



Daniel Boechat de Marins

**Técnicas de Identificação de Sistemas Híbridos:
Algoritmos Black Box e Abordagens Grey Box
para Simulações com Dados Reais na Produção
de Petróleo e Análise da Velocidade de
Perfuração**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Engenharia Mecânica, do Departamento de Engenharia Mecânica da PUC-Rio.

Orientador: Ph.D Arthur Martins Barbosa Braga

Rio de Janeiro
Maio de 2024



Daniel Boechat de Marins

**Técnicas de Identificação de Sistemas Híbridos:
Algoritmos Black Box e Abordagens Grey Box
para Simulações com Dados Reais na Produção
de Petróleo e Análise da Velocidade de
Perfuração**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Engenharia Mecânica da PUC-Rio. Aprovada pela Comissão Examinadora abaixo:

Ph.D Arthur Martins Barbosa Braga

Orientador

Departamento de Engenharia Mecânica – PUC-Rio

Dr. Igor Braga de Paula

Departamento de Engenharia Mecânica – PUC-Rio

Dr. Hans Ingo Weber

Departamento de Engenharia Mecânica – PUC-Rio

Rio de Janeiro, 13 de Maio de 2024

Todos os direitos reservados. A reprodução, total ou parcial do trabalho, é proibida sem a autorização da universidade, do autor e do orientador.

Daniel Boechat de Marins

Graduado em Engenharia Química pela Universidade Federal Fluminense (UFF).

Ficha Catalográfica

Marins, Daniel Boechat de

Técnicas de Identificação de Sistemas Híbridos: Algoritmos Black Box e Abordagens Grey Box para Simulações com Dados Reais na Produção de Petróleo e Análise da Velocidade de Perfuração / Daniel Boechat de Marins; orientador: Arthur Martins Barbosa Braga. – 2024.

73 f: il. color. ; 30 cm

Dissertação (mestrado) - Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Mecânica, 2024.

Inclui bibliografia

1. Engenharia Mecânica – Teses. 2. Identificação de Sistemas. 3. Aprendizado de Máquina. 4. Produção de Petróleo. 5. Perfuração. I. Braga, Arthur Martins Barbosa. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Mecânica. III. Título.

CDD: 621

À minha mãe, irmãs e família
pelo apoio e encorajamento.

Agradecimentos

Ao meu orientador Professor Arthur Braga e ao professor Helon Ayala pelo estímulo e parceria para a realização deste trabalho.

Ao CNPq, e à PUC-Rio, pelos auxílios concedidos, sem os quais este trabalho não poderia ter sido realizado.

Às minhas "duas mães" Ana Claudia e Terezinha, pela educação, atenção e carinho de todas as horas.

À Camila e às minhas Irmãs Dayana e Rossana, pelas palavras de apoio, incentivo e suporte nos momentos mais difíceis.

Aos meus colegas da PUC-Rio.

Aos professores que participaram da Comissão examinadora.

A todos os professores e funcionários do Departamento pelos ensinamentos e pela ajuda.

A todos os amigos e familiares que de uma forma ou de outra me estimularam ou me ajudaram.

Ao apoio financeiro da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis – ANP – e da Financiadora de Estudos e Projetos – FINEP, por meio do Programa de Recursos Humanos da ANP para o Setor Petróleo e Gás – PRH-ANP.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Resumo

Marins, Daniel Boechat de; Braga, Arthur Martins Barbosa. **Técnicas de Identificação de Sistemas Híbridos: Algoritmos Black Box e Abordagens Grey Box para Simulações com Dados Reais na Produção de Petróleo e Análise da Velocidade de Perfuração.** Rio de Janeiro, 2024. 73p. Dissertação de Mestrado – Departamento de Engenharia Mecânica, Pontifícia Universidade Católica do Rio de Janeiro.

Ambientes industriais, especialmente no setor de petróleo e gás, apresentam desafios únicos para técnicas de identificação de sistemas. Apesar dos avanços, ainda existe uma lacuna em nossa compreensão da integração de algoritmos black box, abordagens grey box e aprendizado de máquina para simulação de dados reais. Com o objetivo de otimizar a compreensão e previsão em ambientes industriais complexos, foram explorados a simulação de dados do mundo real na produção de petróleo e análise da velocidade de perfuração. Este estudo propõe uma análise da integração de algoritmos black box, abordagens grey box e aprendizado de máquina na simulação de dados reais, com ênfase na produção de petróleo e o estudo da interação broca rocha no processo de perfuração de poços de petróleo. Neste trabalho foram empregados técnicas de aprendizado de máquina, como redes neurais e métodos clássicos de identificação de sistemas, como modelos lineares como ARX (*AutoRegressive with eXogenous inputs*) e não lineares como o NARX (*Nonlinear AutoRegressive with eXogenous inputs*), para capturar os comportamentos dinâmicos dos processos em estudo utilizando dados reais da produção de petróleo e de perfuração, levando em consideração as características específicas e desafios operacionais desses ambientes. Com base nos resultados obtidos, as técnicas utilizadas demonstraram viabilidade de aplicação, na qual a utilização desses modelos híbridos, que combinam conhecimentos físicos com abordagens de múltiplos modelos formados por algoritmos de identificação de sistemas e aprendizado de máquina, demonstrou potencial para aprimorar as simulações. Esses resultados ressaltam a eficácia desses métodos, indicando que pesquisas futuras podem se dedicar à implementação dessa técnica na identificação de sistemas complexos.

Palavras-chave

Identificação de Sistemas; Aprendizado de Máquina; Produção de Petróleo; Perfuração.

Abstract

Marins, Daniel Boechat de; Braga, Arthur Martins Barbosa (Advisor). **Hybrid System Identification Techniques: Black Box Algorithms and Grey Box Approaches for Real Data Simulations in Oil Production and Drilling Speed Analysis**. Rio de Janeiro, 2024. 73p. Dissertação de Mestrado – Departamento de Engenharia Mecânica, Pontifícia Universidade Católica do Rio de Janeiro.

Industrial environments, especially in the oil and gas sector, present unique challenges for system identification techniques. Despite advancements, there still exists a gap in our understanding of integrating black box algorithms, grey box approaches, and machine learning for simulating real-world data. With the aim of optimizing understanding and prediction in complex industrial environments, real-world data simulation in oil production and drilling speed analysis was explored. This study proposes an analysis of the integration of black box algorithms, grey box approaches, and machine learning in simulating real-world data, with an emphasis on oil production and the study of the drill-rock interaction in the oil well drilling process. In this work, machine learning techniques such as neural networks and classical system identification methods, such as linear models like ARX (AutoRegressive with eXogenous inputs) and nonlinear ones like NARX (Nonlinear AutoRegressive with eXogenous inputs), were employed to capture the dynamic behaviors of the processes under study. Additionally, real data from oil production and drilling were utilized, considering the specific characteristics and operational challenges of these environments. Based on the results obtained, the techniques used demonstrated applicability and yielded satisfactory outcomes. Specifically, the use of hybrid models, combining physical knowledge with multiple model approaches formed by system identification algorithms and machine learning, showed potential for enhancing simulation. These findings underscore the effectiveness of these methods, suggesting that future research could focus on implementing this technique in identifying complex systems.

Keywords

System Identification; Machine Learning; Oil Production; Drilling.

Sumário

I	Introdução	14
1	Introdução	15
1.1	Contextualização	15
1.2	Motivação	17
1.3	Revisão da Literatura	18
1.4	Objetivos	20
1.5	Organização da Dissertação	20
II	Fundamentação teórica	22
2	Aprendizado de Máquina	23
2.1	Rede Neurais Artificiais	23
2.2	Treino e Seleção de Hiper parâmetros	27
2.3	Análise Quantitativa de Erros	29
3	Identificação de Sistemas	31
3.1	Algoritmos Lineares ARX e ARMAX	32
3.2	Algoritmos não Lineares NARX e NARMAX	33
3.3	Estimadores de Parâmetros	35
4	Modelagem Híbrida de Redes Neurais na Identificação de Sistemas	37
III	Contribuições	40
5	Modelos híbridos Baseados em Identificação de Sistemas e Aprendizado de Máquina para Simulações de Pressão em Profundidade de Poços	41
5.1	Estudo de Caso	41
5.2	Metodologia	43
5.3	Resultados e Discussão	45
5.4	Conclusão Parcial	49
6	Avaliação de Técnicas de Identificação de Sistemas Dinâmicos para a Instabilidade Torsional em Sistemas de Perfuração: Modelos Black Box vs. Grey Box	50
6.1	Efeito Stick-Slip	50
6.2	Estado da Arte	51
6.3	Descrição do estudo de caso	52
6.4	Metodologia	54
6.5	Resultados e Discussão	57
6.6	Conclusão parcial	64

IV	Conclusão	65
7	Conclusão e trabalhos futuros	66
8	Referências bibliográficas	68

Lista de figuras

Figura 1.1	Divisão da indústria de petróleo e gás em setores. Figura adaptada de Koroteev e Tekic (2021).	15
Figura 1.2	Representação de uma haste de perfuração com vibrações associadas durante operações de perfuração. Adaptado de Rocha, Andrade e Rocha (2008)	17
Figura 2.1	Um modelo de rede neural MLP. Adaptado de Nelles (2021)	24
Figura 2.2	Gráfico de uma função de ativação Sigmoid	25
Figura 2.3	Gráfico de uma função de ativação ReLU	26
Figura 2.4	Gráfico de uma função de ativação Tanh	26
Figura 2.5	Mecanismo para avaliação de modelos no desenvolvimento de redes neurais.	27
Figura 4.1	Arquitetura geral de um modelo de NARX-ANN (HEIDARI et al., 2020).	38
Figura 5.1	Quantidade de combinações de variáveis por rodada	44
Figura 5.2	Exemplificação da seleção de variáveis por rodada	44
Figura 5.3	Representação da metodologia adotada neste estudo.	44
Figura 5.4	Resultado da Simulação livre (FR) para o melhor modelo ARX desenvolvido	46
Figura 5.5	Resultado da Simulação livre (FR) para o melhor modelo NARX desenvolvido	46
Figura 5.6	Comparação da simulação de um passo à frente e execução livre para identificação do sistema.	47
Figura 5.7	Comparação da simulação de um passo à frente e execução livre, incluindo o modelo de simulação de erro NARX-ANN no conjunto de dados de treinamento.	48
Figura 5.8	Comparação da simulação de um passo à frente e execução livre, incluindo o modelo de simulação de erro NARX-ANN no conjunto de dados de teste.	48
Figura 6.1	Velocidade de rotação da broca versus tempo	53
Figura 6.2	Torque na broca versus tempo.	53
Figura 6.3	Dados de campo disponíveis: torque na broca versus velocidade da broca	53
Figura 6.4	Esquema da modelagem da broca de perfuração	55
Figura 6.5	Exemplificação da metodologia empregada neste trabalho	57
Figura 6.6	Resultado da simulação livre de treinamento e teste do modelo ARX	60
Figura 6.7	Resultado da Simulação n passos à frente para o modelo ARX	60
Figura 6.8	Evolução temporal dos erros de estimação no modelo ARX	60
Figura 6.9	Simulação livre de treinamento e teste do modelo NARX	62
Figura 6.10	Simulação n passos à frente para o modelo NARX	62
Figura 6.11	Evolução temporal dos erros de estimação no modelo NARX.	62
Figura 6.12	Estimações do modelo caixa cinza.	63

Figura 6.13 Erros de estimação ao longo do tempo no modelo de caixa cinza 63

Lista de tabelas

Tabela 5.1	Estatísticas descritivas da variável de interesse, pressão de fundo de poço, agrupada por diferentes poços presentes no banco de dados selecionado.	42
Tabela 5.2	ERR de acordo com cada regressor selecionado	47
Tabela 6.1	Estatísticas descritivas de entrada e saída	58
Tabela 6.2	Métricas estatísticas de erro: Avaliação do modelo ARX	59
Tabela 6.3	ERR de acordo com cada regressor selecionado - ARX	59
Tabela 6.4	ERR de acordo com cada regressor selecionado - NARX	61
Tabela 6.5	Métricas estatísticas de erro: Avaliação do modelo NARX.	61
Tabela 6.6	Métricas estatísticas de erro do modelo de caixa branca.	62

Parte I

Introdução

1

Introdução

1.1

Contextualização

O uso da abordagem orientada a dados na área de petróleo e gás está em crescimento impulsionado pelas técnicas de aprendizado de máquina e pela evolução do processamento de energia. A simulação de reservatórios e engenharia de produção exigem uma grande quantidade de informações para a estratégia de tomada de decisão (ONALO et al., 2019). Geralmente, essas áreas demandam informações de reservatórios para construir modelos matemáticos complexos e descobrir qualquer relação física (LI; SUN; HORNE, 2019). No caso real, considerando todas as relações entre propriedades, requer um enorme poder computacional. Assim, algumas suposições ideais podem tornar as equações simplificadas não representativas dos comportamentos complexos dos fluidos no subsolo (WERNECK et al., 2022).

A digitalização das instalações da indústria petrolífera contribui para uma maior eficiência, aprimorar a detecção e controle de falhas, e possibilitar a previsão de rendimento, produção e taxa de fluxo (AGGOUN; CHETOUANI, 2021; BO; JIANNAN; XIANGDONG, 2020; SOLANKI et al., 2022; LEI et al., 2020), desenvolvimento e aprimoramento dos Sensores de Pressão e Temperatura no Fundo do Poço, fundamentais para monitorar reservatórios de petróleo e gás em águas profundas (HE et al., 2023) entre outros.




Figura 1.1: Divisão da indústria de petróleo e gás em setores. Figura adaptada de Koroteev e Tekic (2021).

Pesquisadores exploraram diversas aplicações de Inteligência Artificial

(IA), como o uso de telemetria de perfuração em tempo real para identificar tipos de rochas e prever falhas por meio de uma ferramenta dedicada (KOROTEEV; TEKIC, 2021), e a otimização da eficiência de produção com previsões objetivas para campanhas de tratamento de poços (SHETH et al., 2022). Além disso, há estudos sobre gêmeos digitais (VRABIE et al., 2020), previsão de curto prazo da produção de poços com uma abordagem híbrida probabilística (EVSEENKOV et al., 2021). Algumas aplicações de técnicas de IA em áreas do setor de óleo e gás pode ser observada na Fig. 1.1.

Por outro lado, o desenvolvimento de estudos relacionados aos aspectos da perfuração também é de extrema importância no contexto da melhoria da eficiência operacional e redução de custos, juntamente com avanços em técnicas alinhadas ao aumento da segurança durante este processo (SHETH et al., 2024; AGHITO; BJØRKEVOLL, 2020; CARPENTER, 2021). A exploração de poços profundos é uma tarefa complexa que envolve elementos críticos, como a broca, o equipamento de fundo de poço (BHA) e as interações intrincadas com a rocha. O conceito fundamental inclui o uso de colunas de perfuração que percorrem longas distâncias para transmitir a força axial e o torque necessários para penetrar na rocha (RITTO; AGUIAR; HBAIEB, 2017).

Os esforços para melhorar a eficiência da perfuração buscam desvendar interações complexas do sistema (SHETH et al., 2024). Pesquisas recentes exploram várias abordagens, incluindo a identificação de eventos a partir de relatórios de perfuração por meio de sistemas especialistas (CINELLI et al., 2021), reconhecimento de padrões (LI et al., 2022) e investigação do impacto e pré-processamento de dados no desempenho do modelo e na precisão preditiva (SRIVASTAVA et al., 2022). Estes esforços exemplificam a abordagem orientada por dados na otimização das operações de perfuração.

Um dos principais focos de estudo está na interação entre a broca e a rocha, que pode resultar em vibrações indesejadas na coluna de perfuração. Essas vibrações, como verificado na Fig.1.2, são classificadas em três modos principais: torcional, também conhecido como *stick-slip*; axial, referido como ricocheteio da broca; e lateral, conhecido como vibrações rotativas (ALKARAGOOLEE; BRYANT, 2022).

O *stick-slip*, em particular, ocorre quando a broca sofre oscilações irregulares durante a perfuração de poços de petróleo que, resultando em uma ação de "agarra e solta", o que impacta significativamente os custos operacionais sejam de desempenho da perfuração ou vida útil da broca (CHEN et al., 2020). Este ciclo de limite induzido por atrito está principalmente associado às brocas de corte por cisalhamento e é intensificado por configurações inadequadas de Peso Sobre a Broca (WOB) e rotações por minuto (RPM) (VOGEL; CREE-




Figura 1.2: Representação de uma haste de perfuração com vibrações associadas durante operações de perfuração. Adaptado de Rocha, Andrade e Rocha (2008)

GAN, 2016). Ele descreve o comportamento oscilatório da broca de perfuração enquanto ela avança no fundo do poço. Quando a broca é presa (*stick*), ela fica temporariamente enganchada na rocha, causando uma interrupção na rotação. À medida que o acionador superior continua sua rotação, a energia armazenada eventualmente supera as forças de atrito, iniciando o movimento (*slip*) (HONG; GIRLANG; DHUPIA, 2016).

As consequências dessas oscilações são significativas, resultando em danos à broca, aumentando o risco de falha por fadiga nas juntas roscadas, reduzindo a taxa de penetração, comprometendo o controle direcional, induzindo respostas de curvatura da ferramenta inconsistentes e elevando os níveis de choque e vibração no fundo do poço (BAYLISS; PANCHAL; WHIDBORNE, 2012; LI et al., 2022). Estes efeitos cumulativos contribuem significativamente para a falha prematura da ferramenta e destacam a importância primordial de abordar o fenômeno *stick-slip* na otimização da eficiência de perfuração e longevidade do equipamento (CHEN et al., 2020). Múltiplos parâmetros influenciam este fenômeno, incluindo velocidade de deslizamento, propriedades do material na superfície de contato, temperatura e a presença e natureza da lubrificação (ALKARAGOOLEE; BRYANT, 2022).

1.2 Motivação

A motivação deste trabalho reside na busca por avanços significativos na simulação e previsão de processos cruciais na indústria de petróleo e gás, especificamente no contexto da perfuração de poços e na produção de óleo. A primeira parte deste estudo concentra-se na investigação e comparação de modelos lineares e não lineares para a simulação da pressão no fundo do poço,

utilizando dados reais do campo de petróleo Volve da Equinor (EQUINOR, 2018). Estes dados, que são provenientes de medições diárias, oferecem uma oportunidade única de examinar e validar a eficácia de diferentes abordagens de modelagem na representação precisa do comportamento do sistema ao longo do tempo.

Vários modelos baseados em aprendizado profundo e redes neurais recorrentes já foram desenvolvidos com diferentes arquiteturas, dados de entrada e combinações de características presentes no conjunto de dados para estimar a pressão de fundo do poço ao longo do período de produção usando ou não modelos baseados em física e aprendizado de máquina (ZHENG et al., 2024; LI; SUN; HORNE, 2019; HE et al., 2023; CARPENTER, 2022). Os impactos do uso de diferentes técnicas de pré-processamento foram analisados, várias configurações de redes neurais recorrentes empilhadas também foram variadas, janelas e escalas de tempo arranjadas para treinar estes modelos usando dados reais e dados de benchmark sintéticos (TIAN; HORNE, 2017; WERNECK et al., 2022). As tentativas de otimização foram feitas com as variáveis de entrada presentes no banco de dados, como temperatura, razão gás-óleo, porcentagem de abertura da válvula, fluxo de gás, para obter um conjunto de dados de entradas mínimas que permitam a geração de um modelo que represente bem o fenômeno de interesse e, ao mesmo tempo, tenha a menor complexidade possível (WANG et al., 2021).

Na segunda parte deste estudo, a motivação reside na aplicação de modelos híbrido de caixa cinza para simular a interação entre broca e rocha durante a perfuração. Estes modelos, que combinam técnicas de identificação de sistemas e aprendizado de máquina, têm o potencial de capturar a complexidade e a não linearidade dos processos envolvidos nessa interação crítica (NAUTIYAL; MISHRA, 2023; HEGDE; GRAY, 2018). A escolha de modelos de caixa cinza é particularmente relevante devido à natureza complexa e mal compreendida da interação broca-rocha, que envolve uma variedade de fatores físicos e operacionais, como a composição do solo, a geometria da broca e os parâmetros de perfuração (RITTO; AGUIAR; HBAIEB, 2017; CHEN et al., 2024).

1.3

Revisão da Literatura

A indústria de petróleo tem testemunhado um aumento significativo no uso de técnicas de IA para resolver uma variedade de desafios operacionais e de produção. O uso de metodologias de *soft computing* tem se mostrado promissor para lidar com diversos problemas complexos relacionados aos processos de campo petrolífero (SIRCAR et al., 2021). Vários estudos têm demonstrado

que os métodos de IA e ML proporcionam respostas úteis para dificuldades relacionadas às operações industriais e podem auxiliar efetivamente na abordagem dos problemas associados a otimização dos processos upstream, como estudos de reservatórios, perfuração e engenharia de produção (BAHALOO; MEHRIZADEH; NAJAFI-MARGHMALEKI, 2023).

Ng, Jahanbani Ghahfarokhi e Nait Amar (2022) compararam sete modelos de aprendizado de máquina diferentes (SVR, FNN, PSO, RNN, LSTM e GRU) para análise comparativa de suas capacidades na previsão da produção de hidrocarbonetos. Neste estudo foram utilizados dados provenientes de um poço real no campo de Volve.

Lu et al. (2022) desenvolveram um modelo computacional para previsão de produção de óleo de xisto e otimização de fraturamento com base em aprendizado de máquina com o acoplamento de uma rede neural profunda com otimização por enxame de partículas. Neste trabalho os autores conseguiram determinar rapidamente parâmetros de fraturamento razoáveis para poços horizontais sob diferentes qualidades de reservatório.

Wei et al. (2021) estudaram o desempenho de um processo complexo de recuperação de óleo pesado térmico reativo em uma abordagem orientada a dados. Foram utilizados métodos de agrupamento K-means, misturas normais e hierárquico para compreender as inter-relações das variáveis de produção e buscar uma estratégia operacional ótima para maximizar a taxa de produção.

No estudo desenvolvido por Pan et al. (2023), foi criado um modelo combinado de rede neural convolucional e rede neural recorrente (CNN-LSTM) baseado no mecanismo de atenção. Neste modelo, a CNN foi utilizada para extrair características espaço-temporais dos dados de produção de poços de petróleo, enquanto o LSTM foi empregado para capturar as características de séries temporais desses dados.

Du et al. (2024) propuseram um modelo de Séries Temporais Autor-regressivas Profundas (M-GRU) para prever a produção anual de petróleo, incorporando características técnicas e econômicas, com ênfase na fusão de informações de séries temporais e conhecimento prévio.

Já sobre a temática de perfuração, em Guilherme et al. (2011) foi proposto um sistema inteligente de monitoramento de perfuração de poços baseado em imagens. O sistema conseguiu detectar em tempo real anomalias com relação às mudanças no volume de corte em tempo real usando regressão vetorial de suporte, o que pode indicar um possível problema durante o processo de perfuração.

Hegde, Millwater e Gray (2019) apresentaram um método para classificar um índice baseado em vibração chamado índice de *stick-slip* (SSI) usando pa-

râmetros operacionais de perfuração. Neste trabalho foram utilizadas técnicas de classificação utilizando algoritmos de aprendizado de máquina para classificar a gravidade do SSI tais como regressão logística, SVM, florestas aleatórias e modelos de mistura gaussiana. Segundo os autores, esta técnica poderia ser utilizada em conjunto com um modelo de otimização de taxa de penetração (ROP) para controlar as vibrações de perfuração enquanto melhora a ROP.

Em Prezelj et al. (2022) foram estudados métodos para detecção e identificação em tempo real das manifestações de ruídos de arrasto. Transições de *stick-slip* foram detectadas utilizando análises de domínio de tempo. O estudo se baseou na emissão acústica, que utiliza conteúdos de aceleração de alta frequência associados às transições *stick-slip* dos ruídos de arrasto. Diferentes características foram testadas nos sinais de som e acelerômetro, incluindo fator de crista, curtose, nível de sinal e características psicoacústicas e foram utilizados os algoritmos de classificação não supervisionada k-means e mapa auto organizável de Kohonen. Segundo os autores os resultados da classificação sugerem uma interação entre dois padrões significativos de vibração durante o ruído de arrasto, provavelmente um deslocamento longitudinal e torsional do eixo.

1.4

Objetivos

Dessa forma, a relevância de aprofundar-se neste tema é justificada pela necessidade de desenvolver, compreender e caracterizar os fenômenos alinhados ao processo de produção de petróleo, permitindo previsões e simulações de desempenho.

Portanto, este trabalho tem como principal objetivo desenvolver e validar modelos de simulação baseados na identificação de sistemas aplicados ao segmento de petróleo e gás. Isso envolve o uso de abordagens lineares, não lineares e híbridas, empregando modelos de aprendizado de máquina. O objetivo é minimizar o erro associado à previsão convencional usando apenas modelos de ML para determinar e simular a pressão de fundo de poço e identificar dinamicamente com uma quantidade limitada de dados iniciais a identificar interações que provocam instabilidade torsional em sistemas de perfuração.

1.5

Organização da Dissertação

Este documento está dividido em quatro partes principais.

A Parte I é dedicada a introduzir o tema de pesquisa explorado nesta dissertação. O capítulo 1 fornece contextualização, motivação, objetivos e contribuições desta dissertação.

A Parte II discute os métodos de identificação de sistemas e aprendizado de máquina empregados neste trabalho. O Capítulo 2 aborda os conceitos de aprendizado de máquina e os fundamentos dos algoritmos de aprendizado supervisionado adotados, assim como as estratégias de construção e validação do modelo utilizadas. O Capítulo 3 apresenta os conceitos do sistema de identificação, com foco nos algoritmos ARX e NARX, modelos lineares e não lineares, respectivamente. O Capítulo 4 explora a modelagem híbrida de identificação de sistemas com aprendizado de máquina, utilizando redes NARX combinando os pontos fortes da identificação tradicional com a flexibilidade do aprendizado de máquina, resultando em modelos mais precisos e robustos para sistemas dinâmicos complexos.

A Parte III constitui as contribuições originais desta dissertação. O Capítulo 5 concentra-se na construção de Modelos Híbridos Baseados em Identificação de Sistemas e Aprendizado de Máquina para Simulações de Pressão em Profundidade de Poços. Já o Capítulo 6 apresenta uma avaliação das Técnicas de Identificação de Sistemas Dinâmicos para a Instabilidade Torsional em Sistemas de Perfuração: Modelos Black Box vs. Grey Box.

Em seguida, na Parte IV, o Capítulo 7 apresenta as conclusões dos estudos de caso elaborados e sugestões de trabalhos futuros.

Parte II

Fundamentação teórica

2

Aprendizado de Máquina

2.1

Rede Neurais Artificiais

A rede neural artificial pode ser definida com uma ferramenta computacional que é composta por uma grande quantidade de elementos simples interconectados, também chamados neurônios (BILLINGS, 2013). O funcionamento desses neurônios é baseado no sistema nervoso humano, em que a informação é processada ou apreendida via reconhecimento de padrões (HAYKIN, 1999). A rede neural artificial assemelha-se ao cérebro devido à possibilidade de obtenção de um certo conhecimento a partir de um processo de aprendizagem e pela presença de pesos de sinapses que promovem o armazenamento desse conhecimento adquirido. O grande avanço na utilização das redes neurais dá-se pela sua rápida adaptação a inúmeras aplicações, poder de previsão e/ou classificação e possibilidade da integralização de outras técnicas para a criação de uma nova, sendo esta híbrida, a qual apresente maior eficácia na resolução de problemas propostos.

As vantagens da utilização de um modelo formado por rede neural são dadas pela sua capacidade de aprender modelos não lineares, grande habilidade para armazenar informações de forma relativamente simples para os seres humanos, o que permite uma flexibilização de sua utilização, melhor adaptação em casos cujo banco de dados apresenta grandes ruídos ou estão incompletos (BILLINGS, 2013; MEDEIROS, 2018). As desvantagens podem ser atribuídas a uma grande possibilidade de o algoritmo de otimização encontrar um mínimo local, isto é, sintonizar os pesos de forma que não seja obtido o melhor modelo que gere a minimização da função objetivo. Logo, verifica-se a necessidade da utilização de um algoritmo de busca acoplado, de forma que seja garantida a obtenção de um mínimo global (QUANTRILLE; LIU, 1991). No entanto, tal acoplamento gera um aumento na complexidade do algoritmo e no tempo de treinamento.

O modelo de rede neural artificial é formado pela camada de entrada, que recebe os dados de entrada e direciona às camadas posteriores; camada oculta, se necessário, a qual realiza os cálculos considerando os dados de entrada e as diversas interações existentes; pesos de sinapse, que possibilitam o armazenamento do aprendizado e, assim, gerar uma saída reprodutível; função de ativação e função de transformação, que são responsáveis pelos processa-

mentos das diversas conexões existentes entre os neurônios, considerando os dados resultados de uma camada anterior com influência de seus respectivos pesos sinápticos; e finalmente uma camada de saída, a qual promove a obtenção de um resultado desejado (NELLES, 2021; BISHOP, 2015). Cada neurônio recebe entradas, realiza uma transformação linear dessas entradas ponderadas por pesos, adiciona um viés (bias), e aplica uma função de ativação não linear para produzir uma saída, como explicitado pela Eq. 2-1.

$$\hat{y} = f \left(\sum_{i=1}^n w_i x_i + b \right) \quad (2-1)$$

onde, $\hat{y}$ representa a saída prevista pela rede neural, f é a função de ativação aplicada após a soma ponderada das entradas, w_i são os pesos associados às entradas x_i , b é o viés (bias), e n é o número de entradas para o neurônio. O modelo de um neurônio presente em uma rede neural também pode ser verificado na Fig. 2.1.




Figura 2.1: Um modelo de rede neural MLP. Adaptado de Nelles (2021)

A função de ativação em uma rede neural é responsável por determinar a saída de um neurônio, com base na soma ponderada das entradas. Ela introduz não linearidades nas saídas da rede, permitindo que a rede modele e aprenda relações complexas nos dados.

Existem várias funções de ativação comumente utilizadas em redes neurais, cada uma com suas características e aplicações específicas. Alguns exemplos incluem:

- **Função de Ativação Sigmoide:** Esta é uma função logística que mapeia os valores de entrada para o intervalo $[0, 1]$, conforme verificado

na Eq. 2-2 e na Fig. 2.2. É frequentemente usada em redes neurais para problemas de classificação binária.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2-2)$$




Figura 2.2: Gráfico de uma função de ativação Sigmoide

- **Função de Ativação ReLU:** A Eq. 2-3 e Fig. 2.3 demonstram que esta função retorna zero para valores negativos e a entrada para valores não negativos. A função ReLU é amplamente utilizada em redes neurais profundas devido à sua simplicidade e eficácia na mitigação do problema de desaparecimento do gradiente.

$$f(x) = \begin{cases} x, & \text{se } x > 0 \\ 0, & \text{caso contrário} \end{cases} \quad (2-3)$$

- **Função de Ativação Tangente Hiperbólica (tanh):** Similar à função sigmoide, a função tanh mapeia os valores de entrada para o intervalo $[-1, 1]$. Ela é frequentemente usada em redes neurais para problemas de regressão. A equação da função tanh é demonstrada na Eq. 2-4 e na Fig 2.4.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2-4)$$

A escolha da função de ativação depende do tipo de problema que está sendo resolvido e da arquitetura da rede neural. Cada função de ativação tem suas vantagens e desvantagens, e a seleção adequada pode afetar significativamente o desempenho da rede (COPPIN, 2004).

A introdução de pelo menos uma camada oculta cria o conceito de redes neurais multicamadas, também conhecido como **Multi Layer Perceptrons**,




Figura 2.3: Gráfico de uma função de ativação ReLU




Figura 2.4: Gráfico de uma função de ativação Tanh

MLP, e possibilita a resolução da maioria dos problemas reais, os quais não são linearmente separáveis (NELLES, 2021; MEDEIROS, 2018). A quantidade de neurônios nas camadas ocultas e a quantidade de camadas ocultas possibilitam a aproximação de praticamente qualquer função existente, devido a sua grande quantidade de interconexões.

A camada de entrada é formada por nodos, os quais recebem a informação de uma fonte externa e introduzem na rede neural. Esses não são propriamente neurônios, uma vez que apenas passam os valores dos sinais de entrada, não havendo qualquer função de ativação (COPPIN, 2004). A camada oculta recebe a informação da camada de entrada e realiza o processamento da informação, direcionando para a camada de saída, que então envia o resultado para um receptor externo.

2.2

Treino e Seleção de Hiper parâmetros

O aprendizado de máquina desempenha um papel fundamental em uma variedade de aplicações científicas e industriais, proporcionando insights valiosos a partir de dados complexos. O processo de desenvolvimento de uma modelo que generalize para um determinado fim envolve o processo de obtenção de dados, divisão dos dados históricos para treino e teste, treinamento do modelo, avaliação das métricas das previsões do grupo de treino e teste e por fim a seleção de hiper parâmetros. Todo o processo é exemplificado na Fig 2.5.




Figura 2.5: Mecanismo para avaliação de modelos no desenvolvimento de redes neurais.

O algoritmo mais comum de aprendizagem é o de retropropagação, ou *backpropagation*. Basicamente, o algoritmo é composto por duas etapas, sendo a primeira a passagem da camada de entrada até a camada de saída, seguido de uma passagem ao contrário. Durante a primeira passagem, os pesos são fixados de forma a se obter um sinal de saída. Já na passagem de volta, os pesos são ajustados conforme a magnitude do sinal de erro, que é a subtração do sinal gerado pelo sinal alvo, conhecido.

No início do processo, a rede neural é iniciada com pesos aleatórios, em que geralmente são utilizados valores entre -0,5 e 0,5 (COPPIN, 2004). A atualização e seleção de pesos melhores é realizada após a passagem de dados de entrada sobre essa rede com os pesos definidos aleatoriamente, gerando, assim, uma previsão da variável desejada. É calculado, então, o erro total da rede neural e a atualização dos pesos é realizada com base na redistribuição do valor do erro em cada peso presente nas conexões entre os neurônios. Essa variação e novo cálculo da variável desejada normalmente é sequencial, isso é, cada alteração do valor de um peso gera um novo valor da variável desejada e logo um novo erro de previsão ou classificação, o qual permite a atualização de outro peso presente na rede neural. Ou seja, esses valores de erros são alimentados novamente pela rede neural, de forma a alterar os pesos das conexões entre

neurônios presentes. O algoritmo repete-se até que a saída produzida seja suficientemente próxima do valor desejado, ocasionando a obtenção de um menor valor da função objetivo.

Para atualização dos pesos, existem alguns métodos de aprendizagem aplicáveis às redes neurais artificiais. O mais comum é a atualização por retropropagação, na qual os novos pesos são calculados a partir da camada de saída em direção à camada de entrada, caminho contrário ao processo de geração de um sinal de saída. Ainda o método de aprendizagem pode ser do tipo gradiente descendente ou BFGS (BROYDEN-FLETCHER-GOLDFARB-SHANNO).

Para o método de gradiente descendente, por exemplo, calcula-se inicialmente o sinal de erro e_k , definido pela diferença do valor da variável alvo obtido com os pesos atribuídos inicialmente, $\hat{y}_k$ com o valor verdadeiro desejado y_k (FURTUNA; CURTEANU; CAZACU, 2009).

$$e_k = \hat{y}_k - y_k \quad (2-5)$$

Posteriormente é calculado o gradiente de erro para cada neurônio na camada de saída da rede neural. O gradiente de erro é obtido multiplicando a derivada da função de ativação pelo erro do neurônio. Para uma função de ativação logística, o gradiente de erro é dado por:

$$\delta_k = y_k(1 - y_k)e_k \quad (2-6)$$

Como o nome já informa, o erro é retropropagado e após a etapa anterior é efetuado o cálculo do gradiente de erro para a camada oculta o qual dado por:

$$\delta_j = y_j(1 - y_j) \sum_{k=1}^N w_{jk} \delta_k \quad (2-7)$$

e finalmente os pesos são atualizados de acordo com a regra do gradiente descendente, atrelada a uma taxa de aprendizado α :

$$\begin{aligned} w_{ij} &\leftarrow w_{ij} + \alpha x_i \delta_j \\ w_{jk} &\leftarrow w_{jk} + \alpha x_j \delta_k \end{aligned} \quad (2-8)$$

Uma forma de melhorar a generalização do modelo é o processo de divisão do conjunto de dados em para treinamento e teste é uma das etapas cruciais no desenvolvimento de modelos de aprendizado de máquina. Nesta etapa os

dados são divididos em conjuntos de treinamento e teste (PEDREGOSA et al., 2011), de forma que sejam efetuadas as etapas de treinamento, validação do treinamento e teste do modelo. Essa divisão permite avaliar o desempenho do modelo em dados não vistos e evitar o sobre ajuste, garantindo que o modelo generalize bem para novos dados (NELLES, 2021).

Outra etapa importante no processo de desenvolvimento de modelos baseados no aprendizado de máquina é a seleção de variáveis independentes que propiciam uma melhor predição na variável de interesse de forma a obter um modelo mais generalista possível. Esta é uma técnica para melhorar a eficiência e a precisão dos modelos de aprendizado de máquina. Por meio da seleção criteriosa das variáveis mais relevantes para o problema em questão, é possível simplificar o modelo e reduzir o tempo de processamento, sem comprometer a qualidade dos resultados.

Por fim, a seleção de hiper parâmetros desempenha um papel essencial na otimização do desempenho dos modelos de aprendizado de máquina. Os hiper parâmetros são parâmetros configuráveis que afetam diretamente o comportamento, na obtenção de pesos ótimos e, conseqüentemente, na capacidade de generalização do modelo. A escolha adequada dos hiperparâmetros é crucial para garantir que o modelo atinja seu melhor desempenho possível.

2.3

Análise Quantitativa de Erros

Os testes de validação são uma etapa crítica no desenvolvimento e avaliação de modelos em aprendizado de máquina. Eles são projetados para avaliar a capacidade de generalização de um modelo, ou seja, sua capacidade de realizar previsões precisas em dados não vistos (PINTELON; SCHOUKENS, 2012). Existem várias técnicas de validação disponíveis, cada uma com suas próprias características e adequações para diferentes tipos de problemas e conjuntos de dados.

Neste trabalho, a validação dos modelos desenvolvidos foi realizada por meio de estatísticas de erro, incluindo Erro Quadrático Médio (RMSE) Eq. 2-9, Erro Médio Absoluto (MAE) Eq. 2-10, Erro Quadrático Médio (MSE) Eq. 2-11 e Erro Quadrático Médio Relativo (RRSE) Eq. 2-12. Essas métricas ajudaram a garantir a precisão e confiabilidade de nossos resultados. Além disso, o coeficiente de determinação (R^2) Eq. 2-13 foi considerado como um fator adicional de correlação.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2-9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2-10)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2-11)$$

$$RRSE = \frac{RMSE}{\bar{y}} \times 100\% \quad (2-12)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2-13)$$

onde n é o número total de observações, y_i é o valor observado, $\hat{y}_i$ é o valor previsto pelo modelo, $\bar{y}$ é a média dos valores observados.

3

Identificação de Sistemas

Neste trabalho, aplicamos diferentes procedimentos numéricos para simular a temperatura no fundo do poço. Utilizamos a técnica de identificação de sistemas Autorregressivo com Entrada Exógena (ARX) e o Autorregressivo Não Linear com Entrada Exógena (NARX), juntamente com o Neural NARX (NNARX) para montar duas estratégias de simulação.

A identificação de sistemas é frequentemente descrita como a arte e ciência de construir modelos matemáticos de sistemas dinâmicos a partir de dados de entrada e saída observados (LJUNG, 1999). Isto é, identificação de sistemas é a tarefa de usar dados de entrada e saída para construir um modelo, que serve como uma abstração matemática do processo. Esse processo de identificação desempenha um papel crucial em várias aplicações, como simulação, projeto de controle, diagnóstico de falhas, testes de hardware em loop entre outros (NELLES, 2021). Ao aproveitar dados observados, a identificação de sistemas permite a criação de representações matemáticas que capturam a dinâmica subjacente de sistemas complexos, facilitando análises, previsões e controle em diversos domínios de engenharia e industriais. Através da integração de algoritmos avançados, técnicas de aprendizado de máquina e métodos clássicos de identificação de sistemas, os praticantes podem extrair insights valiosos dos dados, aprimorar o entendimento do comportamento do sistema e otimizar o desempenho em aplicações do mundo real. Como uma ferramenta fundamental em engenharia e ciências aplicadas, a identificação de sistemas continua a evoluir, impulsionando inovações e avanços em campos onde os sistemas dinâmicos desempenham um papel fundamental.

Uma regra crucial na estimação de parâmetros, como aponta (SJÖBERG et al., 1995), é evitar estimar o que já se sabe. Essa prática, além de ser redundante, pode levar a resultados inconsistentes e dificultar a análise dos dados. Isto é, deve-se utilizar o conhecimento prévio e a intuição física sobre o sistema ao selecionar a estrutura do modelo. Com isso, podemos distinguir entre três níveis de conhecimento prévio, sendo os modelos White-box, ou caixa-branca as quais o modelo é perfeitamente conhecido; Modelos Grey-box, modelos nos quais algum conhecimento físico está disponível, mas vários parâmetros ainda precisam ser determinados a partir de dados observados; e os Modelos Black-box, os quais nenhum conhecimento físico está disponível ou é usado.

Com base em diferentes níveis de conhecimento prévio sobre o sistema

em questão, podemos classificar os modelos em três categorias:

1. **Modelos White-box** (caixa-branca): caracterizam-se por uma completa compreensão da estrutura interna e dos mecanismos de funcionamento do modelo.
2. **Modelos Grey-box** (caixa-cinza): apresentam conhecimento parcial sobre a estrutura interna do modelo, exigindo a estimação de parâmetros a partir de dados observados.
3. **Modelos Black-box** (caixa-preta): não possuem informações sobre a estrutura interna ou os mecanismos do modelo, operando como uma verdadeira "caixa preta" para o usuário.

Neste trabalho, serão abordadas duas das três formas de modelos desenvolvidos: os modelos black box e grey box.

3.1

Algoritmos Lineares ARX e ARMAX

A popularidade do modelo ARX decorre do fato de que seus parâmetros podem ser estimados diretamente usando um algoritmo de mínimos quadrados.

O modelo ARX é descrito na Eq. 3-1.

$$y(k) + a_1 y(k-1) + \dots + a_{na} y(k-na) = b_1 u(k-1) + \dots + b_{nb} u(k-nb) + \xi(k), \quad (3-1)$$

onde $y(k)$ é a k -ésima amostra do sinal de saída, $u(k)$ é a k -ésima amostra do sinal de entrada, e a e b são os parâmetros que ajustam o modelo. na e nb são o número de coeficientes do modelo. Podemos considerar o modelo em termos de um produto de matrizes. Portanto, apresentamos a entrada e a saída como vetores, $\mathbf{u}$ e $\mathbf{y}$, respectivamente, com parâmetros organizados em um vetor de parâmetros Θ . O termo $\xi(k)$, também conhecido como ruído branco representa a incerteza inerente ao sistema e a influência de fatores externos que não são explicitamente considerados no modelo. O sinal considerado é composto por N amostras. Em seguida, consideramos o número auxiliar $p = 1 + \max(na, nb)$. Os vetores são definidos conforme exibido na Eq. (3-2).

$$\begin{aligned} \mathbf{y} &= [y(p), y(p-1), \dots, y(N)] \\ \Theta &= [a_1, \dots, a_{na}, b_1, \dots, b_{nb}] \end{aligned} \quad (3-2)$$

É necessário definir uma matriz de regressão, Φ , para compor o sistema.

$$\mathbf{X} = \begin{pmatrix} -y(p-1) & -y(p-2) & \cdots & -y(p-na) & u(p-1) & u(p-2) & \cdots & u(p-nb) \\ -y(p) & -y(p-1) & \cdots & -y(p+1-na) & u(p) & u(p-1) & \cdots & u(p+1-nb) \\ -y(p+1) & -y(p) & \cdots & -y(p+2-na) & u(p+1) & u(p) & \cdots & u(p+2-nb) \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ -y(N-2) & -y(N-3) & \cdots & -y(N-1-na) & u(N-2) & u(N-3) & \cdots & u(N-1-nb) \\ -y(N-1) & -y(N-2) & \cdots & -y(N-na) & u(N-1) & u(N-2) & \cdots & u(N-nb) \end{pmatrix} \quad (3-3)$$

Por conveniência, a matriz 3-3 pode ser preenchida com os vetores, sendo reescrita conforme verificado na Eq. 3-4 e Eq. 3-5:

$$\mathbf{x}(k) = [-y(k-1), \cdots, -y(k-na), u(k-1), \cdots, u(k-nb)] \quad (3-4)$$

$$\mathbf{X} = \begin{pmatrix} \mathbf{x}(p) \\ \mathbf{x}(p+1) \\ \cdots \\ \mathbf{x}(N) \end{pmatrix} \quad (3-5)$$

Portanto, o sistema pode ser reescrito como na Eq. (3-6).

$$\mathbf{y} = \mathbf{X}\boldsymbol{\Theta} + \boldsymbol{\xi} \quad (3-6)$$

A solução de mínimos quadrados para estimar o vetor de parâmetros desconhecido $\boldsymbol{\Theta}$ é explicitado na Eq. 3-7 (BILLINGS, 2013).

$$\hat{\boldsymbol{\theta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} \quad (3-7)$$

3.2

Algoritmos não Lineares NARX e NARMAX

Modelos não lineares são modelos matemáticos nos quais as relações entre as variáveis não podem ser representadas por uma função linear. Em outras palavras, as mudanças em uma variável não resultam em mudanças proporcionais em outra variável (SJÖBERG et al., 1995).

Esses modelos são usados para descrever sistemas ou fenômenos complexos nos quais as interações entre as variáveis não podem ser adequadamente capturadas por modelos lineares simples (LJUNG, 1999). Eles são aplicados em uma ampla variedade de campos, incluindo engenharia, física, economia, biologia e ciências sociais.

Da mesma forma que nos modelos lineares, a saída do sistema em um dado instante de tempo é definida por uma função matemática que descreve com precisão a relação entre as saídas e entradas passadas do sistema. Essa função, como podemos observar na Eq. 3-8, também leva em consideração quaisquer termos exógenos, ou seja, fatores externos que podem influenciar o comportamento do sistema.

$$\begin{aligned} y(k) = F[y(k-1), y(k-2), \dots, y(k-n_a), \\ u(k-1), u(k-2), \dots, u(k-n_b)] \end{aligned} \quad (3-8)$$

A diferença do modelo NARMAX para os outros modelos lineares, por exemplo, são a introdução do termo relativo ao ruído e os termos de não linearidade, como verificado na Eq. 3-9, o que aumenta significativamente a complexidade do modelo. Este também resulta em um aumento no tempo de processamento necessário para treinar e estimar os parâmetros do modelo.

$$\begin{aligned} y(k) = F[y(k-1), y(k-2), \dots, y(k-n_a), \\ u(k-1), u(k-2), \dots, u(k-n_b), \\ \xi(k), \xi(k-1), \dots, \xi(k-n_c)] + \xi(k) \end{aligned} \quad (3-9)$$

onde $\xi(k)$ são termos de erros de previsão e n_c é o número de termos exógenos de média móvel considerados definidos como $\xi(k) = y(k) - \hat{y}(k)$, Esses termos de ruído são incluídos para acomodar os efeitos do ruído de medição, erros de modelagem e/ou distúrbios não medidos (BILLINGS, 2013).

O modelo NARMAX mais comumente usado é a representação polinomial em forma potencial

$$\begin{aligned} y(t) = \theta_0 + \left(\sum_{i=1}^n \theta_{i1}(x_{i1}(t)) \right) + \left(\sum_{i=1}^n \sum_{j=i+1}^n \theta_{i1i2}(x_{i1}(t)x_{i2}(t)) \right) + \dots \\ + \left(\sum_{i_1=1}^n \dots \sum_{i_l=i_{l-1}+1}^n \theta_{i_1i_2\dots i_l}(x_{i_1}(t)x_{i_2}(t)\dots x_{i_l}(t)) \right) + e(t) \end{aligned} \quad (3-10)$$

onde l representa o grau de não-linearidade polinomial, $\theta_{i_1, i_2, \dots, i_m}$ são os parâmetros do modelo, $n = n_y + n_u + n_e$.

Considerando as definições,

$$\begin{aligned} y_k &= [y_{k-1}, y_{k-2}, \dots, y_{k-n_y}] \\ u_k &= [u_{k-1}, u_{k-2}, \dots, u_{k-n_u}] \\ \varepsilon_k &= [\varepsilon_{k-1}, \varepsilon_{k-2}, \dots, \varepsilon_{k-n_\varepsilon}] \end{aligned} \quad (3-11)$$

o objetivo geral da identificação do sistema usando o modelo NARMAX é encontrar um mapeamento não linear $F(\cdot)$ tal que:

$$y(k) = F(y^{(k-1)}, u^{(k-1)}, \varepsilon^{(k-1)}) + \varepsilon(k) \quad (3-12)$$

onde o erro de previsão ou inovação ε_k é assumido ser limitado, e $\varepsilon(k) = y(k) - \hat{y}(k|k-1)$, no qual $\hat{y}(k|k-1)$ calculado a partir da Eq. 3-12 é referido como a previsão de um passo à frente (BILLINGS, 2013).

3.3

Estimadores de Parâmetros

No contexto da Identificação de Sistema diversos algoritmos de estimação de parâmetros são empregados para determinar os parâmetros desconhecidos nesses modelos. Esses algoritmos visam minimizar o erro de predição entre a saída do modelo e a saída real do sistema (BILLINGS, 2013). Nesta seção serão abordados alguns estimadores como os mínimos quadrados, mínimos quadrados estendidos, mínimos quadrados ortogonais e Mínimos quadrados recursivos:

3.3.1

Mínimos Quadrados

O método de Mínimos Quadrados é análogo à regressão linear da estatística. O objetivo é encontrar os coeficientes de regressão Θ que minimizam a soma dos quadrados dos erros entre a saída do modelo e a saída real do sistema, representados pelo termo de erro ξ na Eq. 3-6 (AGUIRRE, 2007).

A abordagem do método Mínimos Quadrados envolve minimizar a soma dos quadrados dos erros entre as saídas previstas pelo modelo e as saídas observadas. Formalmente, a função objetivo a ser minimizada é:

$$J(\theta) = \sum_{i=1}^N (y(i) - \hat{y}(i))^2 \quad (3-13)$$

onde $\hat{y}(i)$ é a saída prevista pelo modelo linear:

$$\hat{y}(i) = \theta_1 x_1(i) + \theta_2 x_2(i) + \dots + \theta_n x_n(i) \quad (3-14)$$

A minimização desta função objetivo resulta em um sistema de equações normais que pode ser resolvido para encontrar os parâmetros ótimos θ .

Existem ainda algumas extensões relativo ao método de mínimos quadrados como é o caso do algoritmo de Mínimos Quadrados Estendidos para tratar de parâmetros variáveis no tempo (NELLES, 2021).

3.3.2

Mínimos Quadrados Ortogonais

O Estimador de Mínimos Quadrados Ortogonais foi desenvolvido para a estimativa de parâmetros de modelos NARMAX, que podem ser expressos como uma representação linear nos parâmetros. A ideia básica por trás do estimador Mínimos Quadrados Ortogonais é definir e introduzir um modelo auxiliar cujos termos sejam ortogonais sobre o conjunto de dados de estimação, de modo que cada coeficiente do modelo possa ser independentemente dos outros termos do modelo na presença de ruído de medição correlacionado (BILLINGS, 2013).

3.3.3

Mínimos Quadrados Recursivos

Quando o método de mínimos quadrados é necessário para funcionar online em tempo real, um novo algoritmo precisa ser desenvolvido, pois o esforço computacional do método de mínimos quadrados cresce com o número de amostras de dados coletadas (NELLES, 2021). O algoritmo mínimos quadrados recursivos, calcula uma nova atualização para o vetor de parâmetros ($\hat{\theta}(i)$) cada vez que novos dados são medidos.

O funcionamento básico do algoritmo RLS é calcular a nova estimativa de parâmetro ($\hat{\theta}(k)$) no instante de tempo k adicionando um vetor de correção à estimativa de parâmetro anterior ($\hat{\theta}(k-1)$) no instante de tempo $k-1$.

4

Modelagem Híbrida de Redes Neurais na Identificação de Sistemas

No domínio da modelagem de sistemas dinâmicos, encontramos diversos tipos de redes neurais, cada uma com suas características e vantagens distintas. Em trabalhos anteriores, exploramos as Redes Neurais Artificiais Multicamada, conhecida como ANN e algoritmos de identificação de sistemas utilizando modelos Autorregressivos Exógenos (ARX/NARX), desvendando suas capacidades e aplicações. Neste capítulo, aprofundamos nosso conhecimento sobre a rede NARX (NARX-ANN), uma ferramenta poderosa para modelar sistemas dinâmicos não lineares.

A rede NARX, também conhecida como NARX-ANN, se destaca por sua capacidade de capturar relacionamentos não lineares complexos nos dados. Essa característica a torna ideal para modelar sistemas dinâmicos que apresentam comportamentos intrinsecamente não lineares, onde a relação entre causa e efeito não é linear simples (MUSTAPA et al., 2020). Essa arquitetura é utilizada em uma variedade de aplicações, desde previsão em múltiplas etapas até filtragem não linear e modelagem de sistemas dinâmicos não lineares (MUSTAPA et al., 2020).

As NARX-ANN são baseadas em conexões recorrentes, com *feedbacks* que envolvem várias camadas da rede. Essa arquitetura tem a capacidade de capturar os relacionamentos não lineares subjacentes nos dados, o que lhes permite modelar efetivamente sistemas complexos sem sofrer com a maldição da dimensionalidade (NELLES, 2021). Isso permite que a rede capture as dependências de longo prazo entre as variáveis, algo crucial para modelar sistemas dinâmicos. Ao aprenderem as principais direções da não linearidade, as redes MLP podem representar dados de alta dimensionalidade em um espaço de menor dimensão, reduzindo a complexidade computacional e melhorando o desempenho de generalização. Outras duas vantagens desse modelo são a rápida convergência, juntamente com a boa capacidade para lidar com problemas que possuem dependências de longo prazo (HEIDARI et al., 2020).

A arquitetura geral de uma rede NARX é ilustrada na Fig 4.1. Os atrasos na entrada da rede NARX lidam com as dependências de longo prazo da saída do modelo em relação aos valores anteriores do sinal de saída e aos valores anteriores e presentes de um sinal de entrada exógeno (HEIDARI et al., 2020). A camada oculta tanto extrai algumas características das variáveis de entrada e saída quanto incorpora a natureza não linear do processo.




Figura 4.1: Arquitetura geral de um modelo de NARX-ANN (HEIDARI et al., 2020).

A equação definidora para o modelo NARX-ANN registra o próximo valor do sinal de saída dependente ($y(k)$) com base nos valores anteriores do próprio sinal de saída e do sinal de entrada independente ($u(k)$). Isso permite que a rede aprenda as relações dinâmicas entre as variáveis de entrada e saída ao longo do tempo. A implementação do modelo NARX geralmente é feita por meio de uma rede neural *feedforward*, onde a função (f) é aproximada pela rede neural.

Uma configuração importante para o treinamento da NARX-ANN é o uso de arquiteturas em série-paralelo, onde a saída verdadeira é utilizada durante o treinamento, em vez de alimentar a saída estimada de volta para a entrada da rede (HAYKIN, 1999; MUSTAPA et al., 2020). Isso proporciona uma arquitetura puramente *feedforward*, simplificando o processo de treinamento. Neste modelo, saídas e variáveis de entrada passadas são usadas como entradas para prever a saída futura do sistema. O modelo aprende a relação entre entradas e saídas passadas para prever saídas futuras. A rede neural ajusta seus pesos durante o processo de treinamento para minimizar o erro entre as saídas previstas e reais.

O algoritmo NARX-ANN possui diversas aplicações, incluindo a previsão de séries temporais, filtragem não linear e modelagem de sistemas dinâmicos não lineares (MathWorks, acessado em 2024). Esses modelos também têm demonstrado eficácia em vários contextos, tais como para estimativa do fluxo em oleodutos com diversos produtos (LEI et al., 2020), o uso como método alternativo para gerar registros de raios gama a partir de parâmetros de perfuração (OSAROGIAGBON et al., 2020), e como ferramenta para prever e reproduzir com alta precisão logs sônicos de poços de petróleo (ONALO et

al., 2019) e previsão de emissões de NOx em usinas termelétricas a carvão (TUTTLE et al., 2021)

Parte III

Contribuições

5

Modelos híbridos Baseados em Identificação de Sistemas e Aprendizado de Máquina para Simulações de Pressão em Profundidade de Poços

5.1

Estudo de Caso

Identificou-se a possibilidade de desenvolver modelos dinâmicos, ao invés dos estáticos comumente encontrados na literatura, para resolver problemas relacionados à estimação de variáveis alvo, como o fluxo de produção de petróleo ao longo do tempo ou a identificação de padrões presentes em um conjunto de dados para detecção de falhas e anomalias, por exemplo. Já foi demonstrado que esses modelos NARX permitem a detecção de padrões de uma série temporal específica (TIAN; HORNE, 2017). Essa técnica utiliza atrasos de entrada e saída para desenvolver um modelo dinâmico capaz de gerar uma saída confiável a partir de parâmetros estimados e erros entre o valor verdadeiro e os obtidos.

Por outro lado, a abordagem usual de aprendizado de máquina para previsões de medições, como taxa de fluxo, produção de petróleo e gás, é baseada na tecnologia de sensoriamento suave. Esses métodos são comumente utilizados para determinar quantidades físicas e exigem um conhecimento mínimo do processo (LEI et al., 2020). O principal problema dessa abordagem é a necessidade de informações de entrada atualizadas, o que pode ser bastante desafiador em tempo real.

Para superar as limitações da abordagem de sensoriamento suave, propõe-se um método híbrido para melhorar a precisão da estimativa de produção de petróleo. Os modelos NARX e a ANN são adotados como modelos adaptativos baseados em dados.

O objetivo desta contribuição é introduzir uma abordagem para auxiliar na tomada de decisões de curto prazo para simulação de produção de poços e pressão na indústria de petróleo e gás.

5.1.1

Base de Dados

Em maio de 2018, a Equinor (2018) disponibilizou ao público um conjunto de dados de um poço real no campo de Volve para fins de pesquisa. Este conjunto de dados, utilizado para construir modelos, inclui informações

geológicas, geofísicas e de engenharia de reservatórios do campo de petróleo de Volve, localizado no Mar do Norte, aproximadamente 200 km a oeste de Stavanger, Noruega.

Este é um conjunto de dados proveniente de um poço real no campo de Volve, um dos últimos bancos de dados lançados pela (EQUINOR, 2018) para o público para fins de pesquisa. Uma parte dos dados do poço é usada para desenvolver e treinar os modelos, enquanto a parte restante dos dados é usada como benchmark para verificar o desempenho preditivo dos modelos.

O conjunto de dados Volve inclui registros de poços, dados sísmicos, dados de produção e dados de engenharia de reservatórios, entre outros tipos de informações. Ele fornece um conjunto de dados abrangente e realista para testar e avaliar tecnologias e fluxos de trabalho subsuperficiais, além de promover a colaboração e inovação na indústria de petróleo e gás.

Os dados de produção analisados neste estudo abrangem informações detalhadas de sete poços. Para cada poço, foram coletados dados como horas em operação, pressão média no fundo do poço, temperatura e percentual médio de abertura do choke, entre outros parâmetros. A Tabela 5.1 fornece uma descrição estatística desses dados, com um foco especial na variável de saída de interesse: a pressão de fundo de poço, agrupada por diferentes poços.

Poço	Qtd.	Média	Dp	Min	Max	Data Inicial	Data Final
NO-15/9-F-01 C	743	246.67	30.75	0	313.87	07-abr-14	21-abr-16
NO-15/9-F-11 H	1159	233.96	34.82	0	317.55	07-ago-13	17-set-16
NO-15/9-F-12 H	3050	80.73	120.09	0	317.70	12-fev-08	17-set-16
NO-15/9-F-14 H	3050	233.07	64.92	0	334.66	01-dez-14	17-set-16
NO-15/9-F-15 D	978	226.03	42.72	193.19	397.59	01-set-07	01-dez-16

Tabela 5.1: Estatísticas descritivas da variável de interesse, pressão de fundo de poço, agrupada por diferentes poços presentes no banco de dados selecionado.

Neste estudo, utilizamos dados do poço NO 15/9-F-1 C, localizado no campo de Volve, para fins ilustrativos. Esses dados foram disponibilizados para pesquisa pela Equinor. Para este poço, o período de produção abrange de abril de 2014 a abril de 2016, incluindo uma variedade de informações relevantes para o estudo, resultando em 741 registros diários para todas as variáveis mencionadas.

Apesar de o poço possuir informações sobre diversas variáveis, focamos na análise de: Pressão Média no Fundo do Poço, Temperatura Média no Fundo do Poço, Horas de Operação, Volume de Óleo, Gás e Água Produzidos e Percentual Médio de Abertura do Choke. A escolha do poço NO 15/9-F-1 C se deu pela possibilidade de comparação dos resultados com o trabalho publicado

por Li, Sun e Horne (2019), o qual aborda diferentes arquiteturas de redes neurais recorrentes para predição de variáveis definidas no artigo mencionado.

5.2 Metodologia

Neste estudo, empregamos diferentes métodos numéricos para simular a temperatura nas profundezas do poço. Utilizamos a técnica de identificação de sistemas Autorregressiva com entrada Exógena (*ARX*) e o modelo Autorregressivo Não Linear com entrada Exógena (*NARX*), além do modelo Neural NARX (*NARX-ANN*), para formar duas estratégias de simulação.

O processo seguiu uma sequência de etapas com base na metodologia recomendada para a identificação de sistemas:

1. Aquisição de Dados: Foram coletadas informações de entrada/saída no domínio do tempo, incluindo a pressão no fundo do poço e outras variáveis disponíveis no banco de dados.

2. Seleção de Dados: Foram selecionadas e preparadas variáveis relevantes de um conjunto total de sete variáveis potenciais para nosso modelo de identificação de sistemas lineares, incluindo temperatura e porcentagem de abertura da válvula choke, com o objetivo de simular a variável de interesse. Diversos modelos foram desenvolvidos para avaliar a influência das variáveis independentes na simulação da pressão de fundo de poço. No Modelo 1, utilizamos uma única variável independente para simular a pressão no fundo do poço. Nesse modelo, todas as sete variáveis independentes presentes no conjunto de dados foram avaliadas separadamente, e seus resultados na simulação da variável dependente foram comparados. Para explorar mais combinações, avançamos para o Modelo 2, no qual selecionando duas variáveis independentes de cada vez entre as sete, resultando em várias combinações, totalizando 21 modelos, como verificado na Fig. 5.1. Este procedimento foi repetido para os Modelos 3 no qual foram testados conjuntos de 3 variáveis independentes e subsequentes, aumentando gradualmente o número de variáveis independentes em cada iteração. O esquema proposto pode ser verificado na Fig.5.2.

O desempenho de cada modelo foi avaliado utilizando métricas como erro médio quadrático e coeficiente de determinação, selecionando os modelos mais eficazes com base nos resultados obtidos.

3. Definição e Seleção da Estrutura do Modelo: Após a seleção das variáveis, foram variados os coeficientes de atraso ou coeficientes do modelo para identificar o melhor modelo adaptado ao objetivo deste trabalho. Com isso, foi determinada e escolhida uma estrutura de modelo, que consiste em um conjunto de alternativas para descrever o sistema em estudo.




Figura 5.1: Quantidade de combinações de variáveis por rodada



Figura 5.2: Exemplificação da seleção de variáveis por rodada

4. Estimação dos Parâmetros: Os parâmetros da função de transferência da estrutura do modelo foram calculados utilizando os dados de entrada/-saída preparados, juntamente com as técnicas de identificação implementadas em Python utilizando a biblioteca Sysidenpy (JUNIOR et al., 2020).

5. Análise da Adequação do Modelo: A compatibilidade do modelo obtido foi avaliada em relação aos dados experimentais, utilizando o coeficiente de correlação múltipla R^2 entre a resposta estimada do modelo $\hat{y}$ e as medições observadas $y(t)$. Um valor de R^2 superior a 0.9 é considerado satisfatório para muitas aplicações (SCHAIBLE; XIE; LEE, 1997).

A exemplificação do algoritmo utilizado também pode ser verificada na Fig. 5.3.



Figura 5.3: Representação da metodologia adotada neste estudo.

Por último, uma Rede Neural Autorregressiva Não Linear com Exógenas (NARX-ANN) foi empregada para simular o erro inerente ao sistema, conforme expresso na Equação 5-1.

$$\mathbf{error}(k) = y(k) - \hat{y} \quad (5-1)$$

Nessa abordagem, o modelo recebe como entrada o erro gerado pelo primeiro modelo ARX/NARX, o qual visa simular as discrepâncias em relação ao modelo desenvolvido. Em seguida, o valor do erro simulado é combinado com a saída do modelo ARX/NARX original, com o propósito de ajustar o valor desejado da pressão de fundo. Esse procedimento de simulação e correção do erro permite uma melhor adaptação do modelo às variações reais observadas no sistema, contribuindo para uma representação mais precisa e confiável do comportamento da pressão no fundo do poço.

Foram empregadas as abordagens de Predição de um passo à frente (**OSA** do inglês **One-Step-Ahead**) e Simulação Livre (**FR**, do inglês **Free-Run**) para avaliar a precisão do modelo. Na OSA, o modelo é utilizado para prever os valores futuros com base nos dados anteriores, permitindo a comparação entre as previsões e as medições reais. Essa técnica é crucial para verificar a adequação do modelo aos dados observados. Já na simulação livre (FR), os dados anteriores são usados para prever os futuros, porém os erros acumulados ao longo do tempo podem afetar o resultado. Embora a FR reflita melhor a dinâmica real do sistema, a OSA é amplamente empregada devido à necessidade de um modelo inicialmente aderente aos dados, uma vez que a FR utiliza esses mesmos dados para as previsões.

5.3

Resultados e Discussão

Primeiramente, tentamos simular a pressão média no fundo do poço utilizando um modelo ARX variando as variáveis usadas como entradas, assim como o número de coeficientes do modelo na e nb .

Apesar do desempenho relativamente bom para o ARX, ele não foi capaz de incorporar toda a dinâmica do sistema verificada nos testes de validação, como mostrado na figura 5.4. O modelo desenvolvido foi construído usando a temperatura média no fundo do poço como entrada e $na = nb = 15$, resultando em $RMSE = 0,3305$ e $R^2 = 0,9082$.

Para aprimorar o modelo NARX, implementamos um modelo NARX polinomial variando os graus do modelo. O modelo utilizou a temperatura média no fundo do poço como entrada, com hiper parâmetros ótimos de $na = nb = 10$, conforme mostrado na Figura 5.5. Definimos $ylag$ e $xlag$ para o




Figura 5.4: Resultado da Simulação livre (FR) para o melhor modelo ARX desenvolvido




Figura 5.5: Resultado da Simulação livre (FR) para o melhor modelo NARX desenvolvido

mesmo valor de 10 nesse caso. Apesar da capacidade do modelo de incorporar comportamento não linear, os resultados foram um pouco melhores do que os obtidos com o modelo ARX, como evidenciado pelo RMSE de 0,2841 e R^2 de 0,9264.

A Tabela 5.2 mostra o Índice de Redução de Erro (ERR) para os regressores responsáveis pela maior redução.

A Figura 5.6 mostra que o uso do feedback de saída resultou em bom desempenho tanto em simulações de um passo à frente quanto em simulações de execução livre. A simulação de um passo à frente envolve a previsão da saída

Regressores	Parâmetro	ERR
0	$y(k-1)^2$	1.1837E+00
1	$y(k-9)y(k-3)$	1.8132E-07
2	$x(k-1)y(k-2)$	1.8155E-03
3	$y(k-2)y(k-1)$	-6.4768E-04
4	$x1(k-2)^2$	1.9229E-03
5	$x(k-3)^2$	-1.1813E-01
6	$x(k-20)x(k-18)$	-7.1323E-04
7	$y(k-19)y(k-6)$	-2.5525E-03
8	$x1(k-10)x(k-5)$	2.2329E-03
9	$x(k-1)y(k-10)$	-2.0845E-03

Tabela 5.2: ERR de acordo com cada regressor selecionado




Figura 5.6: Comparação da simulação de um passo à frente e execução livre para identificação do sistema.

de um sistema em cada etapa de tempo usando dados históricos, enquanto a execução livre envolve a previsão da saída ao longo de um período mais longo sem nenhum conhecimento das entradas ou condições iniciais. A verificação das simulações foi feita usando as entradas brutas.

Uma última tentativa foi feita para simular o erro do modelo NARX usando o modelo NARX-ANN, utilizando a abertura do tamanho do estrangulador como a variável de entrada. No entanto, apesar da maior capacidade da rede neural de reconhecer a dinâmica do sistema, isso não resultou em uma melhoria na precisão, conforme plotado na figura 5.7 e 5.8. Neste estudo,

constatou-se que mapear o sinal de erro não era uma tarefa trivial, e o aumento observado no ruído e erro de ponto flutuante provavelmente foi atribuído ao comportamento caótico inerente do sistema.




Figura 5.7: Comparação da simulação de um passo à frente e execução livre, incluindo o modelo de simulação de erro NARX-ANN no conjunto de dados de treinamento.




Figura 5.8: Comparação da simulação de um passo à frente e execução livre, incluindo o modelo de simulação de erro NARX-ANN no conjunto de dados de teste.

Para este estudo, utilizamos uma rede neural com 30 neurônios na camada de entrada e três camadas ocultas, cada uma consistindo em 100 neurônios com camadas de desistência configuradas para 0,2. Utilizamos a função tangente hiperbólica ($\tanh$) como função de ativação e uma taxa

de aprendizado de 1×10^{-3} . A parada antecipada foi implementada com um parâmetro de paciência de 16. A rede neural foi treinada por 128 épocas, utilizando um tamanho de lote de 32.

5.4

Conclusão Parcial

Neste estudo, desenvolvemos modelos híbridos ARX, NARX e NARX-ANN para simular a pressão média no fundo de um poço no campo de Volve. Os modelos foram treinados e testados para garantir que capturassem com precisão a relação entrada-saída antes de realizar uma validação cega.

Este estudo demonstra os benefícios potenciais do uso de técnicas de identificação de sistemas para otimização da produção de petróleo, fornecendo insights precisos e oportunos sobre o comportamento do sistema de produção. Essa abordagem pode ajudar os operadores a aprimorar a eficiência, confiabilidade e lucratividade de suas operações.

Embora tenhamos tentado melhorar os resultados da simulação usando um modelo mais complexo para estimar o erro de estimação NARX-ANN, isso não resultou nas melhorias esperadas. O erro de simulação mostrou-se desafiador de gerenciar usando a abordagem neural NARX-ANN para identificação de sistemas devido ao comportamento caótico inerente ao sistema.

Nossa análise revelou que o uso de técnicas de identificação de sistemas pode melhorar a otimização da produção de petróleo, prevendo com precisão o comportamento do sistema de produção. O modelo foi capaz de identificar estratégias de produção ótimas que resultaram em taxas de produção mais altas e custos operacionais reduzidos.

Pesquisas futuras nessa área podem se concentrar no desenvolvimento de modelos mais sofisticados que incorporem fontes adicionais de dados e técnicas avançadas de análise, bem como explorar os benefícios potenciais da otimização e controle em tempo real com foco na simulação de variáveis medidas tendo como input as variáveis manipuladas tais como a porcentagem de abertura da válvula choke e tempo de funcionamento.

6

Avaliação de Técnicas de Identificação de Sistemas Dinâmicos para a Instabilidade Torsional em Sistemas de Perfuração: Modelos Black Box vs. Grey Box

6.1

Efeito Stick-Slip

Uma perturbação documentada e reconhecida no desempenho da perfuração é a oscilação *stick-slip*, que impacta significativamente nos custos operacionais.

O fenômeno *stick-slip* representa um desafio crucial nas operações de perfuração, contribuindo para uma série de consequências prejudiciais. Esse fenômeno envolve a interrupção momentânea da broca devido ao atrito (fase de stick), criando um efeito cascata que leva a vários problemas operacionais. À medida que o top drive persiste em sua rotação, a energia armazenada eventualmente supera as forças de atrito, iniciando o movimento (fase de slip) (HONG; GIRLANG; DHUPIA, 2016). As ramificações dessas oscilações são profundas, causando danos à broca, aumentando o risco de falha devido à fadiga nas juntas roscadas, reduzindo a Taxa de Penetração, comprometendo o controle direcional, induzindo respostas inconsistentes de curvatura da ferramenta e elevando os níveis de choque e vibração no fundo do poço (BAYLISS; PANCHAL; WHIDBORNE, 2012). Esses efeitos cumulativos contribuem significativamente para a falha prematura da ferramenta e destacam a importância primordial de abordar o fenômeno stick-slip na otimização da eficiência de perfuração e na longevidade do equipamento. Múltiplos parâmetros influenciam esse fenômeno, incluindo a velocidade de deslizamento, as propriedades do material na superfície de contato, temperatura e a presença e natureza da lubrificação (ALKARAGOOLEE; BRYANT, 2022).

Os esforços para melhorar a eficiência de perfuração exploram a desvendar as interações complexas do sistema. Pesquisas recentes exploram várias abordagens, incluindo identificação de eventos a partir de relatórios de perfuração por meio de sistemas especialistas (CINELLI et al., 2021), reconhecimento de padrões (LI et al., 2022) e investigação do impacto do pré-processamento de dados no desempenho do modelo e na precisão preditiva (SRIVASTAVA et al., 2022). Esses esforços exemplificam a abordagem baseada em dados na otimização das operações de perfuração.

Além disso, outros esforços de pesquisa concentram-se em aproveitar

insights físicos para entender eventos observados, como o fenômeno stick-slip. Essas iniciativas visam criar modelos matemáticos que descrevam como o evento ocorre, buscando uma representação que elucide seu funcionamento. Esses esforços resultam no desenvolvimento de modelos de caixa cinza, visando representar e compreender esses fenômenos complexos.

6.2

Estado da Arte

Vromen et al. (2015) desenvolveram um controlador de feedback de saída para aliviar as vibrações torsionais stick-slip modelando interações não lineares entre a broca e a rocha. Seu estudo também envolveu o desenvolvimento e avaliação de um sistema automatizado para identificar e mitigar o stick-slip em operações de perfuração, visando aprimorar o desempenho da perfuração por meio da redução de ocorrências de stick-slip e otimização de parâmetros de perfuração como WOB e RPM.

Ritto, Aguiar e Hbaieb (2017) conduziram um estudo empírico utilizando dados de campo para validar um modelo numérico de vibração torsional, visando discernir as nuances da interação entre a broca e a rocha. Sua pesquisa se estendeu à investigação da estabilidade torsional por meio de um mapa de estabilidade abrangente, incorporando variáveis controladas.

Oyedere e Gray (2020) desenvolveram uma abordagem para otimizar a eficiência de perfuração redesenhando a previsão de Taxa de Penetração (ROP) e torque-on-bit (TOB) como um problema de classificação. Eles introduzem um método de classificação de duas regiões, aproveitando algoritmos de aprendizado de máquina (regressão logística, análise discriminante linear, análise discriminante quadrática, máquinas de vetores de suporte e floresta aleatória) para prever com precisão ROP e TOB com base em limiares definidos pelo usuário.

O trabalho de Sheth et al. (2022) focou no desenvolvimento de um modelo híbrido, mesclando princípios baseados em física com aprendizado de máquina por meio de redes neurais recorrentes. Essa abordagem híbrida melhorou significativamente a estimativa de parâmetros, estendendo a previsão de resposta do sistema além dos parâmetros históricos. Suas previsões oferecem aos operadores insights para otimizar os processos de perfuração, especialmente em relação às faixas eficazes de WOB e rotações por minuto.

No estudo conduzido por Pires, Ayala e Weber (2023), foi investigada a aplicabilidade de uma abordagem de conjunto que combina metodologias de caixa cinza e caixa preta para melhorar a precisão da previsão em modelos de atrito, em cenários práticos de resolução de problemas. A pesquisa explorou um

modelo híbrido que integra a interpretabilidade característica da abordagem de caixa cinza com o poder preditivo das técnicas de caixa preta, visando superar as limitações tradicionais de interpretabilidade encontradas em métodos puramente de caixa preta.

Apesar de um número considerável de estudos focar na otimização da perfuração de poços envolvendo várias interações entre broca e rocha e diferentes tipos de vibrações (torsionais, longitudinais ou laterais), poucos exploram a utilização de sistemas de identificação como alternativa. Além disso, há escassez de comparações com modelos informados por física ou modelos de caixa cinza, indicando uma lacuna notável nessa área de pesquisa.

A principal contribuição deste artigo reside na comparação de modelos de caixa cinza e caixa preta para vibrações torsionais em colunas de perfuração usando técnicas de Identificação de Sistemas. Este estudo visa contrastar esses modelos, empregando especificamente algoritmos ARX e NARX para avaliar a linearidade e a capacidade de identificar um sistema dinâmico e intrincado, como o stick-slip. A incorporação de um modelo de caixa cinza visa criar e comparar uma estratégia alternativa, aproveitando o conhecimento prévio do evento para aprimorar os resultados. Além disso, é importante observar que modelos de caixa preta apresentam limitações quando aplicados a cenários do mundo real, especialmente em contextos dessa natureza.

6.3

Descrição do estudo de caso

O estudo de caso envolve a construção de um modelo dinâmico que correlaciona a velocidade de rotação da broca com o torque fornecido na mesa rotativa (TOB), aproveitando dados de campo conforme mostrado nas Figuras 6.1 e 6.2, respectivamente. Relatórios anteriores sobre este estudo podem ser encontrados em (RITTO; AGUIAR; HBAIEB, 2017). As informações de fundo utilizadas nesta pesquisa foram obtidas por meio de uma unidade de medição de mecânica de fundo, capaz de telemetria de lama em tempo real e gravação contínua de dados em alta frequência. O subsistema, instalado acima da broca dentro do BHA, abriga 19 sensores amostrados a 10.000 Hz, posteriormente reduzidos e filtrados antes do registro a 50 Hz.

No estudo de (RITTO; AGUIAR; HBAIEB, 2017), foram consideradas duas amostras distintas: uma sem stick-slip totalmente desenvolvido e outra demonstrando interação stick-slip. A última amostra, que representa o comportamento stick-slip, serviu como base para identificar o modelo de interação broca-rocha.

A Figura 6.3 exibe os dados de campo registrados a uma taxa de




Figura 6.1: Velocidade de rotação da broca versus tempo




Figura 6.2: Torque na broca versus tempo.

frequência de 50 Hz, adquiridos usando uma ferramenta de módulo de mecânica de perfuração para medições de fundo. Posicionada dentro do BHA acima da broca, esta ferramenta capturou dados durante a execução.




Figura 6.3: Dados de campo disponíveis: torque na broca versus velocidade da broca

A validação desses modelos foi conduzida por meio de estatísticas de erro, incluindo Erro Quadrático Médio (RMSE), Erro Médio Absoluto (MAE), Erro

Quadrático Médio (MSE) e Erro Quadrático Médio Relativo (RRSE). Essas métricas ajudaram a garantir a precisão e confiabilidade de nossos resultados.

6.4 Metodologia

Um modelo grey-box combina elementos de modelagem black-box (baseada em dados) e white-box (baseada em física). Ao unir princípios físicos e métodos baseados em dados, prevê o comportamento do sistema equilibrando fontes de informação (KUMAR et al., 2023). Essa abordagem resulta em soluções mais adaptáveis e interpretáveis, aproveitando tanto a expertise de domínio quanto os dados disponíveis para modelar sistemas complexos com precisão.

Em um contexto mais específico, o modelo grey-box na identificação de sistemas integra modelagem baseada em física com dados de medição. Lidando com parâmetros incertos e estados iniciais estimados por meio de medições, assemelha-se a um modelo quase white-box. No entanto, a estimação de parâmetros, mesmo para modelos lineares, enfrenta desafios devido a funções objetivas multimodais, muitas vezes exigindo algoritmos complexos e compensações computacionais para estimação em tempo real (KANEKO et al., 2022).

Nesta pesquisa, nosso principal objetivo é fortalecer a precisão do modelo e replicar o fenômeno stick-slip empregando um modelo grey-box. Essa metodologia envolve a estimação de parâmetros do modelo físico, aprimorando a capacidade preditiva do modelo. Utilizando uma combinação de conhecimento estabelecido baseado em física e técnicas baseadas em dados, pretendemos criar um modelo híbrido que não apenas capture as complexidades inerentes ao fenômeno stick-slip, mas também forneça previsões mais precisas.

Essa abordagem integra um conjunto de equações derivadas da compreensão física do sistema com um componente baseado em dados, reduzindo a lacuna entre os insights teóricos e as observações empíricas. Para focar no comportamento de torção da coluna de perfuração, é utilizado um modelo de dinâmica torsional.

A coluna de perfuração é segmentada usando uma série de sistemas massa-mola-amortecedor concentrados. Essa abordagem divide o BHA (Conjunto de Fundo de Poço) e os tubos de perfuração em um sistema de segmentos de parâmetros concentrados, conforme ilustrado na Fig. 6.4.

O modelo dinâmico angular do sistema de perfuração foca nas rotações dos componentes principais: mesa rotativa (rt), parcela superior do BHA (tb) e broca de perfuração (db). As equações de movimento que governam a dinâmica angular desses componentes são derivadas usando princípios da




Figura 6.4: Esquema da modelagem da broca de perfuração

mecânica clássica.

As equações de diferença de velocidade angular definem as relações entre as velocidades angulares dos componentes. Duas equações primárias são usadas, mostradas nas Eqs. 6-1 e 6-2, que representam a deformação angular na seção superior e inferior da coluna de perfuração, respectivamente.

$$\delta_{dp} = \theta_{tb} - \theta_{rt} \quad (6-1)$$

$$\delta_{bha} = \theta_{dp} - \theta_{tb} \quad (6-2)$$

As equações de movimento (Eq. 6-3 e 6-4) derivadas da mecânica clássica descrevem a relação entre os torques aplicados aos componentes e suas acelerações angulares. Essas equações consideram os momentos de inércia (J), torques (T), coeficientes de amortecimento (C), rigidez (K), velocidades angulares (ω) e acelerações angulares ($\dot{\omega}$). Elas representam a dinâmica rotacional do sistema e a interação entre seus componentes.

$$\begin{aligned} J_{tb}\dot{\omega}_{tb} + C_{dp}(\omega_{tb} - \omega_{rt}) - C_{bha}(\omega_{tb} - \omega_{db}) \\ + K_{dp}\delta_{dp} - K_{bha}\delta_{bha} \\ + C_{tbe}(\omega_{tb}) = 0 \end{aligned} \quad (6-3)$$

$$\begin{aligned} J_{dp}\dot{\omega}_{dp} + C_{bha}(\omega_{dp} - \omega_{tb}) + K_{bha}\delta_{bha} \\ + C_{abe}(\omega_{dp}) = -T_{ob} \end{aligned} \quad (6-4)$$

O modelo caixa cinza, expresso como uma função composta, busca incorporar o modelo baseado em física com os resíduos derivados de dados, conforme

mostrado na Eq. 6-5. Essa representação composta será fundamental para capturar e simular o comportamento de deslizamento durante as operações de perfuração.

$$\begin{aligned}
 \dot{y}_1 &= y_3 - u \\
 \dot{y}_2 &= y_4 - y_3 \\
 \dot{y}_3 &= -(c_{dp}(y_3 - u) + m_{dp}y_1 + c_{bha}(y_3 - y_4) \\
 &\quad - m_{bha}y_2 + c_{dpe}y_3) / J_{dp} \\
 \dot{y}_4 &= -(c_{bha}(y_4 - y_3) + m_{bha}y_2 + c_{bhae}y_4 \\
 &\quad + r(a_4 + a_5y_4 + a_6y_4^2 + a_7y_4^3)) / J_{bha}
 \end{aligned} \tag{6-5}$$

Esse conjunto de equações descreve a dinâmica de um sistema de equações diferenciais em que o vetor de estado, representado por $\mathbf{y} = [y_1, y_2, y_3, y_4]$, denota os estados do sistema. A entrada, velocidade imposta no topo da coluna u , influencia o comportamento do sistema. Parâmetros como J_{dp} (momento de inércia da broca), J_{bha} (momento de inércia do conjunto de fundo do poço), c_{dp} (coeficiente de amortecimento da broca), c_{dpe} (coeficiente de amortecimento da extensão da broca), c_{bha} (coeficiente de amortecimento do conjunto de fundo do poço), c_{bhae} (coeficiente de amortecimento da extensão do conjunto de fundo do poço), m_{dp} (constante da broca), m_{bha} (constante conjunto de fundo do poço, BHA), a_4 , a_5 , a_6 , a_7 , e r (parcelas de torque fazem parte das equações governantes do sistema). Essas equações descrevem as taxas de mudança dos estados y_1 a y_4 ao longo do tempo.

De posse da modelagem determinístico, componente da parcela de caixa branca, utilizando conhecimento prévio e simulação numérica com o CASADI (ANDERSSON et al., 2019).

Na segunda etapa, complementamos o modelo caixa cinza com um modelo caixa preta utilizando o SysIdentpy (JUNIOR et al., 2020). Esse modelo caixa preta captura as dinâmicas não lineares e estocásticas do sistema que não podem ser facilmente expressas pelas equações físicas.

A saída da simulação do modelo caixa branca é utilizada como entrada para o modelo caixa preta, juntamente com a entrada exógena do torque aplicado à broca, gerando o . Essa integração com a adição de parcelas da modelagem caixa branca e caixa preta permite obter um modelo completo e preciso da velocidade angular da broca de perfuração.

A Fig. 6.5 ilustra o esquema do modelo híbrido caixa cinza-caixa preta. O modelo caixa cinza determina a velocidade angular da broca com base nas variáveis de estado e parâmetros físicos do sistema. Essa velocidade angular simulada é então utilizada como entrada para o modelo caixa preta, juntamente com o torque aplicado à broca. O modelo caixa preta identifica a dinâmica

não linear e estocástica do sistema, combinando essa informação com a saída simulada do modelo caixa cinza para fornecer uma estimativa precisa da velocidade angular real da broca.




Figura 6.5: Exemplificação da metodologia empregada neste trabalho

A modelagem com simulação numérica utilizando o conhecimento físico prévio do problema fornece uma estimativa inicial da velocidade angular da broca com base nas variáveis de estado e parâmetros físicos do sistema. Essa estimativa é então refinada pelo modelo caixa preta, que captura as dinâmicas não lineares e estocásticas do sistema a partir de dados experimentais.

6.5 Resultados e Discussão

O desempenho da metodologia proposta foi avaliado por meio de identificação de sistemas. Na fase inicial desta pesquisa, foram desenvolvidos modelos ARX e NARX, apresentando resultados abrangentes que englobam saídas, erros e valores estimados dos parâmetros do modelo. Esses modelos foram formulados para simular a velocidade angular da broca, considerando a intrincada interação entre a broca e a rocha. Após realizar uma análise estatística dos erros, obteve-se um modelo ótimo tanto para NARX quanto para ARX.

Posteriormente, a investigação voltou-se para o desenvolvimento de um modelo "grey-box", incorporando o conhecimento físico do problema. Essa abordagem permitiu uma análise mais aprofundada da dinâmica do sistema, considerando a física subjacente e fornecendo insights adicionais sobre o desempenho do modelo em cenários mais realistas.

6.5.1

Modelagem Black-Box

Inicialmente, tentamos simular a Velocidade Rotacional Média utilizando um modelo ARX com o Torque sobre a Broca (TOB) como entrada, variando o número de coeficientes do modelo n_a e n_b . A estimação ARX e NARX foi realizada pela biblioteca SysIdentPy (JUNIOR et al., 2020).

Iniciamos nossa análise examinando os dados de entrada e saída, utilizando várias técnicas de processamento, incluindo normalização e remoção de valores discrepantes. A Tabela 6.1 apresenta estatísticas descritivas, abrangendo medidas que resumem a centralidade, dispersão e forma distribucional do conjunto de dados.

	Bit Rotational Speed (RPM)	TOB (kNm)
count	3000	3000
mean	98.5	5.87
std	90.7	1.70
min	-7.2	-0.73
25%	-0.12	4.60
50%	88.5	5.53
75%	192.5	7.36
max	250.2	11.21

Tabela 6.1: Estatísticas descritivas de entrada e saída

6.5.1.1

Modelagem ARX

Para o modelo ARX, foram priorizados modelos com ordens baixas de n_a e n_b , devido ao melhor desempenho nas métricas de erro estático (Tabela 6.2). Essa escolha justifica-se pela simplicidade da dinâmica do sistema, que pode ser bem representada por modelos com menos parâmetros. Ressalta-se que os três primeiros modelos com $n_a = n_b = 5$, 10 e 15 apresentaram resultados idênticos, reforçando a ideia de que modelos mais simples são suficientes para capturar a essência do sistema.

As Figuras 6.6 e 6.7 apresentam os resultados das simulações ARX, tanto para execução livre quanto para simulações com antecipação de n passos, com $n = 5$. A escolha de $n = 5$ foi definida experimentalmente, buscando um equilíbrio entre a precisão da predição e a capacidade de generalização do modelo.

Não foi utilizado $n = 1$, pois um valor tão baixo poderia resultar em simulações futuras muito próximas dos dados de treinamento, limitando a capacidade do modelo de generalizar para novos cenários. Ao definir $n = 5$, foi

Model Order	R^2	RMSE	MAE	RRSE
5	0.8897	30.1300	20.0585	0.3573
10	0.8897	30.1300	20.0585	0.3573
15	0.8897	30.1300	20.0585	0.3573
20	0.8825	31.0950	20.9852	0.3720
25	0.8766	31.8729	21.9902	0.3843
30	0.8715	32.5141	22.9539	0.3960
35	0.8713	32.5413	23.3997	0.4018
40	0.8711	32.5702	23.4865	0.4076
45	0.8710	32.5843	23.0312	0.4134

Tabela 6.2: Métricas estatísticas de erro: Avaliação do modelo ARX

garantida uma distância maior entre os dados de treinamento e as simulações futuras, permitindo que o modelo aprenda a capturar as tendências do sistema de forma mais abrangente.

Na Figura 6.8, os erros de simulação para esse modelo são mostrados para os conjuntos de treinamento e teste. Finalmente, a Figura 6 ilustra os testes estatísticos realizados para validar o modelo gerado. Além disso, a Tabela 6.3 destaca a taxa de Redução de Erro (ERR, do inglês *error reduction ratio*) para os regressores responsáveis pela redução mais significativa.

Regressors	Parameters	ERR
y(k-50)	6.3314E-01	7.01890939E-01
y(k-100)	-5.2346E-01	8.80986409E-02
1	2.5199E+02	8.49189214E-02
x1(k-1)	-1.3258E+0	4.66032531E-02
x1(k-2)	-9.9231E+00	2.62780573E-03
x1(k-5)	-5.1361E+00	4.36316675E-04

Tabela 6.3: ERR de acordo com cada regressor selecionado - ARX

6.5.1.2 Modelagem NARX

Ao analisar os resultados do modelo NARX, uma divergência notável surge nas saídas resultantes em comparação com modelos que utilizam a metodologia ARX. Essa discrepância torna-se evidente mediante uma análise detalhada da Tabela 6.5, que detalha minuciosamente as métricas de erro geradas pelo modelo NARX. Apesar do desafio intrincado apresentado pela modelagem da interação broca-rocha, o modelo não linear NARX não exibe desempenho significativamente superior em comparação com o modelo linear ARX.




Figura 6.6: Resultado da simulação livre de treinamento e teste do modelo ARX




Figura 6.7: Resultado da Simulação n passos à frente para o modelo ARX




Figura 6.8: Evolução temporal dos erros de estimação no modelo ARX

Além disso, em meio à complexidade inerente à captura das dinâmicas sutis da interação broca-rocha, o modelo NARX demonstra variações de desempenho sutis. Isso fica particularmente evidente em simulações n passo a frente, onde uma melhoria sutil, porém perceptível em comparação com o modelo ARX, é evidenciada, como detalhado nas Figuras 6.9 e 6.10. Adicionalmente, uma análise abrangente dos parâmetros estimados juntamente com suas taxas de redução de erro correspondentes é apresentada na Tabela 6.4.

Adicionalmente, ao analisar a Figura 6.11, que ilustra os erros de simulação do modelo NARX, observa-se uma maior amplitude e grau de variabilidade

Regressors	Parameters	ERR
$y(k - 50)$	1.3148E+00	7.01890939E-01
$y(k - 100)^2$	-3.6860E-03	1.08874755E-01
1	3.7127E+02	6.68316242E-02
$x1(k - 1)$	-1.5613E+01	4.69980542E-02
$x1(k - 2)$	-2.9904E+01	2.65895165E-03
$y(k - 50)^2$	-5.0761E-03	2.50831672E-03
$y(k - 100)y(k - 50)$	2.9763E-03	3.49388486E-03
$x1(k - 2)x1(k - 1)$	1.7838E-02	3.79608186E-03
$x1(k - 3)$	-2.4534E+01	8.32439048E-04
$x1(k - 3)x1(k - 2)$	3.2024E+00	5.30693911E-04

Tabela 6.4: ERR de acordo com cada regressor selecionado - NARX

Model Order	R^2	RMSE	MAE	RRSE
5	0.7573	44.6915	34.0319	0.5701
10	0.7573	44.6915	34.0319	0.5701
15	0.7573	44.6915	34.0319	0.5701
20	0.7070	49.1016	36.9284	0.6274
25	0.6597	52.9164	39.2133	0.6766
30	0.5689	59.5634	42.9555	0.7658
35	0.5663	59.739	42.8884	0.7628
40	0.4535	67.0607	47.97545	0.8572
45	0.7089	48.9395	36.5759	0.6028

Tabela 6.5: Métricas estatísticas de erro: Avaliação do modelo NARX.

em relação às saídas geradas. Isso reforça ainda mais a conclusão de que, neste caso, o modelo NARX não capturou efetivamente as dinâmicas do sistema de maneira superior em comparação com o modelo linear ARX.

6.5.2

Modelagem Grey-Box

Em nossa investigação, incorporamos conhecimento físico prévio na construção de um modelo grey box para superar as limitações inerentes aos modelos caixa-preta em aplicações práticas. Nossos resultados demonstraram que o modelo grey box apresentou um desempenho superior em relação aos dois modelos caixa-preta anteriores de identificação de sistemas, conforme ilustrado na Figura 6.12. As saídas geradas exibiram uma conformidade aprimorada e um comportamento irregular significativamente reduzido. No entanto, apesar dos resultados superiores, o modelo grey box simulou um movimento reverso pouco provável no cenário estudado.

A análise dos erros de simulação, representados na Figura 6.13 e na




Figura 6.9: Simulação livre de treinamento e teste do modelo NARX




Figura 6.10: Simulação n passos à frente para o modelo NARX




Figura 6.11: Evolução temporal dos erros de estimação no modelo NARX.

Tabela 6.6, ao comparar os valores reais e previstos pelo modelo, revelou uma menor dispersão. No entanto, é essencial observar que, embora o modelo grey box tenha apresentado um desempenho robusto, não conseguiu reproduzir o fenômeno de stick-slip.

R^2	RMSE	MAE	RRSE
0.9287	24.2137	19.3645	0.2765

Tabela 6.6: Métricas estatísticas de erro do modelo de caixa branca.

Análises adicionais destacaram o potencial de aprimoramento por meio




Figura 6.12: Estimações do modelo caixa cinza.




Figura 6.13: Erros de estimação ao longo do tempo no modelo de caixa cinza

da adoção de uma abordagem híbrida, combinando a flexibilidade dos modelos caixa-preta com as restrições dos modelos grey box. Essa hibridização, voltada para replicar fenômenos de stick-slip, promete resultados superiores. No entanto, embora o modelo grey box tenha fornecido insights valiosos, sua capacidade de simular efetivamente o stick-slip ainda requer refinamentos adicionais. Especificamente, é necessário aumentar a complexidade do modelo para melhor encapsular a intrincada interação entre a broca e a rocha.

Além disso, a incorporação de restrições físicas ao modelo pode ser uma estratégia eficaz para mitigar o problema de movimentos reversos improváveis observados nas simulações. A aplicação de tais restrições permite que o modelo respeite as leis físicas subjacentes ao sistema, melhorando assim a precisão e o realismo das previsões.

Recomenda-se, no futuro, a implementação de restrições físicas diretamente no modelo, para assegurar que as simulações permaneçam dentro dos limites esperados do comportamento do sistema, evitando, dessa forma, resultados não realistas e melhorando a robustez das previsões.

6.6

Conclusão parcial

Este estudo investigou diversos métodos de modelagem para compreender as interações entre a broca e a rocha durante a perfuração. Foram avaliados modelos black box, como ARX e NARX, cada um com suas vantagens e limitações distintas. Enquanto o trabalho de (RITTO; AGUIAR; HBAIEB, 2017) se concentrou em um modelo simplificado de parâmetros concentrados, nossa abordagem incorporou metodologias mais complexas, como os modelos ARX e NARX, juntamente com um modelo híbrido grey box.

Contrariando as descobertas de estudos anteriores, nossa pesquisa revelou que os modelos lineares (ARX) superaram o modelo não linear (NARX). Embora o ARX tenha apresentado um desempenho louvável em certos cenários, a abordagem não linear do modelo NARX exibiu resultados mais nuances, especialmente em previsões de vários passos. O objetivo era aprimorar a precisão das previsões relacionadas às vibrações torsionais, combinando compreensão baseada em princípios físicos com técnicas orientadas por dados.

Além disso, a incorporação de um modelo grey box, que integrou princípios baseados em física e observações empíricas, superou as limitações dos modelos black box. O modelo grey box demonstrou desempenho superior, com maior conformidade na saída e comportamento não uniforme reduzido em comparação com os modelos black box. Este estudo destaca a importância de integrar abordagens de modelagem diversas e aproveitar o conhecimento prévio para previsões precisas na dinâmica da sonda de perfuração, abrindo caminho para avanços nas operações de perfuração.

Trabalhos futuros devem se concentrar em aumentar a complexidade do modelo incorporando graus adicionais de liberdade, possibilitando uma acomodação mais abrangente da dinâmica de interação entre a broca e a rocha com a implementação de restrições físicas diretamente no modelo. Essa abordagem tem o potencial de aprimorar significativamente os resultados da modelagem e a precisão preditiva.

Parte IV

Conclusão

Conclusão e trabalhos futuros

Na primeira contribuição, desenvolvemos modelos híbridos ARX, NARX e NARX-ANN para simular a pressão média no fundo de um poço no campo de Volve. Utilizamos técnicas de identificação de sistemas para otimizar a produção de petróleo, fornecendo insights precisos sobre o comportamento do sistema de produção. Essa abordagem pode ajudar os operadores a aprimorar a eficiência, confiabilidade e lucratividade de suas operações.

Embora tenhamos tentado melhorar os resultados da simulação usando um modelo mais complexo para estimar o erro de estimação NARX-ANN, isso não resultou nas melhorias esperadas. O erro de simulação mostrou-se desafiador de gerenciar usando a abordagem neural NARX-ANN para identificação de sistemas devido ao comportamento caótico inerente ao sistema.

Nossa análise revelou que o uso de técnicas de identificação de sistemas pode melhorar a otimização da produção de petróleo, prevendo com precisão o comportamento do sistema de produção. O modelo foi capaz de identificar estratégias de produção ótimas que resultaram em taxas de produção mais altas e custos operacionais reduzidos. Além disso, forneceram insights valiosos sobre o desempenho do sistema de produção, destacando áreas para melhoria e potenciais pontos de falha.

Pesquisas futuras nessa área podem se concentrar no desenvolvimento de modelos mais sofisticados que incorporem fontes adicionais de dados e técnicas avançadas de análise, bem como explorar os benefícios potenciais da otimização e controle em tempo real.

Já na segunda contribuição investigamos diversos métodos de modelagem para compreender as interações entre a broca e a rocha durante a perfuração. Modelos black box, como ARX e NARX, foram avaliados, cada um apresentando forças e limitações distintas. Foram incorporadas metodologias mais complexas do que as convencionais, como o uso de modelos ARX e NARX, juntamente com um modelo híbrido grey box.

O estudo revelou que os modelos lineares (ARX) superaram o modelo não linear (NARX) em termos de desempenho. Embora o ARX tenha demonstrado um desempenho significativo no cenário estudado, o modelo NARX apresentou resultados mais detalhados, especialmente em previsões de múltiplos passos. Ademais, a integração de um modelo grey box, que combinou princípios baseados em física com observações empíricas, mitigou as limitações inerentes aos modelos black box.

Este estudo destaca a importância de integrar abordagens de modelagem diversas e aproveitar o conhecimento prévio para previsões precisas na dinâmica da sonda de perfuração, abrindo caminho para avanços nas operações de perfuração.

Trabalhos futuros devem se concentrar em aumentar a complexidade do modelo incorporando graus adicionais de liberdade, possibilitando uma acomodação mais abrangente da dinâmica de interação entre a broca e a rocha, o que pode aprimorar significativamente os resultados da modelagem e a precisão preditiva.

Referências bibliográficas

AGGOUN, L.; CHETOUANI, Y. Fault detection strategy combining narimax model and bhattacharyya distance for process monitoring. **Journal of the Franklin Institute**, v. 358, n. 3, p. 2212–2228, 2021. ISSN 0016-0032.

AGHITO, M.; BJØRKEVOLL, K. S. Hybrid Approach for Drilling Automation. In: . [S.l.: s.n.], 2020. (SPE Norway Subsurface Conference, Day 2 Tue, November 03, 2020), p. D021S007R002.

AGUIRRE, L. A. **Introdução à Identificação de Sistemas: Técnicas Lineares e Não-Lineares aplicadas a Sistemas Reais**. 3. ed. [S.l.]: Editora UFMG, 2007.

ALKARAGOOLEE, M. Y.; BRYANT, D. Investigation into the effect of friction decay factor on the modelling and attenuation of stick-slip vibrations of oilwell drilling systems. **Petroleum**, v. 8, n. 3, p. 344–351, 2022. ISSN 2405-6561.

ANDERSSON, J. A. E. et al. CasADi – A software framework for nonlinear optimization and optimal control. **Mathematical Programming Computation**, Springer, v. 11, n. 1, p. 1–36, 2019.

BAHALOO, S.; MEHRIZADEH, M.; NAJAFI-MARGHMALEKI, A. Review of application of artificial intelligence techniques in petroleum operations. **Petroleum Research**, v. 8, n. 2, p. 167–182, 2023. ISSN 2096-2495.

BAYLISS, M. T.; PANCHAL, N.; WHIDBORNE, J. Rotary steerable directional drilling stick/slip mitigation control. **IFAC Proceedings Volumes**, v. 45, n. 8, p. 66–71, 2012. ISSN 1474-6670. 1st IFAC Workshop on Automatic Control in Offshore Oil and Gas Production.

BILLINGS, S. A. **Nonlinear system identification: NARMAX methods in the time, frequency, and spatio-temporal domains**. [S.l.]: John Wiley & Sons, 2013.

BISHOP, J. M. History and philosophy of neural networks. **Computational Intelligence**, v. 1, p. 400, February 2015.

BO, L.; JIANNAN, G.; XIANGDONG, X. The digital twin of oil and gas pipeline system. **IFAC-PapersOnLine**, v. 53, n. 5, p. 710–714, 2020. ISSN 2405-8963. 3rd IFAC Workshop on Cyber-Physical & Human Systems CPHS 2020.

CARPENTER, C. Optimization With Real-Time Monitoring Results in Enhanced Drilling Performance. **Journal of Petroleum Technology**, v. 73, n. 12, p. 51–52, 12 2021. ISSN 0149-2136.

CARPENTER, C. Machine-Learning and Physics-Based Models Compared in Downhole Pressure Prediction in Deepwater Reservoirs. **Journal of Petroleum Technology**, v. 74, n. 08, p. 83–85, 08 2022. ISSN 0149-2136.

- CHEN, S. et al. Identification and Mitigation of Friction- and Cutting-Action-Induced Stick/Slip Vibrations with PDC Bits. **SPE Drilling & Completion**, v. 35, n. 04, p. 576–587, 12 2020. ISSN 1064-6671.
- CHEN, X. et al. A real-time drilling parameters optimization method for offshore large-scale cluster extended reach drilling based on intelligent optimization algorithm and machine learning. **Ocean Engineering**, v. 291, p. 116375, 2024. ISSN 0029-8018.
- CINELLI, L. P. et al. Automatic event identification and extraction from daily drilling reports using an expert system and artificial intelligence. **Journal of Petroleum Science and Engineering**, v. 205, p. 108939, 2021. ISSN 0920-4105.
- COPPIN, B. **Artificial Intelligence Illuminated**. 1st. ed. [S.l.]: Jones and Bartlett Publishers, 2004. ISBN 9780763732301.
- DU, J. et al. A deep learning-based approach for predicting oil production: A case study in the united states. **Energy**, v. 288, p. 129688, 2024. ISSN 0360-5442.
- EQUINOR, E. Volve data village. **Equinor Data Portal Beta**, 2018.
- EVSEENKOV, A. S. et al. Short-Term Forecasting of Well Production Based on a Hybrid Probabilistic Approach. In: . [S.l.: s.n.], 2021. (SPE Russian Petroleum Technology Conference, Day 2 Wed, October 13, 2021), p. D021S006R005.
- FURTUNA, R.; CURTEANU, S.; CAZACU, M. Optimization methodology applied to feedforward artificial neural network parameters. **International Journal of Quantum Chemistry**, Iasi, Romênia, v. 111, n. 3, p. 539–553, dezembro 2009.
- GUILHERME, I. R. et al. Petroleum well drilling monitoring through cutting image analysis and artificial intelligence techniques. **Engineering Applications of Artificial Intelligence**, v. 24, n. 1, p. 201–207, 2011. ISSN 0952-1976.
- HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2. ed. [S.l.]: Bookman, 1999.
- HE, J. et al. Downhole Pressure Prediction for Deepwater Gas Reservoirs Using Physics-Based and Machine Learning Models. **SPE Journal**, v. 28, n. 01, p. 371–380, 02 2023. ISSN 1086-055X.
- HEGDE, C.; GRAY, K. Evaluation of coupled machine learning models for drilling optimization. **Journal of Natural Gas Science and Engineering**, v. 56, p. 397–407, 2018. ISSN 1875-5100.
- HEGDE, C.; MILLWATER, H.; GRAY, K. Classification of drilling stick slip severity using machine learning. **Journal of Petroleum Science and Engineering**, v. 179, p. 1023–1036, 2019. ISSN 0920-4105.
- HEIDARI, E. et al. Prediction of the droplet spreading dynamics on a solid substrate at irregular sampling intervals: Nonlinear auto-regressive exogenous artificial neural network approach (narx-ann). **Chemical Engineering Research and Design**, v. 156, p. 263–272, 2020. ISSN 0263-8762.

HONG, L.; GIRSANG, I. P.; DHUPIA, J. S. Identification and control of stick-slip vibrations using kalman estimator in oil-well drill strings. **Journal of Petroleum Science and Engineering**, v. 140, p. 119–127, 2016. ISSN 0920-4105.

JUNIOR, W. R. L. et al. Sysidentpy: A python package for system identification using narx models. **Journal of Open Source Software**, The Open Journal, v. 5, n. 54, p. 2384, 2020.

KANEKO, T. et al. Hybrid model of a physics-based model and machine learning for real-time estimation of unmeasurable parts: Mapping from measurable to unmeasurable variables. **Ocean Engineering**, v. 261, p. 112123, 2022. ISSN 0029-8018.

KOROTEEV, D.; TEKIC, Z. Artificial intelligence in oil and gas upstream: Trends, challenges, and scenarios for the future. **Energy and AI**, v. 3, p. 100041, 2021. ISSN 2666-5468.

KUMAR, P. et al. Grey-box model and neural network disturbance predictor identification for economic mpc in building energy systems. **Energy and Buildings**, v. 286, p. 112936, 2023. ISSN 0378-7788.

LEI, H. et al. Hybrid method based on particle filter and NARX for real-time flow rate estimation in multi-product pipelines. **Journal of Process Control**, v. 88, p. 19–31, 2020.

LI, Y.; SUN, R.; HORNE, R. Deep Learning for Well Data History Analysis. **OnePetro**, Day 1 Mon, September 30, 2019, 09 2019. D011S008R002.

LI, Y. et al. Pattern recognition of stick-slip vibration in combined signals of drillstring vibration. **Measurement**, v. 204, p. 112034, 2022. ISSN 0263-2241.

LJUNG, L. **System Identification: Theory for the User**. [S.l.]: Prentice Hall, 1999.

LU, C. et al. Shale oil production prediction and fracturing optimization based on machine learning. **Journal of Petroleum Science and Engineering**, v. 217, p. 110900, 2022. ISSN 0920-4105.

MathWorks. **Design Time Series NARX Feedback Neural Networks**. acessado em 2024. <<https://www.mathworks.com/help/deeplearning/ug/design-time-series-narx-feedback-neural-networks.html>>.

MEDEIROS, L. F. de. **Inteligência Artificial Aplicada: Uma Abordagem Introductória**. 1st. ed. Curitiba: Intersaberes, 2018.

MUSTAPA, R. F. et al. Quantification of energy savings from an awareness program using narx-ann in an educational building. **Energy and Buildings**, v. 215, p. 109899, 2020. ISSN 0378-7788.

NAUTIYAL, A.; MISHRA, A. K. Machine learning application in enhancing drilling performance. **Procedia Computer Science**, v. 218, p. 877–886, 2023. ISSN 1877-0509. International Conference on Machine Learning and Data Engineering.

NELLES, O. **Nonlinear System Identification: From Classical Approaches to Neural Networks, Fuzzy Models, and Gaussian Processes**. 2nd. ed. [S.l.]: Springer, 2021.

NG, C. S. W.; Jahanbani Ghahfarokhi, A.; Nait Amar, M. Well production forecast in volatile field: Application of rigorous machine learning techniques and metaheuristic algorithm. **Journal of Petroleum Science and Engineering**, v. 208, p. 109468, 2022. ISSN 0920-4105.

ONALO, D. et al. Dynamic data driven sonic well log model for formation evaluation. **Journal of Petroleum Science and Engineering**, v. 175, p. 1049–1062, 2019. ISSN 0920-4105.

OSAROGIAGBON, A. U. et al. Gamma ray log generation from drilling parameters using deep learning. **Journal of Petroleum Science and Engineering**, v. 195, p. 107906, 2020. ISSN 0920-4105.

OYEDERE, M.; GRAY, K. Rop and tob optimization using machine learning classification algorithms. **Journal of Natural Gas Science and Engineering**, v. 77, p. 103230, 2020. ISSN 1875-5100.

PAN, S. et al. Oil well production prediction based on cnn-lstm model with self-attention mechanism. **Energy**, v. 284, p. 128701, 2023. ISSN 0360-5442.

PEDREGOSA, F. et al. Scikit-learn: Machine learning in python. **Journal of machine learning research**, v. 12, n. Oct, p. 2825–2830, 2011.

PINTELON, R.; SCHOUKENS, J. **System Identification: A Frequency Domain Approach**. [S.l.]: Wiley-IEEE Press, 2012.

PIRES, I.; AYALA, H. V. H.; WEBER, H. I. Nonlinear ensemble gray and black-box system identification of friction induced vibrations in slender rotating structures. **Mechanical Systems and Signal Processing**, v. 186, p. 109815, 2023. ISSN 0888-3270.

PREZELJ, J. et al. Identification of different manifestations of nonlinear stick–slip phenomena during creep groan braking noise by using the unsupervised learning algorithms k-means and self-organizing map. **Mechanical Systems and Signal Processing**, v. 166, p. 108349, 2022. ISSN 0888-3270.

QUANTRILLE, T.; LIU, Y. Overview of knowledge-based applications in chemical engineering. In: **Artificial Intelligence in Chemical Engineering**. [S.l.]: Academic Press, 1991.

RITTO, T. G.; AGUIAR, R. R.; HBAIEB, S. Validation of a drill string dynamical model and torsional stability. **Meccanica**, v. 52, p. 2959, 2017. ISSN 1572-9648.

ROCHA, L. A. S.; ANDRADE, R. A.; ROCHA, D. **Perfuração Direcional**. 2. ed. ed. Rio de Janeiro: Interciência, 2008. 323 p. ISBN 9788571931862.

SCHAIBLE, B.; XIE, H.; LEE, Y.-C. Fuzzy logic models for ranking process effects. **IEEE Transactions on Fuzzy Systems**, IEEE, v. 5, n. 4, p. 545–556, 1997.

SHETH, P. et al. A Hybrid Physics-Based and Machine-Learning Approach for Stick/Slip Prediction. In: . [S.l.: s.n.], 2022. (SPE/IADC Drilling Conference and Exhibition, Day 2 Wed, March 09, 2022), p. D022S005R001.

SHETH, P. et al. Real-Time Gamma Ray Log Generation from Drilling Parameters of Offset Wells Using Physics-Informed Machine Learning. **SPE Journal**, v. 29, n. 03, p. 1350–1360, 03 2024. ISSN 1086-055X.

SIRCAR, A. et al. Application of machine learning and artificial intelligence in oil and gas industry. **Petroleum Research**, v. 6, n. 4, p. 379–391, 2021. ISSN 2096-2495.

SJÖBERG, J. et al. Nonlinear black-box modeling in system identification: a unified overview. **Automatica**, v. 31, n. 12, p. 1691–1724, 1995. ISSN 0005-1098. Trends in System Identification.

SOLANKI, P. et al. Artificial intelligence: New age of transformation in petroleum upstream. **Petroleum Research**, v. 7, n. 1, p. 106–114, 2022. ISSN 2096-2495.

SRIVASTAVA, S. et al. Impact of data quality on supervised machine learning: Case study on drilling vibrations. **Journal of Petroleum Science and Engineering**, v. 219, p. 111058, 2022. ISSN 0920-4105.

TIAN, C.; HORNE, R. N. Recurrent Neural Networks for Permanent Downhole Gauge Data Analysis. **OnePetro**, Day 1 Mon, October 09, 2017, 10 2017. D011S008R007.

TUTTLE, J. F. et al. A systematic comparison of machine learning methods for modeling of dynamic processes applied to combustion emission rate modeling. **Applied Energy**, v. 292, p. 116886, 2021. ISSN 0306-2619.

VOGEL, S. K.; CREEGAN, A. P. Case study for real time stick/slip mitigation to improve drilling performance. In: . [S.l.: s.n.], 2016. v. 2016-January.

VRABIE, I. et al. Digital Twin for Downhole Pressure Gauges: Model and Field Case Study. In: . [S.l.: s.n.], 2020. (SPE Russian Petroleum Technology Conference, Day 2 Tue, October 27, 2020), p. D023S012R002.

VROMEN, T. et al. Robust output-feedback control to eliminate stick-slip oscillations in drill-string systems. **IFAC-PapersOnLine**, v. 48, n. 6, p. 266–271, 2015. ISSN 2405-8963. 2nd IFAC Workshop on Automatic Control in Offshore Oil and Gas Production OOGP 2015.

WANG, F. et al. Field Application of Deep Learning for Flow Rate Prediction with Downhole Temperature and Pressure. In: . [S.l.: s.n.], 2021. (IPTC International Petroleum Technology Conference, Day 1 Tue, March 23, 2021), p. D012S045R068.

WEI, W. et al. An analysis of toe-to-heel air injection for heavy oil production using machine learning. **Journal of Petroleum Science and Engineering**, v. 197, p. 108109, 2021. ISSN 0920-4105.

WERNECK, R. de O. et al. Data-driven deep-learning forecasting for oil production and pressure. **Journal of Petroleum Science and Engineering**, v. 210, p. 109937, 2022. ISSN 0920-4105.

ZHENG, H. et al. Knowledge-Guided Machine Learning Method for Downhole Gauge Record Prediction in Deep Water Gas Field. In: . [S.l.: s.n.], 2024. (Offshore Technology Conference Asia, Day 3 Thu, February 29, 2024), p. D031S020R004.