



## USO DE REDES NEURAIIS PARA A PREVISIBILIDADE DE PARÂMETROS DE PERFURAÇÃO DE POÇOS DE PETRÓLEO

Tháísa Loureiro Pixinine

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Mecânica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Mecânica.

Orientadores: Thiago Gamboa Ritto

Fernando Augusto de Noronha  
Castro Pinto

Rio de Janeiro  
Outubro de 2019

USO DE REDES NEURAS PARA A PREVISIBILIDADE DE PARÂMETROS DE  
PERFURAÇÃO DE POÇOS DE PETRÓLEO

Tháisa Loureiro Pixinine

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO  
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA  
(COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE  
DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE  
EM CIÊNCIAS EM ENGENHARIA MECÂNICA.

Examinada por:

---

Prof. Thiago Gamboa Ritto, D.Sc

---

Prof. Fernando Augusto de Noronha Castro Pinto, Dr.-Ing

---

Prof. José Márcio do Amaral Vasconcellos , D.Sc

---

Prof. Virgilio Jose Martins Ferreira Filho, D.Sc

RIO DE JANEIRO, RJ - BRASIL  
OUTUBRO DE 2019

Pixinine, Thaísa Loureiro

Uso de redes neurais para a previsibilidade de parâmetros de perfuração de poços de petróleo/  
Thaísa Loureiro Pixinine. – Rio de Janeiro:  
UFRJ/COPPE, 2019.

X, 58 p.: il.; 29,7 cm.

Orientadores: Thiago Gamboa Ritto

Fernando Augusto de Noronha  
Castro Pinto

Dissertação (mestrado) – UFRJ/ COPPE/  
Programa de Engenharia Mecânica, 2019.

Referências Bibliográficas: p. 50-53.

1. Redes Neurais. 2. Previsibilidade. 3.  
Parâmetros de Perfuração. I. Ritto, Thiago Gamboa  
*et al.* II. Universidade Federal do Rio de Janeiro,  
COPPE, Programa de Engenharia Mecânica. III.  
Título.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

## USO DE REDES NEURAIIS PARA A PREVISIBILIDADE DE PARÂMETROS DE PERFURAÇÃO DE POÇOS DE PETRÓLEO

Tháisa Loureiro Pixinine

Outubro/2019

Orientadores: Thiago Gamboa Ritto

Fernando Augusto de Noronha Castro Pinto

Programa: Engenharia Mecânica

Este trabalho desenvolve o uso de sistemas inteligentes com o objetivo de alcançar o mínimo custo financeiro por metro perfurado no menor tempo, através de previsibilidades de parâmetros, essa seleção atualmente é realizada através da análise de poços semelhantes já realizados e na própria experiência do engenheiro de perfuração responsável, existindo poucos artifícios tecnológicos para essa previsão. A utilização de métodos analíticos geralmente é uma tarefa árdua devido à complexidade do problema. Nesta dissertação será apresentado um método de transcrever o conhecimento tácito para a lógica computacional através de redes neurais com o objetivo de prever da forma mais assertiva um dos principais parâmetros de perfuração que no caso é a taxa de perfuração de brocas.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

USE OF NEURAL NETWORKS FOR THE PREVISIBILITY OF PETROLEUM  
WELL DRILLING PARAMETERS

Tháisa Loureiro Pixinine

October/2019

Advisors: Thiago Gamboa Ritto

Fernando Augusto de Noronha Castro Pinto

Department: Mechanical Engineering

This work develops the use of intelligent systems with the objective of achieving the minimum financial cost per meter drilled in the shortest time, through parameter predictions, this selection is currently performed through the analysis of similar wells already made and in the experience of the engineer of responsible drilling, there are few technical devices for this forecast. The use of analytical methods is usually an arduous task due to the complexity of the problem. This dissertation will present a method of transcribing tacit knowledge for computational logic through neural networks in order to predict in a more assertive way one of the main drilling parameters, which in this case is the drilling rate of drills.

# Índice

Nomenclatura.....	x
1. Introdução.....	11
1.1 O Petróleo no mundo e no Brasil.....	11
1.2 Objetivo.....	11
1.3 Estrutura do texto.....	12
2 Perfuração de Poços de Petróleo.....	13
2.1 Fundamentos.....	13
2.1.1 Sistema de Rotação.....	14
2.1.2 Sistema de circulação.....	15
2.1.3 Sistema de Monitoramento.....	16
2.2 Parâmetros de Perfuração.....	18
2.2.1 Taxa de Perfuração (ROP).....	18
2.3 Broca.....	19
2.3.1 Brocas sem partes móveis.....	20
2.3.2 Brocas com partes móveis.....	22
2.4 Programa de Brocas.....	23
2.5 Estado da Arte.....	24
2.5.1 Modelos matemáticos para prever a taxa de perfuração (ROP).....	25
2.5.2 Modelos computacionais para otimização de parâmetros de perfuração.....	27
3 Aprendizagem de máquina.....	29
3.1 Data Science e Inteligência Artificial.....	29
3.2 Redes Neurais.....	30
3.2.1 Histórico.....	30
3.2.2 Neurônio Artificial.....	32
3.2.3 Funções de Ativação.....	33
3.2.4 Arquitetura.....	34
3.2.5 Formas de aprendizado – Treinamento.....	36
3.2.6 Modelagem de uma RNA.....	38
3.2.7 Tratamento dos padrões de entrada para as RNA.....	38
3.2.8 Número de neurônios.....	39
3.2.9 Validação cruzada e generalização e testes do modelo.....	40
3.2.10 Desempenho de uma RNA.....	41
4 Metodologia.....	42
4.1 Conjunto dos dados.....	42
4.1.1 Tratamento dos dados.....	43
4.2 Linguagem Utilizada.....	44

4.3 Topologias de redes testadas.....	45
4.4 Erros de Previsões.....	45
4.4.1 Erros de Previsão.....	46
4.4.2 Erro percentual.....	46
4.4.3 Erro médio percentual absoluto.....	46
5 Resultados.....	47
5.1 Treinamento realizado.....	47
5.2 Escolha do modelo - Verificação dos resultados.....	47
5.3 Comparando com a Base de treinamento.....	52
5.4 Poços novos.....	54
5.5 Sensibilidade da rede.....	56
6 Conclusões.....	59
Bibliografia.....	60
Anexo A.....	64

## Índice de figuras

Figura 1: Modelo da estrutura em poços de petróleo.....	13
Figura 2: Sistema de Rotação da sonda.....	14
Figura 3: Sistema de circulação da sonda.....	16
Figura 4: Tipos de brocas.....	20
Figura 5: Ângulos de ataque - Broca PDC.....	21
Figura 6: Forma de corte - Broca PDC.....	21
Figura 7: Forma de corte - Broca Impregnada.....	22
Figura 8: Forma de corte - Broca Tricônica.....	22
Figura 9: Tipos de dentes - Brocas Tricônicas.....	23
Figura 10: Instâncias Data Science.....	30
Figura 11: Esquemático da direção de propagação de sinais durante o processamento de informações.....	31
Figura 12: Organização existente entre os neurônios naturais.....	31
Figura 13: Representação de um neurônio artificial.....	33
Figura 14: Formato das principais funções de ativação.....	34
Figura 15: Representação gráfica de uma topologia de rede neural.....	34
Figura 16: Rede Feed Forward.....	35
Figura 17: Rede parcialmente recorrente (Rede de Elman).....	36
Figura 18: Rede totalmente recorrente (Rede de Hopfield).....	36
Figura 19: Aprendizagem Supervisionada.....	37
Figura 20: Ilustração do treinamento de uma RNA.....	38
Figura 21: Relação entre o erro de treinamento e o erro de validação em uma RNA do tipo MLP com treinamento por Backpropagation.....	40
Figura 22: Método da parada antecipada com conjunto de validação.....	41
Figura 23: Tratamento dos dados.....	44
Figura 24: Simulações - Poço 1 (broca impregnada).....	49
Figura 25: Simulações Modelo 5 - Poço 1 (broca impregnada).....	50
Figura 26: Simulações - Poço 2 (broca PDC).....	50
Figura 27: Simulações Modelo 5 - Poço 2 (broca PDC).....	51
Figura 28: Simulações - Poço 3 (broca impregnada e PDC).....	51
Figura 29: Simulações Modelo 5 - Poço 3 (broca impregnada e PDC).....	52
Figura 30: Comparação com a base de treinamento - Poço 1 (broca impregnada).....	53
Figura 31: Comparação com a base de treinamento - Poço 2 (broca PDC).....	53
Figura 32: Comparação com a base de treinamento - Poço 3 (broca impregnada e PDC).....	54
Figura 33: Simulação de confiabilidade - Poço 4.....	55
Figura 34: Simulação de confiabilidade - Poço 5.....	55
Figura 35: Sensibilidade do modelo: 6 e 12 poços.....	57
Figura 36: Sensibilidade do modelo: 18 e 18* poços.....	57

## Índice de tabelas

Tabela 1: Características das brocas sem partes móveis.....	20
Tabela 2: Características das brocas com partes móveis.....	22
Tabela 3: Parâmetros analisados.....	43
Tabela 4: Topologias testadas.....	45
Tabela 5: Valores calculados dos erros (Poço 1 - Impregnada).....	48



Tabela 6: Valores calculados dos erros (Poço 2 - PDC).....	48
Tabela 7: Valores calculados dos erros (Poço 3 – Misto).....	48
Tabela 8: Desvios padrão por modelo.....	48
Tabela 9: Erro Percentual dos poços novos.....	56
Tabela 10: Erro percentual variando o treinamento.....	57

# Nomenclatura

BHA - Bottom Hole Assembly

Cm – Custo Métrico

Cb – Custo da broca

Ch - Custo da sonda

IA – Inteligência Artificial

IADC - International Association of Drilling Contractors

Mp – Intervalo perfurado

N - Rotação na coluna

PDC - Polycrystalline Diamond Compact

PSB - Peso sobre broca, expresso em lb/ pol<sup>2</sup>

Q - Vazão

ROP - Taxa de perfuração, expressa comprimento por tempo

RPM - Rotação Por Minuto

SMAPE - Symmetric Mean Absolute Percentage Error

TBF - Tempo de Broca no Fundo, expresso em horas

tm – Tempo gasto manobrando

tp – Tempo gasto perfurando

# 1. Introdução

## 1.1 O Petróleo no mundo e no Brasil

A indústria petrolífera é uma das mais importantes do mundo, sendo possivelmente, a de maior consumo da atualidade em inúmeros setores da economia global. Todas as sociedades modernas apresentam dependência do petróleo, seja para gerar energia, alimentar e energizar máquinas ou promover a locomoção de pessoas e materiais ao redor do planeta.

Os números do mercado petrolífero em todo o planeta são impressionantes. Segundo *USA Energy Information Administration*, no ano de 2018 foram produzidos no mundo aproximadamente 98 milhões de barris de petróleo por dia, cerca de 15,6 bilhões de litros de petróleo por dia. Multiplicando a cotação atual, próxima aos US\$ 75 o barril, foram movimentados US\$ 2,7 trilhões, na economia mundial, em todo o ano de 2018, apenas considerando a produção de petróleo. (Nexus Journal,2019)

Estes números impressionantes e que continuam em expansão são possíveis graças aos processos modernos de extração de petróleo.

No Brasil, a principal forma de extração de petróleo é *offshore*, aproximadamente 78% da produção brasileira estão no mar e dessa porcentagem 48% correspondem a águas ultraprofundas segundo dados da Petrobras, empresa participante em 90% da produção nacional de petróleo, segundo dados da Empresa de pesquisa energética (EPE) governamental.

Os gastos envolvidos na extração e produção no mar são superiores aos envolvidos na perfuração na terra. A relação corresponde a 5/8 do custo total, segundo a Agência reguladora de petróleo no Brasil, e esses gastos aumentam quando aplicado em águas ultraprofundas (Lâmina de água > 1501 m) que exigem tecnologias mais avançadas para serem viabilizadas, por exemplo no caso do pré-sal brasileiro. Sondas de perfuração com capacidade para operar em lâminas d'água da ordem de 2.000 m tem custos diários superiores a US\$ 500.000,00.

Tendo em vista todo esse histórico de valores envolvidos na indústria uma redução de custos atrelados as melhorias no processo atendem a uma necessidade latente do seguimento. A previsão da taxa de perfuração (ROP) reduziria os custos da perfuração, pois viabilizaria uma perfuração mais controlada, reduzindo imprevistos que comprometam o tempo de execução do projeto.

## 1.2 Objetivo

O objetivo dessa dissertação é prever o valor do ROP esperado para a perfuração de determinado poço. E para isso é utilizado o histórico de poços perfurados em determinada região para treinar uma rede neural e obter como resposta o comportamento do ROP. Sempre em função dos parâmetros de perfuração que são utilizados no projeto.

Essa previsão também possibilita a escolha de forma mais eficaz dos parâmetros que serão utilizados durante a perfuração, permitindo a utilização das brocas até o limite operacional do fabricante.

Utilizando os softwares aberto Python e Open Office, o estudo modela topologias para previsão de ROP.

A principal limitação do projeto será a área de aplicação da rede neural, uma vez que foram utilizados dados com características similares para treinar e validar a rede.

Os dados apresentam semelhanças na Litologia (formação rochosa), configuração do poço, número de fases perfuradas e tipo de fluido do reservatório perfurado.

O desenvolvimento de um modelo de previsão de ROP está bastante sujeito a alteração do cenário ao qual é aplicado, não é algo sistemático. Uma metodologia aplicada em um cenário de perfuração (geologia, tipo de broca, parâmetros de perfuração aplicados etc.), não necessariamente apresentará um bom resultado em outro por depender da semelhança entre as amostras que são inseridas na simulação.

### 1.3 Estrutura do texto

O texto da dissertação está dividido em seis capítulos com o objetivo de apresentar e discorrer sobre a aplicação de redes neurais na previsão de Taxas de Perfuração.

No capítulo um é realizada uma contextualização da importância do petróleo na indústria e a possibilidade na melhoria dos parâmetros de perfuração.

O capítulo dois apresenta um resumo de como se constrói um projeto de poço, de como as brocas são classificadas e como a indústria utiliza esse componente. Por último são abordados artigos que analisam a melhoria contínua no projeto de poço.

O capítulo três faz um levantamento das técnicas de aprendizagem de máquina, a fim de introduzir o método que será utilizado para realizar a previsão das taxas de perfuração.

No capítulo quatro encontram-se os dados que foram utilizados na simulação, com as topologias de redes propostas para serem testadas e bem como os erros serão calculados

No capítulo cinco os resultados são apresentados e é selecionado aquele modelo que apresenta menor erro em relação ao valor de referência. Além de um comparativo gráfico entre os valores previstos e realizados.

Por último no capítulo seis, discorre-se sobre as conclusões que são retiradas do estudo analítico realizado para a previsão das taxas de perfuração, fazendo um breve resumo de tudo tratado ao longo do texto.

## 2 Perfuração de Poços de Petróleo

### 2.1 Fundamentos

As atividades de exploração de petróleo são divididas em intervenções principais: Perfuração, avaliação exploratória, completação e *workover*. Não cabe ao escopo dessa dissertação entrar a fundo em nenhuma delas, porém visto a intenção da previsibilidade de taxa de perfuração, é apresentada rapidamente a intervenção de perfuração para mostrar a relevância da previsão da taxa de perfuração de determinada fase.

Os poços são classificados de várias maneiras: pela finalidade da perfuração: Pioneira, exploratória, para avaliação, desenvolvimento, injeção; pela profundidade: Raso (< 1500 m), médio (1500-2000m) ou profundo (>2500m); ou quanto ao percurso da perfuração: Vertical, direcional ou horizontal.(Triggia,2004)

As regiões geográficas onde ocorrem as perfurações são áreas analisadas previamente pela equipe de geologia, a qual levanta a chance de presença de óleo no local, uma vez confirmada essa suspeita um projeto de poço é desenvolvido visando alcançar da forma mais eficiente possível a profundidade de interesse.

Definido o escopo do projeto, junto as caracterizações das formações é necessário começar a mapear quais e quantas etapas terá o poço, essas etapas recebem o nome de fases, cada fase possui seu diâmetro e comprimento específico, definidos pelos objetivos do projeto. Inicia-se com um diâmetro maior e à medida que a perfuração vai se aprofundando o diâmetro vai sendo reduzido, até alcançar a profundidade de interesse, onde estimasse ter óleo ou gás. E para conseguir perfurar diâmetros variáveis é necessário utilizar brocas do tamanho específico do diâmetro de cada fase. (Triggia,2004)

A nomenclatura varia de acordo com sua função no projeto, na Figura 1 consegue-se ver um exemplo de projeto de perfuração.

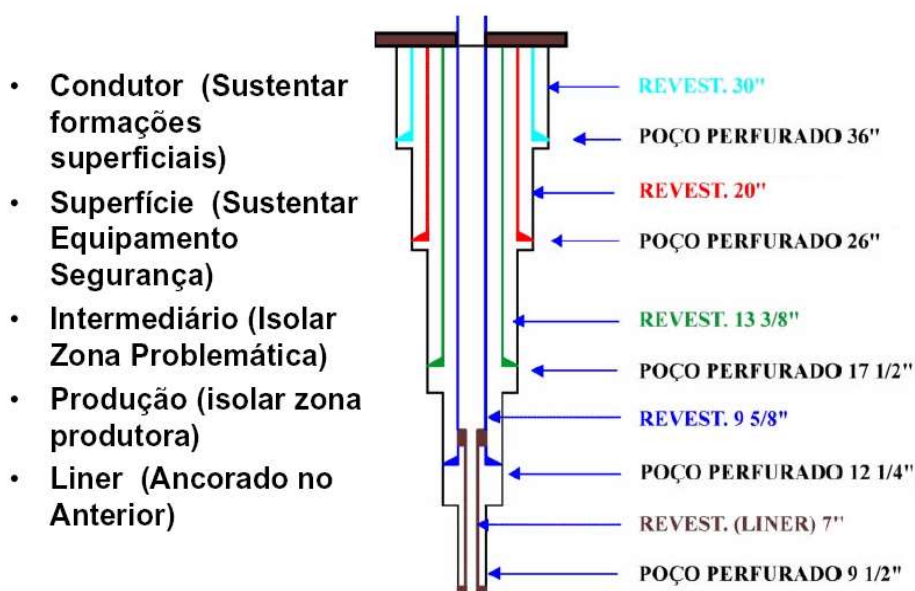


Figura 1: Modelo da estrutura em poços de petróleo

Fonte: UFBA,2011

Além de ser necessário o conhecimento de como é estruturada a perfuração de um poço, não menos importante é ter um entendimento básico de como ocorrem as operações.

Começando pelas sondas de perfuração, que podem ser marítimas: do tipo fixa ou flutuante, cuja escolha é baseada na capacidade da sonda em perfurar o poço; ou sondas de perfuração terrestres. Qualquer que seja o tipo de sonda ela possui diversos sistemas operacionais os quais, podem ou não, trabalhar de forma interligada. A seguir, são descritos alguns desses sistemas que atuam diretamente na perfuração de poços e que são relevantes para essa dissertação.

### 2.1.1 Sistema de Rotação

O sistema de rotação é o responsável por transmitir rotação à coluna de perfuração e a broca a partir da superfície. Há duas configurações básicas de equipamentos, mas a mais utilizada e mais antiga é a associação da coluna de transmissão de rotação (*kelly*) com a cabeça de injeção (*swivel*), e do *kelly* com a mesa rotativa por intermédio da bucha do *kelly*, vide Figura 2.




Figura 2: Sistema de Rotação da sonda

Fonte: Weebly,2017

O *kelly* é constituído por uma haste metálica de seção quadrada ou hexagonal conectada ao topo da coluna de perfuração e é o elemento de transmissão de rotação à mesma. A mesa rotativa é o equipamento que transmite rotação ao *kelly*, além de permitir seu livre deslizamento dado o aumento de profundidade do poço.

O *swivel*, por sua vez, é o elemento do sistema que permite a separação dos elementos rotativos daqueles estacionários na sonda, suportando ainda o peso da coluna de perfuração, além de ser por onde o fluido de perfuração é injetado para o interior da coluna.

Com o avanço tecnológico surgiu um acionador superior automático (*Top Drive*) equipamento de superfície que elimina a necessidade de um *kelly* e mesa rotativa, uma vez que tem em sua composição um motor conectando-o ao topo da coluna de perfuração. Por ser um equipamento mais robusto e composto por dois braços mecânicos, apresenta como vantagem permitir a realização muito mais rápida da operação de manobra – retirada ou descida da coluna de perfuração do poço.

Dessa forma, a perfuração com *Top Drive*, diminui o tempo de manobra para troca de uma broca, por exemplo, e o tempo das conexões de tubos, diminuindo o tempo operacional da perfuração, fatores que afetam diretamente no cálculo de custo por metro perfurado. Além disso, provê mais potência para girar a coluna que a mesa rotativa. (Triggia,2004)

### 2.1.2 Sistema de circulação

Os principais componentes de um sistema de circulação de uma sonda incluem: bombas de circulação; tanques de fluido de perfuração ou como também é conhecida lama de perfuração; equipamentos de mistura de compostos químicos, adicionados ao fluido para adequar suas propriedades reológicas; e equipamentos de separação responsáveis pela remoção de contaminantes.

O fluido de perfuração tem diversas funções durante a perfuração de um poço. Ele, quando com suas propriedades reológicas adequadas, densidade, por exemplo, confere pressão hidrostática ao poço evitando que haja influxo de fluidos da formação para dentro do poço, evento denominado *kick*, e quando o influxo é no sentido oposto, isto é de dentro para fora do poço, caracteriza-se perda de circulação.

O fluido deposita uma fina camada de reboco nas paredes do poço reforçando a proteção à perda ou ganho de fluido. Ele é responsável pelo carreamento de sedimentos e fragmentos de rocha gerados durante a perfuração, também lubrifica e refrigera a broca de perfuração. No contato da rocha com a broca gera atrito, conseqüentemente calor, o qual em excesso pode reduzir a vida útil de componentes do BHA (Conjunto de componentes localizados na extremidade inferior da coluna de perfuração, consistindo, geralmente, de broca, sub-broca, motor de perfuração - em certos casos, estabilizadores, sistema de navegação direcional, MWD, LWD, comandos de perfuração, tubos pesados de perfuração, percursos e subs de cruzamento).

Na extremidade da coluna de perfuração encontra-se a broca de perfuração, por onde o fluido sai através de seus jatos, os quais podem ter diferentes diâmetros, além de suas disposições espaciais apresentarem configurações variadas. O objetivo dos jatos das brocas é melhorar a ação de limpeza do fluido de perfuração no fundo do poço, a qual é maximizada a partir da determinação da força hidráulica de impacto dos jatos (JIF), vide Figura 3.




Figura 3: Sistema de circulação da sonda

Fonte: Autoria Própria

Quando a JIF é insuficiente, problemas como o encerramento de broca podem ocorrer acarretando na diminuição da ROP. Trata-se da adesão de cascalhos na broca, geralmente de formações pouco permeáveis ou impermeáveis, folhelhos, por exemplo, em razão da ausência parcial ou total de filtração do fluido de perfuração por esses cascalhos.

O fluido começa então a fase de retorno do circuito a partir do fluxo pelo espaço anular do poço – determinado pela diferença entre o diâmetro do poço e da coluna – carregando consigo os cascalhos e outras partículas sólidas geradas durante a perfuração, até chegar à superfície. Na superfície, o fluido é direcionado através da linha de retorno para tratamento em peneiras vibratórias e em outros equipamentos até chegar ao tanque de fluido passando pela linha de sucção e retornando à bomba.(Triggia,2004)

### 2.1.3 Sistema de Monitoramento

Para esta dissertação o sistema de monitoramento é mais importante, pois os dados analisados se originam do monitoramento do poço. Porém, todos os sistemas da sonda são dependentes.

O sistema de monitoramento de poços é constituído por equipamentos que fornecem informações dos parâmetros necessários ao controle das operações de perfuração em tempo real feito pela equipe da sonda (supervisores e engenheiros de perfuração, químicos, sondadores etc.) em conjunto com os representantes da companhia operadora e seus prestadores de serviço contratados.

Dentre os diversos parâmetros podemos citar: profundidade de poço vertical (TVD), profundidade medida de poço (MD), Peso sobre a broca (PSB), rotações na coluna (RPM), pressão de bombeio, vazão de fluido, vazão de retorno de fluido, torque, ROP, volume de tanques de lama, etc.

A transmissão dessas informações pode ser feita através de equipamentos de medição durante a perfuração (*Measurement While Drilling – MWD*), durante a



exploração (*Logging While Drilling - LWD*) ou durante a extração da lama (*mud logging*). Em geral, a depender do orçamento para a perfuração de um poço, as três fontes de informação são utilizadas, aumentando a segurança da operação com a maior aquisição de dados.

As ferramentas de M/LWD realizam leituras durante a descida da coluna de perfuração e também no fundo do poço, já o *mud logging* é o monitoramento de tais parâmetros em superfície.

Tradicionalmente essas leituras suportam três serviços principais:

- Avaliação geológica: tal avaliação se dá a partir das coletas de amostra de calha - partículas maiores de fragmentos de rocha - que chegam às peneiras através do sistema de circulação da sonda, sendo descritas a litologia e mineralogia pelo geólogo. A análise das amostras auxilia a inferência de propriedades petrofísicas, tais como a densidade, porosidade e permeabilidade da formação perfurada, além do tipo de litologia e das feições geológicas da rocha importantes para tomar as melhores decisões no que se refere a escolha de parâmetros de perfuração e integridade do poço;
- Suporte a engenharia de perfuração e operações (planejamento e execução de construção de poços);
- Manutenção de operações de perfuração e avaliação de acordo com as políticas de segurança, meio ambiente e saúde vigentes.

Dessa forma, tais serviços buscam identificar potenciais zonas produtoras de hidrocarbonetos, marcadores estratigráficos e correlações geológicas, além de prover à equipe de perfuração as informações para que seja realizado um trabalho de forma segura e otimizada. Para aquisição de dados de superfície, o profissional responsável pelo monitoramento instala sensores em diversas localidades do caminho da lama.

O sensor de torque funciona baseado na leitura de correntes elétricas, quanto maior o torque gerado pela rotação da coluna de perfuração maior será a corrente elétrica pelo cabo de energia do *Top Drive*. A leitura de torque pode estar relacionada à litologia e suas variações durante a perfuração, problemas durante a perfuração, por exemplo, restrições de diâmetro do poço para passagem de componentes do BHA, desgaste das estruturas cortantes das brocas de perfuração etc.

O sensor para leitura do número de rotações por minuto é colocado na coluna de perfuração através do sistema de rotação da sonda que é instalado no *Top Drive* e para casos de sondas que utilizam a mesa rotativa como provedor de giro na coluna o sensor é colocado no *Kelly*.

O sensor de peso, que registra o parâmetro de peso sobre a broca, é instalado em uma âncora que sustenta o cabo de perfuração no sistema de movimentação de carga da sonda.

Para segurança da operação, monitoram-se os volumes de entrada e saída de fluido do poço, analisa-se o fluido de perfuração que retorna à superfície, sob a ótica das propriedades das partículas carregadas pelo fluido, presença de óleo e/ou gás, coletadas na sonda e coleta amostras de calha também.

São instalados sensores nas bombas de lama para contagem dos bombeios e da leitura de vazão, permitindo verificar se a vazão de bombeio na entrada do poço é a mesma na saída do sistema de circulação, sensores que medem o volume de fluido de perfuração nos tanques. Ambos os sensores auxiliam na verificação da estanqueidade da parede do poço, se há ganho ou perda de fluido para a formação.

A aquisição computadorizada de dados e uma rotina contínua de transferência deles em tempo real para monitores espalhados na sonda de perfuração e/ou escritório em terra permitem tomadas de decisões mais rápidas e com menor erro. (Triggia,2004)

## 2.2 Parâmetros de Perfuração

Os parâmetros de perfuração podem ser divididos em 2 grupos: os que são aplicados pelo responsável da perfuração (sondadores, engenheiros direcionais), dados de entrada, como exemplo: vazão, PSB, RPM e o grupo que obtemos como resultado de saída, como exemplo: torque e ROP.

A vazão é o bombeio de fluido de perfuração para dentro do poço tendo como uma de suas principais funções o carregamento de cascalhos, gerados pelo corte da formação, até a superfície. A RPM é a rotação que se aplica à broca, através da coluna de perfuração, a partir dos equipamentos de superfície do sistema de rotação da sonda, ou diretamente a broca pelo motor de fundo ou turbina.

O PSB é a força que se aplica à broca dependendo do peso disponível no BHA para que haja avanço da perfuração. A faixa de peso a ser aplicada varia com o diâmetro da broca. Quanto maior o diâmetro, maior o limite para aplicação de peso, variando também com o tipo e modelo da broca.

Tais parâmetros têm que estar de acordo com as limitações técnicas da sonda, do BHA montado, variando de acordo com o diâmetro da fase, logo, as limitações técnicas dos fabricantes de brocas também devem ser levadas em consideração. O uso descontrolado de qualquer um desses parâmetros pode impactar negativamente no desempenho de uma broca, abreviando sua vida útil.

O torque é uma leitura realizada na sonda, a partir da interação entre a broca e a formação. Essa interação se dá com a aplicação de rotação a broca, seja com ou sem giro da coluna de perfuração. Em estudo sobre energia mecânica específica utiliza-se o torque como indicativo de uma possível ineficiência de perfuração.

No campo, a boa prática da indústria diz que o torque é de grande importância para identificar um desgaste severo da broca dificultando seu avanço, sendo um indicativo para retirada da broca em momento adequado. No entanto, o torque não deve ser o único parâmetro a ser avaliado. As mudanças de litologia ao longo da perfuração e de parâmetros aplicados influenciam nessa decisão. (Triggia,2004)

A trajetória, a integridade da parede do poço e a composição do BHA também influenciam a leitura de torque e o peso aplicado que chega à broca. Em poços direcionais, que diferentemente dos poços verticais, não têm o objetivo de perfuração verticalmente abaixo do ponto onde o poço está sendo perfurado, apresentam uma necessidade de uso de técnicas específicas de perfuração a fim de direcionar a perfuração na direção e angulação certa para atingir o objetivo da perfuração.

Nos poços direcionais parte do peso da coluna é suportada pela parede do poço, que na maior parte do tempo fica em contato direto, o que acarreta problemas como desgaste e atrito alto com os equipamentos que compõe a coluna do BHA.

### 2.2.1 Taxa de Perfuração (ROP)

É a leitura mais importante resultante da aplicação dos parâmetros de perfuração que podem ser alterados pelos responsáveis da operação. É um dos indicadores que ajudam na decisão da continuidade ou não da perfuração. Sua unidade de medida é comprimento por tempo.

O tempo que se leva para perfurar um poço de petróleo está diretamente associado à sua taxa de perfuração e, com isso, é uma medida associada ao custo. Os custos de perfuração são dependentes do tempo. Qualquer método que ajude a aumentar a taxa de perfuração e preservar a broca levará a redução do custo. Fatores que afetam a ROP

devem ser analisados antes que seja feita qualquer mudança nos parâmetros, visando compreender quão efetiva está sendo a perfuração de um poço.

Há diversos fatores que influenciam diretamente o ROP durante a perfuração.

- Tipo de broca;
- Características da formação (por exemplo, resistência à compressão da rocha, porosidade, permeabilidade);
- Propriedades do fluido (densidade, viscosidade etc.);
- Parâmetros de perfuração aplicados (RPM e PSB);
- Desgaste de cortadores/dentes da broca;
- Hidráulica da broca (inclui a vazão aplicada).

Os diversos tipos de broca possuem diferentes valores de parâmetros de perfuração ideais a serem aplicados para potencializar o corte.

A litologia perfurada é um fator do qual não se tem controle, por mais que se façam estudos preliminares, sísmicas, por exemplo, e pela experiência do autor no campo, o previsto pelo geólogo nem sempre é o real.

O cenário ideal seria perfurar uma formação homogênea, isotrópica. Porém, na prática, o que se vê são formações intercaladas, as quais sofreram processos diferenciados gerando variadas características dentro de uma mesma formação, por exemplo, um mesmo tipo de arenito possui diferentes leituras dos perfis geológicos (sônico, raio gama, etc.). Sendo assim, cada intervalo perfurado possui suas próprias características que afetam a resistência à perfuração e por consequência a taxa de perfuração.

As propriedades reológicas dos fluidos, que são diversas, variam de acordo com o cenário da perfuração. Há modelos de previsão de ROP que utilizam esses dados como variáveis de entrada.

Outro fator relevante é a eficiência humana, o sistema de monitoramento é suscetível ao erro humano a todo o momento, devido ao cansaço e ao estresse que os operadores estão constantemente submetidos muitas informações importantes adquirida no monitoramento são perdidas e não são analisadas como deveriam.

Falhas nos equipamentos, tanto nos sensores de superfície quanto nos que compõe o BHA afetam diretamente a coleta de dados, porque dados não recolhidos resultam em informações não acompanhadas. Tais questões resultam em registros de dados suspeitos e mal dimensionados que são armazenados durante a perfuração, comprometendo a qualidade das amostras e impedindo uma eventual correção na taxa de perfuração.

Além disso, critérios adotados ao longo da perfuração, valores de PSB e RPM aplicados, por exemplo, podem impactar negativamente na vida útil da broca. Utilização de parâmetros de perfuração além das recomendações do fabricante, impacto da broca com a formação devido a uma manobra em alta velocidade, falta de uso adequado dos compensadores de movimento do mar em sondas marítimas flutuantes, tudo pode afetar a broca, logo o ROP registrado. (Mendes,1998)

## 2.3 Broca

É a ferramenta de corte localizada no extremo inferior da coluna de perfuração, a qual é utilizada para cortar ou triturar a formação rochosa durante a intervenção de perfuração.

Para perfurar, as brocas utilizam como base os princípios fundamentais para vencer os esforços da rocha, variando sua forma de ataque. A forma de ataque dependerá do tipo e das características da rocha que se deseja cortar, principalmente em função de sua

dureza e abrasividade. As formas de ataque mais utilizadas são: cisalhamento, esmerilhamento, esmagamento, e até mesmo erosão por ação de jatos de fluido.

As principais classificações das brocas são de acordo com suas estruturas cortantes, que são as brocas com partes móveis e brocas sem partes móveis. Nas Tabelas 1 e 2 serão apresentadas as principais características e utilizações de cada tipo.

Para melhor classificar os diversos tipos de brocas, a IADC criou um código internacional para a classificação, que no caso das brocas tricônicas vem sendo empregado desde 1972, tendo sido revisado para se adequar a novas tecnologias em 1992. As brocas com cortadores fixos (PDC, Diamante e TSP) ganharam um sistema de classificação IADC em 1990.

Na Figura 4 são apresentados os principais tipos de brocas do mercado:



Figura 4: Tipos de brocas

Fonte: Autoria própria

### 2.3.1 Brocas sem partes móveis

Tabela 1: Características das brocas sem partes móveis

Principais tipos:	Características:	Vantagens:	Principais utilizações:
*Integral de lâminas de aço *diamantes naturais (impregnada) *diamantes artificiais (PDC).	*Impregnada: mecanismo de perfuração é por esmerilhamento *PDC: mecanismo de perfuração é pelo cisalhamento. Composta por uma fina camada de diamantes aglutinados com cobalto, fixada a outra camada composta de carbureto de tungstênio (bom dissipador de calor).	A inexistência de partes móveis e rolamentos diminui a possibilidade de falha	*Impregnada: Utilizadas em formações extremamente duras e abrasivas. *PDC: Para rochas mais moles possuem poucos cortadores de maior tamanho, enquanto que para rochas mais duras possuem cortadores menores e em maior quantidade. Foram introduzidas para perfurar formações moles com altas taxas de penetração e maior vida útil

Nas Figuras 5 e 6 fica claro o formato e a forma de corte das brocas PDC. O ataque por cisalhamento ocorre devido a forma com que os diamantes são dispostos na extremidade da broca.




Figura 5: Ângulos de ataque - Broca PDC

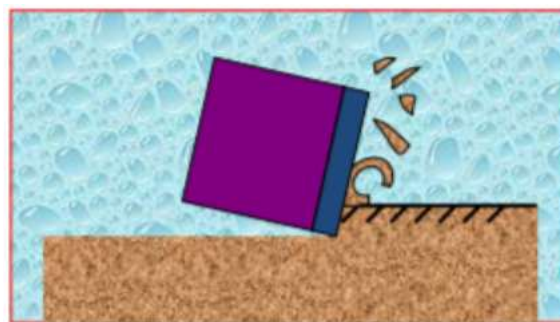


Figura 6: Forma de corte - Broca PDC

Fonte: Apostila de brocas – UGF

O ângulo é medido em relação a vertical, quanto menor o ângulo mais agressivo é o corte, o que permite altas taxas de perfuração e quanto maior o ângulo maior durabilidade e menor agressividade (menor o ROP).

O que possibilita as brocas PDC um range de taxas de perfuração grande, além disso esse tipo de broca apresenta uma curva de velocidades decrescentes com o tempo, pois a medida que os diamantes da superfície vão se desgastando a taxa, mesmo que alta inicialmente, vai decaindo com o desgaste. Esses dois fatores dificultam o cálculo instantâneo da taxa de perfuração.

A Figura 7 é uma representação de como fica o cascalho com a broca Impregnada, ele é pulverizado. Broca impregnada é a evolução da broca de diamante. Elas possuem seus elementos de corte (cristais de diamante) impregnados na matriz de carboneto de tungstênio.

Geralmente são utilizadas em ambientes de perfuração duros e abrasivos. Devido à pequena exposição, tal qual nas brocas de diamante, a impregnada necessita trabalhar a altas rotações para atingir taxas de penetração significativas. Estas brocas são geralmente usadas com turbinas ou motores de alta rotação. São projetadas de forma a ter cobertura completa de diamante no fundo do poço.

A ação de esmerilhamento da formação a altas rotações acarreta a quebra da cimentação entre os grãos da rocha. Durante a perfuração, com o desgaste da broca, novos cristais de diamantes impregnados na matriz se expõem continuamente ao ambiente de perfuração mantendo a estrutura de corte afiada. Há que se planejar bem a aplicação destas brocas uma vez que é necessário que se desgastem para que se exponham novos cristais de diamante e se atinjam resultados satisfatórios de taxa de perfuração.



Figura 7: Forma de corte - Broca Impregnada

Fonte: Apostila de brocas – UGF

As brocas com cortadores fixos não possuem o problema da perda de um cone. Essa característica diferenciada faz com que esse tipo de broca seja preferido para perfurar maiores intervalos e em regiões mais profundas por não ter uma limitação de tempo dentro do poço e nem número de revoluções, ficando submetida apenas ao desgaste do uso. (Mendes, 1998)

### 2.3.2 Brocas com partes móveis

Tabela 2: Características das brocas com partes móveis

Principais tipos:	Características:	Vantagens:	Principais utilizações:
Tricônica	Possuem dois elementos principais: estrutura cortante e rolamentos. A ação da estrutura cortante das brocas tricônicas envolve a combinação de raspagem, lascamento, esmagamento e erosão por impacto dos jatos de lama	Possuem alta eficiência e menor custo inicial em relação as demais brocas	*Nas rochas moles o efeito de raspagem é predominante. *Em rochas duras onde a taxa de penetração é baixa e os custos de perfuração tendem a ser altos, o mecanismo de esmagamento provou ser o mais adequado.

Na Figura 8 a formação é triturada e compactada até que seja rompida, evidenciando a forma de corte das brocas tricônicas.




Figura 8: Forma de corte - Broca Tricônica

Fonte: Apostila de brocas – UGF

Fonte: Catálogo Drillmine



Figura 9: Tipos de dentes - Brocas Tricônicas

Já na Figura 9 tem a disponibilidade dos dentes, quanto mais dura a formação, maior a quantidade de dentes para distribuir as cargas, e menores os dentes para diminuir os esforços na base dos mesmos. Dessa forma a broca ideal para formações duras é a do lado direito, enquanto a da esquerda é ideal para formações moles. (Mendes,1998)

## 2.4 Programa de Brocas

No programa de brocas é definido quais e quantas brocas serão utilizadas em determinada fase do projeto, a escolha das brocas é feita utilizando 2 referências, o custo métrico da perfuração dado pela Equação 1 e utilizando os dados de poços de correlação da região.

$$C_m = \frac{(C_b + C_h(t_p + t_m))}{M_p} \quad (1)$$

Onde,  $C_m$  representa o custo métrico da broca,  $C_b$  é o custo da broca utilizada e  $C_h$  mede o custo diário da sonda. Já  $t_m$  é o tempo gasto manobrando e  $t_p$  representa o tempo gasto perfurando e por fim  $M_p$  é a metragem perfurada.

A escolha do momento certo da troca de broca é baseada na fórmula do custo métrico, uma vez que se o valor aumentar é indicativo que está na hora da troca de broca. Outros parâmetros que indicam a hora da troca é a diminuição do torque na mesa rotativa e a variação na taxa de perfuração. (Mendes, 1998)

Alguns parâmetros mecânicos e hidráulicos precisam ser analisados para maximizarem o tempo de uso das brocas, como o PSB e o RPM para tentar minimizar o custo do metro perfurado.

Já a energia hidráulica, responsável por carrear os cascalhos, uma vez mal calculada gera um retrabalho para a broca, pois a broca precisa re-perfurar os cascalhos acumulados no fundo do poço.

Dessa forma para uma realização eficiente do programa de brocas projetado para a perfuração, todos os parâmetros envolvidos precisam ter valores bem definidos anteriormente e controlados durante a operação.

Atualmente existem ferramentas de decisão no mercado de petróleo que são aplicações computacionais que auxiliam a equipe de projeto na tomada de decisão de quais e quantas brocas serão utilizadas no projeto.

Como exemplo de solução têm o SIS Brocas, aplicação que funciona como um grande banco de dados onde as informações dos poços realizados ficam armazenadas, dados como: número de brocas, taxas efetivas, intervalo perfurado, etc.

O programa não sugere nenhuma taxa para o projeto, apenas expõe o passado dos poços correlatos e o responsável pelo projeto usando seu conhecimento tácito que seleciona o melhor conjunto de brocas.

Os dados originais vêm direto da planilha direcional, onde estão os dados oriundos dos sensores nos poços. A base de dados dessa dissertação será montada com dados direcionais.

Resumindo o processo de seleção de brocas utilizando o exemplo do software do mercado: o projetista levanta no SIS Brocas os poços que serão utilizados como correlação no estudo, em seguida um estudo dos modelos de brocas disponíveis é feito e a partir desse ponto, com a combinação entre histórico e disponibilidade de brocas que o projetista estima o tipo, o número de brocas e as taxas que serão utilizadas em cada trecho perfurado.

## 2.5 Estado da Arte

Quando se trata do mundo do petróleo, todas as dimensões, custo, tempo e riscos tornam-se onerosos. Assim aperfeiçoar a perfuração está diretamente ligada a escolher parâmetros de modo a se conseguir uma perfuração mais econômica e segura. Os elementos que mais influenciam no custo da perfuração são: programa de brocas, programa de fluido e programa de revestimento.

Os principais componentes de interesse em um projeto são: o número de fases, tipo e profundidade de assentamento do revestimento, tipo de fluido de perfuração e suas propriedades, tipo de broca e suas características.

A capacidade de melhorar os procedimentos de perfuração e economizar envolvem simulações para entender os efeitos que cada parâmetro operacional carrega. Diversos estudos foram desenvolvidos para aplicar modelagens de otimização do desempenho de perfuração.

Vários modelos e métodos foram publicados para prever e potencialmente otimizar a taxa de perfuração (ROP) (Bourgoyne et al., 1986; Mason, 1987; Warren, 1987; Falconer et al., 1988; Bond, 1990; Pessier Medo, 1992; Hareland e Hoberock, 1993; Rampersad et al., 1994; Hareland et al., 1996; Perrin et al., 1997; Xu, 1997; Smith, 1998-2000; Alsaleh, 1999; Millheim e Gaebler, 1999; Uboldi et al., 1999; Wilmot et al., 1999; Abouzeid e Cooper, 2001; Aghassi e Smith, 2002; Nygard e Hareland, 2002; Cooper e Hatherly, 2003; Hareland e Nygard, 2007).

Métodos foram desenvolvidos para determinar a força da rocha a partir de medições mecânicas. Muitos são baseados em uma interpretação de sonares, acrescido de informações derivadas de um registro de porosidade e emissão de raios gama. Tais medidas são capazes de gerar estimativas de resistência à compressão das rochas, mineralogia e outras propriedades que são de valor para prever o desempenho de perfuração.

Modelos analíticos e matemáticos também foram desenvolvidos em tentativa de descrever a relação entre os parâmetros de controle e a taxa de perfuração com graus variados de complexidade Warren, 1987, Kuru, 1990, Bourgoyne, 1991, Hareland e Hoberock, 1993, Fear, 1996, Hareland et al., 1996, Smith, 1998, Millheim e Gaebler,



1999, Oort et al. al., 1999, Talor et al. al., 2000, King et. al., 2001, Pinckard, 2001, Nygaard, R. e Hareland, e Hareland e Nygaard, 2007.

Da abordagem de Hareland e Nygaard, a força da rocha pode ser calculada invertendo a equação do modelo de ROP. (Hareland e Nygaard, 2007).

### 2.5.1 Modelos matemáticos para prever a taxa de perfuração (ROP)

Vários modelos matemáticos também conhecidos como modelos ROP, têm sido desenvolvidos nas últimas décadas para descrever como a taxa de perfuração é afetada devido a mudanças nos parâmetros operacionais de perfuração, mudanças na rocha propriedades e alterações nos tipos de brocas e no design. Esses modelos empíricos têm como insumos as informações operacionais de perfuração, ou seja, peso na broca, velocidade de rotação, propriedades da lama e taxa de fluxo, etc. às saídas, ou seja, taxa de perfuração.

A) Modelo de ROP para brocas tricônicas (Warren, 1987)

$$ROP = \left( \frac{aS^{2d}d_b^3}{RPM^b WOB^2} + \frac{b}{RPM d_b} + \frac{cd_b^3 \mu MW}{0.000516 \rho qv_n} \right)^{-1} \quad (2)$$

Na equação acima, S é a resistência da rocha,  $d_b$  é o diâmetro da broca, q taxa de fluxo,  $\rho$  é densidade de lama,  $\mu$  plástico viscosidade, MW é peso de lama,  $v_n$  velocidade na ponta da broca e a, b, c são constantes do modelo. (Warren, 1987)

B) Modelo de ROP para brocas tricônicas (Hareland e Hoberock, 1993)

Incluíram o efeito do desequilíbrio criado pela diferença de pressão entre o peso da lama e pressão de poros MWPP dada como:

$$pe = MW - PP \quad (3)$$

Eles alegaram que o maior peso de lama, comparado com a pressão dos poros abaixo da broca, empurrarão as lascas de rocha já perfuradas para o fundo e reduzir a eficácia da limpeza. Este efeito é chamado de efeito *chip-hold* (Hareland e Hoberock, 1993). Eles incluíram o seguinte termo no modelo de Warren para compensar esse efeito.

$$f_c(pe) = cc + ac(pe - 120)^{bc} \quad (4)$$

O segundo efeito que falta no modelo de Warren é o desgaste das brocas.

C) Modelo de ROP para brocas tricônicas (Hareland et al., 1996)

Explicou que após a perfuração da seção, os dentes das brocas com cones começaram a ficar desgastados. A tensão em cada cortador foi reduzida quando o ensebamento aumenta na área dos dentes.

Portanto, o ROP reduzirá e como resultado deste efeito, a resistência da rocha de perfuração aumentará para valores irreais no modelo de ROP dado acima. O efeito do desgaste da broca no modelo ROP foi então introduzido para obter valores de desgaste mais realistas (Hareland et al., 1996).

$$Wf = 1 - \frac{Wc \sum_{i=1} WOB_i RPM_i Abr_i S_i}{8} \quad (5)$$

O efeito do desgaste da broca é denotado como fator de desgaste ( $Wf$ ) e é um valor entre 0 e 1.  $Wf$  é um coeficiente de desgaste que é específico para o projeto de broca e tem que coincidir com o desgaste de broca reportado em campo. A litologia dependente da abrasividade ( $Abri$ ) da rocha para calcular o efeito do desgaste da broca. Quando o desgaste é incluído no modelo do ROP, ele fornece uma nova Equação de ROP que inclui os principais efeitos sobre o ROP.

$$ROP = Wf (fc(pe)) \left( \frac{aS^{2d} d_b^3}{RPM^b WOB^2} + \frac{b}{RPM d_b} \right) + \frac{cd_b^3 \mu MW}{0.000516 \rho qv_n}^{-1} \quad (6)$$

O modelo de ROP na Equação 6 de Hareland et al., (1996) modela os efeitos que diferentes condições de operação e resistência da rocha têm no ROP. No entanto, usando a força calculada a partir deste modelo ainda apresentaram algumas limitações e a partir dele surgiu o modelo de (Hareland and Nygaard, 2007).

D) Modelo de ROP para brocas tricônicas (Hareland & Nygard, 2007)

O modelo de Hareland et al inclui dois parâmetros importantes que também alteram ROP (Hareland e Nygaard, 2007).

$$ROP = Wf (fc(hyd)) \left( \frac{aS^{2d} d_b^2}{RPM^b WOB^{(2-bs)}} \right)^{-1} \quad (7)$$

Na equação 7, Hareland e Nygaard, (2007) introduziram uma nova constante experimental para ajustar os dados, onde a broca é um pouco dependente dessa constante.

Eles explicaram que a função de retirada de cascalho e a limpeza dos cortadores do modelo ROP da equação 6 é substituída por uma fórmula hidráulica ( $f(hyd)$ ) baseada em tratar o efeito da vazão, peso da lama e viscosidade plástica, potência hidráulica e tamanhos de jatos.

E) Modelo de ROP para brocas PDC (Hareland & Nygard, 2007)

Baseado nos modelos anteriores um modelo específico para brocas PDC foi desenvolvido pensando nas divergências de corte que essa broca apresenta.

$$ROP = Wf (fc(hyd)) \left( \frac{f(bit) aS^{(2-be)} d_b^2}{RPM WOB^{(2-be)}} \right)^{-1} \quad (8)$$

## 2.5.2 Modelos computacionais para otimização de parâmetros de perfuração

O primeiro modelo analisado foi R.A. Arehart (1990) em seu paper descreve uma rede neural que foi construída para determinar o grau (estado de desgaste) de uma broca enquanto ela está perfurando. Com uma rede neural de três camadas e retro propagação

como algoritmo de aprendizado, o sistema foi treinado com dados de laboratório coletados usando pedaços de sondagens conhecidas através de litologias conhecidas. As entradas para a rede neural foram: taxa de perfuração (ROP), peso na broca (WOB), torque (T), revoluções por minuto (RPM) e potência hidráulica por polegada quadrada (HSI). A rede foi testada em formações sintéticas de várias espessuras de leito construídas a partir dos dados de teste.

No entanto, os dados disponíveis não foram suficientes para treinar um sistema para implementação real em um ambiente de perfuração, porque eles não abrangeram todo o domínio de interesse. Por exemplo, os dados de treinamento cobriam apenas duas litologias e apenas um modelo de broca. Muitos outros dados de treinamento devem ser coletados antes que o sistema esteja pronto para testes operacionais.

Já Leea B. Y., Liua H. S, et al.(1998) pesquisaram uma nova forma de modelar processos de perfuração, o uso de *abductive network*. Essa é uma rede composta por uma série de nós funcionais, sendo esses nós auto-organizados para formar uma arquitetura de rede ótima usando um critério de erro quadrático previsto (PSE), que se aproxima da ideia de redes neurais. Uma vez que os parâmetros do processo (diâmetro da broca, velocidade de corte e avanço) são dados, o desempenho da perfuração que seria a vida da ferramenta, taxa de remoção de metal, força de impulso e torque podem ser previstos por esta rede.

Um algoritmo de otimização – *simulated annealing* – é então aplicado à rede desenvolvida a fim de procurar os parâmetros de processo ótimos.

No mesmo ano a utilização de redes neurais por Coelho, Dennis Kerr (1998) em sua dissertação segue a linha da abordagem conexionista ser utilizada na avaliação e previsão do tempo total em operações de perfuração e completação de poços de petróleo em águas profundas. Os valores dos parâmetros utilizados por ele para estimar o tempo total gasto da operação realizada no poço foram retirados de um banco de dados histórico. As correlações e as características dos parâmetros foram detectadas utilizando-se de uma rede neural competitiva (sistemas auto-organizáveis que estão relacionados com aprendizagem não-supervisionada. O objetivo de um algoritmo de aprendizagem não-supervisionada é extrair características significativas dos dados de entrada, sem supervisão. O algoritmo procura encontrar, de forma autônoma, similaridades entre conjuntos de dados, identificando assim, agrupamentos de dados com características comuns. Nos sistemas neurais auto-organizáveis, os pesos dos neurônios armazenam as características de um protótipo correspondente a um agrupamento de dados de entrada com características similares) conectada a uma rede neural direta (arquitetura com múltiplas camadas com fluxo de informação em apenas um sentido) que foi treinada para estimar a média, o desvio padrão e o tempo total gasto na operação realizada no poço. Uma das vantagens da metodologia proposta, está no fato de ser uma ferramenta simples e prática para obtenção de uma estimativa do tempo total de uma operação realizada sobre um poço de petróleo baseado em parâmetros geométricos e tecnológicos, sem a necessidade de especificar todas as sub-operações de perfuração e completação como acontece nos métodos tradicionais de análise de risco.

Enquanto isso, Mendes, J. R (1998) deu início ao uso de sistemas inteligentes distribuídos na seleção de brocas tricônicas para a perfuração de poços, através de redes neurais, lógica nebulosa e ferramentas disponíveis no sistema Kards.

Grant, M. A (2009), em sua pesquisa aborda considerar uma gama de prováveis resultados de poços com as possíveis alternativas disponíveis e seus custos, em conjunto com a distribuição de produtividade e/ou injetividade. Com a distribuição da produtividade é possível determinar os resultados esperados da perfuração e do desempenho do poço em campos geotérmicos.

Utilizando o método de árvore de decisão de possíveis ações (test / accept / sidetrack), os custos de perfuração e as distribuições de produtividade são os critérios definidores da decisão para aceitar ou descartar um poço. Esses critérios são analisados e a decisão é tomada, ações concebíveis são aceitar um poço, desviá-lo ou descartar a plataforma de perfuração e realizar um novo teste. Novamente a previsibilidade impactando diretamente se um projeto é factível ou não.

Já Carlos M.C.Jacinto, Paulo J.Freitas, et al (2013) que investigou as seguintes técnicas em sua pesquisa: uma abordagem de inferência bayesiana para direcionar o processo de levantamento de dados e subsequente combinação de modelos; e um Sistema de Inferência Fuzzy Neural-Evolvente (DENFIS). O uso de uma rede não hierárquica (Bayes) para classificar o ROP não foi suficiente para uma boa classificação dos valores de entrada. Esse tipo de comportamento mostra a complexidade do domínio, não sendo possível dizer que as variáveis são mutuamente independentes. Outras possíveis razões para a baixa qualidade da classificação estão diretamente ligadas à qualidade dos dados e à divisão de classes para cada variável que compõe os dados de entrada. Todos esses fatores tornam essa arquitetura de rede altamente complexa e sua determinação não é uma tarefa simples.

Em Hankins D, Salehi S, et al.(2014) mostram como ótimos parâmetros operacionais e equipamentos bem escolhidos podem ser previstos simulando operações de perfuração de poços preexistentes em um campo dos EUA. Os dados de entrada foram coletados e processados para prever a capacidade de perfuração das formações encontradas, simulações computacionais foram realizadas e um modelo de capacidade de perfuração da formação foi gerado, direcionando para a escolha certa da broca e de todos os outros parâmetros.

Os dados de saída gerados para o poço de estudo foram formatados para simular os próximos poços. Uma análise comparativa foi realizada entre os resultados previstos e os resultados reais para mostrar a precisão da simulação. Uma vez que as simulações foram validadas, os parâmetros de perfuração ótimos e as especificações do equipamento foram aplicadas para obter a maior taxa de perfuração para cada poço. Uma análise qualitativa e quantitativa dos resultados otimizados foi realizada para avaliar os potenciais benefícios operacionais e econômicos nas operações de perfuração.

Encontramos em outros artigos diversas técnicas que vêm sendo empregadas no intuito de melhorar a previsibilidade dos parâmetros de perfuração.

Estudos na mesma linha, porém analisando as incertezas envolvidas no projeto foram discutidos em por Yost K., Valentina A., et al. (2015) onde se descreve um método e apresenta o código computacional associado e adaptado para perfuração de poços, Decision Aids for Tunneling (DAT).

A análise foi feita em forma de estudos paramétricos, nos quais havia incerteza em cada componente. Os custos em geologia e em eventos problemáticos anteriores, foram investigados separadamente e depois em combinação. Isso mostra que o custo e o tempo de perfuração de poço que estão sujeitos a uma grande variedade de incertezas podem ser avaliados sistematicamente.

A bibliografia revisada apresenta as principais soluções para otimizar os parâmetros de perfuração. A aplicação da metodologia de Redes Neurais Artificiais em alguns estudos mostra a possibilidade de aplicação desta metodologia na previsão das taxas de perfuração.

Os trabalhos com RNA apresentados servem de base para o desenvolvimento desta dissertação com o uso de redes neurais do tipo MLP.

## 3 Aprendizagem de máquina

### 3.1 Data Science e Inteligência Artificial

*Data Science* ou ciência de dados é um campo multidisciplinar que utiliza métodos, processos, algoritmos e sistemas científicos para extrair conhecimento e entendimento de dados em várias formas, tanto estruturadas quanto não estruturadas, se assemelhando à mineração de dados.

A ciência de dados é um conceito para unificar estatísticas, análise de dados, aprendizado de máquina e seus métodos relacionados para entender e analisar fenômenos reais com dados. Ela emprega técnicas e teorias extraídas de muitos campos dentro do contexto da matemática, estatística, ciência da informação e da computação.

Tony Hey, Stewart Tansley, *et al.* (2011) trataram em seu livro a ciência dos dados como um “quarto paradigma” uma ciência empírica, teórica, computacional e agora baseada em dados e afirmam que “tudo sobre a ciência está mudando devido ao impacto da tecnologia da informação” e o dilúvio de dados.

A Inteligência Artificial, IA, resumisse a ensinar as máquinas a obter comportamentos inteligentes, tomando a inteligência Humana como referência. É uma área de pesquisa da computação dedicada a buscar métodos ou dispositivos computacionais que repliquem e multipliquem a capacidade racional do ser humano de resolver problemas, pensar ou, de forma ampla, ser inteligente. Também pode ser definida como o ramo da ciência da computação que se ocupa do comportamento inteligente ou ainda, o estudo de como fazer os computadores realizarem coisas que, atualmente, os humanos fazem melhor.

De acordo com Berkeley, I. S. (2009), existem três principais linhas de pesquisa no ramo da inteligência artificial: a linha conexionista, a linha simbólica e a linha evolutiva. A linha conexionista propõe a modelagem da inteligência humana por meio de simulações dos neurônios e suas interligações. A linha simbólica tem o objetivo de simular um especialista humano em assuntos bem específicos, sendo capaz de auxiliar nos processos de tomada de decisão ou até mesmo tomar as decisões sem intervenção humana. Já a linha evolutiva, também chamada de computação evolutiva, se baseia na observação de mecanismos evolutivos encontrados na natureza, tais como a auto-organização e comportamento adaptativo.

As pesquisas no campo da inteligência artificial podem elaborar algoritmos inteligentes que permitem aos computadores armazenar grande quantidade de conhecimento sobre operações corporativas, onde esses sistemas são capazes de praticar as negociações reconhecendo padrões de difícil percepção para o ser humano, além de fornecer capacidade adicional de aprender com sucessos e fracassos obtidos em cada operação realizada.

Na Figura 10 é possível visualizar as instâncias inseridas em ciência de dados, assim como suas ordenações.

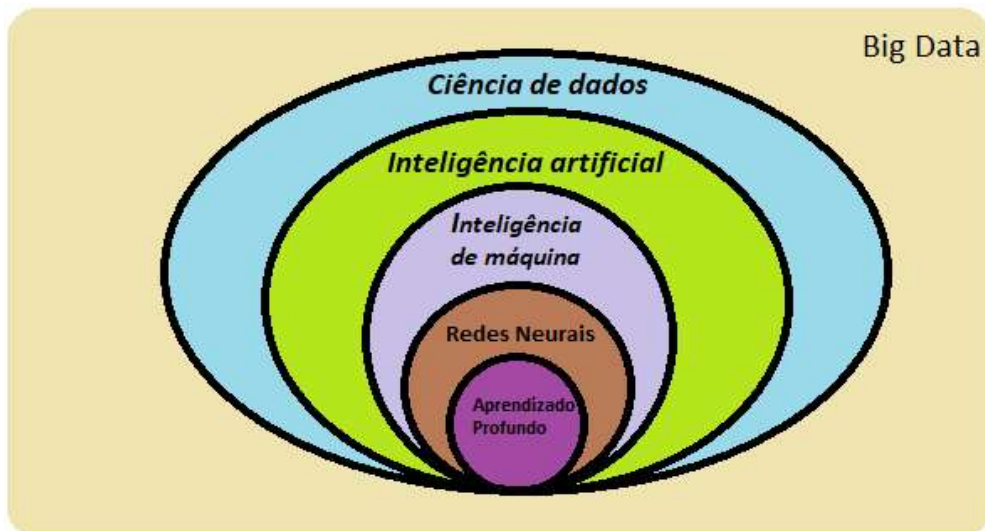


Figura 10: Instâncias Data Science

Fonte: Autoria própria

## 3.2 Redes Neurais

Redes neurais artificial (RNA) são algoritmos que se baseiam no comportamento do cérebro humano. Dessa forma, imita a estrutura massivamente paralela do cérebro, com capacidade de adquirir, armazenar e utilizar conhecimentos experimentais (Haykin, 2001). Apresentam como característica a robustez e tolerância à falhas, ou seja, mesmo diante do mau funcionamento de determinado neurônio a rede neural se mantém estável, produzindo resultados confiáveis.

Seu funcionamento é bastante semelhante ao sistema biológico em dois aspectos: o conhecimento é obtido através de processos de aprendizado e a densidade das sinapses (conexões entre neurônios) é a chave para se armazenar os conhecimentos adquiridos.

A estrutura das RNAs é formada por diversas unidades de processamento, chamadas neurônios artificiais, que se encontram interligadas. Essa rede de neurônios artificiais se comunica através de sinais e são capazes de representar comportamentos complexos.

No decorrer deste capítulo 3, serão apresentados um pouco dos eventos e pesquisas que levaram ao desenvolvimento das RNA. Serão discutidos seus princípios de funcionamento, arquiteturas em que podem ser apresentadas, lógica e formas de treinamento assim como outros aspectos importantes.

### 3.2.1 Histórico

Embora os computadores atualmente consigam realizar operações matemáticas com uma velocidade muito superior ao que nossos cérebros podem processar informação, não existem máquinas ou software que consigam resolver problemas simples do dia a dia.

Por exemplo, o processo de andar conversando com outra pessoa e no caminho reconhecer objetos sem nunca tê-los vistos especificamente é tão cotidiano que nem raciocinamos conscientemente sobre esses feitos. Nosso sistema nervoso consegue resolver esses problemas de como locomover o corpo para andar, manter atenção dando

continuidade a uma conversa e reconhecer padrões tudo ao mesmo tempo e sem problemas.

Fazemos isso recebendo (órgãos sensoriais) as informações do ambiente, enviando sinais para a nossa rede neural (cérebro), que processa as informações recebidas e envia um sinal para nossos músculos atuarem no ambiente externo com uma resposta.




Figura 11: Esquemático da direção de propagação de sinais durante o processamento de informações

Fonte: Repositório UFSC,2019

Em contrapartida o cérebro também recebe informações sobre as respostas dadas ao ambiente externo, enviando novos sinais para os receptores do nosso organismo, realizando um processo de retroalimentação.

Diante desse poder de interpretação, surgiu o interesse de desenvolver um sistema artificial capaz de assemelhar ao cérebro. Dessa forma, as redes neurais artificiais foram idealizadas de forma a serem capazes de alcançar a capacidade apresentada pelo cérebro humano em identificar, reconhecer e classificar padrões, processando grandes quantidades de informação em tempo reduzido.

As pesquisas em inteligência computacional se esforçam para reorganizar o processamento de informações, deixando de lado o conceito linear e sequencial empregado até então, e passando a considerar o processamento paralelo de informações.

Assim, a ideia de redes de processadores de informações ganhou força. Esses processadores foram desenvolvidos incorporando muito dos processos realizados por neurônios no cérebro humano.

Na Figura 12 mostra a representação da organização e entrelaçamento existentes entre os neurônios no cérebro humano.




Figura 12: Organização existente entre os neurônios naturais

Fonte: Repositório UFSC,2019

Pode-se observar que as conexões entre um neurônio e o outro é realizada através de sinapses. Esse conceito foi levado para a área de inteligência artificial e é utilizado para representar as conexões entre os processadores ou neurônios artificiais.

Historicamente, o primeiro modelo de neurônio artificial apareceu na década de 40. Em 1943 o psiquiatra e neuroanatomista Warren Mc Culloch em parceria com o matemático Walter Pitts trabalharam para desenvolver uma máquina que utilizava um modelo de neurônio artificial chamado Psychon, que apesar de interessante ainda não possuía poder de aprendizado.

Em 1949, é proposto o primeiro modelo de aprendizado para um conjunto de neurônios interligados, a partir da atualização dos pesos sinápticos. Esse modelo ficou conhecido como Regra de Hebb. Um pouco mais tarde, no ano de 1951, o pesquisador Marvin Minsky desenvolveu o primeiro neuro computador em que o processamento de informação foi utilizado como inspiração para outros trabalhos posteriores.

Em 1958, alguns pesquisadores liderados por Frank Rosenblatt e Charles Wightman desenvolveram o primeiro neuro computador bem-sucedido. Seu trabalho deu força para o desenvolvimento do algoritmo do Perceptron, baseado nas regras de Hebb. No início da década de 60, Widrow e Hoff realizaram importantes contribuições ao modelo Perceptron (redes de uma única camada), introduzindo o conceito de erro médio quadrático.

Em 1969, Minsky e Papert demonstraram matematicamente a impossibilidade de se obter resolução de problemas linearmente inseparáveis através do Perceptron. Um grande impulso nos estudos das RNAs foi dado na década de 1980. Em 1982 John Hopfield propôs uma rede neural diferente do Perceptron. O seu modelo propunha uma rede com conexões recorrentes entre os neurônios. Desta forma o sinal não se propagava somente para frente, além disso, o seu aprendizado era conduzido de forma não supervisionada.

Outras contribuições foram realizadas nesta década, entretanto, somente em 1986 que Rumelhart, Hilton e Williams desenvolveram o algoritmo baseado no Perceptron de múltiplas camadas (Multi Layer Perceptron), treinadas com algoritmos de aprendizado por retro propagação de erro (*Back-propagation*). Este modelo possibilitou a resolução de qualquer tipo de problema.

### 3.2.2 Neurônio Artificial

O neurônio artificial é a base para o funcionamento das RNAs. Sua estrutura é simples e pode ser entendida como um processador que realiza uma soma ponderada dos sinais de entrada, representados por  $x_1$  até  $x_n$ , pelos pesos.

Estes, que podem ser conhecidos como parâmetros da rede, representam a memória da rede e são adquiridos através da experiência obtida por diversas apresentações dos padrões de entrada. A ativação de um sinal de saída depende do valor dessa soma e de uma função denominada função de ativação.

Na Figura 13, a representação de um neurônio artificial com seus pesos, sinais de entrada e função de ativação está demonstrado.

É importante ressaltar que a função de ativação representa a parte não linear de cada neurônio, sendo de fato o único lugar aonde a não linearidade se encontra.

O termo  $b_k$ , é conhecido como termo polarizador ou *bias*, a sua função é de indicar o ponto em que a função de ativação se encontra acima do eixo, elevando ou reduzindo a entrada da função de ativação.



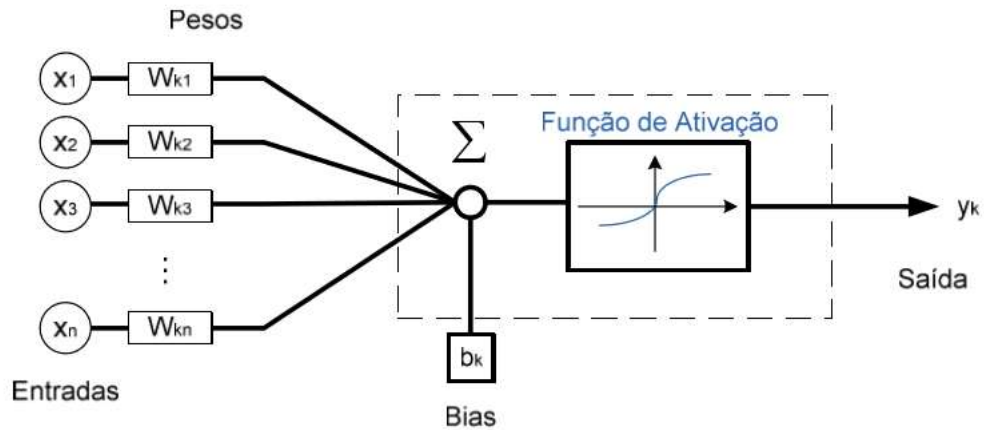


Figura 13: Representação de um neurônio artificial

Fonte: Repositório UFSC, 2019

Matematicamente o comportamento de um neurônio artificial pode ser representado pela equação 9

$$y_k = F\left(\sum_{i=1}^n (x_i \cdot w_{ki}) + b_k\right) \quad (9)$$

Onde:

- $x_i$  é o  $i$ -ésimo padrão de entrada
- $w_{ki}$  é o  $i$ -ésimo peso do neurônio  $k$
- $b_k$  função *bias* do neurônio  $k$
- $F$  função de ativação do neurônio
- $y_k$  sinal emitido pelo neurônio  $k$

Os pesos e a *bias* são os parâmetros que são estimados por uma RNA durante o seu treinamento. Após o treinamento seus valores são fixados, permanecendo constantes.

### 3.2.3 Funções de Ativação

Existem algumas formas de função de ativação. Entretanto as mais utilizadas são a função degrau, linear, sigmoide (ou logística) e hiperbólica (Haykin, 2001). A forma da função de ativação, Figura 14, está relacionada com a amplitude do intervalo da resposta de um neurônio.




Figura 14: Formato das principais funções de ativação  
 Fonte: Repositório UFSC,2019

A determinação da função de ativação é um dos fatores importantes para o bom funcionamento da RNA. Não se aconselha o uso, por exemplo, da função hiperbólica quando o estudo envolvem resultados somente positivos, visto que esse tipo de função aceita valores negativos. Já o uso das funções lineares e degrau seria indicado em situações em que se deseja evitar efeitos de saturação.

### 3.2.4 Arquitetura

O comportamento do sistema é controlado pela estrutura das ligações definidas pela sua arquitetura (ou topologia), pelos valores atribuído por conexão (pesos sinápticos) e a resposta de cada neurônio modulada pela função de ativação. Assim, a arquitetura e o número de neurônios em uma RNA é fundamental para o seu bom funcionamento, tendo influência direta no seu poder de processamento. Na Figura 15 é mostrada a arquitetura de uma RNA, com a camada de entrada, camada escondida (intermediárias) e camada de saída.




Figura 15: Representação gráfica de uma topologia de rede neural

Fonte: Repositório UFSC,2019

Pode-se classificar a arquitetura da RNA como:

- Redes de arquitetura Recorrente
- Redes de arquitetura Não Recorrente.

As redes não recorrentes são definidas por não possuírem realimentação das suas saídas para as entradas. São ditas "sem memória" e a sua estrutura é formada por uma ou mais camadas, vide Figura 16.




Figura 16: Rede Feed Forward

Fonte: Autoria própria

Nesse tipo de arquitetura não é permitido ligações (transferência de sinal efetivo) de um neurônio a outro de uma camada anterior, ou mesmo da mesma camada. É importante diferenciar aqui os sinais efetivos e informações de erro. O sinal efetivo é que não encontra conexões para neurônios da mesma camada ou de camadas anteriores, as informações de erro podem e são retro propagadas em muitos casos.

Esse tipo de arquitetura também é conhecido como “Rede Neural *Feedforward*”, pois apenas é permitido a um neurônio da camada  $I$  se conectar a um neurônio da camada  $(I+1)$ . Em uma rede *feedforward*, cada camada se conecta à próxima camada, porém não há caminho de volta. Todas as conexões têm a mesma direção, partindo da camada de entrada rumo a camada de saída, vide Figura 16.

Para definirmos uma estrutura de uma rede *feedforward* precisa-se definir as camadas de entrada, camadas intermediárias e camada de saída. Algumas técnicas são indicadas para definir a estrutura ótima.

Na camada de entrada cada neurônio deve representar alguma variável independente que influência o resultado da rede neural. Na camada de saída o número de neurônios está diretamente relacionado com a tarefa que a rede neural executa.

Quando falamos de camadas intermediárias, os problemas que requerem mais de duas camadas são raros. Basicamente, uma rede neural com duas camadas intermediárias é capaz de representar funções de qualquer formato. Não existem razões teóricas para se utilizar mais que duas camadas. Na prática, para muitos problemas comuns, não há razões para se utilizar mais que uma camada intermediária.

Já as redes recorrentes possuem como principal característica as conexões de neurônios entre camadas ou com camadas anteriores. Por isso mesmo, as RNA recorrentes são chamadas de redes “com memória”. Nesse tipo de rede, a arquitetura não se encontra amarrada a estruturas de camadas. Podem ser encontrados redes parcialmente recorrentes, Figura 17, ou totalmente recorrentes, Figura 18.




Figura 17: Rede parcialmente recorrente (Rede de Elman)

Fonte: Repositório UFSC,2019




Figura 18: Rede totalmente recorrente (Rede de Hopfield)

Fonte: Repositório UFSC,2019

As redes recorrentes são interessantes em algumas aplicações temporais, uma vez que conseguem gravar informações em tempo anterior, possibilitando uma melhor previsão para o futuro.

### 3.2.5 Formas de aprendizado – Treinamento

O treinamento de uma RNA é a fase em que os pesos em cada conexão nos neurônios são sistematicamente ajustados de forma a transformar o sinal de entrada em um sinal de saída desejado ou consistente. Em outras palavras, o objetivo do treinamento é determinar a intensidade das conexões entre os neurônios. O ajuste dos pesos da rede é realizado até que os mesmos converjam para um determinado valor. A densidade das conexões é definida pela quantidade de conexões ligadas (pesos com valores entre 1 e -1, exceto zero) e conexões desligadas (pesos com valores iguais ou muito próximos a zero).

Os procedimentos de treinamento podem ser classificados por treinamento não supervisionado ou supervisionado. No treinamento não supervisionado, é inexistente um valor de referência. Dessa forma, os resultados obtidos pela RNA não podem ser comparados para gerar informações de erro que guiem a atualização dos pesos. Logo, este tipo de treinamento é caracterizado pela comparação entre os próprios sinais de entrada. Assim, a rede descobre padrões característicos (correlações) dos dados de treinamento.

Já o treinamento supervisionado utiliza um valor de alvo a ser atingido pela RNA. Dessa forma, dado um valor de entrada a rede gera um valor de saída que será comparado ao alvo pré-determinado, gerando um valor de erro. Esse erro então é utilizado para ajustar os pesos da rede de forma a minimizá-lo. Normalmente os erros médios quadráticos da rede são o fator usado como parâmetro de treinamento.



Figura 19: Aprendizagem Supervisionada

Fonte: Autoria própria

Já o aprendizado é o algoritmo utilizado para modificar o valor dos pesos de forma a garantir que a RNA responda adequadamente ao problema proposto. Nesse sentido, o ajuste dos parâmetros da rede através de regras de aprendizado bem estabelecidas é o que define um algoritmo de aprendizagem. Existem diferentes regras de aprendizado. Entre as mais conhecidas vale a pena citar: *Adaline*, *Backpropagation*, *Competitive Learning*, *Delta Rule* (Mendel, 1995; Timoszczuk, 2004).

O algoritmo de aprendizagem mais utilizado neste caso é o chamado de retro propagação de erro (*Backpropagation*).

Este algoritmo não funciona alterando os pesos de cada conexão entre os neurônios, quando o sinal passa da camada de entrada para a saída. Nesse ponto um valor de erro é gerado através da comparação da saída com o valor alvo, e esse erro é retro propagado pra toda a rede, atualizando os valores dos pesos sinápticos.

O aprendizado é adquirido através da apresentação de exemplos relacionados com o problema que se deseja solucionar. Dessa forma, é de suma importância a apresentação de um histórico em dados para que seja possível desenvolver um algoritmo em redes neurais. Quando não há mais alterações significantes nesses pesos a rede realizou a aprendizagem.

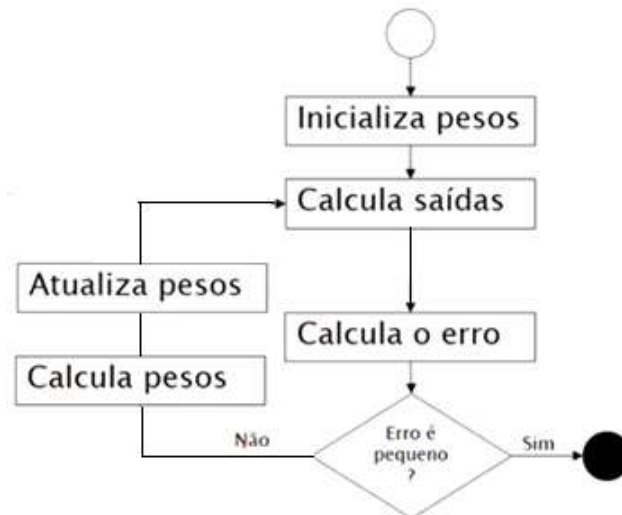


Figura 20: Ilustração do treinamento de uma RNA

Fonte: Autoria própria

### 3.2.6 Modelagem de uma RNA

A modelagem de uma RNA leva em conta a escolha dos dados que servirão para treinar a rede e garantir a sua capacidade de generalização, a melhor forma de apresentação desses dados (normalização, codificação, filtragem, etc.) e a escolha do número de neurônios em cada camada.

O primeiro passo da modelagem de uma RNA é, sem dúvida, com relação aos dados relacionados ao problema em questão, os quais estão disponíveis na forma de um histórico de casos. Como a rede aprende através destes, é de suma importância que os mesmos sejam representativos do problema ou do conhecimento que se deseja extrair.

Nesta etapa divide-se o conjunto de dados em 3 subconjuntos: Conjunto de treinamento, conjunto de validação e conjunto de teste. Normalmente o conjunto de treinamento representa um valor em torno de 70% de todos os dados, enquanto o percentual dos conjuntos de validação e teste giram por volta de 20% e 10% respectivamente.

### 3.2.7 Tratamento dos padrões de entrada para as RNA

Tanto na hora da realização do seu treinamento quanto para o seu teste e aplicação real, é imprescindível que os padrões sejam previamente tratados. Os processos mais utilizados para o tratamento desses padrões são a codificação, filtragem e normalização.

O processo de codificação (como uma codificação binária) é necessário em alguns casos, visto que eventualmente estes não são representados por valores numéricos. Por exemplo, um problema forneça para a RNA uma entrada como o mês do ano de determinada ocorrência, não pode ser realizada com o nome do mês em questão.

A filtragem dos dados disponíveis para o treinamento também pode ser interessante para o melhor funcionamento da rede. Isso é especialmente verdade quando em um conjunto de informações somente uma determinada parcela representa o fenômeno estudado. Dessa forma ao se retirar o restante, a complexidade do conhecimento que a rede deve representar diminui, aumentando a eficiência da RNA.

Por fim é importantíssimo a normalização dos dados antes de que os mesmos sejam fornecidos à rede. Isso é melhor entendido para um caso em que os dados de entrada são

formados por diferentes variáveis, as quais possuem ordens de grandeza distintas. Dessa forma, os dados de entrada com ordem de grandeza superior acabam por mascarar o restante. Outra justificativa para normalizar os dados vem do fato de que os neurônios da RNA sempre transmitirão sinais que variam de -1 à +1.

É interessante ressaltar ainda que a normalização dos dados deve deixar uma margem (tanto inferior quanto superior), visto que nem sempre é possível se trabalhar com informações que sejam completamente representativas do problema analisado. Dessa forma, ao se estabelecer essa margem de segurança evita-se que a RNA se confunda com valores fora da curva de normalização, provocados por dados de valor inferior ou superior aos apresentados para seu treinamento.

### 3.2.8 Número de neurônios

Outro fator que influencia na modelagem da RNA é o número de neurônios contido, principalmente na(s) camada(s) escondida(s). Isso por que o número de neurônios na camada escondida acaba definido o grau de complexidade do modelo da RNA. Se o número de neurônios é baixo para o problema, ou seja, se o modelo tem complexidade inferior à necessária, a rede não apresentará bons resultados (não fará uma boa representação do caso em estudo). Entretanto se o número de neurônios é excessivo, a rede terá uma complexidade muito maior que o necessário e irá com isso aprender o que não precisa, como ruído.

Existem classificações quando o número de neurônios presente na rede não é o adequado:

*Underfitting*: poucos neurônios que não conseguem detectar adequadamente os sinais em um conjunto complicado de dados.

*Overfitting*: muitos neurônios a serem treinados por um número limitado de informação contida no conjunto de dados. Muitos neurônios podem fazer com que o treinamento não termine adequadamente em tempo hábil.

O número de neurônios nas camadas intermediárias segundo a professora Joseana Macêdo Fachine (2017) deve ser:

1. Entre o número de neurônios nas camadas de entrada e saída.
2.  $\frac{2}{3}$  do tamanho da camada de entrada, somado ao tamanho da camada de saída.
3. Menor que duas vezes o tamanho da camada de entrada.
4. Em redes pequenas o número de neurônios da camada intermediária (oculta) pode ser a média geométrica entre o número de neurônios de entrada pelo número de neurônios de saída.

Dessa forma definem-se quais seriam os melhores modelos de rede para testar e resolver o problema. Entretanto cumpre lembrar que a regra 3 é praticamente obedecida para qualquer rede neural prática, por conta da regra 1. Esses critérios serão utilizados para escolher o número de camadas intermediárias dos modelos propostos na dissertação.

Exemplo: Parâmetros de entrada (camada de entrada):15 ; Parâmetro de saída (camada de saída):1

- 1-  $1 < \text{n}^\circ \text{ de neurônios intermediários} < 15$
- 2-  $\frac{2}{3} \text{ camada de entrada} + \text{camada de saída} ; 10 + 1 = 11$
- 3-  $< 2 \text{ camada de entrada} ; < 2 * 15 = 30$
- 4-  $\text{camada intermediária} = \frac{\text{camada de entrada} + \text{camada de saída}}{2} ; \frac{15 + 1}{2} = 8$

O mesmo cuidado na quantidade de neurônios nas camadas de entrada e saída deve ser considerado. Isso por que, além de também aumentarem ou reduzirem o grau de complexidade do modelo da rede, os neurônios na camada de entrada pode apresentar correlação e dessa forma se tornarem redundantes (o que prejudica o funcionamento adequado da RNA).

### 3.2.9 Validação cruzada e generalização e testes do modelo

Já foi observado que o treinamento é realizado apresentando-se os padrões à rede. A apresentação de todo o conjunto de padrões de treinamento corresponde ao que se convencionou chamar de uma época para a rede neural. Geralmente são necessárias algumas épocas para que uma rede esteja treinada e pronta para produzir resultados.

Entretanto, para que a RNA não reconheça somente os padrões do conjunto de treinamento um procedimento de validação é executado. Essa validação, ou validação cruzada é feita da seguinte forma, o treinamento da RNA é iniciado apresentando todos os padrões do conjunto de treinamento. Esse procedimento é repetido por algumas épocas, em média de 10 a 20.

Neste instante a rede é testada com dados do conjunto de validação. O erro é então calculado e armazenado. Novamente o treinamento é reiniciado e executado por mais algumas épocas (mesmo número de épocas utilizadas anteriormente). Obviamente o erro associado ao treinamento é sempre inferior ao erro associado ao teste de validação. O que se avalia então não é a relação entre estes erros mas sim a curva de erro de validação, que deve atingir um mínimo para determinada época. Após esse mínimo de validação, mesmo com o erro de treinamento decrescendo, o de validação tende a crescer, como mostrado na Figura 21.

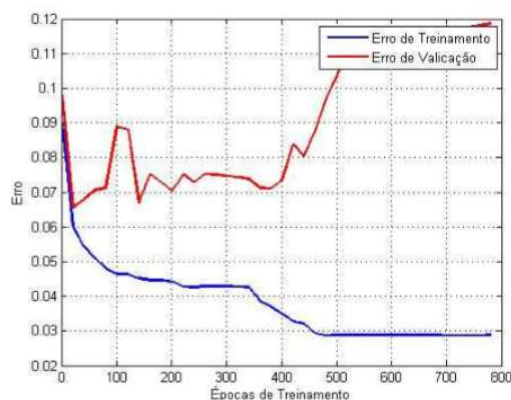


Figura 21: Relação entre o erro de treinamento e o erro de validação em uma RNA do tipo MLP com treinamento por Backpropagation

Fonte: Repositório UFSC, 2019

Neste ponto é correto afirmar que apesar de a rede melhorar o seu desempenho com os dados do conjunto de treinamento ela começa a perder poder de generalização. A rede está atendendo somente os padrões de treinamento e não mais conseguindo representar outros padrões. Esse fenômeno é conhecido como supertreinamento ou *overfitting*.



O teste final é executado com a rede que obteve o melhor desempenho (relacionado ao erro de validação) e com os dados do conjunto de teste (os quais nunca foram apresentados a RNA em questão).

### 3.2.10 Desempenho de uma RNA

De forma a avaliar os resultados de uma rede neural, o erro médio quadrático (MSE – *Mean Square Error*) é normalmente usado como indicador de desempenho da rede. A equação 10 expressa esta função:

$$MSE = \frac{1}{N} \cdot \sum_{k=1}^N (y_{jk} - y_{djk})^2 \quad (10)$$

Onde, N é o número de amostras de treinamento ou validação,  $y_{dj}$  é a saída da rede,  $y_j$  é o valor de saída desejado.

Durante o treinamento, o MSE normalmente começa com valores altos e então decresce conforme aumenta o número de épocas. Ao final, o MSE se mantém praticamente constante e a rede neural converge.

A capacidade de generalização de uma rede pode ser avaliada através dos exemplos de validação que não foram usados durante o treinamento. Quando uma rede é treinada excessivamente, a mesma pode perder a sua capacidade de generalização. Este fenômeno é denominado supertreinamento (*overfitting*), aonde o erro durante os treinos são bastante pequenos, porém podem ser grandes quando novos dados são apresentados à rede.

De forma a projetar uma RNA com bom poder de generalização, pode-se usar um conjunto de validação durante o processo de treinamento de forma a determinar qual o momento exato de se interromper o mesmo. Este método é conhecido como o Método da Parada Antecipada (*Early Stopping*), o qual testa a rede com os dados de validação após cada época. O ponto de parada antecipada é dado na época aonde o MSE de validação começa a crescer, como ilustrado na Figura 22.



Figura 22: Método da parada antecipada com conjunto de validação

Fonte: Repositório UFSC, 2019

## 4 Metodologia

### 4.1 Conjunto dos dados

Os dados são compostos por uma base histórica bem estruturada e volumosa de informações onde as medições datam de 2007 até hoje. São informações de poços reais, porém com seus nomes alterados, a fim de manter o sigilo da informação.

Ao todo são analisados e tratados 2000 amostras da fase do reservatório, de determinado campo A de litologia carbonática, isso corresponde a todos os 27 poços até então perfurados nesse local, considerando aproximadamente 75 amostras em cada poço. Mais dados vindos da ANP poderiam ser adicionados, porém para tornar a análise detalhada de cada poço, para essa dissertação, factível delimitou-se o espaço amostral.

Dessa forma poços semelhantes, em formação rochosa e lâminas de água, permitem ter uma menor divergência entre os valores estimados pela rede.

A fase de reservatório foi escolhida por ser a fase com maior impacto financeiro, por se tratar do trecho da perfuração que atinge a zona onde os hidrocarbonetos estão retidos. Dessa forma, os maiores custos estão atrelados a essa fase, quanto mais controlada for a perfuração, maior o retorno financeiro. A rede apresentada nesta dissertação pode ser utilizada nas demais fases do poço, mas para critério de análise, foi decidido estudar o ponto de maior criticidade e interesse na perfuração.

No primeiro momento, foram selecionados 11 parâmetros relacionados à perfuração de poços e foram escolhidos os 2 que mais se relacionavam com o ROP. Relação essa encontrada a partir de análises de fatores de correlação entre todos os parâmetros através de regressão linear.

Em um segundo momento, utilizando novamente regressão linear, porém com 15 parâmetros, novas correlações altas são encontradas. Quando essas relações são forçadas nos modelos é verificado que o impacto na previsibilidade de ROP é diferente do esperado.

Ou seja, em vez de diminuir a diferença entre o valor de referência e o valor previsto, a indução de correlação aumenta a diferença. Deste modo é deixado à própria inteligência da máquina a escolha da decisão pelas melhores correlações, fornecendo apenas para a aplicação todos os valores de parâmetros disponíveis para cada amostra.

Abaixo na Tabela 3 conseguimos ver todos os parâmetros que são fornecidos para cada amostra.

Tabela 3: Parâmetros analisados

Medidas [un]	Exemplos de valores	Faixa amostral / Normalização
Código IADC	M843	Normalizado para numeral (entre 1 e 15)
Desgaste	5-6-AQ-T-D-1-ID-TE	Não foi normalizado
Diâmetro da fase [pol]	12 1/4	9” e 12 1/4”
Peso do fluido [ppg]	9,9	Entre 9,4 e 10,3
Pressão [Pa]	5	Entre 2 e 60
Profundidade entrada [m]	5602	Valor inicial: 5320m
Profundidade saída [m]	5608	Valor final: 6290m
Rotações da Broca [rpm]	914	Entre 20 e 1490
ROP [m/h]	1,8	Entre 0,5 e 20
Tipo de Broca	Impregnada	Normalizado para numeral (entre 1 e 5)
Tipo de fluido	Sintético	Normalizado para numeral (entre 1 e 8)
Torque off (fora do fundo) [Nm]	5	Entre 2 e 27
Torque on (no fundo) [Nm]	7	Entre 3 e 40
Vazão [gpm]	730	Entre 100 e 915
WOB [Klb]	20	Entre 5 e 75

Por amostra, entende-se os parâmetros tomados em uma profundidade específica e em determinado instante de tempo, o que possibilita um poço com um trecho perfurado ter  $n$  amostras para a mesma fase. Esses parâmetros são medidos ou calculados de acordo com o que foi brevemente discutido no capítulo 2. Lembrando que todos esses parâmetros estão suscetíveis as movimentações da sonda, pelas instabilidades no mar.

#### 4.1.1 Tratamento dos dados

O tratamento dos dados consistiu em sanear as informações originais vindas diretamente do campo. Na literatura há diversas metodologias para tratamento de dados e optou-se pelo método de diagrama em caixas, conhecido como *Box-Plot*.

Para melhor entendimento deste método alguns conceitos devem ser apresentados. Média aritmética e desvio padrão são as medidas mais usadas para avaliar a posição central e a dispersão de um conjunto de valores. Contudo, essas medidas são fortemente influenciadas por valores discrepantes. Dessa forma, utiliza-se a mediana  $M_d$  que sofre menos impacto com os valores discrepantes.

Em geral, dado um conjunto de dados, a média é a medida de posição central mais adequada, quando se supõe que tais dados tenham distribuição razoavelmente simétrica, enquanto a mediana é uma alternativa para representar a posição central em distribuições muito assimétricas.

Além da mediana, para uso do *Box-Plot*, é necessário o cálculo do 1º e 3º quartis para definição dos limites inferiores e superiores da caixa. O 1º quartil (Q1) corresponde ao valor que delimita os 25% menores valores do conjunto de dados. Já o 3º quartil (Q3) é o valor que separa os 25% maiores valores, sendo o 2º quartil (Q2) a própria mediana. Ficando claro na Figura 23.

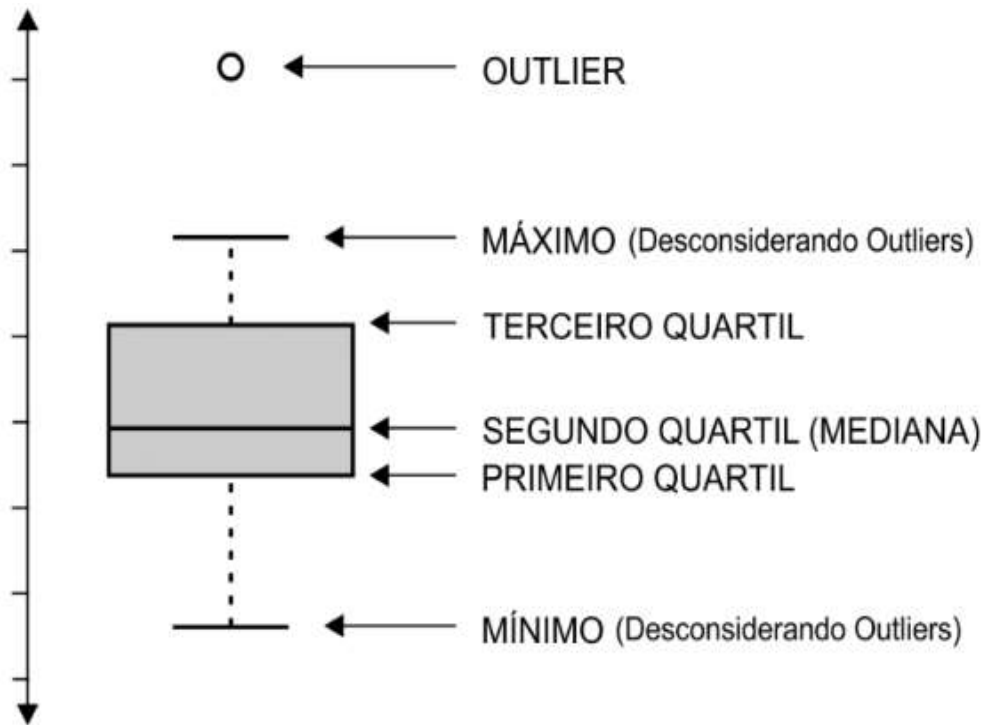


Figura 23: Tratamento dos dados

Fonte: OPER,2018

O limite de detecção de pontos fora do padrão (*outlier*) é construído utilizando o intervalo interquartil, dado pela distância entre o primeiro e o terceiro quartil. Sendo assim, os limites inferior e superior de detecção de *outlier* são dados pelas equações 11 e 12:

$$Limite_{inferior} = 1^{\circ}Quartil - 1,5(3^{\circ}Quartil - 1^{\circ}Quartil) \quad (11)$$

$$Limite_{superior} = 3^{\circ}Quartil + 1,5(3^{\circ}Quartil - 1^{\circ}Quartil) \quad (12)$$

A partir daí investigam-se os *outlier* a fim de não comprometer a realidade das informações, valores não registrados ou nulos também são retirados quando não condizem com a realidade operacional. Esses pontos são ocasionados por erro humano ou falha na medição dos sensores.

## 4.2 Linguagem Utilizada

Todas as simulações desta dissertação foram feitas na linguagem Python, a qual vem sendo constantemente utilizada para implementação de algoritmos relacionados a Ciência de dados.

A linguagem exibe uma grande biblioteca padrão, geralmente citada como um de seus maiores trunfos, disponibilizando ferramentas para desenvolvimento de diversos algoritmos. Para trabalhar com a inteligência artificial foi necessário utilizar algumas bibliotecas específicas, para Redes Neurais, como por exemplo KERAS.

Keras é uma biblioteca de alto nível para trabalhar com redes neurais, rodando sobre o *TensorFlow*. Ela simplifica muitas tarefas específicas e reduz muito a quantidade de código para a aprendizagem profunda.

A versão atual, e que foi utilizada é a 3.7.2, a linguagem possui licença livre e pode ser utilizada em múltiplas plataformas tais como Unix, Windows, .NET, MacOS, etc, além de permitir integração com outras linguagens, como por exemplo C.

### 4.3 Topologias de redes testadas

De acordo com o descrito na seção 3.2.9 foram testadas 6 topologias, conforme será apresentado na Tabela 4. Estas foram testadas e avaliadas separadamente para a escolha da topologia de melhor aderência ao problema.

Tabela 4: Topologias testadas

	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6
<b>n° de neurônios de entrada</b>	12	13	12	13	14	15
<b>n° de camadas intermediárias</b>	1	1	2	2	2	2
<b>n° de neurônios na 1ªcamada</b>	9	10	10	11	11	12
<b>n° de neurônios na 2ªcamada</b>	-	-	10	11	11	12
<b>n° de neurônios de saída</b>	1	1	1	1	1	1
<b>Parâmetros desconsiderados</b>	*Variável de desgaste *Profundidades de entrada e saída	*Profundidades de entrada e saída	*Variável de desgaste *Profundidades de entrada e saída	*Profundidades de entrada e saída	*Variável de desgaste	-

Detalhando um pouco mais os modelos escolhidos para teste, observa-se que o número de camadas varia pouco, visto que como explicado na seção 3.2.4, duas camadas são suficientes para a resolução da maioria dos problemas complexos.

Já o número dos neurônios de entrada, que representam os parâmetros de perfuração, podem variar dependendo de quais estão sendo considerados ou não no teste do modelo.

Também na Tabela 4 são apresentados quais os parâmetros estão sendo retirados de cada modelo testado. Durante a análise do impacto ficou claro que a variável de desgaste é o fator que interfere de forma mais contundente na previsibilidade. Como existem diversas classificações para os desgastes, ficou complicado achar combinações semelhantes de falhas em um número significativo de brocas para montar um padrão de repetições.

### 4.4 Erros de Previsões

A análise de resultados de uma simulação numérica depende do que se deseja provar, analisar e apresentar como resultado. Para isso foi feita uma análise numérica comparativa entre o ROP real ou valor de referência e o ROP calculado pela rede para cada amostra.

Todas as análises numéricas são baseadas conforme descrito a seguir.

#### 4.4.1 Erros de Previsão

A diferença entre o valor de referência e o valor previsto, pode ser estimativo a partir da Equação 13.

$$e_t = A_t - P_t \quad (13)$$

Onde,  $e_t$  representa o erro no período,  $A_t$  como valor referência no período e  $P_t$  o valor previsto para o período.

Na literatura são encontradas algumas formas de cálculo para esse erro de previsão. As mais utilizadas são:

- Erro médio: deve ser muito próximo de zero caso o modelo de previsão esteja atendendo ao esperado, porém caso a soma de erros positivos seja igual à soma de erros negativos, o modelo de previsão é imparcial.
- Erro médio absoluto: uma das medidas mais comuns de erro de previsão. O DMA não leva em conta se um erro foi sobrestimado ou subestimado, caracterizando-se por ser a média dos erros cometidos pelo modelo de previsão durante uma série de períodos de tempo.
- Erro quadrático médio: semelhante ao erro médio, mas com o erro de previsão elevado ao quadrado.
- Erro percentual: foi o erro escolhido para analisar os modelos dessa dissertação devido à facilidade de entendimento da sua unidade de medida. Será detalhado melhor à frente.
- Erro médio percentual: semelhante ao erro percentual, mas torna-se imparcial quando os erros positivos forem compensados pelos erros negativos.
- Erro médio percentual absoluto: se a previsão do item é medida em milhares, os valores do desvio médio absoluto e do erro quadrático médio podem ser muito grandes, dessa forma esse erro veio para facilitar o problema de dimensão dos resultados. Também será analisado e utilizado na dissertação

#### 4.4.2 Erro percentual

O erro percentual, EP, de acordo com Machado, Virgilio Cruz, *et al.* (2009) mede a porcentagem do erro em relação ao valor de referência. Calcula-se, subtraindo ao valor de referência no período  $t$  a previsão no respectivo período e divide-se o resultado pelo valor de referência utilizado anteriormente, conforme Equação 14.

$$EP = \frac{|A_t - P_t|}{A_t} 100 \quad (14)$$

#### 4.4.3 Erro médio percentual absoluto

De acordo com Heizer, Jay e Render, Barry, tanto os valores do desvio médio absoluto como do erro quadrático médio dependem da importância do item que está sendo previsto, o que pode causar problemas ao nível da dimensão dos resultados. Se a previsão do item é medida em milhares, os valores do desvio médio absoluto e do erro quadrático médio podem ser muito grandes.

A utilização do erro médio percentual absoluto, EMPA, é uma medida eficaz para resolver esse problema. O EMPA é a média da diferença absoluta entre os valores previstos e atuais, expressa em porcentagem dos valores atuais através da Equação 15.

$$EMPA = \frac{(\sum_{i=1}^n |EP_i|)}{n} \quad (15)$$

## 5 Resultados

### 5.1 Treinamento realizado

Para realizar o treinamento e os testes da rede, é utilizada a base de dados histórica, onde dividiu-se em 90% dos dados para treinamento – 24 poços e 10% dos dados para testes – 3 poços. Os poços de teste foram selecionados, um com cada padrão de broca (um poço Impregnada, um poço PDC e outro misto), com o intuito de verificar a aplicabilidade dos modelos em cada tipo específico de broca.

Da mesma forma optou-se por juntas o conjunto de poços de validação, que corresponderiam a 20% das amostras, com os poços de treinamento, pois a quantidade de amostras para treinamento ficaria muito reduzida o que poderia impactar negativamente no resultado do treinamento. Sendo assim, a divisão ficou apenas em dois grupos, fortalecendo o conjunto de treinamento.

Os dados precisaram sofrer um pré-processamento para ficarem utilizáveis pelas funções do Python, campos em branco foram retirados, pontos fora do padrão foram tratados individualmente, conforme descrito nas seções 3.2.8 e 4.1.1 desse material.

Os dados que foram utilizados para treinar a rede não serão usados para testá-la, dessa forma os valores são totalmente novos para o modelo, essa forma de teste é conhecida como “Teste Cego” (*blind test*), porém os valores são de conhecimento do programador da rede, o qual pode a partir dos resultados propor novas configurações de redes embasado na dimensão do erro.

Cada poço de teste é calculado individualmente em cada modelo para depois serem comparados com o real.

### 5.2 Escolha do modelo - Verificação dos resultados

O erro que foi utilizado para balizar a acurácia do modelo foi o Erro Percentual a forma de cálculo foi explicada anteriormente na seção 4.4.5 dessa dissertação, a escolha do erro percentual foi por sua contabilização ser em percentual facilitando o entendimento e a comparação entre os modelos.

Foram selecionados 3 poços para testar os modelos: um poço de broca impregnada, um poço de broca PDC e um poço misto (PDC e Impregnada). Essa seleção foi feita com o objetivo de facilitar a verificação do impacto do tipo de broca na simulação dos modelos.

Abaixo nas Tabelas 5, 6 e 7 estão representados o valor do erro médio percentual absoluto para cada poço simulado.

Tabela 5: Valores calculados dos erros (Poço 1 - Impregnada)

Erro	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6
<b>Erro Percentual</b>	28%	52%	59%	29%	27%	48%

Tabela 6: Valores calculados dos erros (Poço 2 - PDC)

Erro	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6
<b>Erro Percentual</b>	76%	66%	51%	78%	80%	69%

Tabela 7: Valores calculados dos erros (Poço 3 – Misto)

Erro	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6
<b>Erro Percentual</b>	64%	65%	71%	65%	57%	65%

Observando os resultados dos erros duas considerações podem ser levantadas: qual o modelo com menor erro encontrado e qual padrão de brocas obtêm-se os resultados mais precisos. Para essa conclusão, é necessário apresentar a Tabela 8 com os todos os desvios padrões expostos.

Tabela 8: Desvios padrão por modelo

Rede (Modelo)	Poço 1	Poço 2	Poço 3
<b>1</b>	0,99	4,12	3,42
<b>2</b>	0,97	3,76	3,21
<b>3</b>	0,99	4,15	3,51
<b>4</b>	1,03	3,80	3,26
<b>5</b>	0,80	3,71	3,03
<b>6</b>	1,34	3,89	3,16

Observando os resultados numéricos apresentados, duas visões podem ser retiradas da Tabela 8, uma vertical (dentro de cada poço) e outra horizontal (andando pelos poços). Na visão vertical percebe-se que as redes são próximas em desvio, mas o modelo 5 apresenta o menor valor de desvio, o que indica ter as respostas com maior acurácia.

As tabelas 5,6 e 7 mostram que a ordem de grandeza dos erros, no mesmo poço, também é próxima e que a rede 5 apresenta o menor erro percentual, o que novamente indica ter a resposta mais próxima ao valor de referência.

Dessa forma analisando esses dois resultados para a decisão da escolha da rede com mais acurácia aos dados reais a rede nº5 é a melhor escolha, independente do tipo de broca.

Agora analisando a Tabela 8 na horizontal, observa-se que os desvios variam mais, e esse resultado deve-se as características construtivas das brocas, discutidas na seção 2.3 dessa dissertação e a quantidade de amostras para determinada broca, pois quanto maior o número de amostras para determinado tipo, melhores são os resultados. Dessa forma as brocas Tricônicas e Híbridas não foram analisadas nessa dissertação, pois juntas correspondem a 10% de todas as amostras, o que não seria uma amostra representativa.

As brocas PDC (Poço 2) seriam excelentes em representatividade para a previsão, pois correspondem a 40% de todas as amostras, mas devido à sensibilidade com a



formação apresentam resultados mais dispersos, que podem ser visto com o valor alto de desvio padrão.

Já com as brocas Impregnadas (Poço 1), apresentam quantidade de amostras alta, 50% de todos os dados e por conta de sua forma de corte ser mais simples não exige maiores caracterizações das rochas a serem perfuradas, ficando com o menor desvio padrão. Quando no mesmo poço estão presentes os dois tipos de brocas (Poço 3), verifica-se que o desvio fica com valor intermediário entre os dois outros poços, pois acontece a compensação da parte Impregnada com a PDC.

Portanto, mesclando a escolha da rede com o tipo de broca e os valores de erros percentuais e o desvio padrão, obtiveram-se que a rede nº 5 para brocas impregnadas têm os resultados mais próximos do valor real.

Nas Figuras de 24 a 29 são apresentadas a relação entre ROP e profundidade, a fim de validar os pontos discutidos anteriormente.




Figura 24: Simulações - Poço 1 (broca impregnada)

Fonte: Autoria própria

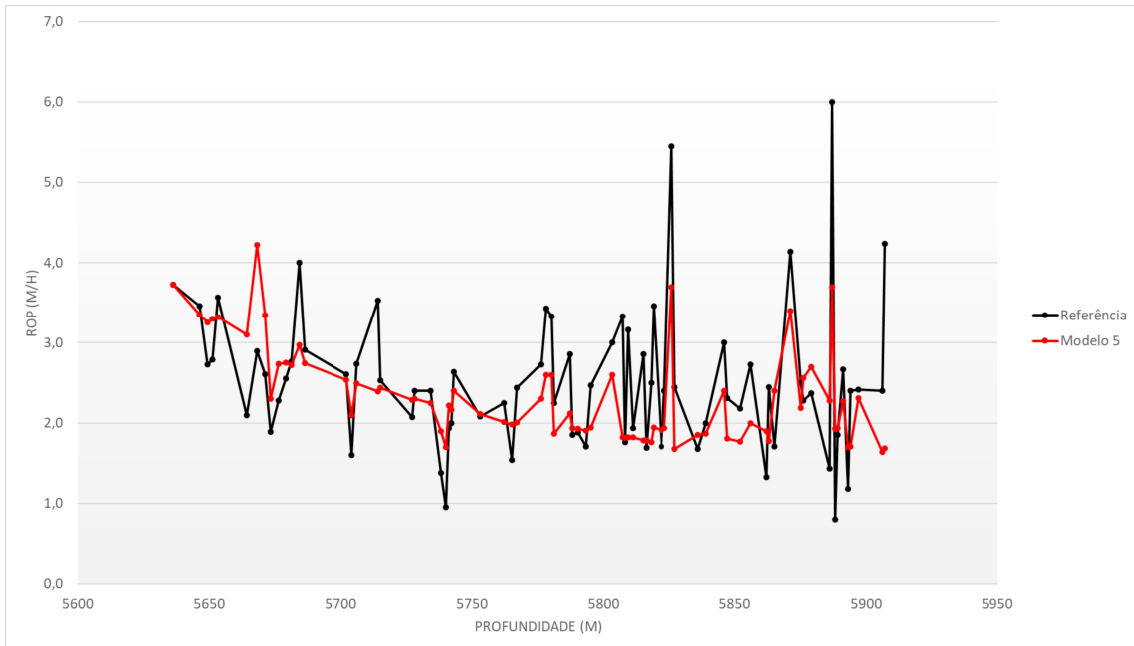


Figura 25: Simulações Modelo 5 - Poço 1 (broca impregnada)

Fonte: Autoria própria

Observasse que na maioria dos modelos os valores seguem a tendência do valor de referência, mas quando se analisa separadamente a rede n°5 percebe-se que em vários pontos é atingido o valor de referência de forma precisa.

Porém, quando o foco é na rede n°3 a discrepância entre a estimativa e a referência é facilmente vista.

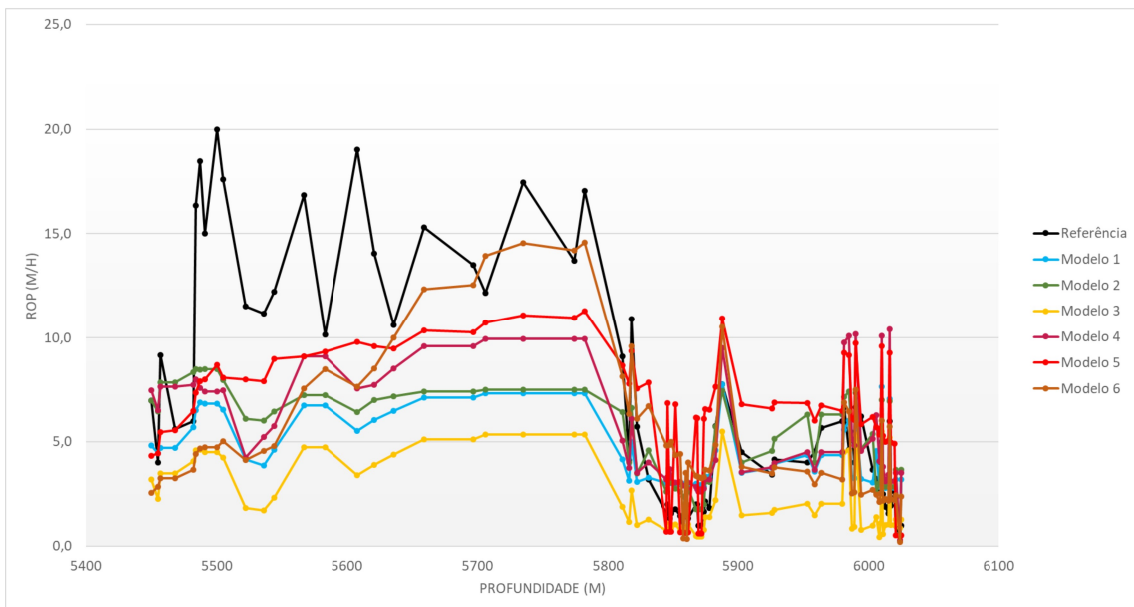


Figura 26: Simulações - Poço 2 (broca PDC)

Fonte: Autoria própria




Figura 27: Simulações Modelo 5 - Poço 2 (broca PDC)

Fonte: Autoria própria

Nas Figuras 26 e 27 fica clara a falha da rede em calcular o ROP para as brocas PDC. O decaimento da taxa de ROP ao longo do tempo não consegue ser prevista por nenhuma das redes simuladas. As redes preveem mais facilmente poços que seguem um valor constante no ROP, caso esse que acontece com as brocas impregnadas.




Figura 28: Simulações - Poço 3 (broca impregnada e PDC)

Fonte: Autoria própria




Figura 29: Simulações Modelo 5 - Poço 3 (broca impregnada e PDC)

Fonte: Autoria própria

Já nas Figuras 28 e 29 conseguem se observar o exato momento da troca de tipo de broca pela variação na previsão do ROP. A falta de previsibilidade no trecho em que a broca é PDC e a aderência no trecho em que é impregnada, reafirma o cenário ideal e o tipo de rede a ser utilizada.

### 5.3 Comparando com a Base de treinamento

Outra visão gráfica importante é como se comporta cada poço selecionado para o teste quando comparado com os poços que foram utilizados para o treinamento das redes. A análise é feita levando em consideração a média global por faixa de profundidade e o desvio padrão encontrado nas amostras de treinamento. Nenhuma simulação foi realizada para essa comparação.

Interpretando e entendendo os pontos analisados:

- Dentre os 24 poços utilizados para treinamento, retirasse o menor e o maior valor de profundidade de entrada encontrado, esses seriam os valores extremos da faixa;
- Dividissemos essa faixa em partes iguais de 50 metros, como abaixo:
  - Prof. min: 5300m ; Prof. máx.: 6200m;
  - Faixas: 5300m – 5350m; 5350m – 5400m; 5400m – 5450m; continua a sequência até 6150m – 6200m.
- Agora distribuímos todas as profundidades de entrada de cada poço que foram utilizadas para o treinamento dentro dessas faixas. Resultando em um conjunto de valores para cada faixa.

Exemplo: 5300m – 5350m

Valores: 3,4; 3,8; 3,1; 3,0; 3,4 m/h

- Com esses conjuntos de dados retira-se as médias e os desvios padrões de cada faixa, resultando em pontos que dão origem a linha que é traçada com todos os valores médios e seus limites inferiores e superiores.

Média aritmética: 3,34 m/h e desvios padrão dentro da faixa:  $\pm\sigma$  0,28 m/h

Essa comparação está representada nas Figuras 30, 31 e 32.

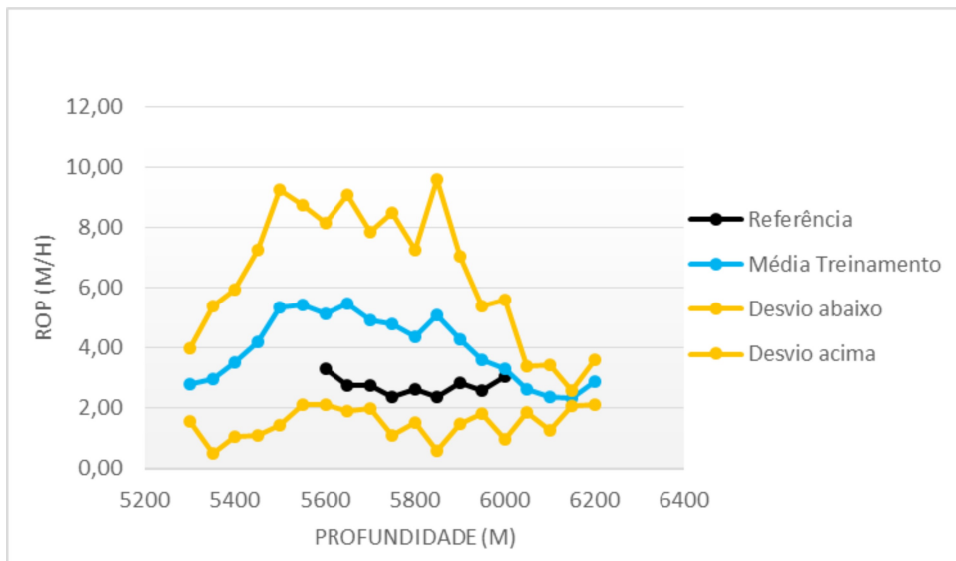


Figura 30: Comparação com a base de treinamento - Poço 1 (broca impregnada)

Fonte: Autoria própria

Na comparação gráfica realizada para o poço 1, observasse que todas as médias por faixa da extensão do poço estão dentro do núcleo formado pelos desvios padrões. O que reitera que as amostras utilizadas no treinamento são boas para poços com o perfil do poço 1.

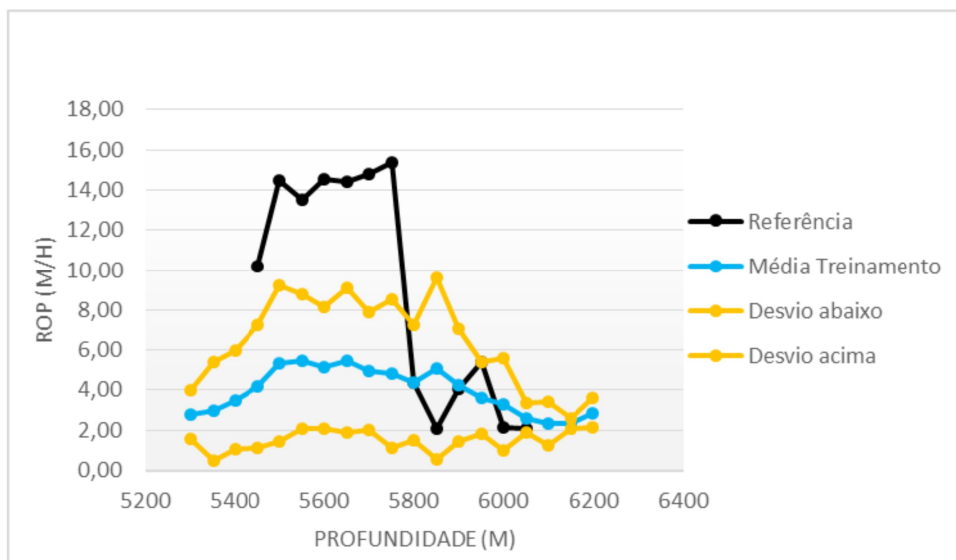


Figura 31: Comparação com a base de treinamento - Poço 2 (broca PDC)

Fonte: Autoria própria

Da mesma forma que a amostra foi ideal para brocas impregnadas, ela é insuficiente para os poços com Brocas PDC, como o poço acima. Percebesse que o trecho de maior aceleração na taxa de perfuração não conseguiu ser mapeado pelas amostras utilizadas no treinamento.




Figura 32: Comparação com a base de treinamento - Poço 3 (broca impregnada e PDC)

Fonte: Autoria própria

Fica, novamente, claro no gráfico que o trecho em que a broca PDC é utilizada os valores não se encaixam na média global dos valores treinados, mas quando a broca é trocada para a impregnada os valores voltam a estar totalmente dentro do núcleo.

## 5.4 Poços novos

Com o objetivo de testar a usabilidade do modelo em outros cenários, como por exemplo, em poços de outras Bacias, dois poços ainda não utilizados de duas regiões distintas, foram selecionados para serem testados na rede.

As taxas de perfuração variam de acordo com a litologia da região, e quando treinamos a rede com determinado cenário ela não consegue se adaptar sem um novo treinamento com dados de regiões semelhantes.

Verifica-se que o ideal para utilizar a rede é treiná-la novamente com os poços de correlação da região que se pretende prever o ROP com o objetivo de obter uma acurácia maior.

Abaixo, nas Figuras 33 e 34, são apresentados os valores de referência para os dois poços novos e o valor encontrado na simulação.




Figura 33: Simulação de confiabilidade - Poço 4

Fonte: Autoria própria

Na Figura 33 fica claro que a aderência é baixa em todo o trecho perfurado, a litologia encontrada no poço 4 permitiu taxas de perfuração mais altas que a litologia do campo original de treinamento. O poço 4 utilizou em todo o trecho perfurado broca impregnada, o que seria um facilitador para o modelo, mas devido a falta de dados de aprendizado semelhante, não foi possível alcançar os resultados esperados.




Figura 34: Simulação de confiabilidade - Poço 5

Fonte: Autoria própria

Na Figura 34 as previsões não seguem a tendência da curva de referência, se afastando em determinadas profundidades totalmente do esperado. Nesse poço ocorreu uma troca de brocas, no início e no meio da fase foi utilizada broca impregnada e para o final na profundidade de 5820m a broca foi trocada para PDC.

Na Tabela 8 os respectivos erros percentuais calculados para cada poço.

Tabela 9: Erro Percentual dos poços novos

Poço	Modelo 5
Poço 4 – Campo B	35%
Poço 5 – Campo C	47%

O resultado da previsibilidade para essas duas locações atingiu um índice de acerto inferior ao alcançado na simulação para o Campo A, utilizado para treinar originalmente a rede, uma vez que a rede não foi treinada novamente e por consequência não foram utilizados poços de correlação da mesma região.

## 5.5 Sensibilidade da rede

A sensibilidade ao treinamento realizado, ou seja, a capacidade de percepção às mudanças nas amostras estão diretamente relacionadas ao número de poços que são utilizados no treinamento.

No caso simulado foram utilizados 24 poços para treino e o percentual de acerto atingiu 73% do valor de referência para o poço 1 (broca impregnada), quanto maior o volume de dados inseridos na rede, mais próximos dos valores de referência são as respostas.

Para ter a percepção da sensibilidade à quantidade de dados mínima para treinamento, quatro simulações novas foram realizadas utilizando o modelo 5.

O objetivo é verificar qual a quantidade de poços mínima, utilizada no treinamento da rede, é necessário para permitir uma previsão adequada do ROP.

Os grupos utilizados são:

- 6 poços para treinamento
- 12 poços para treinamento
- 18 poços para treinamento
- 18 poços para treinamento (\* - alterando o conjunto de poços)

Abaixo, nas Figuras 35 e 36 é verificado o comportamento da previsão da rede para o poço 1 – broca impregnada, considerando os respectivos números de poços utilizados no seu treinamento.



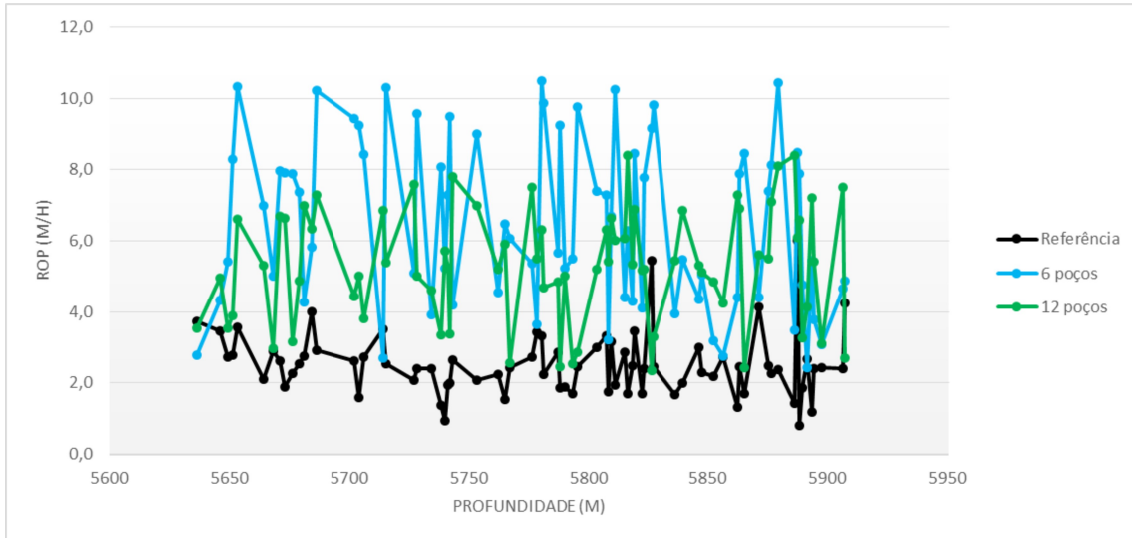


Figura 35: Sensibilidade do modelo: 6 e 12 poços

Fonte: Autoria própria




Figura 36: Sensibilidade do modelo: 18 e 18\* poços

Fonte: Autoria própria

Nos gráficos fica claro o impacto da quantidade de poços na simulação, quanto maior o número de dados, mais próximo do valor de referência. As curvas quando olhadas separadamente, em determinados trechos seguem a direção da tendência da referência mas ficam bem afastadas e em outros trechos a curva foge completamente da direção.

Esse cenário de seguir a tendência é esperado porque o poço que foi analisado perfurou com broca impregnada o que, como visto anteriormente, produz um erro menor no modelo estudado.

A simulação marcada com (\*) significa que foram utilizados 18 poços para treinamento, mas dessa vez um universo de poços diferentes do anterior que também utilizou 18 poços.

Tabela 10: Erro percentual variando o treinamento

<b>Erro</b>	<b>6 poços</b>	<b>12 poços</b>	<b>18 poços</b>	<b>18 poços (*)</b>
<b>Poço 1</b>	87%	74%	65%	61%

Com os percentuais de erro encontradas na Tabela 9, o modelo a partir de 18 poços apresenta o menor erro percentual, mas distante de ser o ideal para ser utilizado no treinamento da rede.

Com um número menor de poços o percentual fica difícil para ser utilizado em campo. Observa-se que com 6 poços o valor de acerto é em torno de 90%, tal valor não agregaria conhecimento prévio sobre o comportamento do ROP.

## 6 Conclusões

Durante a fase inicial do projeto foi realizada uma extensa bateria de testes visando à identificação de possíveis modelos a serem utilizados na previsão de ROP para perfuração de poços. Esta fase teve uma contribuição muito grande para com as etapas posteriores, pois a análise de vários modelos, mesmo que estes não fossem utilizados na rede final, forneceu um bom conhecimento do problema.

Esse conhecimento foi revelado pelo comportamento dos dados reais utilizados durante a etapa de testes.

Os resultados obtidos passaram por baterias de testes o que demonstraram que a arquitetura utilizada na rede é capaz de prever, com grau de confiabilidade possível de ser aplicado na indústria o ROP futuro de determinado cenário de poços. Alguns fatores que influenciam na confiabilidade dos resultados estão listados a seguir:

- Volume de dados: para conseguir uma boa confiabilidade nos resultados devesse possuir uma base de dados com o maior número de casos reais possíveis.
- Saneamento nos dados: a base de dados deve possuir o mínimo possível de dados com valores incorretos, pois muitas vezes esses valores incorretos levam a contradições que dificultam o aprendizado das redes neurais.
- Limitação no cenário litológico: facilitando a validação e teste das previsões.
- Testes com diferentes tipos de brocas: permitindo verificar em qual forma de corte a rede teria maior aderência.

Quando os fatores listados acima são contemplados, o sistema mostrou-se de grande valor na resolução do problema proposto baseado em dados histórico, em um cenário de determinada Bacia A e com o uso de brocas Impregnadas, tendo chegado a resultados aceitáveis e coerentes com a realidade.

Uma avaliação completa da veracidade dos resultados obtidos com o sistema só poderá ser feita com a utilização deste em poços reais. Mesmo cumprindo com qualidade seu objetivo, a rede apresenta algumas deficiências que restringem um pouco o seu uso:

- A rede prevê com erro alto o ROP para brocas PDC devido ao formato de corte e desgaste dessa broca.
- Restrição na área geográfica aplicada, o modelo depende de correlações próximas para ter boa aderência, a litologia é um fator que influencia bastante a resposta da rede.
- Precisa de um número mínimo de 18 poços da região específica para começar a ter um resultado de para uso.

Mesmo com restrições a rede proposta nesta dissertação é uma alternativa aos métodos tradicionais de previsão de ROP. Durante a etapa de testes e validação, foi percebida melhorias que podem vir a serem feitas no modelo para torná-lo mais robusto e mais confiável. As sugestões estão abaixo citadas como trabalhos futuros.

- Adicionar dados litológicos das formações como um novo parâmetro de entrada para a rede;
- Conseguir mais dados de poços de outras regiões para ampliar o espaço de abrangência da rede;
- Entender como as curvas de aprendizado da sonda afetam as taxas de perfuração.
- Utilização de métodos de IA para o processo de seleção no programa de brocas.

## Bibliografia

- Abouzeid, A.A., Cooper G.A. “*The Use of a Drilling Simulator to Optimize a Well Drilling Plan*”. Paper apresentado na Geothermal Resources Council Annual Meeting. San Antonio, Texas, 26-29, 2001.
- Aghassi, A. “*Investigation of Qualitative Methods for Diagnosis of Poor Bit Performance Using Surface Drilling Parameters*”. Dissertação de Doutorado, Louisiana State University, 2003.
- Alsaleh, A. Bit “*Optimization in Kuwait*”. Paper SPE 57552, apresentado em SPE/IADC Middle East Drilling Technology Conference, Abu Dhabi, UAE, 1999.
- Berkeley, I. S. What is Artificial Intelligence. , Acesso em Maio,2009, disponível em UCS Louisiana:  
<http://ucs.louisiana.edu/~isb9112/dept/phil341/wisai/WhatisAI.html>
- Bibliotecas Python para Data Science. (s.d.). Acesso em Janeiro de 2019, disponível em Data Science academy: <http://datascienceacademy.com.br/blog/top-20-bibliotecas-python-para-data-science/>
- Bourgoyne, A. T., Millheim, K. K., Chenevert, M. E. and Young Jr, F. S. “*Applied Drilling Engineering, Rotary Drilling Bits*”. SPE Textbook Series, Richardson, TX, 1991.
- Braga, A. d., Carvalho, A. P., & Ludermir, T. B. Redes Neurais Artificiais: Teoria e Aplicações. Rio de Janeiro: LTC, 2009.
- Bueno, E. I. Utilização de Redes Neurais Artificiais na Monitoração e Detecção de Falhas em Sensores do Reator IEAR1, IPEM - Dissertação de Mestrado. Instituto de Pesquisas Energéticas e Nucleares (IPEN). São Paulo, p. 111, 2006.
- Carlos M. C. Jacintoa, Paulo J. Freitas Filho, Sílvia M. Nassarb, Mauro Roisenbergb, Diego G. Rodriguesb, Mariana D. C. Limab . “*Optimization Models and Prediction of Drilling Rate (ROP) for the Brazilian Pre-Salt Layer*”. AIDIC, v. 33, ISSN:1974-9791, ISBN:978-88-95608-24-2, 2013,.
- Coelho, Dennis Kerr. Sistema Neural para previsão de tempo de perfuração de poços de petróleo - Dissertação de Mestrado. Universidade Federal de Santa Catarina . Santa Catarina, 1998.
- Cooper, G. A., Hatherly, P. “*Prediction of rock mechanical properties from Wire-line Data and their use in Drilling Simulation*”. Paper SPE 83509, apresentado em SPE Western Regional/AAPG Pacific Section Joint Meeting, Long Beach, California, U.S.A., 19–24, 2003.
- Falconer, I.G., Burgess, T. M., and Sheppard, M. C. “*Separating Bit and Lithology Effects from Drilling Mechanics Data*”. Paper IADC/SPE 17191, Drilling Conference, Dallas, TX, 1988.

- Grant, M. A. "*Optimization of drilling acceptance criteria*". Geothermics, 38, 247-253, 2009.
- Granatyr J. "Course of machine learning and data science". Rio de Janeiro, Rio de Janeiro, Brasil. Disponível em UdeMY: [www.udemy.com](http://www.udemy.com). Acesso em maio de 2018.
- Hankins D.; Salehi S.; Saleh F. K, "*An Integrated Approach for Drilling Optimization Using Advanced Drilling Optimizer*". Journal of Petroleum Engineering, Artigo ID 281276, p. 12, 2014.
- Haykin, Simon S. Redes neurais: princípios e prática. Mcmillan Bookman, 2001.
- Hareland, G., and Hoberock, L.L. "*Use of Drilling Parameters To Predict InSitu Stress Bounds*". Paper SPE 2572, apresentado em SPE IADC Drilling Conference, Amsterdam, Netherlands, 23-25, 1993.
- Hornik, K.; Stinchcombe, M.; White, H. "*Multilayer Feedforward Networks are Universal Approximators*". Neural Networks, v. 2, n. 5, p. 359-366, ISSN ISSN:0893-6080, 1989.
- Kaiser M. J. "*Modeling the time and cost to drill an offshore well*". Energy, 34(9), 1097-1112, 2009.
- Kuru, E. "*Effects of Rock/Cutter Friction on PDC Bit Drilling Performance*", Tese de Doutorado, Louisiana: Louisiana State University, 77247, apresentado em: IADC/SPE Asia Pacific Drilling Technology, Jakarta, Indonesia, 2002.
- Leea B.Y.; LIUA H. S.; TARNGB Y. S. , "*Modeling and optimization of drilling process*". Journal of Materials Processing Technology, 74, pp. 149-157; 1998.
- Luger, G. F., Estruturas e Estratégias para a Solução de Problemas Complexos, 4<sup>o</sup> ed. : Bookman, Porto Alegre, 2004.
- Macêdo Fchine Régis de Araújo, Joseana. Inteligência artificial, Material de pós-graduação em Ciência da Computação, UFCG, 2017.
- MACHADO, Virgílio Cruz; CABRITA, Maria do Rosário - Técnicas de Previsão. Caparica: FCT/UNL, cap. II, 2009.
- Mazlish, B., "*The man-machine and artificial intelligence*". Disponível em Stanford.edu: <https://web.stanford.edu/group/SHR/4-2/text/mazlish.htm>, 1995.
- Millheim, K.K. and Gaebler, T. Virtual Experience Simulation for Drilling -The Concept. Paper SPE 52803, presented at the SPE/IADC Drilling Conference, Amsterdam, Netherlands, 9-11 March, 1999.
- McCarthy, J., Minsky, M. L., Rochester, N., et. al., "*A PROPOSAL FOR THE DARTMOUTH SUMMER RESEARCH PROJECT ON ARTIFICIAL*

- INTELLIGENCE*". Disponível em Stanford.edu: <http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>, 1955.
- Mendes, J. R. O uso de conhecimento Especialista e de base de dados na seleção de brocas de perfuração. (U. E. Campinas, Ed.) Campinas, São Paulo, Brasil: Faculdade de Engenharia Mecânica, 1998.
- Mendel, Jerry M. "*Fuzzy logic systems for engineering: a tutorial*". Proceedings of the IEEE, v. 83, n. 3, p. 345-377, 1995.
- Nexus Journal, disponível em: <https://www.nexojournal.com.br/grafico/2018/06/06/A-produ%C3%A7%C3%A3o-o-consumo-e-o-pre%C3%A7o-do-petr%C3%B3leo-no-mundo-ao-longo-dos-anos>, acessado em: Fevereiro 2019.
- Nygaard, R., and Hareland, G., Drops Technology, Budiningsih, Y., Conoco Indonesia, H.E. Terjesen, H.E., Statoil ASA and Stene, F., Norsk Hydro ASA. Eight Years "*Experience with a Drilling Optimization Simulator in the North Sea*". Paper IADC/SPE, 1998.
- Pessier, R.C., and Fear, M.J. "*Quantify Common Drilling Problems with Mechanical Specific Energy and a Bit-Specific Coefficient of Sliding Friction*". Paper SPE 24584, apresentado em: Annual Technical Conference and Exhibition of Society of Petroleum Engineers, Washington, DC, 1992.
- Python-fundamentos. Disponível em: [http://pt.wikipedia.org/wiki/Python#Compilador\\_de\\_bytecode](http://pt.wikipedia.org/wiki/Python#Compilador_de_bytecode) , Acessado em Março de 2019.
- R.A. Arehart – "*Drill-Bit Diagnosis With Neural Networks*". Paper SPE 18558, apresentado em: Annual Technical Conference and Exhibition, San Antonio, 1990.
- Rampersad, P.R., Hareland, G. and Boonyapaluk, P. "*Drilling Optimization Using Drilling Data and Available Technology*". Paper SPE 27034 apresetado em: SPE LAPEC Conference, Buenos Aires, 1994.
- Rezende, S. O. Sistemas Inteligentes:fundamentos e aplicações. Barueri: Manole, 2003.
- Silva, I. N., Spatti, D. H., & Flauzino, R. A. Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas. Fundamentos Teóricos e Aspectos Práticos (1º ed.). Rio de Janeiro: Artliber, 2010.
- Smith, J. "*Diagnosis of Poor PDC Bit Performance*". Tese de doutorado, Louisiana: Louisiana State University, 1998.
- Smith, J. "*Performance Analysis of Deep PDC Bits Runs in Water-Base Muds*". Apresentado em: ASME - Drilling Technology Symposium, Houston, Texas, 2000.

- Smith, J., and Lund, J. “*Single Cutter Tests Demonstrate Cause of Poor PDC Bit Performance*”, Apresentado em: ASME - Drilling Technology Symposium, Houston, Texas, 2000.
- Timoszczuk, Antonio Pedro. Reconhecimento automático do locutor com redes neurais pulsadas. Tese de Doutorado - Escola Politécnica da Universidade de São Paulo, 2004.
- Tony Hey, Stewart Tansley, Kristian Tolle. “O quarto paradigma – Descobertas científicas na era e-science”, Oficina de textos, 2011.
- Triggia, A. A., Correia, C. A., Filho, C. V., & et al., Fundamentos de Engenharia de Petróleo (2º ed.). Rio de Janeiro: Interciência, 2004.
- Turing, A. M. “*Computing machinery and intelligence*”. Disponível em: New York Times Library: <http://www.nytimes.com/library/cyber/surf/1106surf-turing.html>, acessado em: Janeiro de 2019.
- Uboldi, V., Civolani, L., Zausa, F. “*Rock strength measurements on cuttings as input data for optimizing drill bit selection*”. Paper SPE 56441 apresentado em: SPE Annual Technical Conference and Exhibition, Houston, TX, 1999.
- Warren T.M. “*Drilling Model for Soft-Formation Bits*”. JPT, vol 33, no. 6, pp 963, 1981.
- Warren, T.M. “*Penetration Rate Performance of Roller-Cone Bits*”. SPE 13259, apresentado em: SPE Drilling Engineering, p. 9-18. Houston, TX, 1987.
- Warren, T.M., and Armagost, W.K. “*Laboratory Drilling Performance of PDC Bits*”. SPE 15617, 61st apresentado em: Annual Technical Conference and Exhibition of Society of Petroleum Engineers, New Orleans, LA, 1986.
- Wilmot, G.M., Calhoun, B., and Perrin, V.P. “*Formation drillability-definition, quantification and contributions to bit performance evaluation*”. Paper SPE 57558, apresentado em: Proceedings of the SPE/IADC Middle East Drilling Technology Conference held in Abu Dhabi, UAE, 1999.
- Yost K.; Valenti A.; Einstein H.H. “*Estimating cost and time of wellbore drilling for Engineered Geothermal Systems (EGS)*”. Geothermics, 53, 85-99; 2015.

## Anexo A

Segue um exemplo das amostras de poço. Poço representado – Poço 1 com broca impregnada.

Diâmetro da fase	Tipo de fluido	Peso do fluido	Código IADC	Desgaste	Tipo de Broca	Prof entrada	Prof saída	WOB	RPM broca	Vazão	Torque off	Torque on	Taxa
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5636	5646	25	1000	790	13	13	3,7
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5646	5649	30	1000	790	13	13	3,5
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5649	5651	35	1000	790	13	13	2,7
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5651	5653	30	1000	790	13	13	2,8
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5653	5664	30	1000	790	13	13	3,6
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5664	5668	30	1000	790	12	13	7,1
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5668	5671	28	881	690	12	13	2,9
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5671	5673	26	953	750	12	12	2,6
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5673	5676	30	953	750	12	12	1,9
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5676	5679	30	953	750	12	12	2,3
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5679	5681	28	1000	790	12	12	2,6
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5681	5684	30	1000	790	12	12	2,8
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5684	5686	25	1000	790	12	12	4,0
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5686	5702	30	1000	790	12	12	2,9
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5702	5704	30	1000	790	12	12	2,6
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5704	5706	30	1000	790	12	12	1,6
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5706	5714	35	1000	790	12	12	2,7
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5714	5715	35	1000	790	12	12	3,5
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5715	5727	35	1000	790	12	12	2,5
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5727	5728	35	1000	790	12	12	2,1
12 1/4	OLEDRIILL	9,9	I1813	5-5-ID-T-D-1-MA-PF	IMP	5728	5734	35	1000	790	12	12	2,4



			D-1-MA- PF									
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5734	5738	35	1000	790	12	12	2,4	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5738	5740	35	1000	790	12	12	1,4	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5740	5741	35	1000	790	12	12	1,0	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5741	5742	30	1000	790	12	12	1,9	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5742	5743	35	1000	790	12	12	2,0	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5743	5753	35	1000	790	12	12	2,6	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5753	5762	35	1000	790	12	12	2,1	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5762	5765	35	1000	790	12	12	2,3	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5765	5767	35	1000	790	12	12	1,5	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5767	5776	34	1000	790	12	12	2,4	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5776	5778	35	1000	790	12	12	2,7	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5778	5780	35	1000	790	12	12	3,4	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5780	5781	35	1000	790	12	12	3,3	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5781	5787	35	1000	790	12	12	2,3	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5787	5788	28	1000	790	12	12	2,9	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5788	5790	30	1000	790	12	12	1,8	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5790	5793	30	1000	790	12	12	1,9	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5793	5795	30	1000	790	12	12	1,7	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5795	5803	30	1000	790	12	12	2,5	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5803	5807	30	1000	790	12	12	3,0	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5807	5808	30	1000	790	12	12	3,3	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5808	5809	30	1000	790	12	12	1,8	
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T- D-1-MA- PF	IMP	5809	5811	30	1000	790	12	12	3,2	

12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5811	5815	30	1000	790	12	12	1,9
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5815	5816	35	1000	790	12	13	2,9
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5816	5818	35	1000	790	12	13	1,7
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5818	5819	35	1000	790	12	13	2,5
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5819	5822	30	1000	790	12	13	3,5
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5822	5823	30	1000	790	12	13	1,7
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5823	5826	28	1000	790	12	12	2,4
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5826	5827	28	1000	790	12	12	5,5
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5827	5836	31	1000	790	12	12	2,5
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5836	5839	30	1000	790	12	13	1,7
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5839	5846	30	1000	790	12	13	2,0
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5846	5847	35	1000	790	12	13	3,0
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5847	5852	30	1000	790	12	13	2,3
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5852	5856	30	1000	790	12	13	2,2
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5856	5862	30	1020	790	12	13	2,7
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5862	5863	28	1000	790	12	13	1,3
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5863	5865	28	1000	790	12	12	2,4
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5865	5871	25	1000	790	12	14	1,7
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5871	5875	25	1000	790	12	12	4,1
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5875	5876	25	1000	790	12	13	2,5
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5876	5879	23	1000	790	12	14	2,3
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5879	5886	22	1000	790	12	14	2,4
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5886	5887	25	1000	790	12	14	1,4
12 1/4 OLEDRILL	9,9 I1813	5-5-ID-T-D-1-MA-PF	IMP	5887	5888	20	1000	790	12	14	6,0



			D-1-MA- PF									
12 1/4 OLEDRILL	9,9	I1813	5-5-ID-T- D-1-MA- PF	IMP	5980	5994	28	988	780	12	15	3,0
12 1/4 OLEDRILL	9,9	I1813	5-5-ID-T- D-1-MA- PF	IMP	5994	5997	25	1000	790	12	15	3,2
12 1/4 OLEDRILL	9,9	I1813	5-5-ID-T- D-1-MA- PF	IMP	5997	6006	25	1000	790	12	15	2,7
12 1/4 OLEDRILL	9,9	I1813	5-5-ID-T- D-1-MA- PF	IMP	6006	6008	25	1000	790	12	15	2,1
12 1/4 OLEDRILL	9,9	I1813	5-5-ID-T- D-1-MA- PF	IMP	6008	6024	25	1000	790	12	15	2,9
12 1/4 OLEDRILL	9,9	I1813	5-5-ID-T- D-1-MA- PF	IMP	6024	6030	25	1020	790	12	15	4,8
12 1/4 OLEDRILL	9,9	I1813	5-5-ID-T- D-1-MA- PF	IMP	6030	6040	26	1020	790	12	14	2,9
12 1/4 OLEDRILL	9,9	I1813	5-5-ID-T- D-1-MA- PF	IMP	6040	6046	22	1020	790	12	14	2,4
12 1/4 OLEDRILL	9,9	I1813	5-5-ID-T- D-1-MA- PF	IMP	6046	6053	20	1020	790	12	14	3,2