de poros tem papel fundamental na perfuração e, por isso, foi tão importante estudá-la e dar enfoque nos métodos que a estimam. A metodologia mais utilizada atualmente é a de Eaton, mas pode-se observar que sua estimativa depende de como o analista irá desenhar a curva de compactação normal. Por ser muito importante para a indústria do petróleo, a estimativa da pressão de poros não deveria ser feita com base na análise de um profissional, e sim a partir de métodos mais sofisticados.

No artigo, foi apresentada a ideia de usar uma RNA para estimar o gradiente de pressão de poros. O uso de uma RNA bem elaborada e treinada pode acabar com problemas relacionados às elevadas pressões das formações rochosas, além de possibilitar uma boa estimativa da pressão de poros a qualquer profundidade. Como foi apresentado no estudo de caso, a RNA, depois de pronta, pode solucionar diversos problemas. O fato de ela ter capacidade de generalização permite resolvê-los de maneira rápida, o que pouparia tempo e dinheiro.

No estudo de caso, a rede neural criada apresentou bons resultados, tanto no treinamento quanto na geração dos novos dados de saída. No primeiro caso, o erro apresentado foi de apenas 0,2%, o que representa que o treinamento da RNA deu certo e que a rede conseguiu encontrar o menor erro possível entre a saída desejada e a saída gerada. Já no segundo caso, o erro apresentado, ao inserir novos dados à

rede, foi de 5%. Pode-se dizer que foi relativamente baixo devido à baixa quantidade de dados processados pela RNA. Como se sabe, ela funciona muito bem, quando se tem bastantes dados de entrada-saída para treiná-la. A carência desses dados fez com que o erro parecesse alto, quando comparado ao de treinamento. A diferença nos resultados, ilustrada das Figuras 11 e 12, se dá por uma sequência de desvios, desde a construção da linha de tendência até o erro de treinamento da rede. Apresentando tais resultados, pode-se concluir que o valor de apenas 5% foi aceitável devido à baixa complexidade do problema e à baixa quantidade de dados fornecidos.

A vantagem de usar as RNAs para esse tipo de problema é que ela sempre acompanha o avanço da tecnologia, ou seja, ela nunca se tornará obsoleta. Além disso, a rede neural estará sempre disposta a aprender, na medida em que novos dados forem surgindo. Estudos comprovaram que, tendo a RNA bem arquitetada, ela poderia resolver um problema que levaria meses em apenas alguns dias.

Por esses motivos, conclui-se que, no caso deste artigo, a RNA foi fundamental para resolver o problema proposto de maneira mais rápida e objetiva. Pode-se dizer que, em um futuro próximo, a inteligência artificial estará em alta no mercado e, como na indústria do petróleo tempo é dinheiro, aplicá-la trará muitos benefícios econômicos tanto para a indústria quanto para o país.

Para um futuro artigo, a próxima ideia é criar uma RNA que consiga estimar dados geológicos em tempo real durante a perfuração de um poço de petróleo.

REFERÊNCIAS

- Aadnoy, B., Looyeh, R. (2014). *Mecânica de rochas aplicada*. Rio de Janeiro: Elsevier.
- Cai, Z., Zhang, H., Li, J., Zheng, J., Yu, Q., Liu, K., Liu, Y. (2018). New Technology to assist drilling to improve drilling rate in unconventional gas resources: pulsed arc plasma shockwave technology. *Abu Dhabi International Petroleum Exhibition and Conference*. Abu Dhabi. <https://doi.org/10.2118/193279-MS>
- Domingues, F. C. P. (2016). *Aplicação de um projeto de perfuração para um poço marítimo*. Trabalho de Conclusão de Curso. Niterói: Departamento de Engenharia Química e de Petróleo – UFF. Disponível em: <https://app.uff.br/riuff/handle/1/1414>. Acesso em: 16 abr. 2021.
- Eaton, B. (1975). The equation for geopressure prediction from well logs. *SPE Journal* 5544. <https://doi.org/10.2118/5544-MS>
- Gardner, G. H. F., Gardner, L. W., Gregory, A. R. (1974). Formation velocity and density – the diagnostics basics for

- stratigraphic traps. *Geophysics*, 39(6), 770-780. <https://doi.org/10.1190/1.1440465>
- Haykin, S. (2001). *Redes neurais princípios e prática*. 2. ed. Porto Alegre: Bookman.
- Hottmann, C. E., Johnson, R. K. (1965). Estimation of formation pressures from log-derived shale properties. *Journal of Petroleum Technology*, 17(6), 717-722. <https://doi.org/10.2118/1110-PA>
- Laredo, J., Fontoura, S. A. B. (2007). Avanços na previsão de pressão de poros em folhelhos. *4º PDPETRO*. Campinas. Disponível em: www.portalabpg.org.br/PDPetro/4/resumos/4PDPETRO_2_2_0324-1.pdf. Acesso em: 16 abr. 2021.
- Oliveira, E. E., Fernandes, M. A., Ferreira, G. S. (2016). Uma reflexão sobre a importância da geomecânica para a Engenharia de Petróleo. *II Congresso Nacional de Engenharia de Petróleo, Gás Natural e Biocombustíveis*. Disponível em: <https://editorarealize.com.br/artigo/visualizar/27080>. Acesso em: 15 abr. 2021.
- Ribeiro, G. S. (2006). *Novas tecnologias em produção de petróleo*. Rio de Janeiro: Petrobras. Disponível em: http://www.fem.unicamp.br/~instmed/Franca_SBPC_2006.pdf. Acesso em: 7 mar. 2018.
- Rocha, L. A. S., Azevedo, C. T. (2009). *Projetos de Poços de Petróleo: Geopressões e Assentamento de Colunas de Revestimento*. 2ª ed. Rio de Janeiro: Interciência.
- Santos, J. P. L., Andrade, J. F., Oliveira, R. C., Almeida Neto, J. B., Santos, A. P. P. (2015). Avaliação da aplicação dos métodos indiretos de predição do gradiente de pressão de poros em projetos de poços da Bacia Sergipe-Alagoas. *Revista Eletrônica de Petróleo e Gás*, 3, 31-40.
- Scheid, C., Calçada, L. A., Meleiro, L. A. (2020). *Desenvolvimento de novas tecnologias para aplicação na perfuração de poços de petróleo*.
- Silva, I. N., Spatti, D. H., Flauzino, R. A. (2010). *Redes neurais artificiais para Engenharia e Ciências Aplicadas* (2 ed.). São Paulo: Artliber.
- Silva, M. L. O., Leitão, S. R., Barros, N. S. (2015). Análise de redes neurais em variáveis de perfilagem, Sergipe. *VII Simpósio de Engenharia de Produção de Sergipe*. São Cristóvão: UFS. Disponível em: <https://ri.ufs.br/jspui/handle/riufs/7800>. Acesso em: 16 abr. 2021.
- Souza, L. Z. (2011). *Estudo do estado da arte da perfuração direcional de poços de petróleo*. Trabalho de Conclusão de Curso. Vitória: Departamento de Engenharia Mecânica – UFES.
- Teixeira, W., Toledo M. C. M., Fairchild T. R., Taioti F. (2000). *Decifrando a Terra*. São Paulo: Oficina de Textos.
- Vasconcelos, R. R. (2014). *Ajuste de parâmetros de correlações de densidade e tensão efetiva para estimativa do gradiente de pressão de poros*. Trabalho de Conclusão de Curso. Niterói: Departamento de Engenharia Química e de Petróleo – UFF. Disponível em: <https://app.uff.br/riuff/bitstream/1/2167/1/Raiza%20Vasconcelos.pdf>. Acesso em: 16 abr. 2021.

Apêndice A. Dados completos do estudo de caso (dados para treinamento da rede neural criada).

Neste apêndice é possível observar dados relevantes para os cálculos do gradiente de sobrecarga, bem como os dados usados para treinar a rede neural criada. Vale ressaltar que os dados de entrada da rede são apenas: profundidade, densidade, sônico e gradiente de sobrecarga, respectivamente.

	Profundidade abaixo mudline	Delt D	Profundidade Total	Delta T	Densidade	Densidade x Delta D x 1,422	Tensão de Sobrecarga	Gradiente de Sobrecarga
	(m)	(m)	(m)	(μ s/ft)	(g/cm ³)	(psi)	(psi)	(lb/gal)
LDA	0	1.000	1.000	200	1,025	1.457,55	1.457,55	
	200	200	1.200	165	2,06	587,18	2.044,73	10,00
g (m/s ²)	250	50	1.250	158	2,09	148,40	2.193,13	10,30
9,81	300	50	1.300	155	2,10	149,11	2.342,24	10,57
	350	50	1.350	148	2,12	150,84	2.493,08	10,84
	400	50	1.400	149	2,12	150,59	2.643,67	11,08
	450	50	1.450	145	2,13	151,62	2.795,28	11,31
	500	50	1.500	142	2,14	152,41	2.947,69	11,53
	550	50	1.550	141	2,15	152,68	3.100,37	11,74
	600	50	1.600	149	2,12	150,59	3.250,96	11,92
	650	50	1.650	140	2,15	152,95	3.403,91	12,11
	700	50	1.700	138	2,16	153,50	3.557,41	12,28
	750	50	1.750	137	2,16	153,78	3.711,20	12,45
	800	50	1.800	135	2,17	154,35	3.865,54	12,60
	850	50	1.850	133	2,18	154,93	4.020,47	12,75
	900	50	1.900	132	2,18	155,22	4.175,69	12,90
	950	50	1.950	126	2,21	157,03	4.332,72	13,04
	1.000	50	2.000	123	2,22	157,98	4.490,70	13,18
	1.050	50	2.050	125	2,21	157,35	4.648,05	13,31
	1.100	50	2.100	124	2,22	157,66	4.805,71	13,43
	1.150	50	2.150	121	2,23	158,63	4.964,34	13,55
	1.200	50	2.200	118	2,25	159,63	5.123,97	13,67
	1.250	50	2.250	119	2,24	159,29	5.283,27	13,78
	1.300	50	2.300	115	2,26	160,66	5.443,93	13,89
	1.350	50	2.350	105	2,31	164,36	5.608,29	14,01
	1.400	50	2.400	104	2,32	164,75	5.773,04	14,12
	1.450	50	2.450	110	2,28	162,46	5.935,49	14,22
	1.500	50	2.500	119	2,24	159,29	6.094,79	14,31
	1.550	50	2.550	113	2,27	161,37	6.256,16	14,40
	1.600	50	2.600	112	2,27	161,73	6.417,88	14,49
	1.650	50	2.650	109	2,29	162,83	6.580,71	14,57
	1.700	50	2.700	96	2,36	168,08	6.748,79	14,67
	1.750	50	2.750	105	2,31	164,36	6.913,15	14,75
	1.800	50	2.800	97	2,36	167,65	7.080,79	14,84
	1.850	50	2.850	101	2,33	165,96	7.246,75	14,92
	1.900	50	2.900	95	2,37	168,52	7.415,27	15,01
	1.950	50	2.950	94	2,38	168,97	7.584,24	15,09
	2.000	50	3.000	98	2,35	167,22	7.751,46	15,16
	2.050	50	3.050	96	2,36	168,08	7.919,54	15,24
	2.100	50	3.100	100	2,34	166,37	8.085,91	15,31
	2.150	50	3.150	97	2,36	167,65	8.253,56	15,38
	2.200	50	3.200	101	2,33	165,96	8.419,52	15,44
	2.250	50	3.250	98	2,35	167,22	8.586,74	15,51
	2.300	50	3.300	102	2,33	165,55	8.752,29	15,56

Continua.

Apêndice A. Continuação.

Profundidade abaixo mudline	Delt D	Profundidade Total	Delta T	Densidade	Densidade x Delta D x 1,422	Tensão de Sobrecarga	Gradiente de Sobrecarga
(m)	(m)	(m)	(μ s/ft)	(g/cm ³)	(psi)	(psi)	(lb/gal)
2.350	50	3.350	99	2,35	166,79	8.919,08	15,62
2.400	50	3.400	105	2,31	164,36	9.083,44	15,68
2.450	50	3.450	100	2,34	166,37	9.249,81	15,73
2.500	50	3.500	110	2,28	162,46	9.412,27	15,78
2.550	50	3.550	109	2,29	162,83	9.575,10	15,83
2.600	50	3.600	97	2,36	167,65	9.742,74	15,88
2.650	50	3.650	95	2,37	168,52	9.911,26	15,94
2.700	50	3.700	96	2,36	168,08	10.079,34	15,99
2.750	50	3.750	98	2,35	167,22	10.246,56	16,04
2.800	50	3.800	100	2,34	166,37	10.412,93	16,08
2.850	50	3.850	105	2,31	164,36	10.577,29	16,12
2.900	50	3.900	99	2,35	166,79	10.744,08	16,17
2.950	50	3.950	110	2,28	162,46	10.906,54	16,20
3.000	50	4.000	102	2,33	165,55	11.072,09	16,24
3.050	50	4.050	110	2,28	162,46	11.234,55	16,28
3.100	50	4.100	105	2,31	164,36	11.398,91	16,32
3.150	50	4.150	115	2,26	160,66	11.559,57	16,35
3.200	50	4.200	108	2,30	163,20	11.722,77	16,38
3.250	50	4.250	106	2,31	163,97	11.886,74	16,41
3.300	50	4.300	105	2,31	164,36	12.051,10	16,45
3.350	50	4.350	103	2,32	165,15	12.216,25	16,48
3.400	50	4.400	102	2,33	165,55	12.381,80	16,51
3.450	50	4.450	101	2,33	165,96	12.547,76	16,55
3.500	50	4.500	99	2,35	166,79	12.714,55	16,58

Apêndice C. Dados completos do estudo de caso (novos dados da rede neural criada e treinada).

Neste apêndice é possível observar, também os dados relevantes para o cálculo do gradiente de sobrecarga, bem como os novos dados inseridos na rede neural criada e treinada. Vale ressaltar que os dados de entrada da rede são apenas: profundidade, densidade, sônico e gradiente de sobrecarga, respectivamente.

	Profundidade	Delta D	Sônico	Densidade	Densidade x Dd x 1,422	Tensão de Sobrecarga	Gradiente de Sobrecarga
	(m)	(m)	(μ s/ft)	(g/cm ³)	(psi)	(psi)	(lb/gal)
Air Gap	14	14	-	0	0	0	0
LDA	1.285	1.271	-	1,03	1.862	1.862	8,50
Trecho Superficial	1.800	515	118,3035	1,95	1.428	3.290	10,73
	1.900	100	137,34	2,16	307	3.597	11,11
	2.000	100	139,96	2,15	306	3.903	11,45
	2.100	100	134,21	2,17	309	4.212	11,77
	2.200	100	144,99	2,13	303	4.515	12,04
	2.300	100	126,12	2,21	314	4.829	12,32
	2.400	100	129,68	2,19	312	5.141	12,57
	2.500	100	126,89	2,20	314	5.455	12,80
	2.600	100	119,72	2,24	318	5.773	13,03
	2.700	100	115,45	2,26	321	6.094	13,24
	2.800	100	109,2	2,29	326	6.419	13,45
	2.900	100	111,67	2,28	324	6.743	13,65
	3.000	100	109,6	2,29	325	7.068	13,83
	3.100	100	99,85	2,34	333	7.401	14,01
	3.200	100	98,92	2,35	334	7.735	14,18
	3.300	100	92,41	2,39	339	8.074	14,36
	3.400	100	87,2	2,42	344	8.418	14,53
	3.500	100	84,97	2,44	347	8.765	14,70
	3.600	100	88,71	2,41	343	9.108	14,85
	3.700	100	81,12	2,47	351	9.458	15,00
	3.800	100	84,57	2,44	347	9.805	15,14
	3.900	100	74,55	2,52	358	10.164	15,29
	4.000	100	74,15	2,52	359	10.522	15,44
	4.100	100	70,47	2,55	363	10.885	15,58
	4.200	100	63,17	2,62	373	11.259	15,73
	4.300	100	59,56	2,66	379	11.637	15,88
	4.400	100	68,55	2,57	366	12.003	16,01
	4.500	100	64,58	2,61	371	12.374	16,14