

UNIVERSIDADE DE SÃO PAULO
ESCOLA POLITÉCNICA
Departamento de Engenharia de Minas e de Petróleo



Cristiano Eduardo Agostini

Aprendizado de Máquina Probabilístico
Aplicado na Mecânica de Perfuração de Poços de
Petróleo

Supervisor: Prof. Dr. Marcio Augusto Sampaio Pinto

Santos, SP

2021

Agradecimentos

Ao meu supervisor Prof. Dr. Marcio Sampaio pelo apoio e incentivo neste trabalho de pesquisa.

Ao departamento de Engenharia de Minas e de Petróleo na cidade de Santos.

Petróleo Brasileiro S.A. (PETROBRAS) pelo fornecimento e liberação de uso dos dados de mecânica de perfuração.

E em especial a minha família (Adriana, Bruno e Eduardo) pelo carinho e suporte.

Resumo

A utilização de técnicas de aprendizado de máquina na indústria de petróleo tem evoluído ao longo dos últimos anos, com notável evidência na comunidade mundial de engenharia de petróleo. Os dados disponíveis nos sistemas de perfuração não têm sido explorados com todo o seu potencial, com relação ao imenso número de informações geradas com as novas instrumentações instaladas nas sondas de última geração. A utilização destes dados de forma consistente pode auxiliar na tomada de decisão em tempo real durante a perfuração, visando otimizar os processos e minimizar os custos de construção de poços. Este projeto de pesquisa teve como objetivo, gerar um modelo de classificação de desgaste de broca para análise em tempo real, através do uso de rede neural probabilística, para interpretação dos padrões de torque de superfície. Para isso, utilizou-se a técnica de transformação de sinais para o domínio da frequência, através da densidade espectral de potência, transformada posteriormente em imagem. O algoritmo de autoencoder convolucional foi utilizado para extração de características principais das imagens geradas. Esta técnica permitiu extrair os mapas de características principais da base de dados, gerando o treinamento de classificação da rede neural probabilística. Foram efetuados vários testes e a rede neural probabilística mostrou-se superior frente aos demais classificadores clássicos de aprendizado de máquina. Os resultados mostraram-se satisfatórios, onde comprovou-se acurácia de 87% e precisão de 83% para o modelo proposto. Também foram efetuadas simulações em tempo real, utilizando 2 poços com dados de campo, com resultados satisfatórios. O modelo proposto comprova o elevado potencial de aplicação em análise de tempo real durante a perfuração, além de abrir novas perspectivas para o auxílio na tomada de decisão operacional.

Palavras Chave: Mecânica da Perfuração, Aprendizado de Máquina, Rede Neural Probabilística.

Abstract

The use of machine learning techniques in the oil well industry has evolved over the past few years, with notable evidence in the world petroleum engineering community. The data available in drilling systems have not been explored to their full potential, in relation to the immense number of information generated with the new instrumentations installed in the latest rigs. The use of this data in a consistent manner can assist in real-time decision-making during drilling, aiming to optimize processes and minimize well construction costs. This research project aimed to create a drill wear classification model for real-time analysis, using a probabilistic neural network, for surface torque patterns interpretation. For this, we used the signal transformation technique for the frequency domain, through the power spectral density, which was later transformed into an image. The convolutional autoencoder algorithm was used to extract the main features of the generated images. This technique allowed to extract the main dataset features, generating the training dataset classification for probabilistic neural network. Several tests were carried out and the probabilistic neural network proved to be superior to the other classic machine learning classifiers. The results were satisfactory, with 87% accuracy and 83% precision for the proposed model. Real-time simulations were also carried out, using field data from 2 offset wells, with satisfactory results. The proposed model proves the high potential for real-time application analysis during drilling operations, in addition to opening new perspectives for aid in operational decision making.

Key words: Drilling Mechanics, Machine Learning, Probabilistic Neural Network.

Sumário

1	INTRODUÇÃO	10
1.1	Motivação	10
1.2	Aspectos de perfuração.....	10
1.3	Aprendizado de máquina	12
1.4	Aplicações de aprendizado de máquina na perfuração.....	14
1.5	Objetivo	17
2	METODOLOGIA.....	18
2.1	Preparação dos dados de entrada	18
2.2	Classificação supervisionada do desgaste da broca.....	22
2.3	Construção de imagens espectrais	23
2.4	Extração de características.....	24
2.5	Classificação através de rede neural probabilística	26
2.6	Fluxo de trabalho	28
3	ESTUDO DE CASO	31
3.1	Conceitos operacionais de perfuração	31
3.2	Construção do modelo de aprendizado.....	32
3.3	Deep Convolutional Autoencoder	35
3.4	Análise comparativa entre algoritmos	38
3.5	Classificação através da PNN.....	40
4	RESULTADOS E DISCUSSÕES	43
4.1	Comparativos entre modelos de classificação	43

4.2	Testes de validação de campo	44
4.3	Pressão de bombeio com característica principal	49
4.4	Sugestões para implementação em tempo real	51
5	CONCLUSÕES.....	54
5.1	Trabalhos futuros	55
6	REFERÊNCIAS	56

Lista de Tabelas

Tabela 1 – Poços submarinos do pré-sal utilizados para base de treinamento.....	32
Tabela 2 - Arquitetura do modelo de autoencoder convolucional.....	37
Tabela 3 - Precisão para modelos de aprendizado de máquina clássico.	39
Tabela 4 – F1 Score para modelos de aprendizado de máquina clássico.....	40
Tabela 5 – Resultados dos modelos de aprendizado de máquina para DCAE.....	44
Tabela 6 – Dados dos poços utilizados para validação de campo.....	47

Lista de Figuras

Figura 1 – Configuração típica de um poço do pré-sal (Agostini, et. al., 2019).	12
Figura 2 – Broca de perfuração do tipo PDC (Huang et al., 2018).	19
Figura 3 – Mecanismo de corte simplificado broca do tipo PDC (Wang et al., 2019). .	20
Figura 4 – Coluna de perfuração com componentes básicos (Leine et al., 2002).	21
Figura 5 - Arquitetura de uma rede neural probabilística.....	26
Figura 6 – Fluxo de trabalho para o treinamento do modelo proposto.	28
Figura 7 – Fluxo de trabalho para classificação do modelo proposto.	29
Figura 8 – PSD do torque de superfície em janela de 30 min.	33
Figura 9 - Imagem da PSD do torque de superfície em janela de 30 min.	34
Figura 10 - Imagem PSD do torque de superfície após tratamento com histograma em janela de 30 min.....	34
Figura 11 - PCA do sinal do torque de superfície da base total de dados.	35
Figura 12 - PCA do PSD do torque de superfície (todos os dados).	36
Figura 13 - PCA do DCAE do torque de superfície (todos os dados).....	36
Figura 14 - Treinamento do autoencoder convolucional.	38
Figura 15 - Parâmetro de suavização em função da área abaixo do gráfico da curva ROC.	41
Figura 16. Curva ROC com validação cruzada para o fator de suavização $\sigma = 0,47$	42
Figura 17 - Comparativo entre modelos de aprendizado de máquina utilizado DCAE.	43
Figura 18 - Matriz de confusão da rede neural probabilística.	45

Figura 19 - Matriz de confusão normalizada para a rede neural probabilística.	45
Figura 20 – Simulação em tempo real do Poço “J”.	46
Figura 21 – Simulação em tempo real do poço “L”.	46
Figura 22 – Simulação em tempo real do poço “D”	47
Figura 23 – Simulação em tempo real do poço “N”	48
Figura 24 – Simulação em tempo real do poço “O”	48
Figura 25 - PCA do PSD da pressão de bombeio de superfície (todos os dados).	50
Figura 26 - PCA do DCAE da pressão de bombeio de superfície (todos os dados).	51

Acrônimos

Acrônimo	Descrição
AE	Autoencoder
AUC	Area Under Curve
BHA	Bottom Hole Assembly
CDF	Cumulative Density Function
CNN	Convolutional Neural Networks
CSD	Centro de Suporte a Decisão
DCAE	Deep Convolutional AutoEncoder
FFT	Fast Fourier Transform
FP	False Positive
FPR	False Positive Rate
IADC	International Association of Drilling Contractors
KDE	Kernel Density Estimation
KNN	K-nearest neighbors
NFFT	Length of the FFT
PCA	Principal Component Analysis
PDC	Polycrystalline Diamond Compact
PDF	Probability Density Function
PNN	Probabilistic Neural Network
PSD	Power Spectral Density
PSD DCAE	Power Spectral Density generated from autoencoder
PSD IMG	Original Power Spectral Density Image
ROC	Receiver Operating Characteristic
RPM	Rotação da coluna de perfuração (revoluções por minuto)
SVM	Support Vector Machine
TORQ	Dados brutos do sinal do torque de superfície
TPR	True Positive Rate
PSB	Peso sobre Broca

1 INTRODUÇÃO

Nesta seção são apresentadas a motivação do trabalho de pesquisa, conceitos gerais da mecânica de perfuração e aprendizado de máquina de forma global. Além disso, apresenta-se o estado da arte nas aplicações de aprendizado de máquina para perfuração e o objetivo desta pesquisa.

1.1 Motivação

Existem atualmente uma vasta quantidade de dados disponíveis no sistema de monitoramento em tempo real das operações de perfuração na Petrobras, os quais ainda carecem de tratamento avançado para auxílio na tomada de decisão, seja em tempo real ou na melhoria dos projetos visando aumentar o desempenho, confiabilidade e segurança das operações de perfuração. Cenários problemáticos ocorrem com frequência durante a perfuração de um poço, tais como: vibrações excessivas, otimização de parâmetros operacionais e análise de integridade da coluna de perfuração.

Os sistemas e trabalhos atuais focam em aprendizado de máquina com técnicas para classificação ou regressão determinísticas (Toreifi et al., 2017; Wang e Salehi, 2015), porém não abordam as questões de incertezas, as quais só podem ser capturadas com auxílio da abordagem probabilística. Esta abordagem permite avaliar com maior clareza e confiabilidade o desempenho e otimização das operações de perfuração. Diante disso, um sistema no qual pode-se analisar o desempenho e auxiliar no processo de decisão na perfuração em tempo real, baseado em dados, agrega valor ao negócio das empresas.

1.2 Aspectos de perfuração

A perfuração de um poço de petróleo offshore consiste basicamente na perfuração da rocha, instalação e cimentação de revestimentos e sistemas submarinos de cabeça de poço. As atividades de perfuração são efetuadas em seções ou fases, as quais são divididas conforme critérios de projeto, extensão da profundidade total do poço, litologia das rochas a serem perfuradas, pressão de poros, fratura das rochas e finalidade do poço.

Atualmente as sondas de tecnologia de última geração, principalmente em operação nos campos do pré-sal da costa brasileira, possuem elevada capacidade de automação e instrumentação. As operações de perfuração são rotineiramente monitoradas pelas empresas operadoras, companhias de serviço e até mesmo pelas equipes da sonda contratada. Como exemplo, temos o Centro de Suporte a Decisão (CSD) da Petrobras, o qual monitora em tempo real todas as operações de perfuração da empresa, visando tomadas de decisões voltadas para otimização, integridade e segurança nas operações de construção de poços.

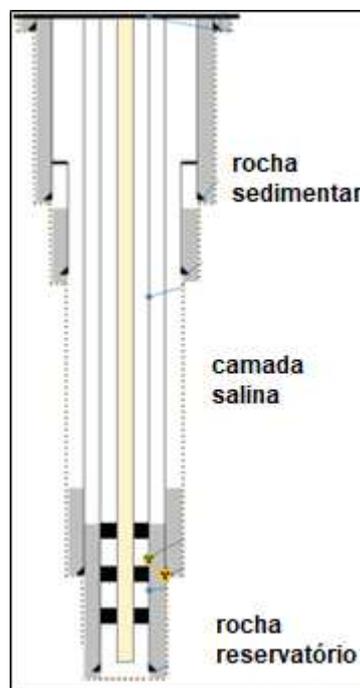
As principais variáveis monitoradas nos centros de acompanhamento da perfuração, são aquelas que mostram os parâmetros mecânicos e hidráulicos da perfuração. Os parâmetros são divididos em dados de superfície e de fundo, ou seja, aqueles sensores instalados próximos a broca de perfuração. A aquisição destes dados é feita pelos sensores da sonda de perfuração (dados de superfície) e os dados de fundo, são coletados pelos sensores instalados na própria coluna de perfuração, os quais são transmitidos até a superfície por telemetria via pulsos de fluido de perfuração.

Os parâmetros mecânicos normalmente utilizados para acompanhamento da perfuração são: Peso sobre Broca (PSB), Rotação da coluna na Superfície (RPM), Torque na Superfície (TORQ), Vazão e Pressão de Bombeio de fluido de perfuração pela coluna. Estes sensores normalmente são pertencentes a sonda de perfuração. Os sensores instalados no conjunto de fundo da coluna de perfuração, conhecido como BHA (Bottom Hole Assembly), transmitem em tempo real dados mecânicos próximo a broca de perfuração, tais como: Peso sobre Broca no fundo (PSBf), Rotação da coluna no fundo (RPMf), Torque no fundo (TORQf), Momento Fletor no fundo (Mflef) e dados de vibração da coluna: lateral, axial e torcional. A taxa de transmissão dos dados de fundo é inferior aos dados de superfície, dado que as informações mais importantes para serem transmitidas para a superfície são referentes aos dados geológicos das rochas, as quais permitem a geonavegação ou aquisição antecipada de informações relevantes para engenharia de reservatórios.

O poço de petróleo costuma atravessar bacias sedimentares, pois são potencialmente mais propensas a acumulação de hidrocarbonetos. Diante disso, as fases do poço podem atravessar rochas de diferentes características. Tomando como exemplo um poço típico do pré-sal brasileiro, algumas características podem ser mencionadas (Agostini et.al., 2019): lâmina de água ultraprofunda (superior a 2000 m), fases iniciais compostas por rochas sedimentares, uma longa camada de sal e por último a rocha

reservatório. As seções iniciais são construídas para atingir o topo do sal, este procedimento visa assegurar resistência suficiente para que um fluido de perfuração de elevada massa específica possa ser utilizada na fase seguinte, de modo a mitigar os efeitos de fluência da rocha salina. A fase do sal, compreende extensões da ordem de 1000 a 2000 m de extensão. A última fase, ou zona de interesse, é composta por rochas carbonáticas de litologia relativamente constante, sob o ponto de vista de perfuração. Nesta última fase o revestimento será instalado para permitir a completação e produção da rocha reservatório. A Figura 1 apresenta a configuração típica de um poço do pré-sal, evidenciando as fases construtivas de cada seção.

Figura 1 – Configuração típica de um poço do pré-sal (Agostini, et. al., 2019).



1.3 Aprendizado de máquina

Aprendizado de Máquina é uma área de inteligência artificial cujo objetivo é o desenvolvimento de técnicas computacionais para construção de sistemas capazes de adquirir conhecimento de forma automática. Um sistema de aprendizado é um programa de computador que gera decisões baseadas em experiências acumuladas através da solução e adaptação bem sucedida de dados anteriores (Rezende, 2003).

Atualmente a enorme quantidade de informações geradas pelos sistemas e sensores, abrem oportunidades para aplicação de aprendizado de máquina visando extrair todo o seu potencial para trazer benefícios para indústria como um todo. A indústria de óleo e gás tem se beneficiado destes sistemas, acoplando sistemas inteligentes aos seus processos decisórios, buscando segurança, integridade e otimizações de elevado valor para as empresas.

Os algoritmos de aprendizado de máquina adotam a estratégia de aprendizado a partir de dados previamente selecionados. Basicamente existem três abordagens possíveis de aprendizagem: supervisionada, não supervisionada e por reforço. A classificação supervisionada demanda dados com as respectivas classes previamente identificadas. Trata-se então de um aprendizado baseado em dados conhecidos para permitir sua futura classificação ou resposta pautadas em dados conhecidos, ou seja, quando apresentamos ao algoritmo dados de entrada e as respectivas saídas. Já na classificação não supervisionada, o próprio algoritmo se encarrega de definir as classes ou grupos, baseado nos dados fornecidos. E por fim, o aprendizado por reforço, é um tipo de abordagem mais avançada na qual busca-se o treinamento dos modelos de aprendizado através de tomada de decisões em sequência. Neste tipo de abordagem, o sistema utiliza tentativa e erro para encontrar uma solução ótima, fornecendo recompensas ou penalidades para cada ação executada. Obviamente o algoritmo visa maximizar a recompensa.

As técnicas de aprendizado de máquina podem fazer previsões ou classificações a partir de amostras ou tomar decisões baseadas unicamente em dados. Entre os vários exemplos de aplicações pode-se citar o processamento de linguagem natural, filtragem de SPAM, reconhecimento de fala e de escrita, visão computacional, diagnóstico médico, sistemas de busca, identificação de anomalias etc.

Existem vários tipos de problemas que podem ser resolvidos com estas técnicas. Neste projeto de pesquisa, optou-se pela abordagem de classificação supervisionada para identificação de anomalias em brocas de perfuração. A identificação de padrões automática visa identificar problemas baseados em dados históricos. O objetivo é identificar, através de técnicas avançadas de aprendizado de máquina, padrões ocultos nos dados de perfuração, visando identificar anomalias nas quais o ser humano não poderia capturar.

1.4 Aplicações de aprendizado de máquina na perfuração

A perfuração de poços em águas ultra profundas tem requerido atingir reservatórios com extensão final cada vez mais profundas, principalmente em cenários do pré-sal na costa marítima brasileira. Diante deste cenário, a otimização da perfuração tem procurado obter a maximização da eficiência construtiva de poços, pois tem sido uns dos indicadores primários da indústria de petróleo. A perfuração de um poço de petróleo requer uma coluna com sistema rotativo com broca de alto desempenho. Porém, devido às incertezas geológicas, o desgaste dos cortadores da broca pode apresentar surpresas indesejadas. Assim, a condição de monitoramento em tempo real é uma realidade no qual as operadoras de campos de petróleo têm feito investimentos de forma maciça. Uma retirada de broca do fundo até a superfície para sua substituição, requer elevado investimento, pois é preciso retirar milhares de metros de tubulação até que se possa substituir a broca desgastada. Neste sentido, é preciso avaliar de forma criteriosa se o momento de sua substituição é realmente o mais adequado, pois basear-se apenas na Taxa de Penetração (do inglês, *Rate of Penetration* - ROP) na rocha, pode gerar uma retirada de coluna inadequada, ou seja, a broca pode estar apenas em um ambiente de rocha com maior dificuldade, mas não significa necessariamente que seus cortadores estejam em situação degradada o suficiente para serem substituídos.

Neste cenário, o uso de algoritmos de interpretação de desgaste de brocas em tempo real apresenta o seu valor, dado que a maximização do tempo de perfuração da fase para cumprir a extensão planejada é obtida, não apenas com otimização de taxas de penetração, mas também com a retirada da broca de perfuração no momento mais adequado possível.

Atualmente, os sistemas de monitoramento em tempo real durante a perfuração de um poço, enviam sinais diretamente para o banco de dados dos computadores da operadora, permitindo que os engenheiros da base de monitoramento possam tomar decisões críticas e otimizações possam ser efetuadas. Os sinais enviados dizem respeito aos parâmetros utilizados para perfuração, tais como: peso sobre broca, rotação da coluna, vazão e pressão de bombeio, torque de superfície entre outros. Estes sinais são obtidos com relação aos equipamentos na superfície, no caso do sinal do torque, é capturado através da resposta do motor elétrico conectado na torre de perfuração, responsável por aplicar rotação na coluna de perfuração. Também há instrumentação em tempo real instalada na própria coluna de perfuração, no qual é possível obter dados de vibrações, além dos mesmos parâmetros citados anteriormente, mas com relação ao ponto de

referência próxima da broca, ou seja, no fundo do poço. Estes sinais, entretanto, têm normalmente uma taxa de aquisição inferior aos obtidos com relação aos sinais enviados pelos equipamentos de superfície.

O monitoramento do estado da broca de perfuração pode ser encarado como um processo de análise de falha de equipamento rotativo. Vários autores têm investido neste tipo de diagnóstico, incluindo aprendizado de máquina e redes convolucionais, porém em áreas não diretamente aplicadas para a mecânica de perfuração de poços de petróleo (Vununu et al., 2018; Li, et al., 2018; Guo et.al., 2018; Heydarzadeh et al., 2016). Existem vários métodos e formas de se avaliar o estado de um equipamento mecânico, e as aplicações variam conforme a necessidade de aplicação. Basicamente, os métodos adquirem os sinais de algum parâmetro que seja importante para o diagnóstico, processam o sinal de forma a extrair características que definam o seu estado e enfim aplica-se um método de análise para prever seu diagnóstico. Neste cenário, o uso de algoritmos de aprendizado de máquina tem apresentado papel relevante para solucionar os problemas de identificação de padrões em falhas de máquinas rotativas.

Na área de petróleo e gás, os algoritmos de aprendizagem de máquina têm sido intensamente explorados nos últimos anos. Conforme Bello et al. (2016), a indústria de óleo e gás tem feito um esforço enorme para o progresso e melhorias no desempenho de perfuração, adicionando análises de sinais de ferramentas em tempo real, instaladas próxima da broca. Estas técnicas têm modificado a forma clássica dos procedimentos de perfuração e, além disso, fazem uso do estado da arte dos sensores de superfície instalados nas sondas modernas de perfuração.

Togni (2018) propôs um modelo preditivo através de aprendizado de máquina para avaliar o tempo esperado de perfuração da fase, de modo a permitir uma análise de falha (decisão durante a construção do poço), caso o tempo previsto da perfuração esteja excedendo o executado na operação. Este trabalho utiliza vários parâmetros de superfície da coluna e avalia o contexto geral de falha de perfuração. Trata-se de um modelo que leva em consideração vários aspectos da perfuração, mas não trata especificamente sobre o estado da broca de perfuração. Em Hegde et al. (2018), o ROP da broca é o objeto de análise, através de uma proposta de modelo híbrido, sendo composto por modelo físico e de aprendizado de máquina (orientado a dados). O trabalho procura determinar a taxa de penetração esperada, e assim poder tomar decisão acerca destes dados. Este trabalho foca na predição de possíveis parâmetros ideais para perfuração, tais como: peso sobre broca,

rotação da coluna e vazão de bombeio, no intuito de prever o cenário de rocha em perfuração e maximização do ROP.

Noshi e Schubert (2018) apresentaram uma série de modelos de aprendizado de máquina para aplicações em perfuração de poços. Neste trabalho é feita uma análise de vantagens e desvantagens sobre os vários aspectos dos modelos de aprendizado de máquina aplicados em perfuração. Uma de suas abordagens é o uso de técnicas probabilísticas com redes bayesianas, que são na verdade um método gráfico similar a árvore de decisão.

Zhao et al. (2017) desenvolveram um modelo de detecção de eventos de perfuração, através de análise de dados, como: parâmetros obtidos de superfície, geometria do poço, litologia e de sensores instalados no fundo da coluna de perfuração. O método proposto baseia-se em vários modelos de aprendizado de máquina para detecção de anormalidades durante a perfuração, mas foca em detecção de anormalidades de forma geral na perfuração.

Gidh et al. (2012) propuseram um modelo de redes neurais desenvolvido para otimização dos parâmetros operacionais de perfuração. O estudo pretendeu eliminar fatores humanos sobre aplicação de parâmetros, como peso e rotação na coluna, retirando a subjetividade do sistema.

Em (Arehart, 1990) uma rede neural convencional foi utilizada para avaliação de desgaste de broca durante a perfuração. O método consiste em se utilizar dados de treinamento de brocas com desgaste e litologia conhecidas, mas com análises somente efetuadas em laboratório. Foram utilizados parâmetros como peso sobre broca, rotação, torque e ROP. Uma das dificuldades foi a baixa quantidade de dados para base de treinamento, o que não permitiu cobrir um cenário real de perfuração no campo.

Rashidi et al. (2010), constataram que o estado de desgaste de uma broca durante a perfuração, enquanto encontra-se em operação, exerce uma elevada influência na análise operacional durante a perfuração. Assim, concluíram que o conhecimento do estado de desgaste da broca em tempo real é fundamental.

A abordagem utilizando rede neural probabilística tem início, principalmente, através do trabalho desenvolvido por Specht (1990). Neste tipo de abordagem, a rede neural é reconhecida como técnica eficiente para solução de problemas de classificação (Sweeney Jr. et al., 1994). A modelagem é efetuada através de uma combinação de estimadores de densidade de probabilidade em conjunto com a Regra de Bayes, para permitir a avaliação sobre a classificação de determinado modelo em análise. Uma das

motivações para uso deste tipo de abordagem, é que operacionalmente, o treinamento é fácil e instantâneo, tornando-se algo interessante para aplicações em tempo real, pois assim que o padrão é identificado em cada categoria, a rede já pode generalizar para novos padrões (Specht, 1990). O uso de rede neural probabilística tem sido empregado atualmente na indústria de petróleo, mas somente em pesquisas relacionadas, como por exemplo, na caracterização sísmica de reservatórios, conforme trabalhos apresentados por (Liu et al., 2019; Gu et.al., 2018).

1.5 Objetivo

O objetivo principal deste trabalho é o desenvolvimento de um modelo de previsão do diagnóstico de desgaste de broca de perfuração, através de uma rede neural probabilística.

2 METODOLOGIA

Nesta seção é apresentada a metodologia desenvolvida, baseada em trabalhos efetuados por (Verstraete et al., 2017; Vununu et al., 2018; Guo et al., 2018), explicitando como os dados de torque de superfície foram obtidos e tratados, para permitir o uso de forma consistente. A seguir são apresentadas a forma de transformação do sinal de torque em imagens de densidade espectral de potência, e sobre a utilização do autoencoder para extração de vetores de características compactas, para obtenção do estado de desgaste da broca. Em seguida, o método de classificação é explicado, utilizando a técnica de redes neurais probabilísticas.

2.1 Preparação dos dados de entrada

A seguir são apresentados como os dados extraídos do sistema de monitoramento da Petrobras foram tratados e analisados, de modo a permitirem a implementação de algoritmos de aprendizado de máquina.

- **Aquisição de dados**

Os dados utilizados neste trabalho foram obtidos diretamente de poços perfurados na costa brasileira da região do pré-sal, perfurados entre 2016 e 2018. O sinal do torque de superfície foi obtido através de softwares de monitoramento em tempo real de perfuração.

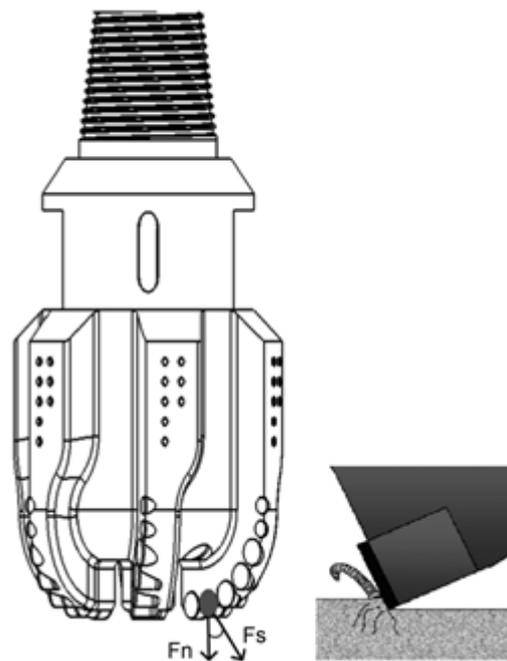
Os dados utilizados foram cedidos pela Petróleo Brasileiro S.A. (Petrobras), no qual foi possível catalogar os poços de interesse para permitir a modelagem de diagnóstico de desgaste de brocas. Os poços foram selecionados de tal maneira que mantivessem um padrão aceitável, no que diz respeito aos aspectos operacionais de perfuração. Para isso, foram utilizados dados de perfuração de uma fase com diâmetro de broca único. Também, foi padronizado o tipo dos cortadores da broca, de modo a evitar alguma interferência no padrão de desgaste nos modelos. As brocas utilizadas para aprendizado são compostas por cortadores de tecnologia Polycrystalline Diamond Compact (PDC), conforme apresentado na Figura 2.

Figura 2 – Broca de perfuração do tipo PDC (Huang et al., 2018).



Os demais parâmetros como Weigth on Bit (WOB) e Rotações por Minuto (RPM) da coluna de perfuração, não foram significativamente diferentes, dada a similaridade dos poços construídos. O mecanismo de corte da broca tipo PDC, no qual a interface entre os cortadores e a rocha a ser perfurada, exerce papel fundamental na resposta do sistema (Gerbaurd et al., 2006). O corte gerado por este tipo de broca é devido ao efeito de cisalhamento, que a depender do formato ou desgaste do cortador, pode apresentar diferentes características no torque, conforme estudos efetuados por (Wang et al., 2019). A Figura 3 apresenta um esquema de forças nos cortadores advindos de uma broca do tipo PDC, onde F_n é a força normal e F_s a força de cisalhamento.

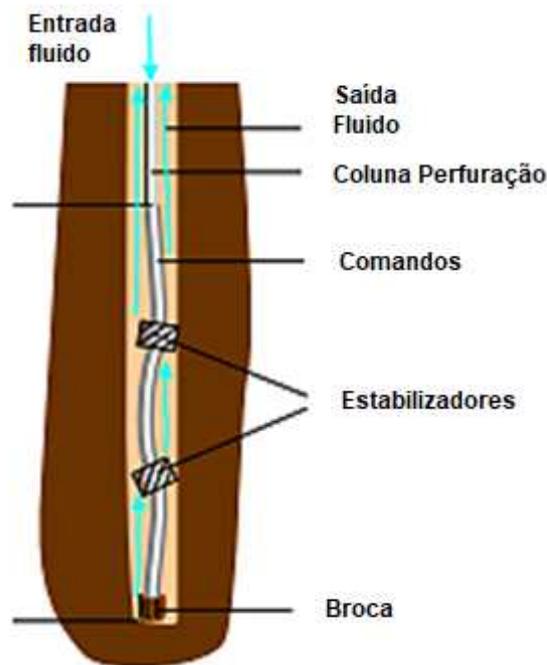
Figura 3 – Mecanismo de corte simplificado broca do tipo PDC (Wang et al., 2019).



A resposta ao torque na superfície em relação a velocidade de rotação da coluna, considerando a interação da broca contra a formação rochosa, torna-se adequado para obtenção de padrões de desgaste, dado o mecanismo de corte promovido por este tipo de broca sem partes móveis.

Por fim, deve-se manter o mesmo tipo de característica litológica de rocha, para consistência no torque reativo a ser utilizado no banco de dados de aprendizado. O sinal escolhido para interpretação do estado da broca foi o torque de superfície, no qual oferece taxa de aquisição a cada 5 s. Este parâmetro foi escolhido por ser aquele que melhor representa a influência no sistema, com relação a interpretação do estado de desgaste da broca. Sabe-se que há influência do torque devido aos contatos da coluna e estabilizadores contra a parede do poço, vibrações, tipos de colunas, fluido de perfuração e interação com a rocha, conforme esquema apresentado na Figura 4.

Figura 4 – Coluna de perfuração com componentes básicos (Leine et al., 2002).



Entretanto, observa-se que considerando a padronização das características citadas anteriormente, além da composição do *Bottom Hole Assembly* (BHA), o uso de torque de superfície torna-se interessante como sinal característico principal, para avaliar o estado de desgaste de uma broca do tipo PDC.

- **Tratamento dos dados**

Inicialmente devem ser eliminados os períodos operacionais que não dizem respeito a perfuração em regime permanente, ou seja, excluir os dados referentes ao corte do cimento no interior do revestimento e os trechos iniciais da perfuração da rocha, nos quais os parâmetros de RPM e WOB ainda encontram-se em fase de ajustes. Assim, a base de treinamento deve ser consistente somente com a operação de perfuração com avanço na rocha após parametrizações iniciais, típicas na operação.

O modelo utiliza dados em série temporal de torque de superfície, conforme a broca de perfuração avança. Os sinais coletados apresentam comportamento não estacionário, confirmado através do método de Dickey-Fuller Test (Dickey e Fuller, 1979). Para manter as propriedades estatísticas constantes ao longo do tempo, o torque de superfície foi convertido para sinal estacionário, através da técnica de diferenciação.

Os sinais precisam ser divididos em janelas de tempo fixa, para permitir a futura construção da matriz de imagem espectral. Esta duração deve ser compatível com o tempo de tomada de decisão de análise de desgaste de broca, e também apresentar pontos de amostras suficientes para gerar um banco de dados de treinamento consistente, conforme número de poços e tempo de broca ao fundo disponíveis para estudo. Por exemplo, uma janela de tempo fixa de 15 min, considerando uma taxa de aquisição de torque a cada 5 s, teria 180 pontos de torque. Neste caso, se o tempo total de broca perfurando fosse 50 h, haveria um vetor contendo 36000 amostras de torque. A matriz de dados seria então composta por 200 linhas e 180 colunas, onde cada linha, seria uma futura imagem espectral.

2.2 Classificação supervisionada do desgaste da broca

O método de classificação para treinamento de dados adotado neste trabalho é o supervisionado, onde o desgaste das brocas foi classificado manualmente, ou seja, através de análise criteriosa dos boletins de perfuração e dados de acompanhamento direcional da construção dos poços, fornecidos pela Petrobras. Para cada poço perfurado, foram analisados o desgaste da broca após sua retirada e confrontados com o ROP durante a construção do poço. Com isso, pode-se inferir o momento no qual a broca poderia ter sido substituída. Evidentemente que tal informação não estava disponível durante o processo de construção, mas a observação da taxa de penetração em conjunto com a extensão já perfurada, em comparação com o desgaste da broca verificado na superfície, foi suficiente para classificar cada poço perfurado.

A forma de classificação utilizada foi do tipo binária, ou seja, broca desgastada ou broca sem desgaste. Esta simplificação é suficiente e aceitável, dada a complexidade do sistema, pois uma broca com desgaste intermediário, certamente avançará mais na fase, o que não implica necessariamente em sua substituição. O que se pretende de fato é saber quando retirar a broca, e o melhor momento, certamente é aquele no qual a broca estará com o máximo desgaste possível e baixo ROP.

Após a classificação dos dados, observou-se um desequilíbrio entre os estados da broca, levando a um problema de desbalanço de dados para classificação. Uma das formas de se contornar este tipo de problema é através de geração de dados sintéticos. Neste trabalho, foi utilizado o algoritmo ADASYN (He et.al., 2009). A implementação foi

efetuada em linguagem Python, assim como toda modelagem proposta neste trabalho. A ideia do algoritmo é usar uma distribuição ponderada para diferentes exemplos de classes minoritárias, de acordo com o nível de dificuldade para a aprendizagem. Assim, mais dados sintéticos são gerados onde observa-se maior dificuldade de aprendizado, e em contrapartida, menos dados são gerados onde há menor dificuldade de aprendizado. Este método torna-se interessante para balancear os dados, dado que a maioria das informações são com broca em estado sem desgaste.

2.3 Construção de imagens espectrais

A Power Spectral Density (PSD) representa a energia de um sinal em uma determinada faixa de frequência. Teoricamente, a PSD de um sinal pode ser obtida através da transformada de Fourier da função de autocorrelação (McConnell e Varoto, 2008). Entretanto, na prática, é usual utilizar estimadores que podem ser paramétricos ou não paramétricos. Os métodos paramétricos são mais complexos em relação aos métodos não paramétricos (Thomas et al., 2015).

Neste trabalho, optou-se pelo uso do método de Welch, para estimativa de PSD (Welch, 1967). O método de Welch obtém a estimativa de PSD através de uma abordagem não paramétrica, no qual faz uso da Transformada Rápida de Fourier (FFT). A ideia básica consiste em utilizar uma janela móvel em que a FFT é calculada em cada uma destas janelas, para posteriormente calcular o PSD como uma média das FFTs de todas as janelas.

O objetivo é transformar o sinal do torque do domínio do tempo para o domínio da frequência, no qual espera-se capturar as diferenças do torque reativo contra a rocha, para broca com cortadores novos e desgastados. Procurou-se obter um sinal sem atenuação, para que os picos de frequência fossem realmente realçados, de modo a facilitar a captura da diferenciação entre as características de desgaste da broca. A resposta do estimador de PSD de Welch é sensível ao tamanho, tipo e a sobreposição da janela, além do número de amostragens para a FFT.

Para melhorar a captura dos contrastes de sinais, ou seja, realçar ainda mais os picos da magnitude do espectro, é aplicada a técnica de tratamento de imagem chamada de equalização de histograma. A técnica consiste em obter a função de densidade de probabilidade (PDF) e a função de densidade cumulativa (CDF) através do histograma da

imagem de entrada. Em seguida, as funções de PDF e CDF são utilizadas para substituir os níveis de cinza da imagem de entrada pelos novos níveis de cinza e, finalmente, obter a nova imagem. Ao final, obtém-se uma imagem com um histograma uniformemente distribuído, o que gera o efeito de melhoria no contraste (Singh e Dixit, 2015).

2.4 Extração de características

Para permitir que os algoritmos de classificação possam atuar de forma eficiente, é preciso que os dados estejam discriminados pelo estado da broca, o mais perceptível possível dentro da base de treinamento. Para isso, foi utilizado o autoencoder convolucional como extrator de características, justamente para capturar, de maneira não supervisionada, as formas relevantes do sinal espectral do torque transformado em imagem, para futura aplicação no classificador não linear de rede neural probabilística.

- **Redes neurais convolucionais**

Recentemente, as redes neurais convolucionais (CNN) tem assumido um papel de destaque, principalmente aplicados à visão computacional. Trata-se de uma forma eficiente de análise de imagens para aprendizado de máquina (Krizhevsky et.al., 2012). A arquitetura básica de uma rede CNN inclui uma série de componentes empilhados em sequência. A rede é formada inicialmente pela primeira camada chamada de convolução. A convolução propriamente dita é uma operação matemática aplicada entre duas funções, gerando uma terceira função, que expressa como a forma de uma modifica a outra. No caso de imagens, a primeira função é a matriz de dados codificada da imagem e a segunda função, é chamada de função kernel. Após o processo de convolução, a terceira função obtida é normalmente chamada de matriz de mapa de características. Em seguida aplica-se a camada chamada de pooling, no qual extraem-se subpartes da camada anterior (matriz de características processada), através de técnicas específicas de seleção, por exemplo, max-pooling, no qual selecionam-se os maiores elementos pertencentes a uma região de 2 x 2. Com isso gera-se uma redução de dimensionalidade de 4 vezes com relação aos dados de entrada anterior. A última camada consiste no vetor final, totalmente conectado com as entradas anteriores, para permitir a classificação final do sistema

(David, E.O. e Netanyahu, 2016). Quando se aplicam várias camadas de convolução e pooling, a rede recebe o nome de Convolutional Deep Learning.

- **Autoencoder**

Um autoencoder é um tipo de rede neural, não supervisionada, que aprende a partir de um dado de entrada, tentando reproduzir o dado de saída, que neste caso é o mesmo, ou seja, reproduzir uma autocópia, com a vantagem de reduzir sua dimensionalidade. A modelagem possui uma camada interna (oculta) que descreve um código usado para representar a entrada e é constituída por duas partes principais: um codificador que mapeia a entrada no código e um decodificador que mapeia o código para uma reconstrução do dado original. A própria cópia do dado de entrada não é o foco principal desta metodologia, pois o objetivo neste caso é capturar apenas os aspectos mais relevantes dos dados a serem copiados, forçado através do processo de sua autocópia. Em sua aplicação padrão, trata-se de um algoritmo de codificação que tem aplicação mais tradicional para redução da dimensionalidade de dados ou captura de características principais (Goodfellow, 2016). Sua principal vantagem em relação ao algoritmo de Análise de Componente Principal (PCA), é de que é possível capturar não linearidades, permitindo que o modelo aprenda mais generalizações e reconstrua a entrada com perda de informações significativamente menor (Hilton e Salakhutdinov, 2006).

- **Deep Convolutional Autoencoder**

As técnicas de rede neural convolucional profunda e autoencoder podem ser combinadas para produzir o modelo chamado de Deep Convolutional AutoEncoder (DCAE). Através desta arquitetura de modelo de aprendizado, pode-se obter o vetor de características da imagem de forma compacta. O modelo DCAE faz uso da vantagem da convolução para compressão da imagem, e para isso, obtém necessariamente o vetor de características principais. Este vetor de características, compacto, contém as informações necessárias para reproduzir a imagem no processo de recodificação.

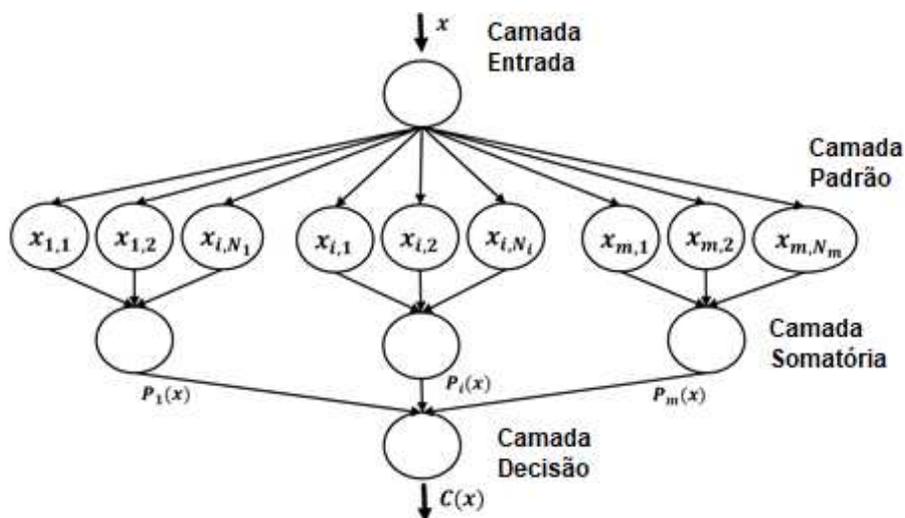
Cabe salientar que o interesse nesta técnica está em capturar a matriz compactada com as características latentes da imagem e não em sua perfeita reprodução com o processo de recodificação. A principal vantagem desta técnica com relação ao método de

CNN, segundo Chen et al. (2017), é de que pode-se fazer uso em conjunto do autoencoder, para o treinamento de extração de características através do método não supervisionado, ou seja, obter justamente os pontos da imagem espectral que realmente podem discriminar as classes em broca desgastada ou sem desgaste, com a colaboração do método de convolução da imagem, visando compactar e capturar não linearidades através de camadas profundas.

2.5 Classificação através de rede neural probabilística

O modelo de rede neural probabilístico (PNN), proposto por Specht (1990), é uma implementação de arquitetura neural através do uso da estimativa de função de densidade de probabilidade. Este tipo de abordagem é normalmente utilizado em problemas de classificação. Esta técnica tem sido utilizada, principalmente, por ser de treinamento muito rápido, em comparação com os métodos tradicionais de redes neurais por retropropagação (Ancona et.al., 1998). A Figura 5 apresenta a arquitetura básica de uma PNN, no qual mostra a composição das 4 camadas, sendo a primeira responsável pela entrada de dados, a segunda para cálculo das probabilidades de cada tipo de classe, e a terceira sendo composta pela somatória das probabilidades das classes obtidas anteriormente, e a última camada, determina de fato em qual classe o dado de entrada é pertencente.

Figura 5 - Arquitetura de uma rede neural probabilística.



Há várias formas de obtenção da PDF, porém neste trabalho, será considerada a estimativa proposta por Parzen (1962). A ativação de um neurônio x_{ij} para um referido dado de entrada x , pode ser calculado conforme Eq. 1.

$$\phi_{ij}(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(x-x_{ij})^2}{2\sigma^2}\right], \quad (1)$$

onde i representa o número da classe e j o número do neurônio, $\phi_{ij}(x)$ é a estimativa de densidade de probabilidade de Parzen de um valor x , σ é o fator de suavização da função de densidade de probabilidade, x_{ij} é o vetor de treinamento e x é o vetor de teste.

Cabe salientar que, a determinação do parâmetro de suavização, é um aspecto crítico na modelagem de uma PNN. Um parâmetro de suavização apropriado geralmente depende dos dados de entrada, portanto, a seleção do parâmetro de suavização é uma etapa essencial a ser executada durante o processo de otimização do modelo. O valor a ser testado x , é introduzido na equação para estimar sua função de densidade de probabilidade, considerando os vetores de treinamento x_{ij} , para cada classe do treinamento. Após a obtenção da estimativa de probabilidade de cada classe, efetua-se a operação de somatória, representada na terceira camada, conforme Eq. 2.

$$P_i(x) = \frac{1}{n_i} \sum_{j=1}^{n_i} \phi_{ij}(x), \quad (2)$$

onde $P_i(x)$ é a máxima probabilidade do vetor de teste x ser pertencente a classe i e n é o número de neurônios da camada de padrões.

A operação na terceira camada consiste simplesmente no cálculo da máxima probabilidade para que um dado x , ou seja, um valor a ser classificado, possa ser membro de uma determinada classe, através da média obtida de todos os neurônios pertencentes a esta mesma classe. Na última camada, haverá o processo de decisão, para determinar qual classe o vetor x é pertencente, escolhido através da comparação entre as várias probabilidades calculadas na camada anterior. A função de ativação deste neurônio está representada na Eq. 3.

$$C(x) = \max \{ P_i(x) \} \quad i = 1, \dots, m \quad (3)$$

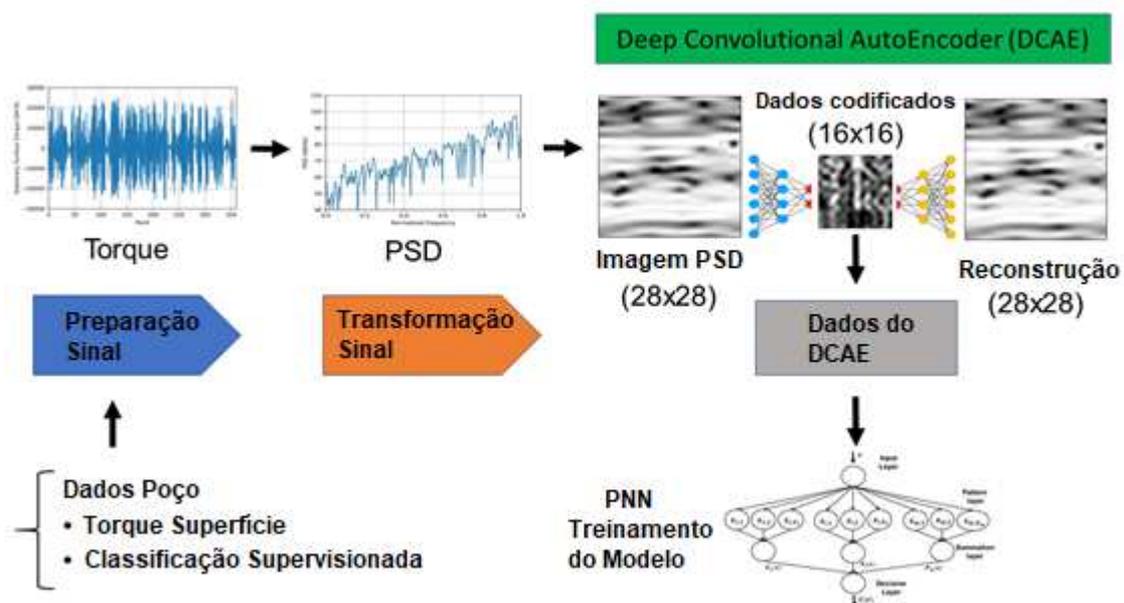
onde $C(x)$ é a classe selecionada para o vetor de teste x e m é o número de classes.

2.6 Fluxo de trabalho

O método de diagnóstico de desgaste de broca proposto visa classificar o estado da broca com relação ao sinal do torque de superfície em tempo real. Após a transformação de todos os sinais temporais do torque de superfície em imagens espectrais, procede-se com o treinamento de captura não supervisionada dos vetores representativos, através do modelo DCAE. Estes dados são alimentados na camada de entrada da PNN, para permitir a classificação final.

O fluxo de trabalho para geração do modelo e classificação em tempo real estão descritos em 2 etapas, sendo a primeira para efetuar o treinamento da base de dados, conforme esquema apresentado na Figura 6, e a segunda para determinação do diagnóstico da broca, conforme Figura 7.

Figura 6 – Fluxo de trabalho para o treinamento do modelo proposto.

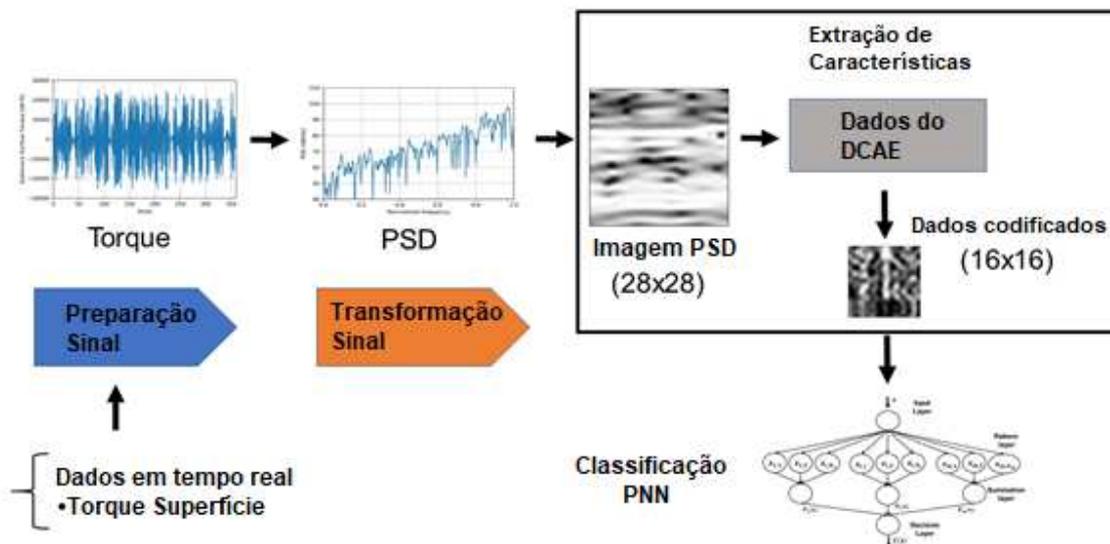


Sequência para montagem da base de dados (Treinamento)

- 1) Definir diâmetro e tipo de broca de perfuração para diagnóstico de desgaste;
- 2) Selecionar poços contendo característica semelhante de litologia de rocha;
- 3) Classificar desgaste da broca de forma binária, sendo (0) para broca sem desgaste e (1) para broca desgastada, conforme classificação manual com relação ao desgaste real apresentado na base de dados de poços;
- 4) Obter torque de superfície com taxa de aquisição constante;

- 5) Transformar sinal de torque em sinal estacionário;
- 6) Obter a PSD, com magnitude em dB, do sinal de torque estacionário;
- 7) Definir o período de tempo (t) da janela de pacote de dados de torque;
- 8) Gerar imagens do sinal obtido no item 6 a cada período de tempo t;
- 9) Aplicar equalização de imagem através da técnica de histograma para cada pacote de imagem;
- 10) Balancear base de dados entre brocas com e sem desgaste, utilizando técnicas de geração de amostras sintéticas;
- 11) Treinar DCAE utilizando as imagens obtidas no item 10;
- 12) Extrair as características principais da imagem codificada no item 11;
- 13) Treinar modelo PNN considerando as entradas obtidas no item 12.

Figura 7 – Fluxo de trabalho para classificação do modelo proposto.



Sequência para diagnóstico da broca (Classificação)

- a) Obter dados de torque de superfície, conforme janela de tempo definido no item 7;
- b) Aplicar item 5, 6, 8, 9;
- c) Abrir modelo treinado pelo DCAE e extrair as características principais da imagem obtida após o processamento do item (b);
- d) Abrir modelo treinado pela PNN e classificar estado atual da broca;
- e) Repetir o item (a) para prosseguir processamento em tempo real.

Importante salientar que não se trata de classificar o estado da broca baseado simplesmente na imagem do torque, mas sim no sinal da PSD do torque, no qual extraem-

se as características relevantes, de forma não supervisionada, através da técnica de compactação de imagem, via autoencoder convolutional.

3 ESTUDO DE CASO

3.1 Conceitos operacionais de perfuração

Alguns conceitos importantes, sob o ponto de vista de operação de perfuração, são apresentados, de modo a permitir a melhor análise do ponto de vista de avaliação de desempenho do modelo proposto.

O modelo de aprendizado de máquina assume a seguinte convenção binária para classificação do estado da broca: 0 (negativo) para broca sem desgaste e 1 (positivo) para broca totalmente desgastada. Esta forma de classificação decorre diretamente da maneira como a base de treinamento foi concebida. Quando ocorre um True Negative (TN), ou seja, o modelo indica broca boa e a broca realmente está boa, a decisão de seguir perfurando a fase é acertada e leva a obter maior eficiência de perfuração. Para o caso de False Positive (FP), onde a broca de fato está boa, mas o modelo prevê erroneamente broca como desgastada, leva a uma necessidade de substituição de broca, o que implica em elevado custo, pois é preciso retirar toda a coluna de perfuração e retornar para o fundo. Já para os casos onde o modelo classifica a broca como boa, mas na realidade está em condição desgastada, caso do False Negative (FN), ocorre baixa eficiência no sistema, pois a broca poderia ser retirada para substituição, com melhoria no ROP ao se fazer uso de uma broca nova. E por fim, a classificação True Positive (TP), que é o caso onde o modelo classifica corretamente que a broca está desgastada, e nesta situação uma manobra para substituição de broca ou término da perfuração, leva a uma maior eficiência da perfuração, foco de otimização neste trabalho.

Analisando no contexto operacional de possível aplicação em tempo real, o modelo de diagnóstico deve minimizar as falhas de predição do FN, para maximizar a eficiência da broca, e maximizar os acertos de TP, para eventual operação de substituição de broca desgastada. Além disso, evidentemente precisa-se minimizar o FP, que leva ao maior custo operacional sobre falha de predição neste cenário.

Cabe lembrar que, para o caso de diagnóstico de estado de desgaste de brocas de perfuração, deve-se levar em consideração fatores como o histórico operacional de desgaste da broca, ROP e extensão remanescente para atingir a profundidade final do poço, os quais não fazem parte da análise neste trabalho.

3.2 Construção do modelo de aprendizado

Para montagem da base de treinamento, foram coletadas informações de 13 poços de petróleo perfurados na costa marítima brasileira, região dos campos do pré-sal. Foram analisadas 15 corridas de brocas do tipo PDC, contabilizando uma extensão total perfurada de 5,5 Km e 1167 h de tempo de broca ao fundo. A Tabela 1 apresenta os poços utilizados para modelagem deste estudo de caso. A taxa de aquisição do torque foi a cada 5 s, conforme dados fornecidos pela Petrobras.

Tabela 1 – Poços submarinos do pré-sal utilizados para base de treinamento.

Poço	Perfurado (m)	Tempo (h)	ROP (m/h)	Perfurado com cortador ruim (m)	Tempo com cortador ruim (h)	ROP com cortador ruim (m/h)	Desgaste IADC (interno-externo)	Motivo manobra
A1	151	40	4	30	18	2	2-8	Taxa de penetração
B	196	16	13	0	0	0	8-7	Falha ferramenta
C	204	23	9	0	0	0	1-0	Término da fase
A2	209	37	6	0	0	0	0-1	Término da fase
D	278	42	7	24	18	1	8-8	Taxa de penetração
E	283	65	4	7	8	1	1-3	Taxa de penetração
F	311	94	3	29	16	2	2-8	Taxa de penetração
G	418	151	3	107	102	1	6-8	Término da fase
H	521	132	4	170	91	2	3-6	Troca de BHA
A3	401	64	6	0	0	0	0-1	Perfilagem
I	634	150	4	224	97	2	4-8	Término da fase
J	428	64	7	0	0	0	1-4	Término da fase
K	441	97	5	4	3	1	1-5	Término da fase
L	523	71	7	39	14	3	4-5	Término da fase
M	507	122	4	0	0	0	4-5	Término da fase
Total	5505	1167		634	367			

Os sinais de torque de superfície foram divididos em janelas de 30 min, para permitir a futura construção da imagem espectral. Com isso, após a retirada de 111 h de tempos não operacionais de perfuração, obtém-se a matriz final de dados composta por (2109 x 360) elementos, nos quais toda a base de dados está representada no domínio do tempo.

Uma janela menor de amostragem tem como consequência uma maior quantidade de dados para serem treinados, entretanto, pode-se perder a captura do padrão gerado do torque ao longo do tempo. A janela de 30 min foi considerada satisfatória, pois atende tanto aos critérios de análise em tempo real, no processo de tomada de decisão do

engenheiro para substituição da broca de perfuração, como também, para geração de quantidade representativa de dados para treinamento e validação do método, embora possa ser alterada conforme a conveniência da base de dados em análise.

Após a geração da matriz de dados de torque de superfície, ordenados conforme a janela de operação de 30 min, procede-se com a criação das imagens de densidade espectral, utilizando a técnica de estimativa proposta por Welch (1967).

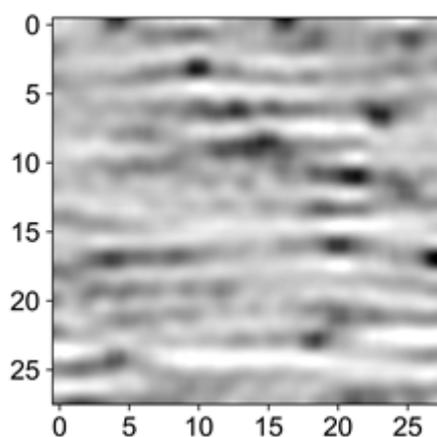
O torque de superfície, montando na matriz de dados com 360 pontos de amostragens, foi transformado, linha a linha da matriz, utilizando número de seguimentos da função de parametrização de Welch com 360 pontos, janela de sobreposição 180, janela do tipo hanning e NFFT de 1568. A Figura 8 apresenta o resultado de uma amostragem de 30 min, considerando os parâmetros descritos acima. Importante notar que o interesse maior é no contraste do sinal (magnitude do PSD), logo o eixo do PSD foi convertido para dB/Hz e o eixo da frequência normalizado.

Figura 8 – PSD do torque de superfície em janela de 30 min.



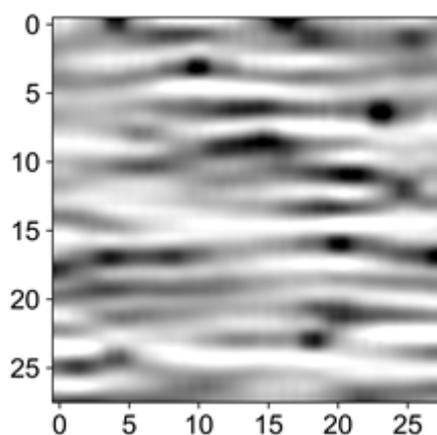
O vetor de saída do sinal do PSD de uma amostra de 30 min contém 785 elementos, devido aos parâmetros utilizados na função de estimativa de PSD de Welch. Com isso, pode-se gerar uma imagem de 28 x 28 pixels, com perda de apenas 1 pixel na imagem do sinal. A geração da imagem é feita, inicialmente com a uniformização do sinal do PSD, entre 0 a 255. A Figura 9 apresenta a imagem obtida do sinal do PSD de uma amostragem, utilizando recurso de interpolação de imagem da biblioteca Matplotlib do Python, para facilitar a visualização.

Figura 9 - Imagem da PSD do torque de superfície em janela de 30 min.



A Figura 10 apresenta a imagem final aplicando a técnica de histograma, também com o recurso de interpolação de imagem do Matplotlib do Python, apenas para facilitar a visualização.

Figura 10 - Imagem PSD do torque de superfície após tratamento com histograma em janela de 30 min.



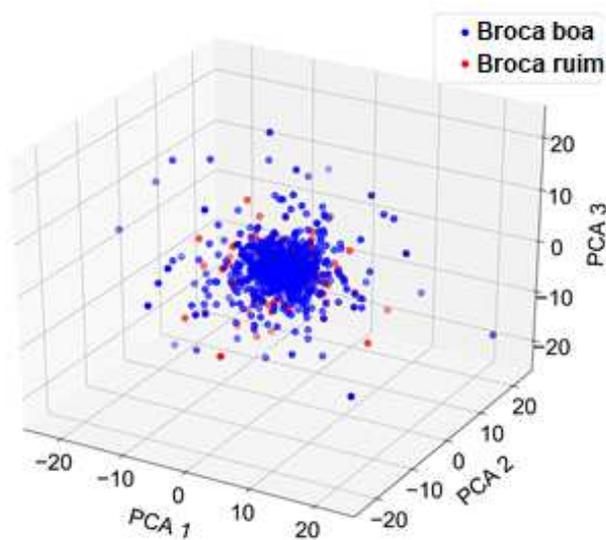
A aplicação das transformações descritas nesta seção são a base para o treinamento do sistema de diagnóstico do estado das brocas. A seguir, as imagens serão utilizadas para captura das características principais, para então, serem utilizadas como dados de entrada no classificador PNN.

3.3 Deep Convolutional Autoencoder

Inicialmente avaliou-se o desempenho dos classificadores tradicionais de aprendizado de máquina, utilizando os dados do sinal temporal do torque de superfície (TORQ), da imagem de densidade espectral (PSD IMG) e da imagem compactada, através do método proposto de autoencoder convolucional (PSD DCAE). Não foi escopo analisar em detalhes cada tipo de algoritmo classificador, mas sim a aplicabilidade do uso de autoencoder convolucional, como forma de obter características principais através do mapa de características, para fins de melhorias de classificação e velocidade de processamento.

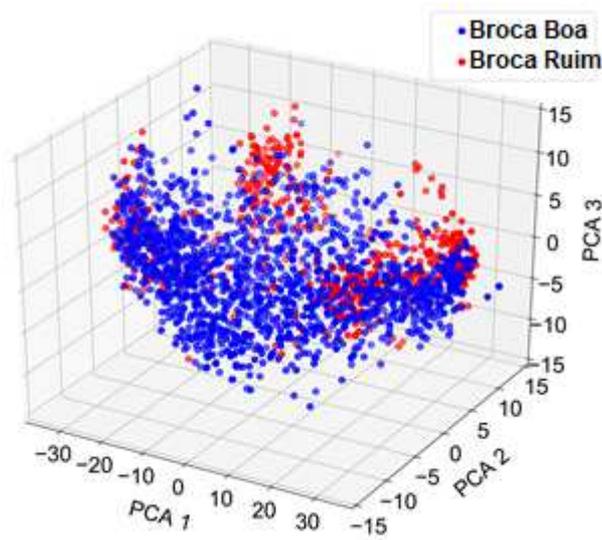
A Figura 11 apresenta a análise 3D do PCA do sinal temporal do torque de superfície. Observa-se que praticamente não há discriminação de classes, o que sugere menor índice de acertos para classificação.

Figura 11 - PCA do sinal do torque de superfície da base total de dados.



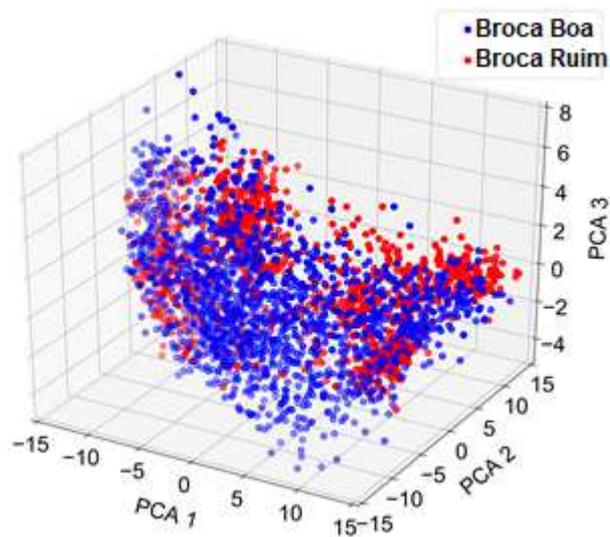
A Figura 12 mostra a análise 3D do PCA para a transformação do sinal para PSD. Observa-se que uma maior discriminação das classes correspondentes a broca boa e desgastada.

Figura 12 - PCA do PSD do torque de superfície (todos os dados).



Já a Figura 13 mostra o resultado da análise 3D do PCA através do método proposto de imagem compactada via autoencoder. Nota-se que há uma melhor discriminação das classes de desgaste, além do impacto do gerador de amostras sintéticas para equilibrar a base de dados.

Figura 13 - PCA do DCAE do torque de superfície (todos os dados).



O algoritmo de PCA foi utilizado como meio auxiliar na investigação para obtenção da melhor rede de autoencoder convolucional, ou seja, treinamento para geração de características principais do sinal de densidade espectral. Foram feitas várias tentativas

no intuito de obter a melhor discriminação de classes, alterando a arquitetura e nível de compactação de imagens.

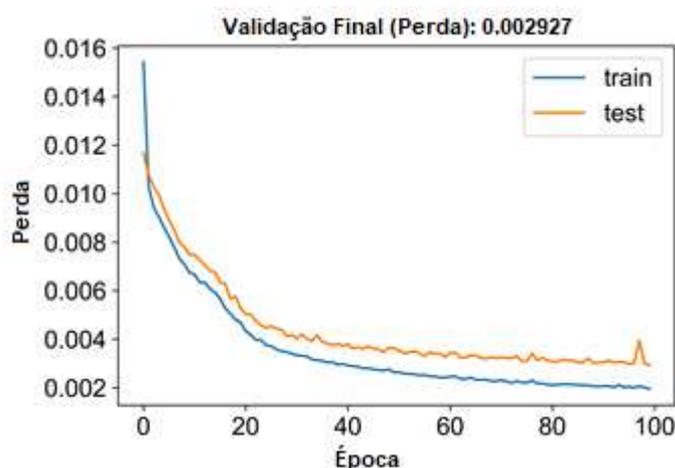
A arquitetura final utilizada para o DCAE está representada na Tabela 2. Foram efetuados diversos testes até se chegar em uma forma que melhor representa uma separação das classes, através da visualização de gráficos de PCA. Constatou-se que a dimensão 16 x 16 foi a mais adequada para representar o problema e, neste caso, teve-se uma redução de dimensionalidade para um terço da imagem original, com relação a dimensão 28 x 28.

Tabela 2 - Arquitetura do modelo de autoencoder convolucional.

Camada	Filtro	Tamanho Kernel	Dimensão Saída	Processo
Input			28 x 28 x 1	
Conv2D_1	128	3 x 3	26 x 26 x 128	Encoding
Max pool_1		2 x 2	13 x 13 x 128	
Conv2D_2	64	3 x 3	13 x 13 x 64	
Max pool_2		2 x 2	7 x 7 x 64	
Conv2D_3	32	3 x 3	7 x 7 x 32	
Max pool_2		2 x 2	4 x 4 x 32	
Conv2D_3	16	3 x 3	4 x 4 x 16	
Flatten			256	Feature Map
Conv2D_4	32	3 x 3	4 x 4 x 32	Decoding
Up sample_1		2 x 2	8 x 8 x 32	
Conv2D_5	64	3 x 3	8 x 8 x 64	
Up sample_2		2 x 2	16 x 16 x 64	
Conv2D_6	128	3 x 3	14 x 14 x 128	
Up sample_3		2 x 2	28 x 28 x 128	
Conv2D_7	1	3 x 3	28 x 28 x 1	

A parametrização da rede convolucional profunda, foram feitas através de funções de ativação do tipo ReLu e strides fixos em 1. O otimizador utilizado foi o Adam e a função de custo foi a logcosh. A modelagem foi implementada com o uso da biblioteca Keras do Python. O treinamento foi executado com 100 épocas, conforme pode ser visualizado na Figura 14, sendo utilizado 80% da base para treinamento e 20% para teste.

Figura 14 - Treinamento do autoencoder convolucional.



Este procedimento visa apenas aferir a eficiência e estabilidade do sistema, pois o que realmente interessa é o vetor de características e não a qualidade final da imagem reproduzida, como em um problema clássico de compactação de imagem, no qual realmente pretende-se uma imagem reconstruída. Para a geração do modelo final de aprendizado, foram utilizados todos os dados disponíveis de imagens.

3.4 Análise comparativa entre algoritmos

Para validação das análises prévias efetuadas com o método PCA, procedeu-se com a investigação dos métodos tradicionais de aprendizado de máquina, para avaliar o impacto em cada tipo de mapa de características de entrada. Foram feitos testes com sinal temporal do torque estacionário (TORQ), da imagem completa do PSD do sinal do torque (PSD IMG) e da imagem obtida através do autoencoder convolucional (PSD DCAE).

A Tabela 3 apresenta os resultados obtidos com os algoritmos de classificação clássicos de aprendizado de máquina. Foram aplicados os métodos de avaliação cruzada contendo 10 grupos, para melhor análise de desempenho. Foram utilizados os indicadores de precisão, de maneira a capturar os melhores classificadores com relação a minimização de FP e o F1 Score, para permitir a análise do balanço entre precisão e recall.

Tabela 3 - Precisão para modelos de aprendizado de máquina clássico.

Dataset	Modelo	Precisão
PSD DCAE	Neural Net	0,81
PSD IMG	Neural Net	0,79
TORQ	Neural Net	0,77
PSD DCAE	AdaBoost	0,71
PSD DCAE	Random Forest	0,70
PSD IMG	Linear SVM	0,69
PSD DCAE	Linear SVM	0,68
PSD IMG	AdaBoost	0,67
PSD DCAE	Decision Tree	0,66
PSD DCAE	KNN	0,63
PSD IMG	Random Forest	0,63
PSD IMG	Decision Tree	0,63
TORQ	Random Forest	0,60
TORQ	Naive Bayes	0,60
TORQ	KNN	0,59
TORQ	Decision Tree	0,58
TORQ	Linear SVM	0,58
PSD IMG	Naive Bayes	0,58
TORQ	AdaBoost	0,58
PSD IMG	KNN	0,55
PSD DCAE	Naive Bayes	0,49

O classificador de redes neurais de retropropagação tradicional, com o mapa de características PSD DCAE, foi o que melhor apresentou resultados de precisão para classificação do estado da broca. Nota-se que o uso dos dados de entrada provenientes do método de autoencoder convolucional (PSD DCAE), apresentou resultado com precisão de 81%, seguido de 79% para a imagem completa (PSD IMG) e 77% para dados brutos de torque de superfície (TORQ).

Para o algoritmo AdaBoost, segundo colocado nesta lista, constatou-se mais uma vez que a imagem compactada (PSD DCAE) foi superior em relação aos demais dados de entrada de características. Nota-se que a utilização das características de entrada, provenientes do método proposto (PSD DCAE), evidencia superioridade em relação aos demais, corroborando análises inicialmente observadas através do método de PCA.

Com relação ao indicador F1 Score, nota-se que não houve alteração no desempenho para os resultados do algoritmo de redes neurais de retropropagação, conforme apresentado na Tabela 4.

Tabela 4 – F1 Score para modelos de aprendizado de máquina clássico.

Dataset	Modelo	F1 Score
PSD IMG	Neural Net	0,85
TORQ	Neural Net	0,85
PSD DCAE	Neural Net	0,85
PSD DCAE	KNN	0,76
PSD IMG	Linear SVM	0,74
PSD IMG	KNN	0,71
PSD DCAE	AdaBoost	0,71
PSD DCAE	Linear SVM	0,69
PSD IMG	Decision Tree	0,69
TORQ	Naive Bayes	0,68
PSD IMG	AdaBoost	0,68
TORQ	KNN	0,68
TORQ	Linear SVM	0,67
PSD DCAE	Decision Tree	0,67
PSD DCAE	Naive Bayes	0,66
PSD DCAE	Random Forest	0,65
PSD IMG	Random Forest	0,62
TORQ	Decision Tree	0,62
TORQ	Random Forest	0,60
TORQ	AdaBoost	0,60
PSD IMG	Naive Bayes	0,50

Ainda assim, o classificador AdaBoost, mostrou-se superior com o uso de PSD DCAE. Observa-se também que o método de KNN não consegue capturar as não linearidades, evidenciado tanto no resultado de precisão como para o F1 Score. A Tabela 3 apresenta os resultados para F1 Score para as bases de dados estudadas.

Os resultados evidenciam que a entrada de dados via mapa de características DCAE, quando comparados com o sinal de imagem sem compactação e com torque de superfície com dados bruto, apresentaram superioridade na precisão e similaridade quando utilizado indicador F1 Score.

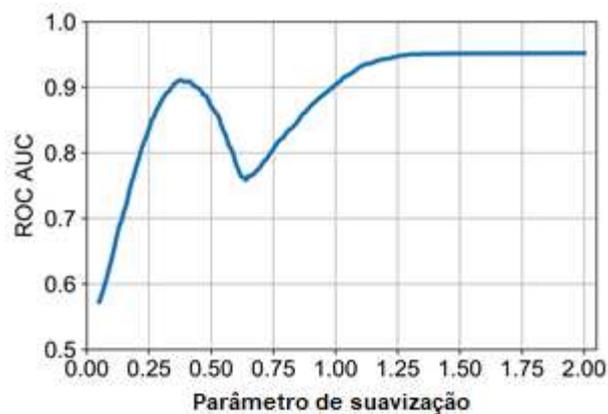
3.5 Classificação através da PNN

O resultado do algoritmo de PNN depende intrinsecamente do fator de suavização. Inicialmente, deve-se proceder com a pesquisa do melhor parâmetro de suavização. A curva de análise que melhor representa o desempenho no cenário operacional de perfuração proposto para análise de desgaste de broca, foi a curva Receiver Operating

Characteristic (ROC), muito utilizada em classificações binárias. Este tipo de análise tem a característica de colocar a taxa de TP (TPR: True Positive Rate) no eixo Y e a taxa de FP (FPR: False Positive Rate) no eixo X. Isto significa que o lado superior esquerdo do gráfico indicaria a região ótima, sendo máximo TPR e mínimo TFR. A obtenção deste ponto ideal não é realista, mas a Área Abaixo da Curva (AUC), mostra um importante indicador da tendência do melhor resultado.

A Figura 15 apresenta os resultados de cada valor de AUC do ROC obtido com relação ao fator de suavização aplicado na PNN. Cada valor de AUC da ROC foi obtido como uso de validação cruzada, com 10 grupos na amostragem da base de dados de imagens características do DCAE.

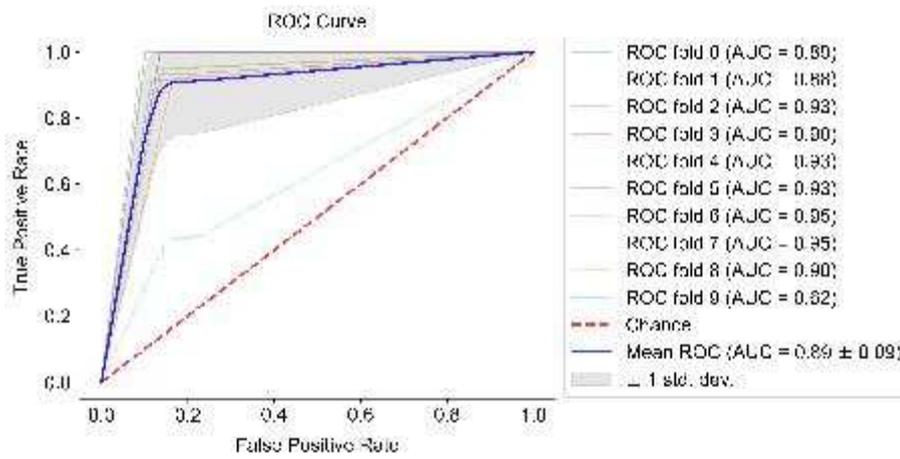
Figura 15 - Parâmetro de suavização em função da área abaixo do gráfico da curva ROC.



Nota-se através da análise do resultado apresentado na Figura 13, que há dois pontos de máximo. O primeiro ponto indica parâmetro ótimo em $\sigma = 0,38$ e o segundo, qualquer valor acima de $\sigma = 1,40$, onde a curva fica constante. Foram testados ambos valores, e o $\sigma = 0,47$ foi o que apresentou os melhores resultados, pois este valor foi o mais adequado para os estudos de caso de campo, conforme será visto na próxima seção.

Os valores apresentados na Figura 15 são uma tendência para a pesquisa do valor ideal do parâmetro de suavização, mas o valor ótimo encontrado, visa balancear as taxas de acertos e erros, de modo a evitar overfitting do algoritmo. A Figura 16 apresenta a curva ROC do valor corresponde ao ponto ótimo do parâmetro de suavização $\sigma = 0,47$.

Figura 16. Curva ROC com validação cruzada para o fator de suavização $\sigma = 0,47$.



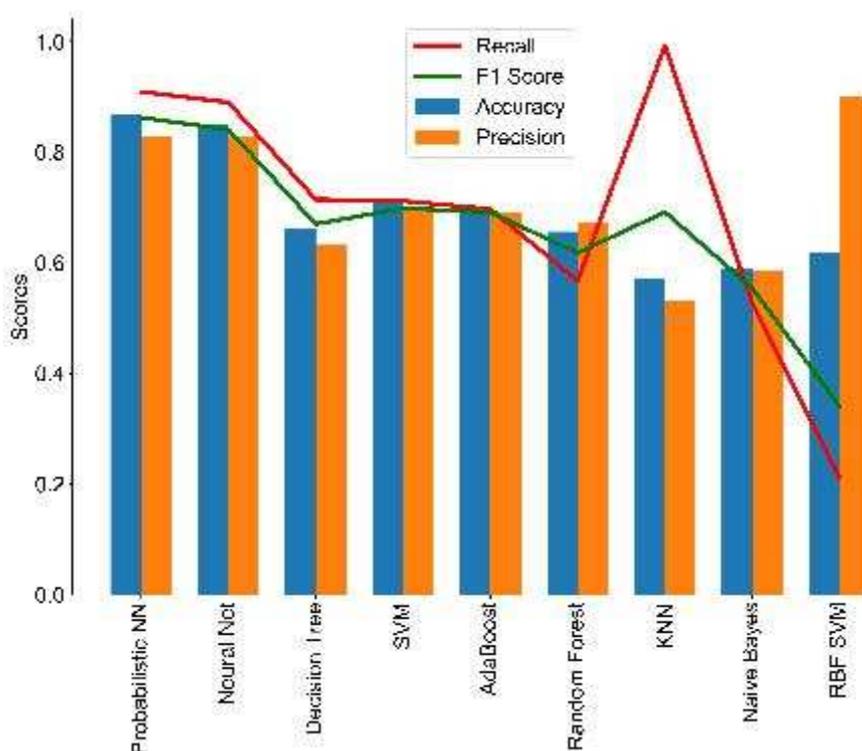
4 RESULTADOS E DISCUSSÕES

4.1 Comparativos entre modelos de classificação

Os resultados obtidos com o modelo proposto não puderam ser comparados diretamente com a literatura atual, pois não há referências diretas para classificação de estado de brocas de forma independente. Para avaliação dos resultados, foi utilizada a comparação entre o modelo proposto com classificação com uso de PNN e demais métodos clássicos de aprendizado de máquina.

A Figura 17 apresenta a comparação entre os vários métodos de aprendizado de máquina, considerando o mapeamento de entrada do DCAE, fazendo uso da técnica de validação cruzada, com extratificação em 10 grupos, entre base de teste e treinamento.

Figura 17 - Comparativo entre modelos de aprendizado de máquina utilizado DCAE.



O modelo PNN apresentou leve superioridade em todos os indicadores e empate no indicador de precisão, quando comparado com o modelo de rede neural tradicional (segundo melhor na lista de modelos de aprendizado de máquina), mas como apresentado anteriormente, o modelo PNN é extremamente rápido no processamento da classificação.

O modelo KNN apresentou descontinuidade no indicador de recall, porém facilmente observa-se que a resposta pode ser desconsiderada, dado que a precisão e acurácia ficaram abaixo de 60%. O método de RBF SVM apresentou valor de precisão em disparidade com os demais, mas também com os demais indicadores abaixo de 60%. A Tabela 5 sintetiza os valores apresentados na Figura 17.

Tabela 5 – Resultados dos modelos de aprendizado de máquina para DCAE.

Modelo	Acurácia	Precisão	Recall	F1 Score
Probabilistic NN	0,87	0,83	0,91	0,86
Neural Net	0,85	0,83	0,89	0,84
Decision Tree	0,66	0,63	0,71	0,67
SVM	0,71	0,69	0,71	0,70
AdaBoost	0,70	0,69	0,70	0,69
Random Forest	0,66	0,67	0,57	0,62
KNN	0,57	0,53	0,99	0,69
Naive Bayes	0,59	0,59	0,53	0,55
RBF SVM	0,62	0,90	0,21	0,34

4.2 Testes de validação de campo

A base de dados da matriz de imagem, considerando o modelo de aprendizado gerado pelo DCAE, incluindo as amostras sintéticas de balanceamento, correspondem a uma matriz de 2848 x 256, sendo composta por 2848 imagens de 30 min cada, obtidas através da medição de torque a cada 5 s. A vetorização das imagens compactadas (16x16) corresponde ao número de colunas 256.

Uma forma de avaliação do modelo, adotado neste trabalho, foi através de uma análise da resposta da PNN, considerando um base de treinamento de 70% dos dados de entrada da matriz de imagem gerada através do DCAE e 30% para dados de teste de desempenho, sendo aplicada a técnica de validação cruzada em 10 grupos. O objetivo é avaliar de maneira global e independente a resposta do modelo. Os resultados são apresentados em forma de matriz de confusão, conforme a Figura 18, mostrando os números absolutos e na Figura 19, de maneira normalizada.

Figura 18 - Matriz de confusão da rede neural probabilística.

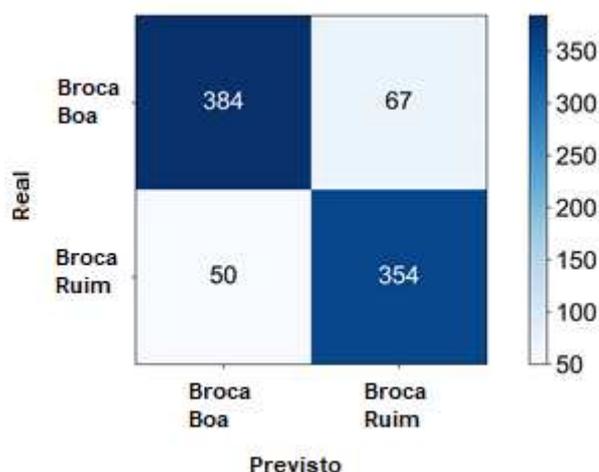
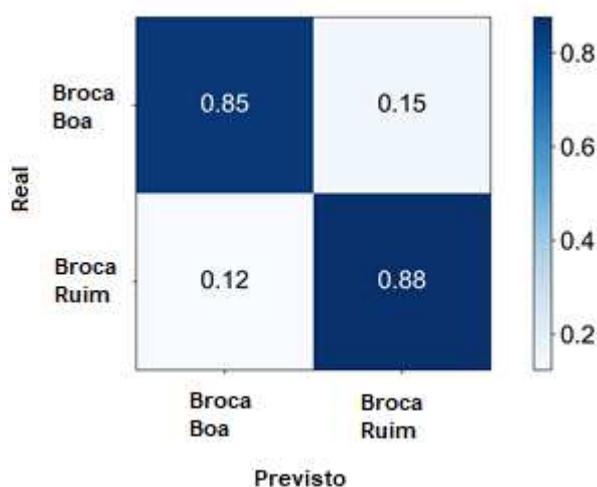


Figura 19 - Matriz de confusão normalizada para a rede neural probabilística.

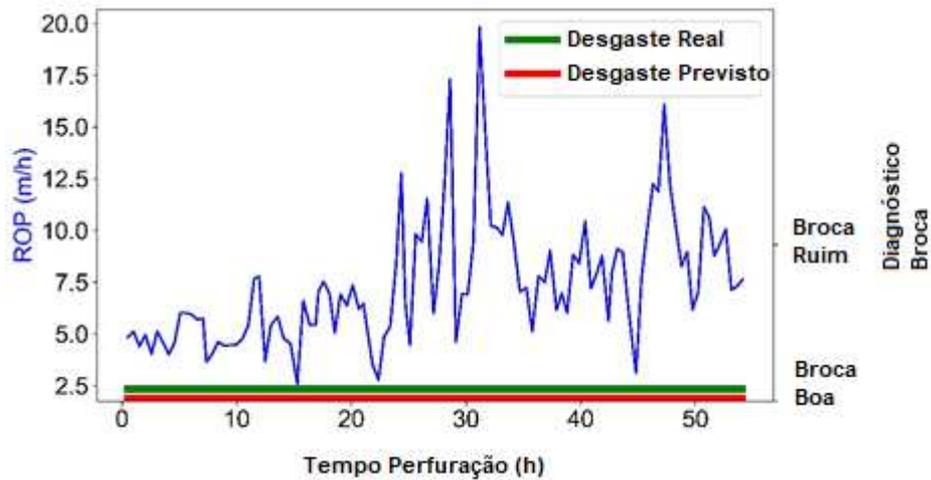


Os resultados mostraram-se satisfatórios, principalmente pela elevada taxa de TP (acerto para broca desgastada) de 88% e valores de 15% para os eventos de FP (classificação de broca ruim quando na verdade está sem desgaste).

Um outra abordagem para analisar o desempenho do modelo é através de análise poço a poço, de modo a representar a realidade prevista de utilização do algoritmo. A simulação de perfuração em tempo real, considerando cenário operacional em poço individual, foi efetuada utilizando os dados dos poços apresentados na Tabela 1. A análise foi executada de modo a evitar falhas de classificação de FP, através da aplicação do Teorema de Bayes. Para confirmar os resultados apresentados no classificador PNN para broca ruim, a resposta probabilística foi arbitrada que deveria ser superior a 67% para ser classificada como broca ruim de fato.

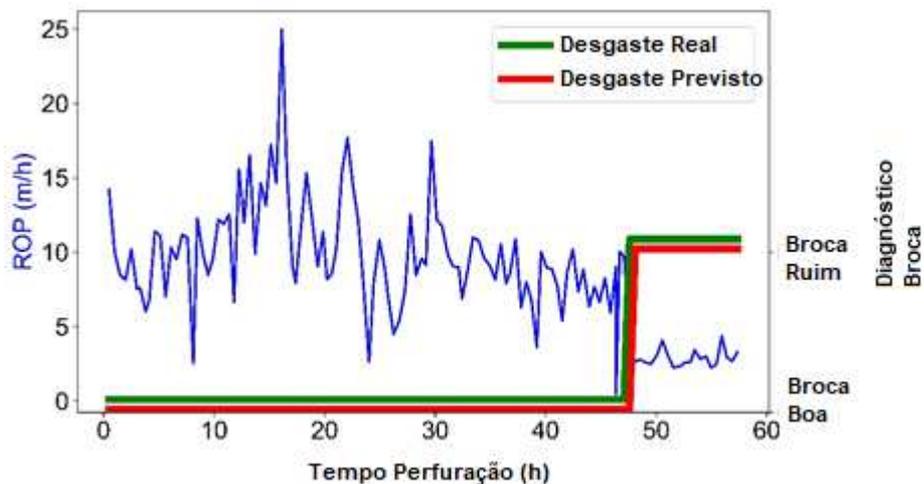
O poço “J” da Tabela 1, contém 64 h de perfuração, foi utilizado no modelo de análise para o caso de não haver desgaste a ser considerado, ou seja, o objetivo é avaliar a sensibilidade para FP, onde uma classificação errada pode levar a interpretação de retirada de coluna de perfuração. A Figura 20 apresenta os resultados obtidos para o poço, onde não houve falha na classificação para FP.

Figura 20 – Simulação em tempo real do Poço “J”.



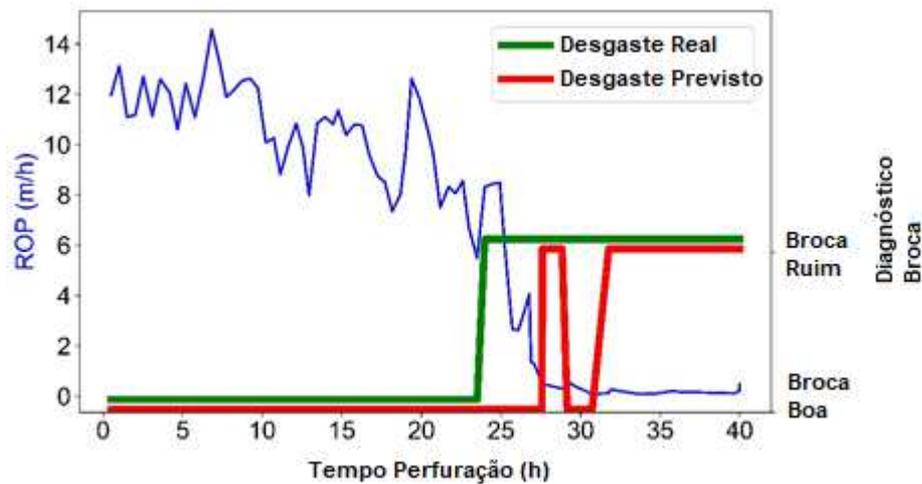
A próxima simulação apresenta os resultados obtidos para o poço “L”, onde ocorre cenário de broca ruim. O sistema de classificação recomenda a retirada da broca no tempo 48,1 h e, conforme classificação supervisionada (real), o momento de retirada da broca seria em 47,6 h. O desvio no tempo decisório foi de 30 min, conforme pode ser visto na Figura 21.

Figura 21 – Simulação em tempo real do poço “L”.



Para o poço “D”, a classificação supervisionada indica retirada de broca em 24 h, mas o sinal do algoritmo em tempo real, indicou retirada da broca em 27,6 h, exibindo um retardo de 3,6 h. Considerando que na operação real de perfuração deste poço, o tempo de ineficiência perfurando com cortadores ruins foi de 18 h, o sistema poderia ter economizado 14,4 h de operação de sonda, conforme apresentado na Figura 22. Apesar disso, houve um ponto de classificação incorreta pelo algoritmo proposto, em torno de 30 h, entretanto após este evento, o sistema permaneceu fixo na recomendação de retirada de broca.

Figura 22 – Simulação em tempo real do poço “D”.



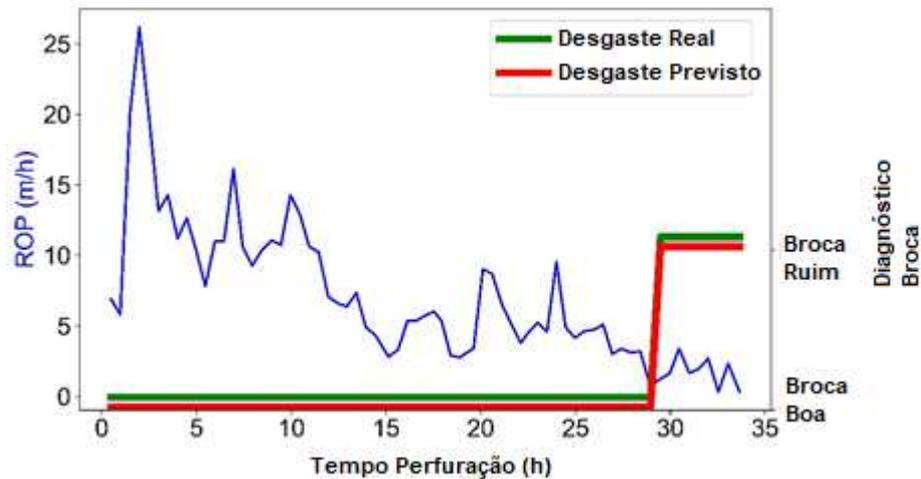
Os poços “N” e “O” apresentados na Tabela 6 foram utilizados para validação de campo, considerando os casos que foram da base de dados utilizada. Estes poços possuem características semelhantes aos utilizados, conforme apresentado na Tabela 1.

Tabela 6 – Dados dos poços utilizados para validação de campo.

Poço	N	O
Perfurado (m)	258.0	177.0
Tempo (h)	37.8	60.4
ROP (m/h)	6.8	2.9
Perfurado com cortador ruim (m)	8.0	0.0
Tempo com cortador ruim (h)	8.0	0.0
ROP com cortador ruim (m/h)	1.0	0.0
Desgaste IADC (interno-externo)	2-8	2-2
Motivo manobra	Taxa penetração	Término da fase

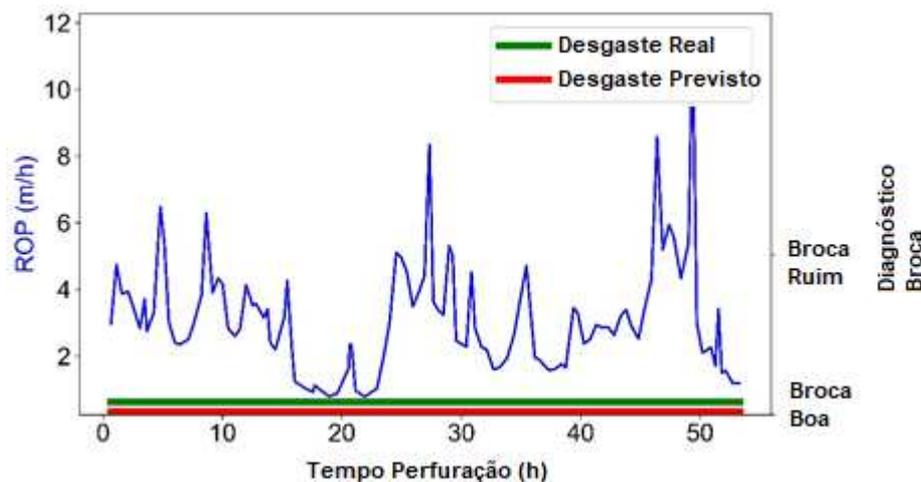
Conforme pode ser visto na Figura 23, houve evidência de acerto do momento de manobra pelo algoritmo, no tempo 29,5 h, ou seja, este seria o melhor momento para execução da operação de substituição da broca.

Figura 23 – Simulação em tempo real do poço “N”.



O poço “O” evidencia a robustez para evitar FP, mesmo em cenários de ROP baixo, o que poderia levar a falha na interpretação de cortadores ruins, entre os tempos 19 h e 22 h. Novamente, o algoritmo apresentou resultado satisfatório na resposta esperada, conforme pode ser visto na Figura 24.

Figura 24 – Simulação em tempo real do poço “O”.



O método proposto para análise de diagnóstico de broca pode ser aplicado em qualquer diâmetro de broca e formação rochosa, bastando manter a coerência e uniformidade dos dados utilizados. A aplicação dependerá da consistência dos poços analisados e de como a base de classificação supervisionada é efetuada. Uma possível

melhoria, seria a captura de sinais de superfície com maior densidade de informações, ou um número maior de poços perfurados, pois isso permitiria aplicar janelas inferiores a 30 min, o que levaria a um maior número de amostras para montagem da base de dados de treinamento.

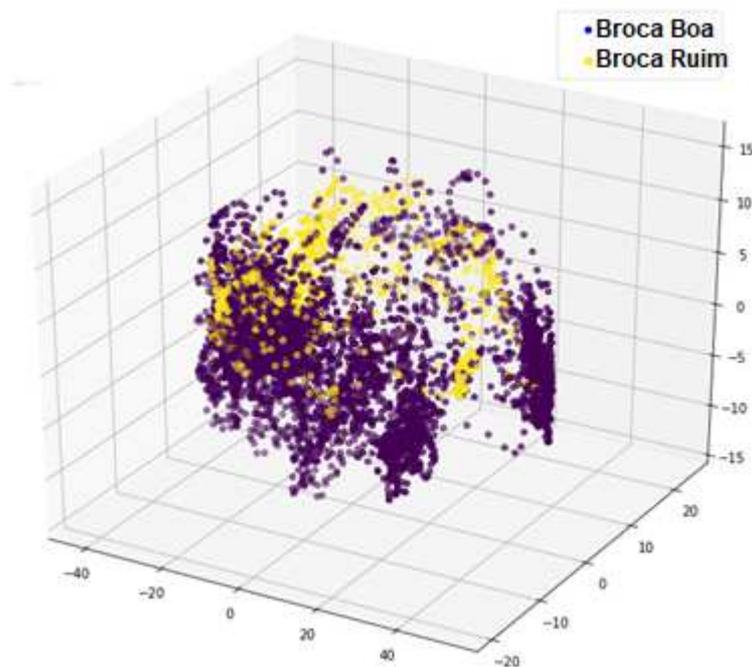
4.3 Pressão de bombeio com característica principal

Diante dos resultados obtidos, o sistema apresentou resultados satisfatórios para o sinal espectral do torque de superfície para a fase de perfuração de reservatório carbonático em 12 ¼”, baseado principalmente na abordagem de que os cortadores exerceriam influência na resposta, na medida em que a broca fosse desgastada, influenciando e permitindo a identificação do sinal a ser classificado. O torque de superfície é um dos sinais obtidos durante a perfuração e, desta forma, abrem-se outras oportunidades de análise espectral de sinais, de modo a fornecer uma possibilidade de classificação mais abrangente.

A investigação deste trabalho evoluiu para análise do sinal de pressão de superfície, ou seja, buscou-se identificar se o sinal da pressão poderia ser um possível candidato a ser utilizado como característica de desgaste da broca. Para isso, utilizou-se os mesmos dados de poços apresentados na Tabela 1 e aplicou-se a mesma metodologia proposta neste trabalho, mas considerando o sinal da pressão de bombeio na superfície, ao invés do torque de superfície.

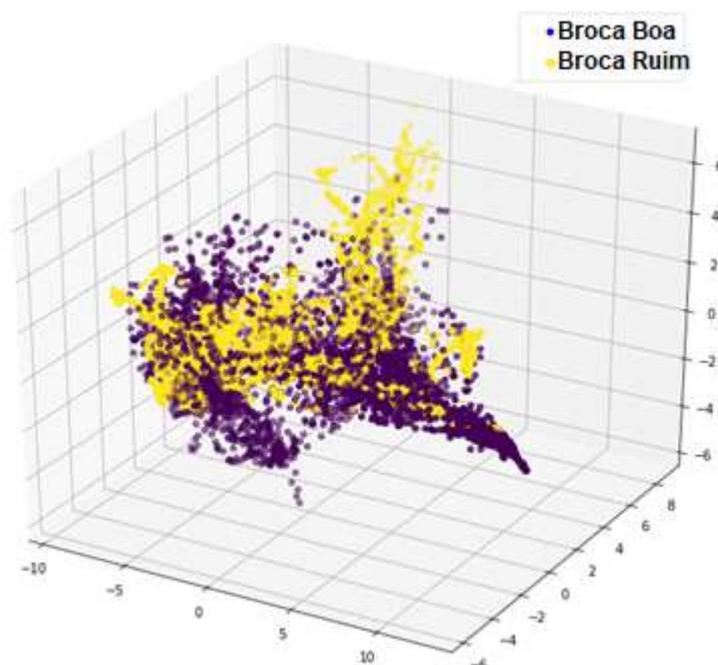
Os resultados não se mostram adequados para permitir contraste de classes que permita uma separação de classes conforme observado com o uso da abordagem do torque de superfície. A Figura 25 apresenta os resultados obtidos através da abordagem PCA do sinal espectral da pressão de bombeio de superfície, onde constata-se que não houve uma separação adequada de classes.

Figura 25 - PCA do PSD da pressão de bombeio de superfície (todos os dados).



A Figura 26 mostra os resultados através da metodologia de separação com o algoritmo DCAE, onde novamente não foi possível identificar com clareza a possibilidade de sucesso para classificador do tipo binário. Foram investigadas várias redes de autoencoder na abordagem DCAE, mas após várias tentativas, não houve sucesso na obtenção de separação de classes. Uma das possíveis explicações é de que não há correlação direta entre a pressão de bombeio de superfície e desgaste da broca, pois como pode ser observado na Tabela 1, os desgastes majoritariamente foram observados na porção externa da broca, o que por sua vez, não exerceria influência nos jatos da broca, provocando alguma perda de carga localizada que pudesse ser detectada na superfície através de identificação de anomalias.

Figura 26 - PCA do DCAE da pressão de bombeio de superfície (todos os dados).



Esta investigação sugere que a análise dos dados brutos de perfuração, combinado com o cenário e desgastes apresentados pelas brocas, podem exercer influência na elaboração da base de dados para aprendizado. Desta forma, é importante frisar que podem ocorrer limitações para extensão das análises, logo é fundamental uma análise coerente entre o sinal a ser observado e sua correlação para permitir a montagem da base de treinamento e classificação final do estado da broca.

4.4 Sugestões para implementação em tempo real

Para aplicação em um possível produto final, é recomendado seguir alguns passos para implementação, de modo a viabilizar o acompanhamento em tempo real em perfuração. Para implementação os seguintes passos são sugeridos para permitir a aplicação do algoritmo em sistemas de acompanhamento em tempo real:

- 1) Obter dados brutos da mecânica de perfuração (torque de superfície ou outro sinal a ser utilizado como característica principal) do software de acompanhamento em tempo real, dentro do tempo estipulado na janela de tempo do algoritmo;

- 2) Filtrar dados para coletar apenas informações com broca no fundo (dados perfurando) e descartar dados com broca fora do fundo;
- 3) Caso a quantidade de dados com broca no fundo na janela estipulada sejam completados, seguir adiante, do contrário, repetir item 1 para nova captura de dados;
- 4) Organizar em uma matriz com os dados dentro do tempo da janela definida no algoritmo de aprendizado (janela de sinal);
- 5) Converter sinal não estacionário para estacionário através da diferenciação temporal;
- 6) Gerar sinal espectral desta matriz de dados da janela de tempo gerada;
- 7) Converter esta matriz para dados entre 0 e 255, de modo a permitir a geração de uma imagem padronizada em pixels;
- 8) Aplicar histograma de equalização de imagem nesta matriz;
- 9) Aplicar filtro de imagem para gerar contraste de picos de imagem;
- 10) Carregar arquivo com treinamento do DCAE (imagens treinadas para compactação e extração de características principais);
- 11) Aplicar o algoritmo DCAE na matriz gerada;
- 12) A resposta gerada anteriormente será uma nova matriz com as características principais do sinal espectral;
- 13) Carregar arquivo com o treinamento do algoritmo classificador PNN;
- 14) Efetuar a classificação da broca com matriz de características principais;
- 15) Calcular a probabilidade do TP (True Positive) baseado no histórico da broca e na profundidade atual desta janela em análise;
- 16) Arbitrar uma probabilidade final no qual haja uma confirmação mais segura de broca desgastada (por exemplo, superior a 60% ou 70%), baseada na classificação do algoritmo de machine learning e histórico de avanço da broca, conforme profundidade atual;
- 17) Caso a classificação final da broca seja por manter a broca no fundo (broca boa), então somar 1 ao vetor de acumulação de dados ao longo do tempo, caso contrário, subtrair 1. Esta função acumulada iniciará crescente e tenderá a ter uma inflexão, a partir do momento em que se confirmarem vários sinais negativos com indicação de broca desgastada;
- 18) Diferenciar o vetor acumulado ao longo do tempo, de modo a capturar o ponto de inflexão para determinar o momento no qual a quantidade de sinais negativos

(broca ruim) se mantiver suficientemente elevados para indicar uma retirada da broca;

- 19) Enviar o sinal de retirada de broca (ou alerta ao sistema) conforme os sinais foram surgindo através do cálculo efetuado no item 18;
- 20) Repetir o item 1 com nova janela de captura de dados

5 CONCLUSÕES

Este trabalho apresentou uma nova forma de modelagem de diagnóstico de desgaste de brocas, através da análise dos sinais do torque de superfície com uso de PNN. Os sinais de torque obtidos diretamente do campo foram processados, para obtenção de imagens correspondentes de PSD, para em seguida serem extraídas as características principais de forma compacta, através do algoritmo DCAE. Em seguida, foi preciso avaliar o melhor parâmetro de suavização para a PNN, onde obteve-se o resultado através da análise ROC. O modelo proposto de PNN mostrou-se superior aos demais métodos de aprendizado de máquina clássicos, no que diz respeito aos indicadores de qualidade, além de contar com maior velocidade no processamento da classificação, ideal para sistemas de análise em tempo real.

Observou-se que os resultados foram satisfatórios, com relação ao banco de dados utilizado e, também, através da comparação de 2 poços obtidos da perfuração nos campos do pré-sal da costa brasileira. No poço A pode-se comprovar, pela simulação de uma eventual análise em tempo real de perfuração, que o modelo pode capturar o momento ideal para substituição da broca. Já no poço B, observou-se a robustez para evitar FP, dado que não haveria necessidade de substituição da broca, pois o ROP estava elevado e a broca, após a sua retirada, não apresentou desgaste que justificasse sua substituição durante a perfuração.

Para fins de análise em tempo real de diagnóstico de brocas de perfuração, o modelo apresentou-se satisfatório. Entretanto, algumas variáveis adicionais poderiam ser levadas em consideração, tais como ROP, histórico de desgaste da broca e trecho ainda a ser perfurado, para enfim elaborar uma resposta completa e assertiva.

O sinal de pressão foi investigado e não houve sucesso para implementação em fase 12 ¼” com brocas do tipo PDC. Esta informação sugere que há influência no tipo de desgaste da broca e o sinal de superfície e isso pode-se constituir um limitante para aplicação geral, utilizando-se apenas o sinal do torque de superfície. Isso sugere que a abordagem dos dados de desgaste de broca e a análise dos sinais de superfície, são a parte fundamental para uma boa montagem da base de dados, e crítico para o sucesso no processo de classificação de desgaste da broca.

Por fim, conclui-se que há um grande potencial de aplicação para auxílio na tomada de decisão em tempo real, para operações de perfuração, dado que o desempenho global

da fase construída está atrelada, não somente a maximização do ROP, mas também na melhor decisão de substituição da broca, quando esta se apresentar com desgaste excessivo, detectado através de algoritmos de interpretação de padrões de sinais em tempo real.

5.1 Trabalhos futuros

Como trabalhos futuros sugerem-se:

- Investigar outros diâmetros de broca em perfuração no carbonato ou outros tipos de formações rochosas, por exemplo, carbonatos com brocas PDC de 8,5” no pré-sal;
- Analisar outros sinais de superfície ou mesmo a combinação entre eles, de forma a possibilitar outras situações de captura de características governantes no processo de classificação de desgaste de broca;
- Avaliar a possibilidade de implementação em sistemas de acompanhamento em tempo real, utilizando técnicas de aprendizado por reforço ou com montagem automática de base de dados para atualização da base de treinamento;

6 REFERÊNCIAS

- Ancona, F., Colla, A.M., Rovetta, S., Zunino, R., 1998. Implementing probabilistic neural networks. *Neural Comput & Applic.* <https://doi.org/10.1007/BF01413860>.
- Arehart, R.A., 1990. Drill-Bit Diagnosis With Neural Networks. *SPE Computer Applications.* <https://doi.org/10.2118/19558-PA>.
- Bello, O., Teodoriu, C., Yaqoob, T., Oppelt, J., Holzmann, J., Obiwanne, A., 2016. Application of Artificial Intelligence Techniques in Drilling System Design and Operations: A State-of-the-Art Review and Future Research Pathways. *SPE Nigeria Annual International Conference and Exhibition, Lagos, Nigeria.* <https://doi.org/10.2118/184320-MS>.
- Chen, M., Shi, X., Zhang, Y., Wu, D., Guizani, M., 2017. Deep Feature Learning for Medical Image Analysis with Convolutional Autoencoder Neural Network. *IEEE Transactions on Big Data.* DOI: 10.1109/TBDATA.2017.2717439.
- David, E.O., Netanyahu, N.S., 2016. DeepPainter: Painter Classification Using Deep Convolutional Autoencoders. *International Conference on Artificial Neural Networks (ICANN), Springer LNCS, Vol. 9887, pp. 20-28, Barcelona, Spain.* DOI: 10.1007/978-3-319-44781-0_3.
- Dickey, D.A., Fuller, W.A., 1979. Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical Association*, 74, p. 427–431.
- Gerbaud, L., Menand, S., Sellami, H., 2006. PDC Bits: All comes from the cutter rock interaction. *IADC/SPE Drilling Conference, Miami, United States.* <https://doi.org/10.2118/98988-MS>.
- Gidh, Y. K., Purwanto, A., Ibrahim, H., 2012. Artificial Neural Network Drilling Parameter Optimization System Improves ROP by Predicting/Managing Bit Wear. *SPE Intelligent Energy International, Utrecht, The Netherlands.* <https://doi.org/10.2118/149801-MS>.

- Goodfellow, I., Bengio, Y., Courville, A., 2016. Deep Learning. MIT Press. ISBN 978-0262035613.
- Gu, Y. Bao, Z., Rui, Z., 2018. Complex Lithofacies Identification Using Improved Probabilistic Neural Networks. Society of Petrophysicists and Well-Log Analysts. SPWLA-2018-v59n2a9.
- Guo, S., Yang, T., Gao, W., Zhang, C., 2018. A Novel Fault Diagnosis Method for Rotating Machinery Based on a Convolutional Neural Network. Sensors 2018, 18, 1429. <https://doi.org/10.3390/s18051429>.
- He, H., Bai, Y., Garcia, E.A., Shutao, L. 2008. ADASYN: Adaptive synthetic sampling approach for imbalanced learning. IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence), Hong Kong, China, DOI: 10.1109/IJCNN.2008.4633969.
- Hegde, C., Soares, C., Gray, K., 2018. Rate of penetration (ROP) modeling using hybrid models: deterministic and machine learning. Unconventional Resources Technology Conference Conference, Houston, Texas, USA. <https://doi.org/10.15530/URTEC-2018-2896522>.
- Heydarzadeh, M., Kia, S. H., Nourani, M., Henao, H., Capolino, G.A., 2016. Gear fault diagnosis using discrete wavelet transform and deep neural networks. IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society, Florence, Italy. <https://doi.org/10.1109/IECON.2016.7793549>.
- Hinton, G. E.; Salakhutdinov, R.R., 2006. Reducing the Dimensionality of Data with Neural Networks. Science 313 (5786): 504–507. DOI: 10.1126/science.1127647.
- Huang, Z., Xie, D., Xie, B., Zhang, W., Zhang, F., He, L., 2018. Investigation of PDC bit failure base on stick-slip vibration analysis of drilling string system plus drill bit. Journal of Sound and Vibration, Vol. 417, pp. 97-109. <https://doi.org/10.1016/j.jsv.2017.11.053>.
- Krizhevsky, A., Sutskever, I., Hinton, G., 2012. Imagenet classification with deep convolutional neural networks. Advances in Neural Information Processing Systems 25, pp. 1106-1114. DOI: 10.1145/3065386.

- Leine, R. I., Van Campen, D. H., Keultjes, W. J. G. 2002. Stick-slip whirl interaction in drillstring dynamics. *Journal of Vibration and Acoustics*, v. 124, n. 2, pp.209–220. <https://doi.org/10.1115/1.1452745>.
- Li, Y., Cheng, G., Pang, Y. Kuai, M., 2018. Planetary Gear Fault Diagnosis via Feature Image Extraction Based on Multi Central Frequencies and Vibration Signal Frequency Spectrum. *Sensors* 2018, 18, 1735. <https://doi.org/10.3390/s18061735>.
- Liu, J., Chen, X., Li, J., Gao, J., Liu, A., 2019. Seismic reservoir characterization based on Probabilistic Neural Networks. Society of Exploration Geophysicists. SEG International Exposition and Annual Meeting, San Antonio, Texas, USA. SEG-2019-3214873.
- McConnell, K.G., Varoto, P.S., 2008. *Vibration Testing: Theory and Practice*. John Wiley & Sons, New Jersey, USA. ISBN: 978-0-471-66651-6.
- Noshi, C.I., Schubert, J.J., 2018. The Role of Machine Learning in Drilling Operations; A Review. SPE/AAPG Eastern Regional Meeting, Pittsburgh, Pennsylvania, USA. <https://doi.org/10.2118/191823-18ERM-MS>.
- Rashidi, B., Hareland, G., Tahmeen, M., Anisimov, M., Abdorazakov, S., 2010. Real-Time Bit Wear Optimization Using the Intelligent Drilling Advisory System (Russian). SPE Russian Oil and Gas Conference and Exhibition, Moscow, Russia. <https://doi.org/10.2118/136006-RU>.
- Rezende, S. O., 2003. *Sistemas Inteligentes: fundamentos e aplicações*. Barueri, SP: Manole, ISBN 85-204-1683-7.
- Singh, R.P., Dixit, M., 2015. Histogram Equalization: A Strong Technique for Image Enhancement. *International Journal of Signal Processing, Image Processing and Pattern Recognition*. <http://dx.doi.org/10.14257/ijcip.2015.8.8.35>.
- Specht, D.F., 1990. Probabilistic neural networks. *Neural Networks*, vol.3, pp. 109-118. [https://doi.org/10.1016/0893-6080\(90\)90049-Q](https://doi.org/10.1016/0893-6080(90)90049-Q).
- Sweeney Jr. W.P., Musavi, M.T., Guidi, J.N., 1994. Classification of Chromosomes Using a Probabilistic Neural Network. University of Maine, Department of

Electrical and Computer Engineering, Orono, Maine.
<https://doi.org/10.1002/cyto.990160104>.

Thomas, B.E., John, S. K., Abe, S., 2015. Power Spectral Density Computation using Modified Welch Method. *IJSTE - International Journal of Science Technology & Engineering*, Vol. 2, Issue 4. ISSN: 2349-784X.

Togni, R., 2018. Predictive model for drilling phase duration of oil & gas wells. Politecnico di Milano. Master's degree in Computer Science and Engineering.

Verstraete, D., Ferrada, A., Droguett, E. L., Meruane, V., Modarres, M., 2017. Deep Learning Enabled Fault Diagnosis Using Time-Frequency Image Analysis of Rolling Element Bearings. *Hindawi, Shock and Vibration*.
<https://doi.org/10.1155/2017/5067651>.

Vununu, C., Moon, K.-S., Lee, S.-H., Kwon, K.-R., 2018. A Deep Feature Learning Method for Drill Bits Monitoring Using the Spectral Analysis of the Acoustic Signals. *Sensors* 2018, 18, 2634. <https://doi.org/10.3390/s18082634>.

Wang, C., Li, S., Zhang, L., 2019. Evaluation of rock abrasiveness class based on the wear mechanisms of PDC cutters. *Journal of Petroleum Science and Engineering* 174 (2019) 959-967. <https://doi.org/10.1016/j.petrol.2018.12.009>.

Welch, P., 1967. The use of fast Fourier transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms. *IEEE Transactions on Audio and Electroacoustics*, Vol. 15, pp. 70-73. DOI: 10.1109/TAU.1967.1161901.

Zhao, J., Shen, Y., Chen, W., Zhang, Z., Johnston, S., 2017. Machine Learning–Based Trigger Detection of Drilling Events Based on Drilling Data. *SPE Eastern Regional Meeting*, Lexington, Kentucky, USA. <https://doi.org/10.2118/187512-MS>.