



RECONSTRUÇÃO DE DIAGRAMAS DE BIFURCAÇÃO PARA SISTEMAS DE PRODUÇÃO DE PETRÓLEO UTILIZANDO REDES NEURONAIS

Deris Eduardo Spina

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

Orientadores: José Carlos Costa da Silva Pinto
Maurício Bezerra de Souza Jr.

Rio de Janeiro
Fevereiro de 2023

RECONSTRUÇÃO DE DIAGRAMAS DE BIFURCAÇÃO PARA SISTEMAS DE
PRODUÇÃO DE PETRÓLEO UTILIZANDO REDES NEURONAIIS

Deris Eduardo Spina

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

Examinada por:

Prof. José Carlos Costa da Silva Pinto, DSc.

Prof. Maurício Bezerra de Souza Jr., DSc.

Prof. Flávio Vasconcelos da Silva, DSc.

Dr. Fábio César Diehl, DSc.

RIO DE JANEIRO, RJ – BRASIL

FEVEREIRO DE 2023

Spina, Deris Eduardo

Reconstrução de diagramas de bifurcação para sistemas de produção de petróleo utilizando redes neuronais/Deris Eduardo Spina – Rio de Janeiro: UFRJ/COPPE, 2023.

XVII, 93 p.: il.; 29,7cm.

Orientadores: José Carlos Costa da Silva Pinto

Maurício Bezerra de Souza Júnior

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia Química, 2020.

Referências Bibliográficas: p. 76 – 85.

1. Diagramas de Bifurcação. 2. Redes Neuronais. I. Costa da Silva Pinto, José Carlos *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Química. III. Título.

Agradecimentos

Agradeço aos meus pais, por todo o esforço que fizeram para que eu pudesse estudar, assim como por todo o carinho e apoio que me dão, mesmo a distância. Agradeço a toda minha família: meus irmãos, avós, tios e primos que, de uma forma ou outra, contribuíram para que eu me tornasse quem eu sou. Agradeço especialmente à minha avó, Nely, por seus cuidados e carinhos e aos meus irmãos Mica, Fiore e Pierino.

Agradeço à minha companheira, Juliana, por todo o amor e apoio diário em tudo o que eu faço, pela sua ajuda na correção e pelas conversas, series e saídas para relaxar após um dia cansativo.

Agradeço ao meu orientador José Carlos Pinto pelos ensinamentos, orientação e pela sua visão alegre e otimista frente aos desafios. Agraço também ao meu co-orientador, Maurício, pelas suas valiosas recomendações e revisões para o presente trabalho.

Agradeço a todo o pessoal do Grupo de Monitoramento de Processos: Tiago, Luiz Felipe, Jesus, Nayher, Giovani, Rafael, Diego, Carol, Thainá, Afrânio, Wall, Juliana pela companhia remota e presencial, assim como pelas recomendações e discussões que enriqueceram este trabalho.

Agradeço ao CNPq e à PETROBRAS pela contribuição financeira para que esse trabalho fosse possível.

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

RECONSTRUÇÃO DE DIAGRAMAS DE BIFURCAÇÃO PARA SISTEMAS DE PRODUÇÃO DE PETRÓLEO UTILIZANDO REDES NEURONAIS

Deris Eduardo Spina

Fevereiro/2023

Orientadores: José Carlos Costa da Silva Pinto

Maurício Bezerra de Souza Jr.

Programa: Engenharia Química

Uma das dificuldades encontradas para estabilizar a produção em poços de petróleo *offshore* é a ocorrência de golfadas (*slugging*), oscilações permanentes tanto na pressão quanto na vazão do sistema devido a instabilidades no escoamento multifásico. A principal ação de controle para estabilizar o sistema é a redução da abertura da válvula choke de produção, o que também reduz a vazão de produção. Portanto, existe um grande interesse em compreender os efeitos dessa válvula na dinâmica do sistema de produção, que pode ser modelada como uma bifurcação de Hopf e apresentada por meio de um diagrama de bifurcação. Nesse contexto, as redes neurais surgem com uma boa alternativa para reconstruir diagramas de bifurcação a partir de dados históricos, devido à capacidade de reconhecer padrões não-lineares. Portanto, nesse trabalho foram utilizadas redes neurais convencionais e duas redes recorrentes: Long Short Term Memory (LSTM) e LSTM Encoder-Decoder (LSTM ED) para um sistema simulado e um sistema real, com o intuito de

reconstruir os diagramas de bifurcação. As redes LSTM e LSTM ED foram capazes de construir diagramas de bifurcação adequados para determinadas pressões do sistema, apresentando bifurcações de Hopf no intervalo esperado e mostrando o comportamento dinâmico adequado para valores baixos e moderados de abertura da válvula choke. Para otimizar os hiperparâmetros das redes, foi proposta uma função objetivo original que, além do erro de predição, considera o tipo de soluções obtidas no diagrama de bifurcação.

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

BIFURCATION DIAGRAM RECONSTRUCTION FOR OIL PRODUCTION SYSTEMS USING NEURAL NETWORKS

Deris Eduardo Spina

February/2023

Advisors: José Carlos Costa da Silva Pinto
Maurício Bezerra de Souza Jr.

Department: Chemical Engineering

One of the challenges for offshore well production stabilization is the surging of slugging, permanent oscillations on the pressure and flow rate of the production system due to instabilities of the multiphase flow. The main control action to stabilize the system is to reduce the opening of the production choke valve, which causes a reduction on the production flow rate. For this reason, it is relevant to understand the effects of the choke valve opening on the dynamic behavior of the production systems, which can be modeled as a Hopf bifurcation, and they can be represented using a bifurcation diagram. In this context, neural networks emerge as a good alternative to reconstruct bifurcation diagrams from historical data, due to their capacity to recognize non-linear patterns. Therefore, in the present work, a conventional neural network and two recurrent neural networks: *Long Short Term Memory* (LSTM) and *LSTM Encoder-Decoder* (LSTM ED) were implemented for a simulated and a real system, with the objective of reconstructing their bifurcation diagrams. The LSTM and LSTM ED networks were able to construct adequate bifurcation diagrams for some system pressures, presenting the Hopf bifurcations at the expected interval and showing correctly the

long-term dynamic behavior for low and moderate choke valve openings. To optimize the neural networks hyperparameters, an original loss function has been proposed considering, besides the prediction error, the type of solutions obtained in the bifurcation diagram.

Sumário

AGRADECIMENTOS	IV
LISTA DE FIGURAS	XI
LISTA DE TABELAS	XIV
LISTA DE SÍMBOLOS	XV
LISTA DE ABREVIACÕES	XVII
INTRODUÇÃO	1
1.1. Motivação	1
1.2. Objetivos perseguidos	3
1.3. Estrutura da dissertação	3
REVISÃO BIBLIOGRÁFICA	5
2.1. Estabilidade de sistemas de produção de petróleo <i>offshore</i>	5
2.2. Análise de sistemas dinâmicos não-lineares	8
2.3. Reconstrução de diagramas de bifurcação a partir de séries temporais	12
2.4. Modelos fenomenológicos	13
2.5. Modelos baseados em dados	14
2.6. Aplicação de redes neurais para a produção de petróleo <i>offshore</i>	19
2.7. Comentários finais	20
METODOLOGIA	22
3.1. Metodologia para a reconstrução de diagramas de bifurcação	22
3.2. Implementação e recursos computacionais.....	28
3.3. Aplicação aos dados simulados com o modelo FOWM	28
3.4. Aplicação a um sistema de produção real.....	32
APLICAÇÃO AOS DADOS SIMULADOS	38
4.1. Análise exploratória.....	38
4.2. Seleção e treinamento das redes	46
4.3. Predições para os dados de validação	47
4.4. Iterações a partir das redes.....	48
4.5. Diagramas de bifurcação.....	49
APLICAÇÃO AOS DADOS REAIS – RESULTADOS E DISCUSSÕES	56
5.1. Análise Exploratória	56

5.2. Seleção de períodos.....	59
5.3. Treinamento das redes neuronais.....	62
5.4. Diagramas de bifurcação.....	63
5.5. Análise de sensibilidade.....	69
5.6. Otimização de hiperparâmetros	71
CONCLUSÕES E PERSPECTIVAS FUTURAS.....	75
REFERÊNCIAS.....	77
ANEXO A: MODELO FOWM.....	87
Parâmetros do sistema de produção	91

Lista de Figuras

Figura 1 - Diagrama de bifurcação para a variável x_1 da equação normal de Hopf.	11
Figura 2 - Diagrama de bifurcação representativo para um sistema de produção de petróleo offshore com problemas de golfadas	12
Figura 3 - Esquema de uma unidade de rede LSTM	18
Figura 4 - Representação esquemática de uma rede LSTM Encoder-Decoder	19
Figura 5 - Exemplos de iterações a partir de uma rede neural para dois valores diferentes do parâmetro e a determinação dos valores máximos e mínimos para o diagrama de bifurcação. Na imagem (a) o sistema atinge um estado estacionário, enquanto na imagem (b) o sistema atinge oscilações permanentes.....	27
Figura 6 - Exemplo da comparação de um diagrama de bifurcação reconstruído com o diagrama de bifurcação real.....	28
Figura 7 - Variação da Abertura da válvula Choke no tempo para os dados de treino simulados com o modelo FOWM.....	38
Figura 8 - Série temporal da massa de gás no anular para os dados de treino (A) e teste (B) simulados com o modelo FOWM.....	39
Figura 9 - Série temporal da pressão na PDG para os dados de treino (A) e teste (B) simulados com o modelo FOWM.....	39
Figura 10 - Série temporal da pressão de topo (Ptop) para os dados de treino (A) e teste (B) simulados com o modelo FOWM.....	40
Figura 11 - Histograma e <i>boxplots</i> para a massa de gás no anular (mga) dos dados simulados.	41
Figura 12 - Histograma e <i>boxplots</i> para a pressão na PDG dos dados simulados.....	41
Figura 13 - Histograma e <i>boxplots</i> para a pressão na Ptop dos dados simulados.....	41
Figura 14 - Matriz de correlação Spearman para as variáveis de estado e as pressões PDG e Ptop dos dados de treino.	42
Figura 15 - Gráficos de autocorrelação para as variáveis PDG e Ptop dos dados de treino simulados com o modelo FOWM.....	43
Figura 16 - Gráfico de dispersão da massa de gás no anular vs abertura da válvula choke para os dados de treino simulados com o modelo FOWM.....	44

Figura 17 - Gráfico de dispersão da pressão na PDG vs abertura da válvula choke para os dados de treino simulados com o modelo FOWM.	45
Figura 18 - Gráfico de dispersão da pressão Ptop vs abertura da válvula choke para os dados de treino simulados com o modelo FOWM.....	45
Figura 19 - Iterações a partir de uma rede LSTM ED com 100 neurônios utilizando três condições iniciais diferentes para a variável PDG.	49
Figura 20 - Iterações a partir de rede LSTM ED com 20 neurônios utilizando três condições iniciais diferentes para a variável PDG.	49
Figura 21 - Diagrama de bifurcação para <i>mga</i> reconstruído com rede ANN convencional	50
Figura 22 - Diagrama de bifurcação para <i>mga</i> reconstruído com rede LSTM.....	50
Figura 23 - Diagrama de bifurcação para <i>mga</i> reconstruído com rede LSTM ED	50
Figura 24 - Diagrama de bifurcação para a pressão na PDG reconstruído com rede ANN convencional.....	51
Figura 25 - Diagrama de bifurcação para a pressão na PDG reconstruído com rede LSTM	52
Figura 26 - Diagrama de bifurcação para a pressão na PDG reconstruído com rede LSTM ED	52
Figura 27 - Diagrama de bifurcação para a pressão Ptop reconstruído com rede ANN convencional.....	53
Figura 28 - Diagrama de bifurcação para a pressão Ptop reconstruído com rede LSTM.....	53
Figura 29 - Diagrama de bifurcação para a pressão Ptop reconstruído com rede LSTM ED	54
Figura 30 - Oscilações da pressão Ptop para uma abertura da válvula choke de 29%. Na figura (a) é mostrada a escala completa e na figura (b) são mostrados os valores de pressão entre 10,2 e 10,7 10 ⁵ Pa.	55
Figura 31 - Variação da abertura da válvula Choke no tempo para o sistema de produção real analisado.	56
Figura 32 - Variação da abertura da pressão no topo do <i>riser</i> (Ptop) no tempo para o sistema de produção real.....	56
Figura 33 - Variação da abertura da pressão na PDG no tempo para o sistema de produção real analisado.	57
Figura 34 - Histogramas e <i>boxplots</i> das variáveis Ptop e PDG para os dados reais.....	57

Figura 35 - Diagramas de dispersão (a) Ptop vs Choke (b) PDG vs Choke para os dados reais.	58
Figura 36 - Matriz de correlação Spearman para os dados reais	59
Figura 37 - Variação na pressão Ptop para (a) o período I, (b) período II e (c) período III .	60
Figura 38 - Histogramas e <i>boxplots</i> da pressão Ptop para os três períodos analisados.	61
Figura 39 - Histogramas e <i>boxplots</i> para a pressão na PDG nos três períodos analisados...	61
Figura 40 - Gráfico de dispersão de PDG vs Choke para os três períodos de treino utilizados.	62
Figura 41 - Gráfico de dispersão de Ptop vs Choke para os três períodos de treino utilizados.	62
Figura 42 - Diagramas de bifurcação para a Ptop com redes LSTM ED e LSTM treinadas com os três períodos analisados.....	64
Figura 43 - Iterações a partir da rede LSTM ED para uma abertura da válvula choke de 46%	65
Figura 44 - Dados reais de Ptop para uma abertura da válvula choke de 46.5%	66
Figura 45 - Diagramas de bifurcação para a pressão na PDG com redes LSTM ED e LSTM treinadas com os três períodos analisados	67
Figura 46 - Variação no diagrama de bifurcação ao alterar o número de defasagens no tempo dos dados de entrada para uma rede LSTM ED de 100 neurônios.....	70
Figura 47 - Variação no diagrama de bifurcação ao mudar o número de neurônios por camada LSTM para uma rede LSTM ED com 6 lags na entrada.	71
Figura 48 - Diagrama de bifurcação obtido a partir de uma rede LSTM-ED com hiperparâmetros determinados na otimização I.....	73
Figura 49 - Diagrama de bifurcação obtido a partir de uma rede LSTM-ED com hiperparâmetros determinados na otimização II.....	73
Figura 50 - Diagrama de bifurcação obtido a partir de uma rede LSTM-ED com hiperparâmetros determinados na otimização III	74

Lista de Tabelas

Tabela 1 - Variáveis geradas pela simulação do modelo FOWM.	29
Tabela 2 - Faixa de valores das variáveis de estado para os possíveis pontos iniciais das simulações.	30
Tabela 3 - Principais hiperparâmetros das redes neuronais utilizadas	31
Tabela 4 - Valores possíveis dos hiperparâmetros das redes LSTM-ED a otimizar.	36
Tabela 5 - Métricas para as predições de três variáveis nos dados de teste utilizando diferentes redes neuronais.	47
Tabela 6 - Comparação do MAE para as predições das redes LSTM e LSTM-ED nos dados de validação para os três períodos analisados.	63
Tabela 7 - Hiperparâmetros obtidos para a rede LSTM-ED a partir das três otimizações realizadas com a biblioteca <i>Optuna</i>	72
Tabela A-1 Descrição das variáveis de estado para o modelo FOWM.	88
Tabela A-2. Pressões e densidades utilizadas no modelo FOWM.	89
Tabela A-3. Frações mássicas e variáveis relacionadas à geometria do sistema utilizadas no modelo FOWM.	91
Tabela A-4. Parâmetros do sistema de produção real (poço A) utilizados na simulação pelo modelo FOWM.	92
Tabela A-5. Parâmetros estimados a partir dos dados reais do poço A para a simulação com o modelo FOWM.	93

Lista de Símbolos

b_c	Vetor de vieses (<i>bias</i>) do <i>input modulation gate</i>
b_i	Vetor de vieses (<i>bias</i>) do <i>input gate</i>
b_o	Vetor de vieses (<i>bias</i>) do <i>output gate</i>
b_t	Vetor de vieses (<i>bias</i>) do <i>forget gate</i>
c_t	Valor de saída do neurônio LSTM
\tilde{c}_t	Valor de saída do <i>input modulation gate</i>
Choke	Abertura da válvula choke
ck_A	Limite inferior do intervalo em que se espera encontrar o ponto de bifurcação de Hopf
ck_B	Limite superior do intervalo em que se espera encontrar o ponto de bifurcação de Hopf
f_t	Valor de saída do <i>forget gate</i>
h_{t-1}	Estado oculto no tempo t-1
i_t	Valor de saída do <i>input gate</i>
m_{ga}	Massa de gás no anular
m_{gb}	Massa da bolha de gás na linha de produção
m_{gr}	Massa de gás na linha de produção e o <i>riser</i>
m_{gt}	Massa de gás no tubo de produção
m_{lr}	Massa de líquido na linha de produção e o <i>riser</i>
m_{lt}	Massa de líquido no tubo de produção
Med	Mediana
o_t	Valor de saída do <i>output gate</i>
P	Proporção de pontos do diagrama de bifurcação que apresentam um tipo de solução incorreto
P_{ai}	Pressão de injeção de gás anular
P_{eb}	Pressão da bolha de gás
P_r	Pressão do reservatório

P_s	Pressão no separador
P_{tb}	Pressão na base do tubo de produção
P_{tt}	Pressão de topo do tubo de produção
s	Desvio padrão de uma amostra
Tanh	Função tangente hiperbólica
var	Variância
V_{gt}	Volume de gás no tubo de produção
w	Peso para regular a importância do termo de penalização na função objetivo
W_c	Matriz de parâmetros do <i>input modulation gate</i>
W_f	Matriz de parâmetros do <i>forget gate</i>
W_{gc}	Vazão de <i>gas-Lift</i>
W_{gout}	Vazão de gás na saída da válvula choke
W_{lout}	Vazão de líquido na saída da válvula choke
W_o	Matriz de parâmetros do <i>output gate</i>
\bar{x}	Média de uma amostra
x_i^*	Valor normalizado
μ	Parâmetro de um sistema dinâmico
μ_{log}	Média logarítmica
σ	Função de ativação sigmoide
σ_{log}	Desvio padrão logarítmico

Lista de Abreviações

Adam	Algoritmo de estimativa de momento adaptável (<i>Adaptive Movement Estimation Algorithm</i>)
ANN	Rede neural artificial (<i>Artificial Neural Network</i>)
ANP	Agência Nacional do Petróleo, Gás Natural e Biocombustíveis
EDO	Equação diferencial ordinária
EDP	Equação diferencial parcial
EML	Máquina de Aprendizado Extremo (<i>Extreme Machine Learning</i>)
FOWM	<i>Fast-Offshore Well Model</i>
GRU	<i>Gate Recurrent Unit</i>
IQR	Varição interquartil (<i>Interquartile Range</i>)
LSTM	<i>Long-Short Term Memory</i>
LSTM ED	<i>Long-Short Term Memory Encoder-Decoder</i>
MAE	Erro absoluto médio (<i>Mean Absolute Error</i>)
MPC	Controle preditivo baseado em modelo
MSE	Erro quadrático médio (<i>Mean Squared Error</i>)
NMPC	Controle preditivo baseado em modelo não linear
PCA	Análise de componentes principais (<i>Principal Component Analysis</i>)
PDG	<i>Permanent Downhole Gauge</i>
PID	Controlador proporcional integral derivativo
PLN	Processamento de linguagem natural
Ptop	Pressão no topo do riser
RBF	Função de base radial (<i>Radial Basis Function</i>)
ReLU	Unidade linear rectificadora (<i>Rectified Linear Unit</i>)
RNN	Rede neural recorrente (<i>Recurrent Neural Network</i>)
SGD	Método do gradiente descendente estocástico (<i>Stochastic Gradient Descent</i>)
TPT	<i>Temperature-Pressure Tool</i>

Capítulo 1

Introdução

1.1. Motivação

A produção de petróleo a partir de poços *offshore* é de grande relevância para o Brasil. Segundo a Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP, 2021), 97.2% do petróleo e 81.7% do gás natural produzido no Brasil em setembro de 2021 tiveram origem em campos marítimos. No entanto, existem diversos fatores que podem afetar a produção nas plataformas *offshore*, devido aos grandes desafios técnicos, econômicos e de segurança. Por esse motivo, uma melhor compreensão do comportamento dinâmico do sistema de produção pode melhorar a segurança e otimizar a produção.

Em particular, o transporte dos fluidos desde os poços até as unidades de processamento apresenta uma grande complexidade para poços *offshore* em águas profundas e ultraprofundas devido às grandes distâncias que os fluidos devem percorrer, assim como a geometria do sistema. Uma das principais dificuldades enfrentadas é o problema de golfadas (*slugging*). Esse fenômeno consiste em um escoamento irregular do fluxo multifásico, onde são geradas de forma periódica bolhas de gás de dimensões próximas ao diâmetro do tubo, que separam longos blocos de líquido, o que leva a oscilações cíclicas permanentes tanto na pressão quanto na vazão do sistema de produção. Golfadas podem acontecer devido às irregularidades no solo oceânico e à inclinação do *riser*, assim como também pela falta de pressão no sistema de *gas-lift*. Este fenômeno reduz a produção, gera maior carga de fadiga nos equipamentos e instalações, encurta o tempo de vida dos equipamentos e, em casos de golfadas severas, pode levar à parada de produção (PEDERSEN *et al.*, 2015).

Para tentar reduzir o problema de golfadas, nas operações de produção *offshore* existem duas variáveis que podem ser manipuladas: a abertura da válvula choke de produção e a vazão de *gas-lift* (DIEHL *et al.*, 2018). Entretanto, a quantidade de gás disponível pode ser um limitante para aumentar a vazão de *gas-lift* do sistema, e, por esse motivo, o ajuste é feito normalmente variando a abertura da válvula choke. A válvula é mantida constante

durante a operação normal, mas na presença de golfadas severas, a abertura pode ser reduzida para tentar estabilizar o sistema.

De modo a automatizar a manipulação da válvula choke para o controle de golfadas, já foram propostas diversas estratégias na literatura de controle linear (DI MEGLIO, 2011, HAVRE, 2001, STORKAAS *et al.*, 2001) e controle não-linear (DIEHL *et al.*, 2018, DIEHL *et al.*, 2021, JAHANSHAHI e SKOGESTAD, 2017). As estratégias lineares geralmente estão limitadas a uma janela pequena de condições de operação (DI MEGLIO *et al.*, 2012), enquanto as estratégias não lineares normalmente demandam um conhecimento aprofundado do comportamento dinâmico do sistema de produção. Por esse motivo, é importante compreender a dinâmica do sistema, para assim poder estabelecer a relação entre a abertura da válvula e a presença de golfadas.

Matematicamente, essa relação pode ser modelada como o resultado de um sistema dinâmico com um parâmetro, dado pela abertura da válvula choke. Para que a mudança da abertura da válvula permita que o sistema possa atingir estados estacionários estáveis e também gerar ciclos limites, é normalmente necessário que o sistema apresente uma bifurcação de Hopf (STORKAAS *et al.*, 2002). Os pontos de equilíbrio e orbitas periódicas do sistema podem então ser representado com auxílio de um diagrama de bifurcação.

A construção desses diagramas não é trivial, pois normalmente são necessários testes no sistema de produção, que podem ter um alto custo, já que o sistema deve trabalhar em condições subótimas de produção por um prolongado período de tempo. A outra opção mais comum na literatura é a construção de diagramas de bifurcação a partir da continuação paramétrica de modelos fenomenológicos (STORKAAS *et al.*, 2002; JAHANSHAHI *et al.*, 2011, DIEHL *et al.*, 2017). No entanto, existe atualmente uma grande dificuldade para realizar o ajuste desse tipo de modelos aos poços reais. Por esse motivo, o uso de técnicas baseadas em dados pode constituir uma opção para reconstruir os diagramas de bifurcação a partir das medições históricas de sistemas reais (DIEHL *et al.*, 2021). Em particular, é possível utilizar redes neurais para prever o comportamento do sistema dinâmico (LU *et al.*, 2018). A partir dessas previsões, é possível também inferir os pontos de equilíbrio e ciclos limites do sistema e reconstruir o diagrama de bifurcação (CESTNIK e ABEL, 2019).

Nesse sentido, o presente trabalho analisou o uso de redes neurais para a reconstrução da dinâmica do sistema de produção de petróleo e sua relação com a abertura

da válvula. Com esse objetivo, foi feita a reconstrução de um diagrama de bifurcação para mostrar os pontos de equilíbrio estáveis e orbitas periódicas que podem ser alcançados pelo sistema. Em particular, pretende-se avaliar se as redes são capazes de evidenciar o valor da abertura da válvula para o qual o sistema deixa de exibir soluções estacionárias e passa a apresentar oscilações periódicas, denominado ponto de bifurcação de Hopf.

1.2. Objetivos perseguidos

- Predizer a ocorrência de golfadas na produção de petróleo *offshore* a partir de dados históricos por meio de modelos de *Machine Learning*;
- Estimar a localização do ponto de bifurcação de Hopf do sistema ao variar a abertura da válvula de produção;
- Analisar a relação entre o comportamento dinâmico real e o comportamento dos modelos de *Machine Learning* utilizados;
- Reconstruir o diagrama de bifurcação para um poço real a partir de dados históricos.

1.3. Estrutura da dissertação

O presente trabalho está estruturado em 5 capítulos. O Capítulo 1 apresentou uma breve introdução e contextualização do trabalho, assim como os principais objetivos a serem atingidos. O Capítulo 2 consiste na revisão bibliográfica e fundamentação teórica do trabalho. Esse capítulo inclui conceitos sobre a estabilidade da produção de petróleo *offshore*, a análise dinâmica de sistemas não-lineares e uma descrição do funcionamento das redes neuronais utilizadas. No Capítulo 3 é apresentada, de forma geral, a técnica utilizada para a reconstrução dos diagramas de bifurcação e as metodologias seguidas para aplicar essa técnica aos dados simulados e reais. O Capítulo 4 apresenta os resultados obtidos durante a aplicação da metodologia aos dados simulados, assim como uma discussão sobre estes resultados. De forma similar, o Capítulo 5 apresenta os resultados e discussões para a aplicação da metodologia aos dados reais. Finalmente, são apresentadas as conclusões e perspectivas futuras sobre o presente trabalho.

O presente trabalho foi desenvolvido integralmente no Grupo de Monitoramento de Processos do Laboratório de Modelagem, Simulação e Controle de Processos (LMSCP) do Programa de Engenharia Química (PEQ) do Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia (COPPE) da Universidade Federal do Rio de Janeiro

(UFRJ). O trabalho integrou parte de um projeto de pesquisas desenvolvido em conjunto com a PETROBRAS, a quem agradecemos pela colaboração técnica e financeira.

CAPÍTULO 2

Revisão bibliográfica

2.1. Estabilidade de sistemas de produção de petróleo *offshore*

A produção de petróleo em poços *offshore* de águas profundas e ultraprofundas apresenta uma alta complexidade técnica. Os poços instalados nessas regiões podem requerer mais de 10 km de tubulações para transportar o fluido desde o reservatório até a superfície (DIEHL *et al.*, 2019). A linha de produção é instalada no solo oceânico e um *riser* vertical é utilizado para elevar o fluido até a superfície. O fluido transportado contém óleo, gás e água, o que gera um fluxo multifásico. Além disso, é comum que várias linhas de produção sejam conectadas à mesma plataforma, para aproveitar a unidade de processamento.

Devido à irregularidade do solo oceânico, as tubulações apresentam diversas inclinações que favorecem o surgimento de instabilidades no escoamento multifásico. Isso pode levar ao acúmulo de líquido em certas regiões, bloqueando a passagem do gás. Como consequência, a pressão no gás aumenta até ele ser capaz de movimentar a coluna de líquido acumulado. Esse fenômeno é conhecido como golfadas (*slugging*) (EHINMOWO e CAO, 2016).

As golfadas acontecem de forma cíclica e podem produzir oscilações permanentes tanto na pressão quanto na vazão do sistema de produção. Quando as golfadas ocorrem na conexão entre a linha de produção e o *riser*, a amplitude das oscilações na pressão é elevada, produzindo golfadas severas. Como consequência, os sistemas de segurança podem ser acionados automaticamente para garantir a integridade dos equipamentos. Além disso, a instabilidade resulta em uma produção menor do que a esperada em uma operação estável (DIEHL *et al.*, 2018).

No regime de golfadas severas, o sistema pode operar em um ciclo limite, que pode ser descrito por quatro etapas (EHINMOWO e CAO, 2016):

- Devido à inclinação do *riser*, o líquido se acumula na base do *riser* e, como consequência, bloqueia a passagem do gás, gerando uma bolha de gás que fica comprimida nas seções da tubulação prévia ao *riser*.

- A quantidade de líquido aumenta, preenchendo quase totalmente o *riser* até que a pressão na bolha de gás fique maior que a pressão hidrostática da coluna de líquido no *riser*.
- Quando o gás atinge a pressão suficiente, ele movimenta todo o líquido da coluna até a bolha de gás sair totalmente do sistema.
- Após a saída do gás, o líquido restante volta a descer pelo *riser* e o ciclo se inicia novamente.

Por outro lado, conforme os poços de produção de petróleo atingem a sua etapa de maturidade, a produção começa a declinar devido à perda de pressão no reservatório. Com o intuito de recuperar essa pressão, água e/ou gás são normalmente injetados no reservatório, com o conseguinte aumento na produção de água. Isto dificulta o escoamento natural do fluido devido à formação de emulsões que aumentam a viscosidade. Por essa razão, são utilizados métodos de elevação artificial para manter a produção do poço (DIEHL *et al.*, 2019). O método de elevação artificial mais utilizado é conhecido como *gas-lift* e consiste na injeção de gás na base da coluna de produção, diminuindo a densidade da coluna de fluido. Nesse caso, o gás é injetado através do espaço anular formado entre a coluna de produção e o tubo de revestimento (*casing*).

Um problema associado ao uso de *gas-lift* é a possibilidade de gerar golfadas severas quando a injeção de gás é baixa ou a pressão da coluna é alta. Nesses casos, a pressão anular é menor que a pressão na coluna e, portanto, não há injeção de gás. O gás se acumula na região anular até a pressão ser suficiente para injetar o gás acumulado. Quando o gás é injetado, a pressão na coluna decresce rapidamente devido à redução da densidade do fluido. No entanto, quando a quantidade de gás diminui, a pressão anular decresce e a pressão na coluna aumenta até o escoamento de gás parar. Esse comportamento gera oscilações na pressão e vazão, ocasionando golfadas que podem ser severas.

2.1.1. Controle de golfadas

As diferentes estratégias utilizadas para reduzir ou eliminar as golfadas podem ser classificadas em duas categorias: métodos passivos e métodos ativos.

Os métodos passivos consistem na inclusão de equipamentos no sistema de produção durante o *design* do processo para evitar o surgimento das golfadas. Entre eles estão os *flow conditioners*, dispositivos utilizados para alterar o regime de escoamento do sistema, e os

slug catchers, que consistem em tanques ou tubulações colocados após o *riser* ou na superfície, com volume suficiente para conter o excesso de fluido produzido nas golfadas (PEDERSEN *et al.*, 2015). Esses sistemas são pouco comuns em plataformas *offshore* porque requerem uma grande área e peso para o sistema ser instalado, além de apresentarem um alto custo de manutenção (DIEHL *et al.*, 2021).

Os métodos ativos consistem na manipulação de atuadores para tornar possível a regulação do sistema. Essas manipulações podem ser feitas a critério dos operadores, ou podem ser automatizadas por meio de esquemas de controle *feedback* ou controle avançado. As duas alternativas tradicionais para controlar a produção quando surgem golfadas são a redução da abertura da válvula choke do sistema de produção ou o aumento da vazão de *gas-lift*, a depender da origem da golfada (DIEHL *et al.*, 2018). Regular a abertura da válvula geralmente é a forma usual de lidar com essas dificuldades, já que os operadores têm maior facilidade para estabelecer sua abertura. Nesse caso, normalmente existe um ponto crítico de abertura da válvula, abaixo do qual as oscilações não se sustentam no tempo e o sistema atinge um estado estacionário com uma pressão estável.

Entretanto, reduzir a abertura da válvula também traz como consequência uma diminuição da produção. Por esse motivo, é economicamente desejável que a abertura da válvula choke seja a máxima possível, desde que garanta a estabilidade do sistema. Para isso, é necessário conhecer o comportamento do sistema, de forma a identificar adequadamente o ponto crítico e compreender se poderão aparecer oscilações sustentadas no tempo.

Existem diversos estudos na literatura que visam automatizar a manipulação da válvula choke por meio de controladores *feedback* (DI MEGLIO, 2011; HAVRE, 2001; STORKAAS *et al.*, 2001). A maioria desses esquemas utiliza como variáveis controladas a pressão no fundo do poço, na região submersa do sistema de produção ou uma combinação dessas pressões com medições de vazão e pressão no topo. No entanto, devido às não linearidades do sistema, o uso dessas estratégias não é usualmente adequado para um intervalo amplo de condições de operação (DI MEGLIO *et al.*, 2012).

Por esse motivo, foram desenvolvidas algumas estratégias de controle avançado e controle não-linear. JAHANSHAHI e SKOGESTAD (2017) propuseram e compararam diferentes estratégias de controle linear e não-linear para a eliminação de oscilações sustentadas que caracterizam as golfadas. DIEHL *et al.* (2017) compararam os desempenhos

de um controlador proporcional integral derivativo (PID) com *gain-scheduling* e de um controlador preditivo baseado em modelo (MPC) linear. Em 2018, foi proposto também um controlador preditivo não linear baseado em modelo (NMPC) por DIEHL *et al.* (2018), utilizando tanto a variação na válvula choke quanto a vazão de *gas-lift* para eliminar as golfadas.

Para aplicar um controlador PID com *gain-scheduling* a um poço real, DIEHL *et al.* (2021) indicaram a necessidade de conhecer o comportamento do poço no estado estacionário para uma ampla faixa de operação. Com esse objetivo, implementaram uma metodologia para reconstruir a curva de equilíbrio do sistema a partir de dados histórico da operação real. Essa metodologia baseia-se na detecção do estado estacionário por meio do uso da inclinação de uma regressão linear para a remoção dos dados transientes.

Em geral, as técnicas de controle não-linear são muito promissoras para a estabilização da produção em poços de petróleo *offshore*, mas ainda apresentam vários desafios para a efetiva implementação. Um desses desafios é a necessidade de conhecer de forma mais aprofundada a dinâmica do sistema, assim como a falta de automatização para a extração desse conhecimento a partir das informações provenientes da operação. Por esse motivo, o presente trabalho visa a apresentar uma metodologia para a reconstrução de diagramas de bifurcação, os quais contêm a informação sobre o comportamento do sistema no equilíbrio, por meio de redes neurais. A automatização deste procedimento pode facilitar a implementação das estratégias de controle não-linear, além de simplificar futuros reajustes para adaptar o controlador ante mudanças no sistema de produção.

2.2. Análise de sistemas dinâmicos não-lineares

2.2.1. Sistemas dinâmicos

Um sistema dinâmico indica a evolução no tempo de um conjunto de variáveis de estado \mathbf{x} , as quais definem o estado de um sistema em um determinado instante (Savi, 2017). Ao considerar que existe um campo vetorial que altera o estado do sistema no tempo e depende tanto dos estados quanto de determinados parâmetros, $\boldsymbol{\mu}$, o sistema pode ser descrito como:

$$\dot{\mathbf{x}} = f(\mathbf{x}, \boldsymbol{\mu}) \quad (1)$$

Esse sistema dinâmico pode ser representado discretamente ao considerar um intervalo de tempo finito entre dois estados \mathbf{x}_{t-1} e \mathbf{x}_t , para os quais é possível criar um mapeamento tal que:

$$\mathbf{x}_t = F(\mathbf{x}_{t-1}, \boldsymbol{\mu}) \quad (2)$$

Como o campo vetorial tem caráter não-linear, o sistema pode apresentar diferentes tipos de soluções. Por exemplo, as variáveis de estado podem atingir um estado estacionário ou equilíbrio, no qual, após um transiente inicial, o sistema atinge um estado tal que $\mathbf{x}_t = F(\mathbf{x}_{t-1}, \boldsymbol{\mu}) = \mathbf{x}_{t-1}$. Esse equilíbrio pode ser localmente estável, se após uma pequena perturbação o sistema volta ao ponto de equilíbrio; ou localmente instável, se após uma perturbação as trajetórias se afastam do ponto de equilíbrio. Outro tipo de soluções são as oscilações periódicas ou ciclos limites, nas quais os estados se repetem a cada certo intervalo de tempo, determinado pelo período τ , de forma que $\mathbf{x}_t = \mathbf{x}_{t-\tau}$.

2.2.2. Estado de fases e trajetória

O estado de fases ou espaço de estados, é o espaço multidimensional formado por todas as diferentes posições que as variáveis de estado do sistema podem atingir. É possível que esse espaço apresente uma topologia particular, definida por suas características dinâmicas, que pode estar restrita a uma superfície (SAVI, 2017). Nesses casos, o espaço de estados pode ser considerado um *manifold*. Por outra parte, uma trajetória indica a evolução, a partir de um ponto inicial, de um sistema dinâmico no estado de fases.

2.2.3. Bifurcação de Hopf

Um sistema dinâmico não-linear pode apresentar diferentes tipos de soluções (estacionárias, oscilações periódicas, dentre outras) dependendo dos valores dos parâmetros do sistema. Por esse motivo, ao variar um parâmetro, μ , existe a possibilidade de gerar bifurcações, isto é, provocar mudanças qualitativas e quantitativas das soluções. Um tipo particular de bifurcações, denominadas bifurcações de Hopf, ocorre quando um ramo de soluções estacionárias passa a apresentar oscilações periódicas. O ponto (x_0, μ_0) onde ocorre

a bifurcação é denominado geralmente como Ponto de Bifurcação de Hopf. Existem três condições para que esse tipo de bifurcação ocorra em um ponto (x_0, μ_0) (MELO, PINTO, 2008).

1. $f(x_0, \mu_0) = 0$;
2. $\frac{\partial f}{\partial x} \Big|_{(x_0, \mu_0)}$ possui um único par de valores característicos puramente imaginários, $\lambda(\mu_0) = \pm \beta i$, não existindo qualquer outro valor característico com parte real igual a zero;
3. $\frac{dRe(\lambda(\mu_0))}{d\mu} \neq 0$.

2.2.4. Diagramas de bifurcação

Para representar as soluções estacionárias e periódicas, assim como a presença de bifurcações em um sistema dinâmico, é utilizado um diagrama de bifurcação. Este diagrama apresenta a variável x no eixo vertical e o parâmetro μ no eixo horizontal, onde os pontos (μ, x) são pontos de equilíbrio do sistema dinâmico (MELO, PINTO, 2008). As soluções estáveis são apresentadas com linhas contínuas, enquanto as soluções instáveis são apresentadas com linhas tracejadas. No caso de soluções periódicas, são apresentados unicamente os limites máximo e mínimo das oscilações. A modo de exemplo, na Figura 1 é apresentado o diagrama de bifurcação para o sistema dinâmico denominado forma normal de Hopf, determinado pelo sistema de Equações (3). A partir do gráfico, pode ser observado que a bifurcação de Hopf acontece para $\mu = 0$, com soluções estacionarias estáveis quando $\mu < 0$ e com um equilíbrio instável e soluções oscilatórias quando $\mu > 0$.

$$\begin{cases} \frac{dx_1}{dt} = -x_2 + x_1(\mu - x_1^2 - x_2^2) \\ \frac{dx_2}{dt} = x_1 + x_2(\mu - x_1^2 - x_2^2) \end{cases} \quad (3)$$

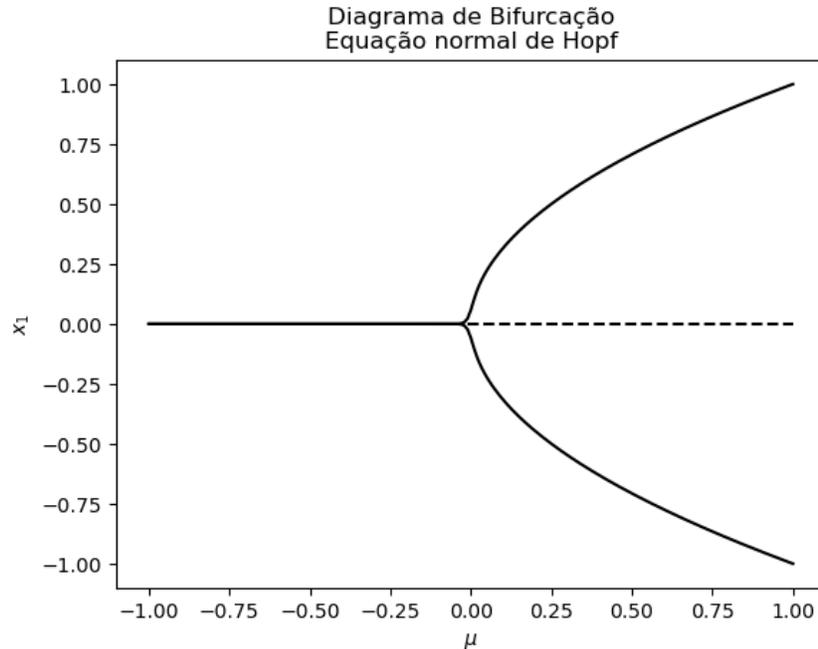


Figura 1 - Diagrama de bifurcação para a variável x_1 da equação normal de Hopf.

2.2.5. Diagramas de bifurcação para sistemas com golfadas

É possível a representação do comportamento dinâmico de sistemas de produção de petróleo *offshore* com presença de golfadas por meio de um diagrama de bifurcação, utilizando a abertura da válvula choke como parâmetro e uma das pressões do sistema como variável no eixo vertical. Essa representação é comum na literatura e pode ser obtida por meio de testes em planta, simulações com softwares comerciais (LING *et al.*, 2006), continuação numérica de modelos simplificados (STORKAAS *et al.*, 2002; JAHANSHAHI *et al.*, 2011, DIEHL *et al.*, 2017) ou a partir de dados históricos (DIEHL *et al.*, 2021). O uso do diagrama de bifurcação tem como vantagem permitir observar as soluções do sistema, sejam estáveis, instáveis ou cíclicas do sistema real e definir o ponto de Hopf.

A Figura 2 mostra um diagrama de bifurcação representativo desse tipo de sistemas. Para valores baixos de choke, a pressão no estado estacionário decresce de forma não-linear quando a abertura da válvula aumenta, até que a abertura é suficiente para permitir o surgimento de golfadas, gerando um ponto de bifurcação de Hopf. A partir desse ponto, o sistema apresenta oscilações periódicas, cujos valores máximos e mínimos são apresentados no diagrama, assim como um equilíbrio instável para valores de pressões intermediários entre os máximos e mínimos das oscilações periódicas.

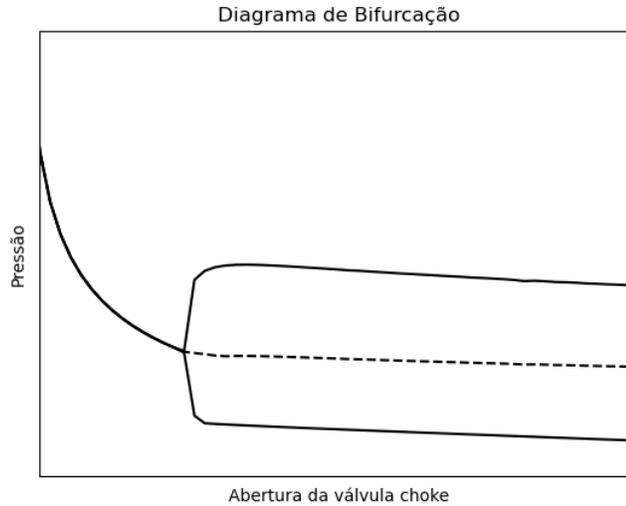


Figura 2 - Diagrama de bifurcação representativo para um sistema de produção de petróleo offshore com problemas de golfadas

2.3. Reconstrução de diagramas de bifurcação a partir de séries temporais

Sobre a reconstrução de diagramas de bifurcação a partir de séries temporais, a maioria dos artigos na literatura está baseada no uso do teorema de TAKENS (1981), que indica a possibilidade de reconstruir o estado de fases a partir da série temporal de uma variável medida. O teorema estabelece que, para um sistema dinâmico determinístico dado por um estado $\mathbf{x}(t)$ de d dimensões, é possível utilizar as últimas k medições de uma variável $y(\mathbf{x}(t))$ para criar um vetor k -dimensional de coordenadas defasadas no tempo. A dinâmica desse vetor será equivalente topologicamente à dinâmica do sistema original, preservando algumas invariantes geométricas. A dimensão k necessária para ter essa equivalência é $k \leq 2d + 1$ (SHALIZI, 2006).

Essa ideia pode ser estendida para sistemas que são afetados por variáveis externas, como os parâmetros de um sistema dinâmico, por meio de modelos não-lineares autorregressivos com entradas externas (NARX). Nesse tipo de modelos, o valor atual da variável medida, y , é função tanto das defasagens no tempo da mesma variável quanto do valor atual e valores defasados da variável externa, μ (BILLINGS, 2013), como mostrado na Equação (4).

$$y_t = F(y_{t-1}, y_{t-2}, \dots, y_{t-k}, \mu_t, \mu_{t-1}, \dots, \mu_{t-k}) \quad (4)$$

Para aproximar a função não-linear, $F(\cdot)$, podem ser utilizados polinômios, redes neurais, funções de base radial, entre outros. Uma vez obtida a função não-linear aproximada que representa a dinâmica do sistema, é possível reconstruir o diagrama de bifurcação do sistema.

A partir dessa ideia, diferentes métodos têm sido analisados para a reconstrução do diagrama de bifurcação, especialmente para sistemas caóticos¹. TOKUNAGA *et al.* (1994) usaram um *multilayer perceptron* para reconstruir o diagrama de bifurcação do modelo de Rossler. BAGARINAO *et al.* (2000) utilizaram modelos autorregressivos não-lineares (NAR) para reconstruir um diagrama de bifurcação de um modelo de neurônio biológico. KRISHNAIAH *et al.* (2002) utilizaram redes neuronais recorrentes (RNN) para prever o diagrama de bifurcação do mapa de Hénon e de um forno de produção de ligas de ferro. VEGA *et al.* (2008) analisaram os diagramas de bifurcação de modelos baseados em redes neurais para aplicações em controle, indicando que redes com boas previsões no curto prazo podem apresentar dinâmica incompatível com o comportamento do sistema no longo prazo.

ITOH (2017) propôs um método inovador, a partir de modelos de *Extreme Machine Learning* (EML) e aplicando uma técnica de análise de componentes principais (PCA) para alterar os parâmetros da rede para cada valor do parâmetro do sistema. Esse método tem como vantagem principal permitir uma melhor extrapolação, mas a desvantagem de precisar uma série temporal para cada valor do parâmetro do sistema. CESTNIK e ABEL (2019) analisaram com sucesso a reconstrução de diagramas de bifurcação para sistemas dinâmicos oscilatórios, utilizando redes recorrentes *Gated Recurrent Unit* (GRU) e *Long Short Term Memory* (LSTM). Nesse caso, foram usados como entradas para as redes um número de medições prévias suficientes para conter uma oscilação completa do sistema.

2.4. Modelos fenomenológicos

O fluxo multifásico do sistema de produção de petróleo *offshore* pode ser modelado rigorosamente por meio de modelos de parâmetros distribuídos que consideram a variação espacial das variáveis de estado. Normalmente, esse tipo de modelo é descrito utilizando

¹ Os sistemas caóticos são sistemas dinâmicos caracterizados pela sua imprevisibilidade e sensibilidade às condições iniciais (SAVI, 2017). Por esse motivo, seu comportamento pode parecer aleatório, embora esteja determinado por regras fixas.

equações diferenciais parciais (EDP). Atualmente existem diversos modelos baseados em EDPs (BALIÑO, 2014; BENDLKSEN, MALNES, *et al.*, 1991; SINÈGRE, 2006). Esses modelos normalmente são utilizados em simuladores comerciais, como o OLGA (2021). Entretanto, as principais desvantagens desses modelos são o custo das licenças e o custo computacional. Em especial, esse último limita sua utilização para aplicações em tempo real.

Por esse motivo, para as aplicações em tempo real é mais conveniente o uso de modelos simplificados, baseados em equações diferenciais ordinárias (EDOs). Existem diversos modelos na literatura (DI MEGLIO, 2011; DIEHL *et al.*, 2017; EIKREM *et al.*, 2008; JAHANSHAH, 2013) que descrevem parcial ou totalmente o sistema de produção e *gas-lift*. Entre eles, o modelo proposto por Jahanshahi apresenta dificuldades numéricas que inviabilizam seu uso em condições reais de operação (JAHANSHAH, 2013). O modelo proposto por Di Meglio não é indicado para grandes variações nas variáveis operacionais (DI MEGLIO, 2011). Entretanto, o modelo Fast-Offshore Well Model (FOWM) (DIEHL *et al.*, 2017) tem sido utilizado com sucesso para a otimização e controle de poços reais.

O modelo FOWM é um modelo dinâmico simplificado de sistemas de produção *offshore* de águas profundas e ultraprofundas. Foi criado para representar tanto as golfadas produzidas pelas irregularidades do terreno e a inclinação do *riser*, quanto aquelas geradas pelo sistema de *gas lift*. Uma descrição mais detalhada do modelo e suas equações pode ser encontrada no Anexo A. Atualmente, estão sendo desenvolvidos estudos para a utilização desse modelo para a análise dinâmica do sistema de produção. No entanto, o uso desse modelo introduz dificuldades para a estimação de parâmetros, motivo pelo qual o uso desse modelo para novos poços não é trivial (DIEHL *et al.*, 2017).

2.5. Modelos baseados em dados

Nas últimas décadas, os avanços tecnológicos têm favorecido o aumento da quantidade de dados gerados na indústria, assim como a capacidade de cômputo e comunicação dos diferentes dispositivos de monitoramento e controle de processos. Como consequência, o desenvolvimento e aplicação de modelos baseados em dados têm se tornado cada vez mais frequentes. Esses modelos têm como vantagem principal a capacidade de modelar alguns sistemas complexos e altamente não lineares que os modelos fenomenológicos apresentam dificuldade de descrever.

Alguns desses modelos baseiam-se na análise não linear de séries temporais, procurando reconstruir a dinâmica de um sistema (GIBSON *et al.*, 1992; PACKARD *et al.*; 1980; SAUER *et al.*, 1991; TAKENS, 1981). A reconstrução, embora não seja igual à dinâmica interna, é idêntica topologicamente e as conclusões obtidas sobre a dinâmica reconstruída também são válidas para a dinâmica real do sistema (BRADLEY, KANTZ, 2015)

Outros modelos amplamente utilizados são os modelos de *Machine Learning*. *Machine Learning* é a área da Inteligência Artificial que estuda como os computadores podem aprender a partir de dados. A partir dessa aprendizagem, os modelos podem realizar classificações, regressões e clusterização por meio do reconhecimento de padrões nos dados de entrada (MUKHAMEDIEV *et al.*, 2021). Um tipo particular de algoritmos de *Machine Learning* que tem se tornado muito importante nas últimas décadas são as Redes Neurais Artificiais (ANNs) por sua flexibilidade e acurácia nas previsões, especialmente quando o volume de dados disponível é grande (BASU *et al.*, 2010).

2.5.1. Redes neurais artificiais

As redes neurais artificiais são modelos de *Machine Learning* utilizados para resolver problemas supervisionados de regressão e classificação. As ANNs se caracterizam pela habilidade para reconhecer relações altamente não-lineares nos dados de entrada. O objetivo de uma ANN é aproximar uma determinada função $f: x \rightarrow y$ a partir de pares de dados de entrada e de saída (SHARMA *et al.*, 2020). A estrutura desses modelos é composta por unidades denominadas nós ou neurônios, que estão conectadas entre si e agrupadas em camadas.

Normalmente, as redes são compostas por uma camada de entrada, para receber os dados, uma ou mais camadas ocultas que processam a informação e uma camada de saída que produz as previsões. Os neurônios e as conexões entre as camadas apresentam uma série de parâmetros denominados pesos, os quais são ajustados durante o treinamento para melhorar as previsões da rede. Além disso, nas camadas ocultas e de saída, os neurônios aplicam transformações não-lineares dos dados, o que permite que as redes aprendam padrões mais complexos (MONTESINOS LÓPEZ *et al.*, 2022).

O número de camadas ocultas, assim como o número de neurônios em cada camada são hiperparâmetros da arquitetura da rede neural que devem ser escolhidos para cada problema. Uma vez definida a arquitetura da rede, ela é treinada de forma iterativa a partir dos dados, com o intuito de minimizar uma função objetivo (*loss function*) associada ao erro das previsões da rede (GOODFELLOW et al., 2016). Para garantir a capacidade de generalização da rede, normalmente uma parte dos dados é separada para validar os resultados, enquanto a maioria dos dados é utilizada para treinar a rede (MONTESINOS LÓPEZ et al., 2022).

2.5.2. Redes neuronais recorrentes

As redes neuronais recorrentes (RNNs) são um tipo de rede neural apropriado para o reconhecimento de padrões em problemas cujas entradas e saídas são sequências dinâmicas (SUTSKEVER, 2013). Como as sequências se caracterizam pela interdependência das observações, as RNNs permitem que saídas prévias sejam utilizadas como entrada para previsões posteriores e mantenham uma certa “memória”, denominada estado oculto. Essas redes são amplamente utilizadas para trabalhar com séries temporais, reconhecimento de fala e tradução automática, entre outras áreas (SARKER, 2021).

Apesar das suas vantagens intrínsecas, esse tipo de rede apresenta grandes dificuldades para serem treinadas, especialmente por causa do problema de dissipação do gradiente. Esse problema é comum em modelos de *Machine Learning* ao analisar dados apresentados na forma de sequências muito longas. Uma das dificuldades consiste no fato de que os componentes de longo prazo tendem a zero com velocidade exponencial (PASCANU et al., 2012). Como consequência, os modelos têm dificuldades para reconhecer padrões no longo prazo. Tanto as RNN convencionais quanto o Modelo Oculto de Markov e outros métodos de aprendizado de sequências sofrem desse problema e, portanto, são afetados pelo comprimento da sequência analisada (PASCANU et al., 2012). Para lidar com esse problema, foram criados diferentes tipos de RNNs, entre os quais destacam-se as redes *Gate Recurrent Unit* (GRU) e *Long-Short Term Memory* (LSTM).

2.5.3. Redes LSTM

As redes *Long-Short Term Memory* (LSTM) são um tipo particular de arquitetura de redes neurais recorrentes criada com o objetivo de minimizar o problema da dissipação do gradiente (HOCHREITER, SCHMIDHUBER, 1997). Cada unidade da rede LSTM possui 4 neurônios e diferentes blocos de memória denominados células (ver Figura 3). A informação é retida nas células e as manipulações de memória são feitas por portões (*gates*). Existem quatro tipos de portões, cujas funções são:

1- *Forget gate*: é utilizado para remover informações que já não são úteis. As entradas são os dados no tempo atual (x_t) e o estado oculto prévio (h_{t-1}). A saída desse portão é binária, sendo 1 se a informação deve ser mantida. A equação que descreve esse portão é:

$$f_t = \sigma (W_f [h_{t-1}, x_t] + b_t) \quad (5)$$

2- *Input gate*: junto com o *input modulation gate* determina quais informações devem entrar no estado da célula, isto é, quais informações devem ser mantidas a longo prazo. De forma similar ao *forget gate*, aplica a função de ativação sigmoideal.

$$i_t = \sigma (W_i [h_{t-1}, x_t] + b_i) \quad (6)$$

3- *Input modulation gate*: como o *input gate*, utiliza a função sigmoide, com saídas entre 0 e 1, só podendo adicionar informações à célula e não as eliminar. Para poder fazer essa eliminação, a *input modulation gate* utiliza a função de ativação $\tanh(x)$, com saídas entre -1 e 1. A função é:

$$\tilde{c}_t = \tanh (W_c [h_{t-1}, x_t] + b_c) \quad (7)$$

4- *Output gate*: determina quais informações do estado da célula devem ser extraídas para serem a saída da rede LSTM.

$$o_t = \sigma (W_o [h_{t-1}, x_t] + b_o) \quad (8)$$

Além dos *gates*, o estado da célula mantém a memória de longo prazo. A célula “esquece” ao multiplicar o estado anterior pelo resultado do *forget gate* e adiciona nova informação que provém da multiplicação das saídas da *input gate* e da *input modulation gate*, como mostrado na Equação (9):

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \quad (9)$$

Finalmente, o estado oculto que será utilizado como entrada nas seguintes células é obtido segundo a Equação (10):

$$h_t = o_t \circ \tanh (c_t) \quad (10)$$

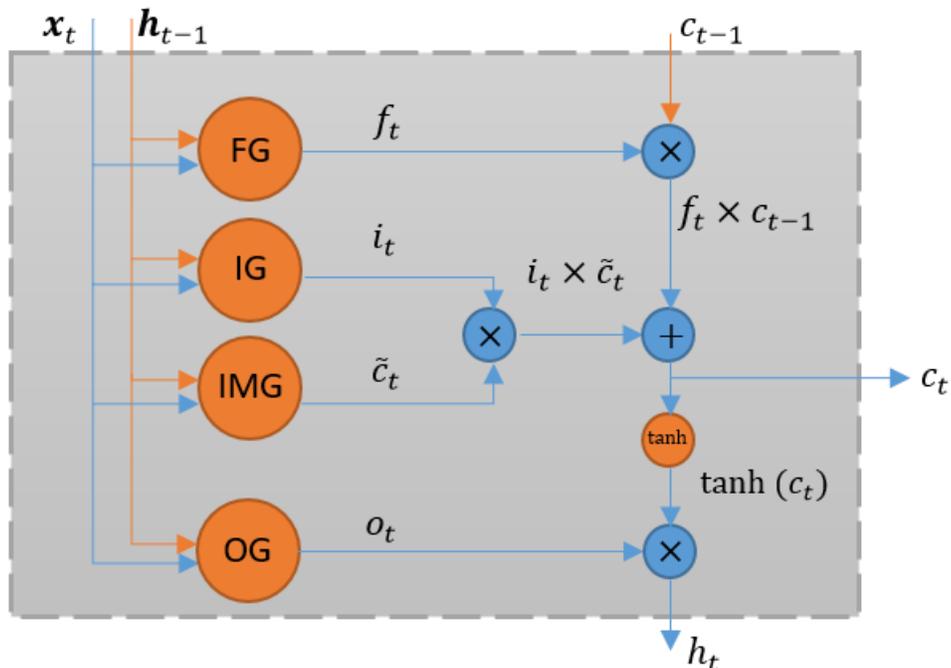


Figura 3 - Esquema de uma unidade de rede LSTM

2.5.4. Redes LSTM Encoder-Decoder

A arquitetura das redes *Encoder-Decoder LSTM*, mostrada de forma esquemática na Figura 4, foi desenvolvida para trabalhar com problemas que transformam sequências em

outras sequências (SUTSKEVER *et al.*, 2014). A sequência de entrada é alimentada a uma rede LSTM, o *encoder*, que lê um valor de cada vez até obter uma representação vetorial de tamanho fixo. Esse vetor é alimentado a uma rede LSTM diferente, o *decoder*, que decodifica a informação para calcular as saídas de forma sequencial. Desse modo, é possível trabalhar com sequências de entrada e saída de tamanhos variáveis. É possível adicionar também camadas densas após a camada LSTM do *decoder*, para tentar melhorar as previsões. Essa arquitetura tem sido testada especialmente para tarefas de processamento de linguagem natural (PLN), como tradução de textos (SUTSKEVER *et al.*, 2014) e diálogo (VINYALS, LE, 2015). Algumas variações também foram testadas para reconhecimento de fala (LU *et al.*, 2015) e descrição de imagens (VINYALS *et al.*, 2014). Mais recentemente, redes recorrentes *encoder-decoder* foram utilizadas para a previsão de séries temporais numa usina elétrica (LAUBSCHER, 2019) com um erro porcentual absoluto médio menor que 1%. Além disso, LI e TONG (2021) criaram uma estratégia de controle preditivo que utiliza uma rede *encoder-decoder* como modelo para controlar o consumo de energia de um prédio.

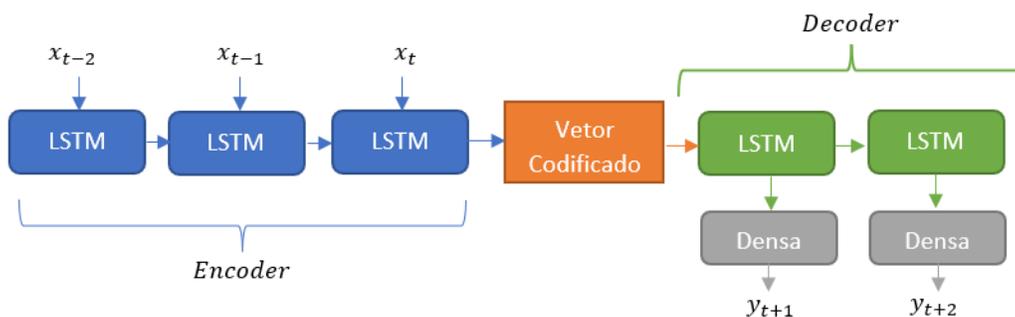


Figura 4 - Representação esquemática de uma rede LSTM Encoder-Decoder

2.6. Aplicação de redes neurais para a produção de petróleo *offshore*

Existem diversos estudos na literatura que aplicam modelos de *Machine Learning* para a produção de petróleo *offshore*. A maioria dos artigos descreve a utilização de redes neurais como medidores virtuais para determinar vazões de líquido e gás (GARCÍA *et al.*, 2010; OLIVARES *et al.*, 2012; SHOEIBI OMRANI *et al.*, 2018; SUN *et al.*, 2018; ZIEGEL

et al., 2014). Em particular, uma revisão atual de modelos fenomenológicos e de *Machine Learning* para a medição virtual de vazões pode ser encontrada em BIKMUKHAMETOV, JÄSCHKE (2020).

As redes neurais também foram utilizadas para fazer previsão (ANDRIANOV, 2018) e otimização (LUO *et al.*, 2018) da produção, assim como para a predição da pressão na *Permanent Downhole Gauge* (PDG) (ANTONELO *et al.*, 2017), devido a sua importância para a modelagem e controle da produção. Existem também alguns estudos que aplicam estratégias de controle baseadas em redes neurais, incluindo *Echo State Networks* para controlar a produção *offshore* (JORDANOU *et al.*, 2019; SPINDOLA RANGEL DIAS *et al.*, 2019), um MPC com um modelo baseado em *Reinforcement Learning* (TALAVERA *et al.*, 2010) e controle NMPC com redes neurais baseadas em Funções de Base Radial (RBF) (SALAHSHOOR *et al.*, 2013).

2.7. Comentários finais

Neste capítulo, foi apresentado o referencial teórico das principais áreas nas quais está fundamentado o presente trabalho e a revisão bibliográfica do estado atual das técnicas utilizadas. Foram descritos os mecanismos pelos quais são produzidas as golfadas em poços *offshore*, assim como as principais formas para o controle das golfadas. Também foi caracterizada a modelagem desse sistema por modelos fenomenológicos e modelos baseados em dados, mostrando que esses últimos são capazes de aproveitar os dados históricos de sistemas reais. Além disso, foi descrita a possibilidade de representar a dinâmica do sistema por meio da utilização da bifurcação de Hopf e a construção de diagramas de bifurcação, o qual normalmente é gerado a partir de testes ou continuação paramétrica de modelos fenomenológicos.

A revisão bibliográfica mostrou que, apesar de existirem técnicas na literatura para a reconstrução dos diagramas de bifurcação a partir de series temporais, ainda não tem sido aplicadas para o problema de golfadas na produção de petróleo *offshore*. Essas metodologias também podem se beneficiar de diferentes arquiteturas de redes neurais, especialmente apropriadas para trabalhar com series temporais e que já tem sido utilizadas na indústria, especialmente para a construção de sensores virtuais. Por esse motivo, o presente trabalho procura entender a viabilidade da aplicação dessas técnicas para descrever sistemas de

produção de petróleo com problemas de golfadas, por meio do estudo e aplicação de uma metodologia para a reconstrução dos diagramas de bifurcação de utilizando diferentes tipos de redes neuronais.

Capítulo 3

Metodologia

3.1. Metodologia para a reconstrução de diagramas de bifurcação

A metodologia utilizada no presente trabalho para a reconstrução de diagramas de bifurcação se baseia na metodologia implementada por CESTNIK e ABEL (2019). Este método assume que a rede neural treinada tem uma dinâmica equivalente à do sistema real no equilíbrio e, portanto, que os diagramas de bifurcação real e da rede são análogos. Além disso, a metodologia não depende do tipo ou da arquitetura da rede neural utilizada, o que permite comparar os resultados para diferentes tipos de redes. Em particular, no presente trabalho serão utilizadas redes ANN convencionais, LSTM e LSTM ED.

É necessário indicar que essa metodologia permite obter os pontos de equilíbrio estáveis e a amplitude das oscilações periódicas, porém não permite estabelecer os pontos de equilíbrio instáveis. A metodologia consiste nas seguintes etapas:

- Escolha dos dados
- Seleção das variáveis
- Pré-processamento
- Determinação da rede
- Treinamento da rede
- Iterações a partir da rede
- Construção do diagrama de bifurcação

3.1.1. Escolha dos dados

Os dados devem consistir de séries temporais de variáveis representativas do sistema a analisar, assim como os valores do parâmetro de bifurcação para cada observação. Para facilitar o treinamento das redes, os dados devem conter observações tanto com valores do

parâmetro inferiores aos do ponto de bifurcação esperado quanto com valores maiores que esse. Desse modo, os dados apresentam tanto medições com um estado estacionário estável quanto medições com comportamento periódico. Além disso, a amostragem dos dados deve ser suficiente para permitir observar adequadamente as oscilações no sistema.

3.1.2. Seleção das variáveis

As variáveis de entrada na rede devem ser no mínimo duas: o parâmetro de bifurcação e a variável para a qual será feito o diagrama. Outras variáveis do sistema também podem ser adicionadas para melhorar a predição. No entanto, como é preciso atualizar as entradas durante as iterações, essas variáveis adicionais deverão ser adicionadas também como saídas do sistema, o que pode dificultar a predição das redes. Para cada uma das variáveis de entrada serão usadas k defasagens no tempo.

A saída da rede consiste na variável a utilizar no diagrama, assim como qualquer outra variável que seja atualizada em cada iteração, para um número n de tempos posteriores. Portanto, para reconstruir o diagrama de bifurcação da variável y variando o parâmetro μ , e utilizando outras medições \mathbf{x} , a transformação feita pela rede é dada pela Equação (11).

$$y_t, \mathbf{x}_t, y_{t+1}, \mathbf{x}_{t+1}, \dots, y_{t+n}, \mathbf{x}_{t+n} = f(y_{t-1}, \mu_{t-1}, \mathbf{x}_{t-1}, \dots, y_{t-k}, \mu_{t-k}, \mathbf{x}_{t-k}) \quad (11)$$

3.1.3. Pré-processamento

Os dados precisam passar por uma etapa de pré-processamento para que possam ser manipulados adequadamente pelas redes. Por um lado, é preciso criar as defasagens de tempo que serão utilizadas na entrada dos modelos a partir das series temporais. Para isto, é possível construir um tensor cujas dimensões estão dadas pelo número de observações, número de variáveis e número de defasagens no tempo, respectivamente. Um tensor similar deve ser gerado para os dados de teste.

Além disso, as redes neuronais, assim como outros modelos de *Machine Learning*, funcionam melhor quando as variáveis de entrada são normalizadas para que tenham escalas similares (BROWNLIE, 2020). Existem diferentes métodos para realizar essa normalização,

dependendo da distribuição dos dados, entre eles a normalização estândar ou gaussiana, a escala Min-Max, a normalização robusta e a normalização logarítmica

A normalização estândar ou gaussiana assume que os dados possuem uma distribuição aproximadamente normal. Utiliza a média (\bar{x}) da variável como medida central e o desvio padrão (s) como medida de dispersão, como mostrado na Equação (12).

$$x_i^* = \frac{x_i - \bar{x}}{s} \quad (12)$$

No caso da escala Min-Max, os dados são escalados entre 0 e 1 utilizando os valores máximos e mínimos da variável, como mostrado na Equação (13).

$$x_i^* = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (13)$$

A normalização robusta, como o seu nome indica, é mais robusta ante a presença de outliers quando comparada com a normalização gaussiana. Utiliza a mediana como medida de centralidade e o rango interquartil (IQR) como medida de dispersão, de acordo com a Equação (14).

$$x_i^* = \frac{x_i - med(x)}{IQR} \quad (14)$$

A normalização logarítmica utiliza uma transformação logarítmica dos dados, permitindo trabalhar com variáveis com uma ampla faixa de valores. A média e a medida de dispersão utilizadas nesse caso são calculadas utilizando as Equações (15) e (16). A formula para a normalização é mostrada na Equação (17).

$$\mu_{log} = \frac{1}{N_{train}} \sum_{j=1}^{N_{train}} \log(x_j) \quad (15)$$

$$\sigma_{log} = \sqrt{var(\log(x))} \quad (16)$$

$$x_i^* = \frac{\log(x_i) - \mu_{log}}{\sigma_{log}} \quad (17)$$

3.1.4. Determinação da rede

Uma vez que os dados tenham sido pré-processados, pode ser determinado o tipo de rede, sua arquitetura e hiperparâmetros. A escolha dessa arquitetura/hiperparâmetros pode ser feita por heurísticas ou, se o custo computacional não constituir uma limitação, pode ser feita uma otimização dos hiperparâmetros. Nessa metodologia, o objetivo da escolha dos hiperparâmetros é obter uma rede neural que consiga boas predições da variável de saída e seja capaz de produzir um diagrama de bifurcação adequado a partir dos dados iniciais.

Os tipos de redes analisados nesse trabalho são redes ANN convencionais, LSTM e LSTM ED com um número variável de neurônios na camada oculta. Os principais hiperparâmetros analisados são as funções de ativação, o uso de regularização lasso e a escolha do otimizador para o treinamento da rede (GREESHMA, SREEKUMAR, 2019).

3.1.5. Treinamento da rede neural

Para o treinamento da rede, os dados selecionados previamente deverão ser divididos em um conjunto de treino e um conjunto de teste. A rede é treinada de modo a minimizar uma função objetivo que avalia o erro entre as predições realizadas e os valores reais nos dados de treino. As métricas mais comuns para a função objetivo são o erro quadrático médio (MSE) e o erro absoluto médio (MAE). Para realizar esse treinamento de forma eficiente, são utilizados o algoritmo de *backpropagation* (HECHT-NIELSEN, 1992) para ANN convencionais e *backpropagation through time* (WERBOS, 1990) para redes com neurônios recorrentes, como as LSTM. Existem também diferentes otimizadores para calcular os parâmetros ótimos para a rede. Os mais utilizados são o método de gradiente descendente

estocástico (SGD) e o método Adam (*Adaptive Movement Estimation Algorithm*) e suas variações (Adamax, Adadelta, etc.) (DOGO *et al.*, 2018).

O treinamento da rede permite gerar redes com boa capacidade de predição no curto prazo. No entanto, esse método não permite avaliar se o comportamento da rede no equilíbrio será o esperado. Portanto, deve ser feita uma análise posterior do diagrama de bifurcação gerado para avaliar o comportamento no equilíbrio. Além disso, pode ser feita uma otimização de hiperparâmetros da rede para obter o melhor diagrama de bifurcação. Nesse caso, uma nova função objetivo, calculada a partir das predições nos dados de validação, deve ser otimizada.

3.1.6. Iterações a partir da rede

Uma vez treinada a rede neural, podemos escolher um valor fixo do parâmetro, μ_i , e um vetor inicial, \mathbf{y}_0 , contendo k defasagens no tempo. A partir desse ponto podemos realizar iterações calculando a próxima saída y_t , utilizando o vetor no tempo prévio como entrada. O vetor \mathbf{y}_{t-1} é atualizado em cada iteração, adicionando a nova observação e excluindo a observação mais antiga.

$$\begin{aligned} y_1 &= f(\mathbf{y}_0, \mu_i) \\ y_2 &= f(\mathbf{y}_1, \mu_i) \\ &\vdots \\ y_t &= f(\mathbf{y}_{t-1}, \mu_i) \end{aligned} \quad (18)$$

Onde $\mathbf{y}_t = (y_t, y_{t-1}, y_{t-2}, \dots, y_{t-k+1})$

O resultado dessas iterações será uma série temporal, que pode atingir um estado estacionário, apresentar oscilações permanentes ou divergir, a depender do comportamento no equilíbrio da rede utilizada. O número de interações deve ser escolhido de forma que permita superar o transiente inicial e permita observar o comportamento no equilíbrio. Posteriormente, será definida uma janela temporal com as últimas n observações, a partir da qual serão calculados os máximos e mínimos da série temporal para o valor do parâmetro μ_i . A Figura 5 mostra dois exemplos de iterações que podem ser geradas: uma que atinge o estado estacionário e outra que leva a oscilações permanentes. Nas figuras é possível observar também a janela analisada para obter os valores máximos e mínimos.

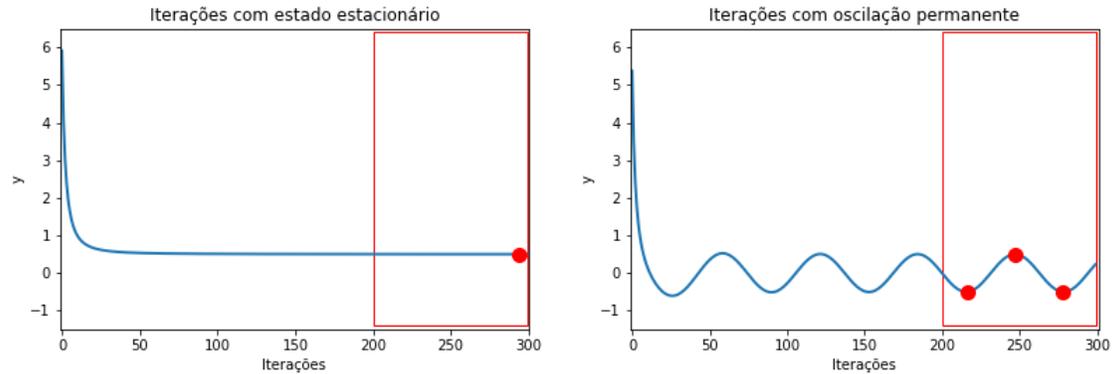


Figura 5 - Exemplos de iterações a partir de uma rede neural para dois valores diferentes do parâmetro e a determinação dos valores máximos e mínimos para o diagrama de bifurcação. Na imagem (a) o sistema atinge um estado estacionário, enquanto na imagem (b) o sistema atinge oscilações permanentes.

3.1.7. Construção do diagrama de bifurcação

Finalmente, podemos construir o diagrama de bifurcação ao escolher diferentes valores do parâmetro, $\mu_i, i = 1..m$, para os quais serão realizadas as iterações indicadas no estado prévio. Para cada valor de μ_i , serão obtidos os valores máximos e mínimos locais, os quais serão plotados em um gráfico com y no eixo vertical e μ no eixo horizontal. O número m de valores para μ_i deve ser suficiente para poder observar as bifurcações e mudanças do comportamento do sistema ao variar o parâmetro, mas sem elevar significativamente o custo computacional.

A reconstrução é discreta e só apresenta as soluções estáveis do sistema, sejam estacionárias ou periódicas. Esse método tem como desvantagem que não permite estimar diretamente o equilíbrio instável. A Figura 6 mostra um exemplo que compara o diagrama esperado com a sua reconstrução.

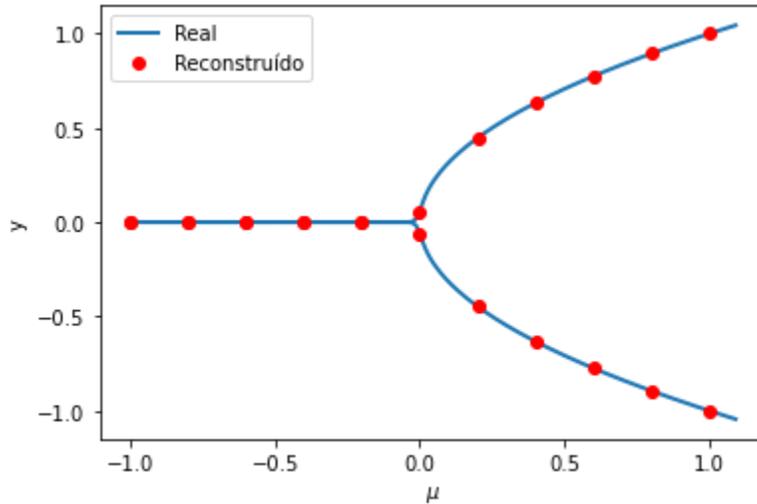


Figura 6 - Exemplo da comparação de um diagrama de bifurcação reconstruído com o diagrama de bifurcação real.

3.2. Implementação e recursos computacionais

Para aplicar essa metodologia, foram gerados códigos em Python 3.8, tanto para a construção e treinamento das redes quanto para a reconstrução do diagrama de bifurcação. A implementação das redes neurais foi feita utilizando os *frameworks* *TensorFlow* v.2.3 (2020) e *Keras* v.2.4.3 (2020). Para a otimização de hiperparâmetros, foi utilizada a biblioteca *Optuna* (AKIBA *et al.*, 2019). Os testes foram realizados utilizando um notebook Samsung NP3000 com um processador Intel Core i5-7200U, 4 GB de memória RAM e equipado com uma GPU NVIDIA GeForce 920MX com 2 GB de memória dedicada.

3.3. Aplicação aos dados simulados com o modelo FOWM

3.3.1. Geração dos dados simulados

Para testar a metodologia de reconstrução de diagramas de bifurcação, foram gerados dados simulados a partir do modelo FOWM (*Fast-Offshore Well Model*). O modelo foi ajustado para um poço real, descrito no artigo de DIEHL *et al.* (2017) como poço A. Uma descrição do modelo e os parâmetros utilizados para o ajuste são apresentados no Anexo A enquanto as principais variáveis geradas na simulação são mostradas na Tabela 1. Os conjuntos de dados contêm simulações para diferentes valores de abertura da válvula choke.

O objetivo foi gerar dados com suficiente tempo nas simulações para atingir o estado estacionário para valores de choke entre 0% e 100%.

Tabela 1 - Variáveis geradas pela simulação do modelo FOWM.

Variável	Unidades	Descrição
Choke	-	Posição da Válvula choke
P_{ai}	Pa	Pressão de injeção de gás anular
PDG	Pa	Pressão na PDG
P_{eb}	Pa	Pressão da bolha de gás
P_r	Pa	Pressão do reservatório
P_s	Pa	Pressão no separador
P_{tb}	Pa	Pressão na base do tubo de produção
P_{top}	Pa	Pressão no topo do <i>riser</i>
P_{tt}	Pa	Pressão de topo do tubo de produção
TPT	Pa	Pressão na TPT (<i>Temperature-Pressure Tool</i>)
V_{gt}	m ³	Volume de gás no tubo de produção
W_{gc}	Sm ³ /d	Vazão de <i>gas-lift</i>
W_{gout}	kg/s	Vazão de gás na saída da válvula choke
W_{lout}	kg/s	Vazão de líquido na saída da válvula choke
m_{ga}	kg	Massa de gás no anular
m_{gt}	kg	Massa de gás no tubo de produção
m_{lt}	kg	Massa de líquido no tubo de produção
m_{gb}	kg	Massa da bolha de gás na linha de produção
m_{gr}	kg	Massa de gás na linha de produção e o <i>riser</i>
m_{lr}	kg	Massa de líquido na linha de produção e o <i>riser</i>

Foram gerados um conjunto de dados para treino e outro para teste, em que a abertura da válvula choke foi variada utilizando degraus de 2%. O conjunto de treino varia entre 1% e 99% enquanto o conjunto de teste varia entre 2 e 100%. Para cada valor de abertura da válvula choke, foram geradas 5 simulações de 10 h amostradas a cada um minuto, utilizando pontos iniciais diferentes. Os pontos iniciais foram escolhidos aleatoriamente dentro de uma faixa próxima a uma condição inicial já conhecida para as variáveis de estado do modelo FOWM. Os valores máximos e mínimos da faixa podem ser observados na Tabela 2.

Tabela 2 - Faixa de valores das variáveis de estado para os possíveis pontos iniciais das simulações.

	Min	Max	Unidades
m_{ga}	6759.31	10138.97	kg
m_{gt}	1485.84	2228.76	kg
m_{lt}	16930.72	25396.08	kg
m_{gb}	1733.01	2599.51	kg
m_{gr}	1009.42	1514.12	kg
m_{lr}	11502.03	17253.05	kg

3.3.2. Análise exploratória dos dados simulados

Para compreender a distribuição e o comportamento dinâmico dos dados simulados, foram feitas algumas análises exploratórias. Inicialmente, foram plotados no tempo algumas das variáveis do sistema mais relevantes para o trabalho: a massa de gás no anular (m_{ga}), a pressão na PDG e a pressão no topo (Ptop). A partir desses gráficos, é possível identificar o ponto de bifurcação de Hopf aproximado e observar a amplitude das oscilações. Também foram gerados histogramas dessas variáveis para ver a distribuição dos dados.

Foi feita também uma análise para determinar o período médio das oscilações, assim como uma análise da autocorrelação dos dados. Finalmente, foram gerados gráficos para as principais variáveis como função da abertura da válvula choke no eixo horizontal, de modo a observar o efeito desse parâmetro no comportamento do sistema.

3.3.3. Uso de variáveis de estado

A forma mais direta de analisar a dinâmica do sistema simulado pelo modelo FOWM é utilizar uma das variáveis de estado do modelo como referência. Por esse motivo, foram reconstruídos os diagramas de bifurcação para uma das variáveis de estado, a massa de gás no anular (m_{ga}). Foram utilizadas redes ANN, LSTM e LSTM ED para reconstruir o diagrama de bifurcação. Os dados foram pré-processados utilizando a normalização robusta. Os principais hiperparâmetros selecionados para as redes utilizadas são mostrados na Tabela 3.

Tabela 3 - Principais hiperparâmetros das redes neuronais utilizadas

	ANN	LSTM	LSTM ED
Nº de camadas ocultas	1	1	1 camada LSTM para o Encoder 1 camada LSTM + 1 camada densa para o Decoder
Nº de neurônios:	100	100	100 nas camadas LSTM 15 na camada densa
Função de ativação	<i>Tanh</i>	<i>Tanh</i>	<i>Tanh</i>
Nº defasagens no tempo	15	15	15
Nº valores futuros a prever	1	1	1
Amostragem	1	1	1

3.3.4. Uso de variáveis medidas

Embora o uso das variáveis de estado para a reconstrução do diagrama de bifurcação seja a forma mais confiável de observar a dinâmica do sistema, no sistema real não existem medições diretas dessas variáveis. Por esse motivo, faz-se necessário o uso de variáveis medidas para a reconstrução do diagrama. Nesse caso, foram gerados os diagramas para duas variáveis: a pressão no fundo do poço, medida pela PDG, e a pressão no topo do sistema de produção. Também foram testados os três tipos de redes neuronais, com os hiperparâmetros mostrados na Tabela 3.

3.3.5. Construção do diagrama de bifurcação

Para a construção dos diagramas de bifurcação, foram realizadas iterações para 20 valores de abertura da válvula choke entre 0% e 100%. Foram realizadas 300 iterações para cada valor de choke. Para cada série temporal criada, foi analisada uma janela contendo os último 60 pontos para determinar os valores máximos e mínimos das oscilações. A partir desses valores, foi gerado o diagrama de bifurcação reconstruído.

O diagrama de bifurcação reconstruído foi comparado com o diagrama de bifurcação esperado, gerado a partir dos dados em estado estacionário. Cabe destacar que a construção desse diagrama de bifurcação esperado só foi possível neste caso porque os dados simulados contêm observações suficientes no estado estacionário. No entanto, a obtenção desse diagrama esperado não é viável para conjuntos de dados reais.

3.4. Aplicação a um sistema de produção real

Uma vez analisados os resultados para os dados simulados, a metodologia para a reconstrução de diagramas de bifurcação foi testada utilizando dados históricos de um sistema de produção de petróleo *offshore* real. Os objetivos dessa análise foram estabelecer se a metodologia pode ser utilizada em aplicações reais, compreender as dificuldades associadas à implementação e avaliar se é possível identificar o ponto de bifurcação de Hopf e a dinâmica do sistema no equilíbrio, com base em dados reais. Nessa análise, foram utilizados modelos de redes LSTM e LSTM ED para a reconstrução dos diagramas.

Existe uma grande variedade de fatores que podem afetar os resultados dos diagramas de bifurcação gerados, como a qualidade dos dados, hiperparâmetros das redes, número de defasagens no tempo, entre outros. Por esse motivo, foram comparados os resultados para três conjuntos de dados diferentes e, posteriormente, foi realizada uma análise de sensibilidade de alguns hiperparâmetros das redes para compreender a robustez dos modelos. Para escolher os hiperparâmetros que levam aos melhores diagramas de bifurcação, foi realizada uma otimização bayesiana por meio da biblioteca *Optuna*, no Python, com o intuito de determinar os valores desses hiperparâmetros que melhoram as previsões das redes.

A seguir será feita uma breve descrição dos dados utilizados e serão detalhadas as principais etapas realizadas durante essa análise.

3.4.1. Descrição dos dados reais

O conjunto de dados utilizado nesse trabalho provém da operação de um sistema de produção de petróleo *offshore* no Brasil. Os dados possuem informação de aproximadamente 3 anos de operação, com as variáveis amostradas a cada um minuto e contendo informação sobre as pressões e temperaturas na linha de produção, pressões e temperaturas no sistema

de *gas-lift* e a posição das válvulas do sistema. Para essa análise, foram consideradas principalmente as seguintes medições:

- Pressão no fundo do poço, medida pela *Permanent Downhole Gauge* (PDG);
- Pressão no topo do *riser* (Ptop);
- Abertura da válvula choke (Choke).

Outras variáveis também foram levadas em conta na hora de escolher os períodos utilizados para o treino e teste das redes neuronais, de modo a escolher períodos com condições de produção similares.

3.4.2. Análise Exploratória e limpeza dos dados reais

Com o intuito de detectar e corrigir erros de medição, dados faltantes, *outliers* ou outros problemas no conjunto de dados utilizados, foi realizada uma etapa de análise exploratória e limpeza dos dados. Em primeiro lugar, foi analisada a quantidade de dados faltantes no conjunto de dados. Foi utilizado o valor prévio para preencher os dados faltantes. Além disso, foram geradas séries temporais para cada uma das variáveis de interesse, para observar o seu comportamento ao longo do tempo. Para observar a distribuição dos dados, foram construídos histogramas e *boxplots*. Também, foi analisada a presença de dados errôneos (pressões negativas, aberturas de choke maiores a 100%, entre outros), os quais foram corrigidos utilizando dados prévios ou interpolando entre o valor prévio e o seguinte.

Para estabelecer se existe uma correlação não-linear entre as principais variáveis analisadas, foi gerada uma matriz com base na correlação Spearman (ARTUSI et al., 2002). Em particular, para observar o efeito da abertura da válvula nas pressões, foram gerados gráficos de dispersão para PDG vs Choke e para Ptop vs Choke.

3.4.3. Seleção dos conjuntos de dados

Embora as redes neuronais geralmente funcionem melhor quando o conjunto de dados é grande, a qualidade desses dados também deve ser levada em conta para obter as melhores predições. Por esse motivo, foram selecionados alguns períodos específicos de dados para o treinamento e teste das redes neuronais. Esses períodos apresentam uma grande variabilidade da abertura da válvula Choke, o parâmetro de interesse, em regiões próximas ao ponto de bifurcação de Hopf. Desse modo, foram selecionados três períodos, denominados períodos I,

II e III, que mostram tanto os estados estacionários estáveis, quanto o comportamento oscilatório das golfadas. Também foi escolhido um quarto período como dados de teste, para comparar os resultados obtidos ao utilizar cada um dos outros três períodos como dados de treino para as redes neuronais. Além disso, os períodos foram escolhidos, de modo a que outras variáveis e válvulas do sistema estivessem relativamente estáveis para evitar que a dinâmica do sistema fosse afetada significativamente por esses outros fatores.

3.4.4. Redes neuronais utilizadas

As redes testadas para a reconstrução dos diagramas de bifurcação dos dados reais foram redes LSTM e LSTM ED. As variáveis de entrada da rede foram a abertura da válvula choke (Choke) e a pressão a estimar (PDG ou Ptop). A saída das redes consiste unicamente da pressão a ser estimada. Com o objetivo de que os dados de entrada à rede incorporem uma oscilação completa, que tem um período de aproximadamente 21 min, os dados foram amostrados a cada 4 minutos e foram usadas 6 defasagens no tempo, abarcando assim os 24 minutos prévios. As variáveis foram pré-processadas para criar as defasagens no tempo e foi aplicada a normalização robusta.

Para determinar o número de neurônios e função de ativação a utilizar, foram feitos alguns testes iniciais. Foi escolhido um valor de 100 neurônios por camada, pois algumas redes têm dificuldade para mostrar as oscilações quando o número de neurônios é baixo e, por outro lado, não houve uma melhora significativa com um número maior de neurônios. Para as redes ANN e LSTM foi utilizada uma única camada oculta, pois nos testes com duas e três camadas, os diagramas de bifurcação não representavam adequadamente o comportamento dos dados. Além disso, foi utilizada a função de ativação *tanh*, que levou a redes com menos problemas de estabilidade no equilíbrio. O treinamento das redes foi feito com o otimizador Adamax, devido a sua velocidade de convergência, e teve como objetivo a minimização do erro absoluto médio (MAE) das previsões.

Finalmente, redes com os hiperparâmetros selecionados foram treinadas para cada um dos três períodos de dados analisados. O conjunto de dados utilizado para validar os resultados foi o período de teste.

3.4.5. Diagramas de bifurcação

A partir das redes neuronais, foram gerados os diagramas de bifurcação utilizando a metodologia descrita previamente. Foram selecionados valores de Choke a cada 2% entre 30% e 58% de abertura e cada 5% entre 60% e 100%. Para cada valor de Choke, foram geradas 300 iterações com cada rede, pois esse número de iterações mostrou-se suficiente para que as redes atingissem o estado estacionário. O tamanho da janela analisada para determinar os máximos e mínimos foi de 40 observações, permitindo observar mais de uma oscilação completa. Os diagramas foram comparados com um gráfico de Ptop vs Choke ou PDG vs Choke, segundo a pressão analisada, para os dados de treino e validação.

Foi analisado também o efeito da condição inicial escolhida ao realizar as iterações para o diagrama de bifurcação. Para isso, foram testadas três condições iniciais diferentes, utilizando a rede LSTM-ED para prever a pressão na Ptop. A partir dessas condições iniciais, foram geradas as iterações para dois valores de Choke: um valor de Choke de 5% e um valor de 50%.

3.4.6. Análise de sensibilidade e otimização de hiperparâmetros

Para compreender a influência de alguns hiperparâmetros nos diagramas de bifurcação, foram feitas análises de sensibilidade variando individualmente o número de defasagens no tempo na entrada e o número de neurônios da rede. Essas análises foram feitas para redes LSTM-ED treinadas com dados do período I. Além do diagrama de bifurcação gerado, foram comparados os valores de MAE das previsões obtidas para os dados de validação.

Por outro lado, também foi testada uma otimização de hiperparâmetros por meio da otimização bayesiana. Para isso, foi utilizada a biblioteca *Optuna* do Python. O intuito dessa análise foi caracterizar se é possível automatizar a escolha desses hiperparâmetros para obter diagramas de bifurcação melhores. Os hiperparâmetros a serem otimizados e as opções possíveis são mostrados na Tabela 4.

Tabela 4 - Valores possíveis dos hiperparâmetros das redes LSTM-ED a otimizar.

Hiperparâmetro	Tipo de variável	Opções
Função de ativação	Categórico	Tanh, ReLU
Nº de neurônios por camada	Inteiro	1 - 130
Nº defasagens	Inteiro	1 - 18
Regularização L1	Loguniforme	10^{-5} -1
Otimizador	Categórico	Adamax, Adadelta

Na primeira otimização realizada (otimização I), a função objetivo testada foi o erro de predição, dado pelo MAE e foram realizadas 200 iterações. O problema de utilizar só o erro de predição como função objetivo é que ele provê informação unicamente sobre as predições a curto prazo, mas não traz informação sobre o tipo de solução estacionária obtida. Por esse motivo, é preciso incorporar informação do diagrama de bifurcação para melhorar a seleção dos hiperparâmetros.

Nesse sentido, uma opção é adicionar à função objetivo uma penalização quando o comportamento o tipo de solução estacionária obtida é diferente do esperado. Uma possível medida é a proporção de pontos do diagrama de bifurcação que apresentam comportamento incorreto. No entanto, fazer essa distinção para todos os pontos implicaria conhecer com precisão o ponto de bifurcação de Hopf, que estamos tentando estimar. Apesar disso, a partir dos dados históricos é possível definir facilmente uma faixa de valores de Choke ($[ck_A, ck_B]$ onde $ck_A < ck_B$) dentro da qual é esperado que esteja o ponto de bifurcação. Logo, podemos utilizar a proporção de pontos do diagrama de bifurcação fora dessa faixa, que têm o comportamento de longo prazo diferente do esperado, para penalizar a função objetivo:

$$P = \frac{x_1 + x_2}{n_1 + n_2} \quad (19)$$

x_1 : Pontos com *Choke* $< ck_a$ onde não foi predito um estado estacionário estável;

x_2 : Pontos com *Choke* $> ck_b$ onde não foi predito um comportamento estacionário oscilatório;

n_1 : Número de pontos com *choke* $< ck_a$;

n_2 : Número de pontos com $choke > ck_b$.

Portanto, na função objetivo é possível adicionar um termo utilizando essa proporção, P , multiplicada por um peso, w , para regular a importância em relação ao MAE:

$$L = MAE + w P \quad (20)$$

O valor mais adequado do peso, w , não é conhecido *a priori*, motivo pelo qual foram testados valores de $w = 300$ (na mesma ordem de magnitude do valor do MAE) e $w = 3000$. Logo, foram feitas duas otimizações (otimização II e otimização III) adicionais com essa nova função objetivo. Os diagramas de bifurcação gerados foram comparados com aquele obtido na otimização conduzida sem o termo de penalização.

Capítulo 4

Aplicação aos dados simulados

4.1. Análise exploratória

A partir das simulações realizadas com o modelo FOWM, foram obtidos um conjunto de dados de treino com 150.000 observações de 20 variáveis e um conjunto de dados de teste com 150.000 observações das mesmas variáveis. Para observar as simulações geradas, foram criados gráficos das principais variáveis utilizadas tanto para dos dados de treino quanto de validação.

A Figura 7 mostra a abertura da válvula choke, que é incrementada gradualmente em intervalos de 2%. A Figura 8, Figura 9 e Figura 10 mostram as séries temporais geradas para as variáveis m_{ga} , PDG e Ptop, que serão utilizadas posteriormente para reconstruir os diagramas de bifurcação. A partir dos gráficos, podemos observar que nas primeiras simulações, quando o valor da abertura da choke é baixo, a variabilidade dos dados também é baixa. A partir de certo tempo, a variabilidade dos dados aumenta significativamente, indicando que a abertura da válvula choke superou o ponto de bifurcação de Hopf e o sistema começou a ter oscilações permanentes. É importante comentar que existem alguns pontos isolados fora da nuvem principal de pontos. Eles se devem às condições iniciais dadas, que em muitos casos estão distantes das condições estacionárias.

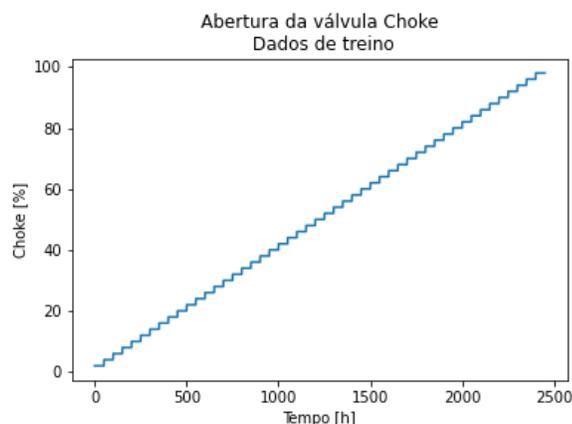


Figura 7 - Variação da Abertura da válvula Choke no tempo para os dados de treino simulados com o modelo FOWM

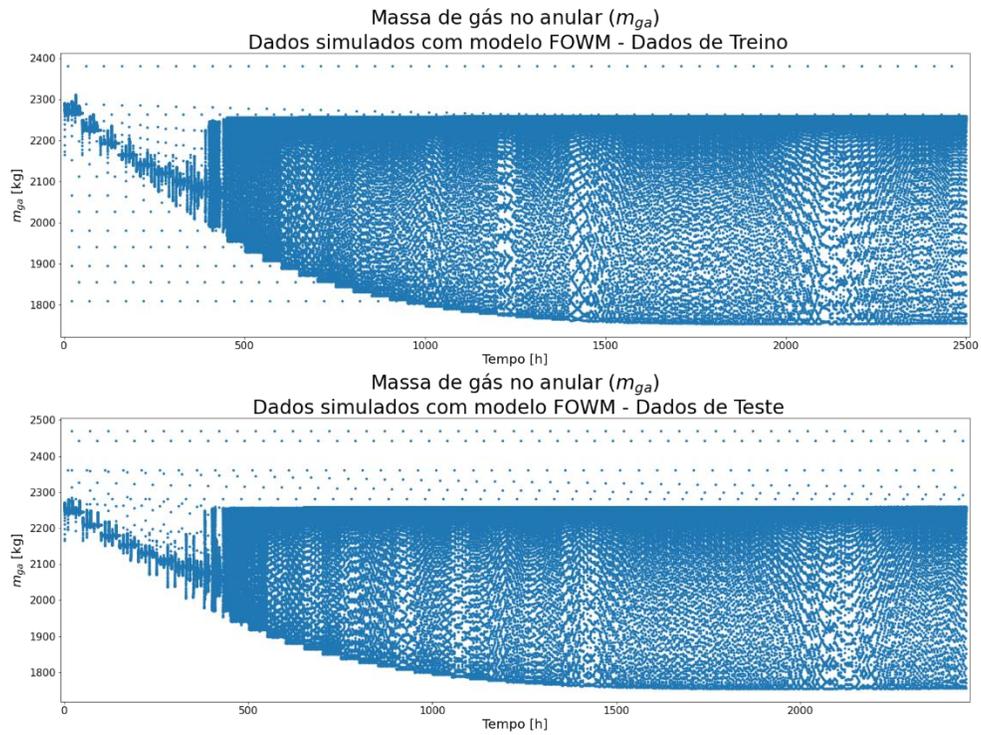


Figura 8 - Série temporal da massa de gás no anular para os dados de treino (A) e teste (B) simulados com o modelo FOWM.

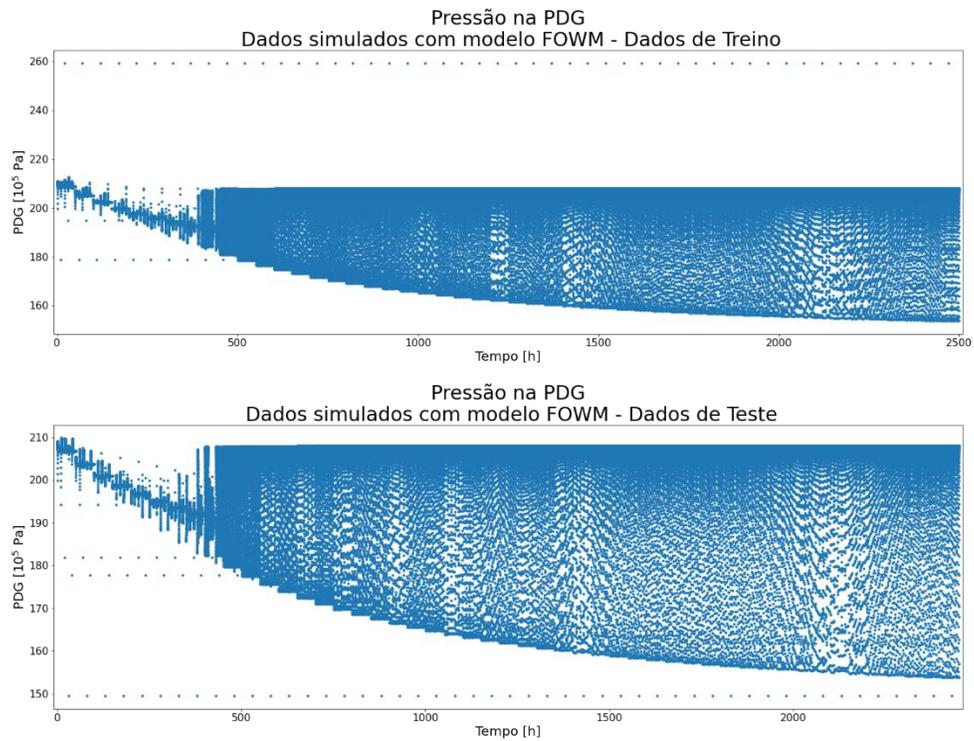


Figura 9 - Série temporal da pressão na PDG para os dados de treino (A) e teste (B) simulados com o modelo FOWM.

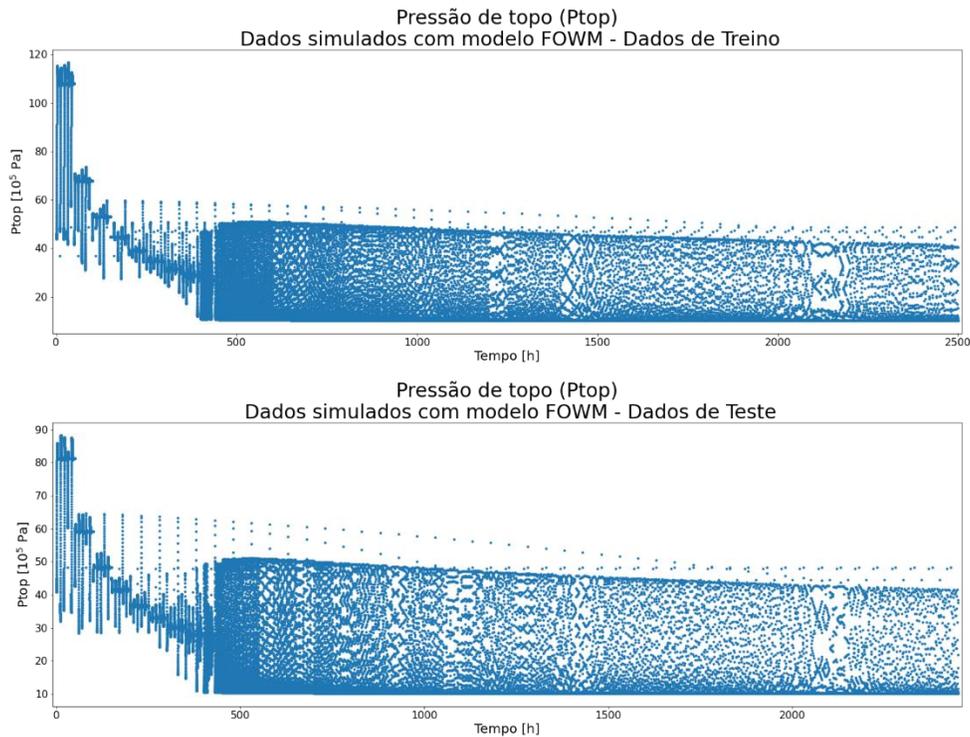


Figura 10 - Série temporal da pressão de topo (Ptop) para os dados de treino (A) e teste (B) simulados com o modelo FOWM.

4.1.1. Histogramas e *boxplots*

Para compreender a distribuição univariada das variáveis m_{ga} , PDG e Ptop, foram gerados histogramas e *boxplots* para cada uma delas (Figura 11, Figura 12 e Figura 13). Podemos observar que a distribuição de valores para a massa de gás no anular é assimétrica à esquerda, com a maior parte das observações entre 2190-2250 kg. Por esse motivo, o *boxplot* mostra uma grande quantidade de *outliers* para valores baixos dessa variável. Em particular, os dados de teste mostram alguns *outliers* para valores altos de m_{ga} , devido à escolha dos pontos iniciais.

Para a pressão na PDG, a distribuição também é assimétrica à esquerda, o que leva a um alto número de *outliers* para valores baixos de PDG no *boxplot*. Por outro lado, os gráficos para a Ptop mostram que essa variável possui uma distribuição assimétrica à direita. Essa variável tem um grupo de *outliers* separado do resto da distribuição, na região entre 105 - 115 x 10⁵ Pa, por causa das condições iniciais utilizadas em algumas das simulações.

O fato de as distribuições das variáveis serem assimétricas favorece o uso da mediana sobre a média como medida de centralidade e o uso da variação interquartil (IQR) como medida de dispersão. Por esse motivo, será aplicada uma normalização robusta das variáveis como pré-processamento para alimentar os dados às redes.

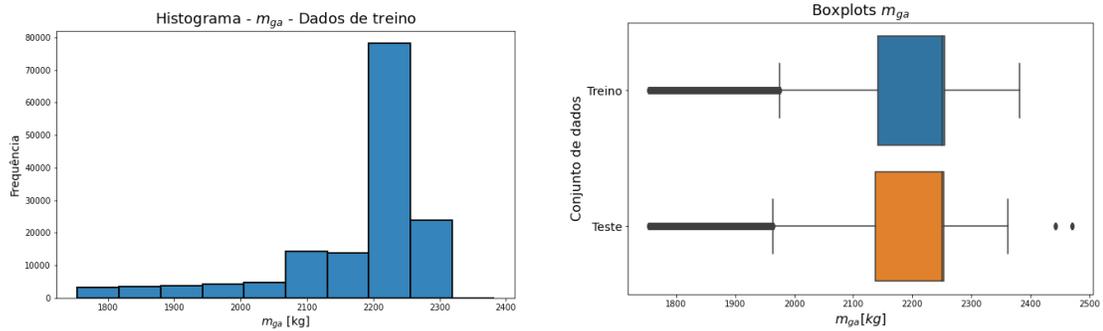


Figura 11 - Histograma e *boxplots* para a massa de gás no anular (m_{ga}) dos dados simulados.

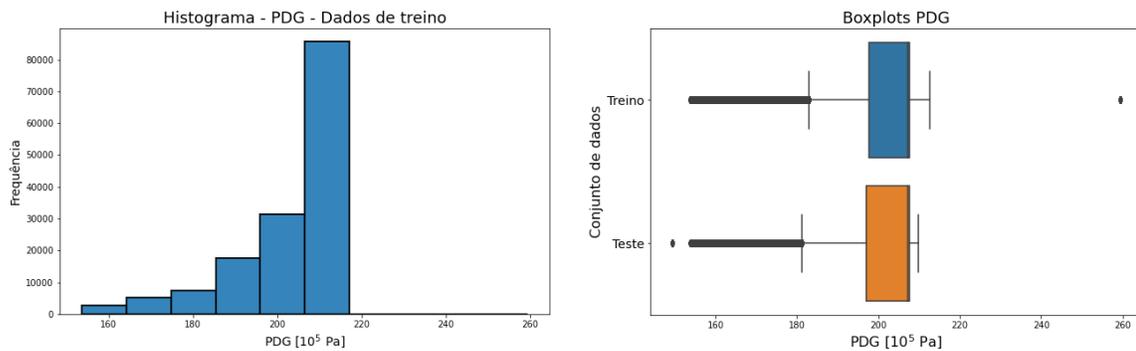


Figura 12 - Histograma e *boxplots* para a pressão na PDG dos dados simulados.

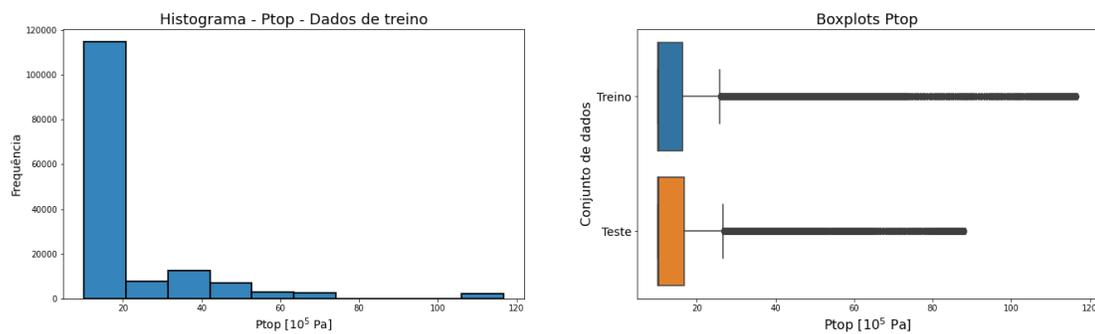


Figura 13 - Histograma e *boxplots* para a pressão na Ptop dos dados simulados.

4.1.2. Matriz de correlação

Para observar as correlações não-lineares entre as variáveis de estado e as variáveis PDG e Ptop, foi gerada uma matriz de correlação Spearman, mostrada na Figura 14. Podemos observar que a PDG tem uma forte correlação positiva com a variável m_{ga} (massa de gás no anular) e correlações moderadas com a maioria das outras variáveis de estado, com exceção de m_{gb} . A correlação da pressão na PDG com m_{ga} deve-se ao fato de que ambas medidas estão relacionadas à pressão no ponto de injeção de *gas-lift* do lado do tubo de produção. Se a pressão no fundo do poço aumenta, tanto a pressão na PDG quanto a pressão no ponto de injeção de gás aumentam, dificultando a injeção de *gas-lift*, o que gera um maior acúmulo de gás no anular.

De forma similar, a variável Ptop tem uma correlação positiva e forte com a variável m_{gr} (massa de gás no riser), o que era esperado pois no cálculo da Ptop no modelo, esta pressão é diretamente proporcional à massa de gás no riser. Também possui correlações moderadas e negativas com as variáveis m_{lr} e m_{ga} , além de uma forte correlação negativa com a válvula choke pois quanto maior for a abertura da válvula, menor a pressão no topo do riser.

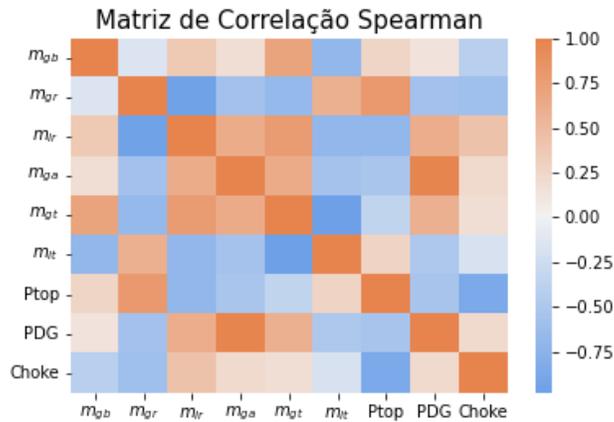


Figura 14 - Matriz de correlação Spearman para as variáveis de estado e as pressões PDG e Ptop dos dados de treino.

4.1.3. Autocorrelação

Os resultados da análise de autocorrelação para a PDG e Ptop são mostrados na Figura 15. As figuras mostram que os dados têm uma alta correlação com os pontos mais próximos (atrasos menores a 10min) e também com pontos com um atraso de aproximadamente 105 min. Essa alta correlação com valores prévios distantes indica que, quando o sistema apresenta comportamento periódico, as oscilações nas pressões têm um período médio próximo aos 105 min.

A principal diferença entre as autocorrelações para PDG e Ptop é que a correlação na Ptop é positiva e relativamente alta para valores intermediários de defasagens no tempo, entre 10 e 100 min. Pelo contrário, para a PDG, a autocorrelação para atrasos entre 18 e 80 minutos é levemente negativa. Em um sistema que só apresenta oscilações, o esperado seria encontrar autocorrelações negativas entre pontos com defasagens de meio período de oscilação. Pelo contrário, em um sistema com um comportamento linear seriam esperadas autocorrelações próximas de +1. Isto indica que, para os dados simulados, as oscilações tem uma maior influência na autocorrelação da PDG do que na Ptop.

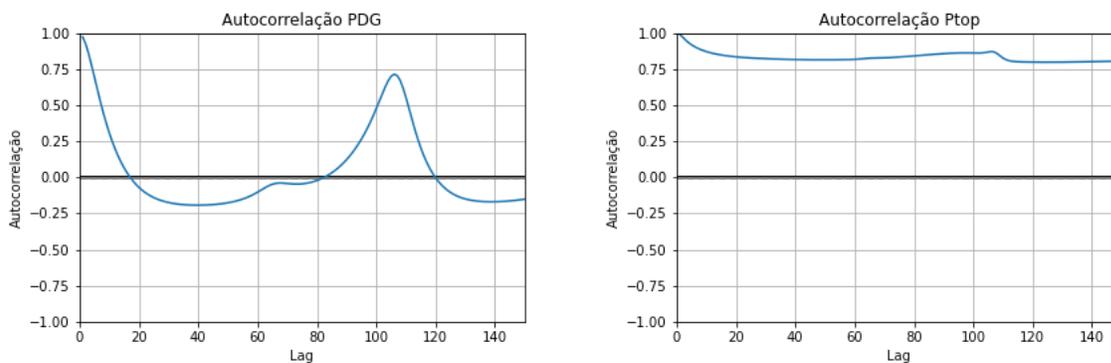


Figura 15 - Gráficos de autocorrelação para as variáveis PDG e Ptop dos dados de treino simulados com o modelo FOWM.

4.1.4. Pressões vs Choke

Para entender a forma com que a abertura da válvula choke afeta as outras variáveis, foram criados gráficos de dispersão para os dados de treino com a abertura da válvula no eixo horizontal e as variáveis m_{ga} , PDG e Ptop no eixo vertical. A Figura 16 mostra o gráfico de m_{ga} vs Choke. Podemos observar que, para valores baixos de Choke, a maior parte dos dados

está concentrada em regiões pequenas de valores de m_{ga} . O ponto médio dessas nuvens de pontos diminui ao aumentar o valor de Choke. Além disso, para uma abertura de aproximadamente 17%, os pontos começam a cobrir uma região maior, possivelmente pelo fato de o sistema apresentar oscilações permanentes. O valor máximo permanece constante para valores maiores a 20%, mas o valor mínimo continua diminuindo até uma abertura de 70% aproximadamente, a partir da qual permanece estável.

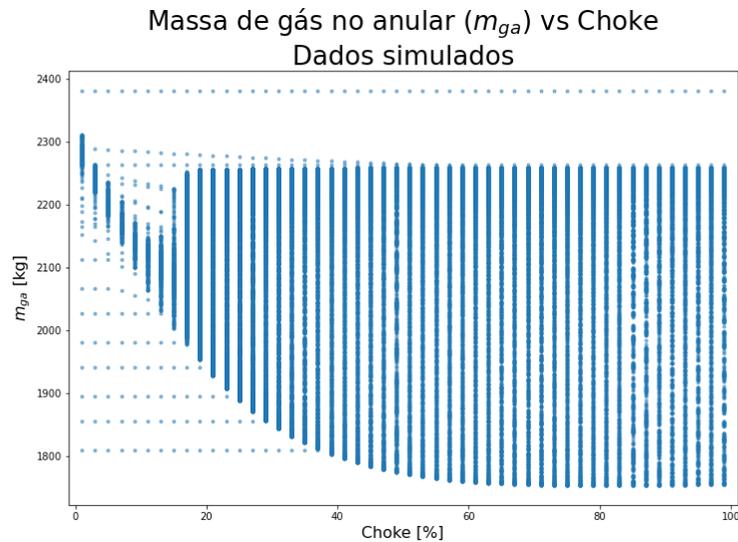


Figura 16 - Gráfico de dispersão da massa de gás no anular vs abertura da válvula choke para os dados de treino simulados com o modelo FOWM.

A Figura 17 mostra o gráfico de dispersão de PDG vs Choke. O gráfico é similar ao obtido para a variável m_{ga} , com a mesma mudança de comportamento por volta de 17%, indicando a presença do ponto de bifurcação de Hopf nesse valor de Choke. Em particular, existem alguns pontos iniciais que estão relativamente longe do resto, com um valor de PDG de aproximadamente 260×10^5 Pa.

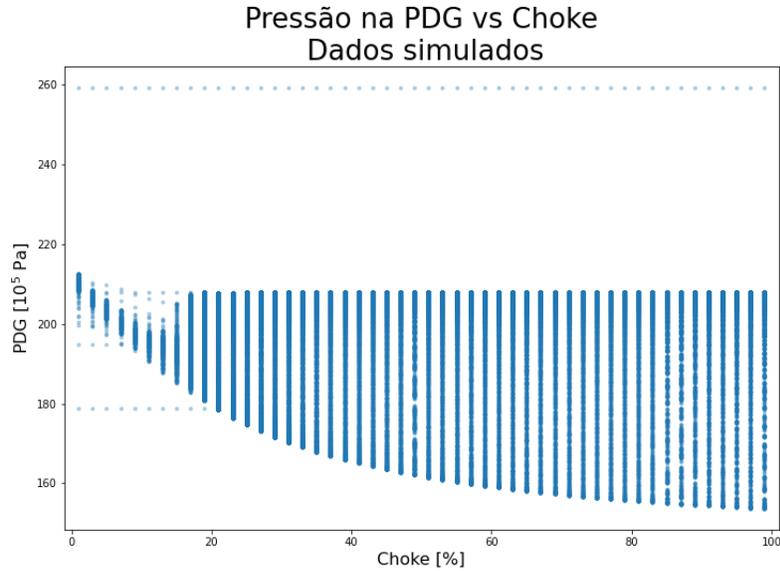


Figura 17 - Gráfico de dispersão da pressão na PDG vs abertura da válvula choke para os dados de treino simulados com o modelo FOWM.

O gráfico de P_{top} vs Choke, mostrado na Figura 18, apresenta resultados similares às das outras duas variáveis. No entanto, nesse caso não é tão clara a mudança de comportamento após o ponto de bifurcação de Hopf. Além disso, para valores baixos de Choke, o sistema apresenta pontos em uma ampla região de P_{top} , possivelmente por causa de grandes oscilações durante o transiente.

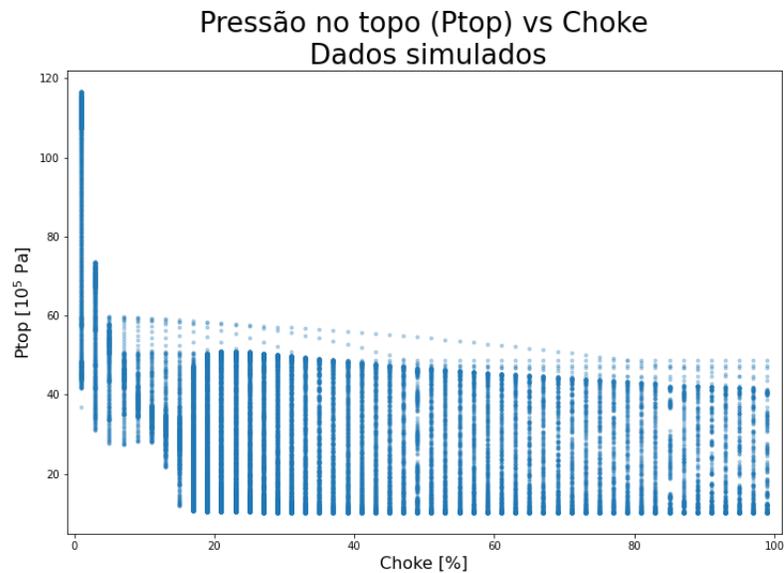


Figura 18 - Gráfico de dispersão da pressão P_{top} vs abertura da válvula choke para os dados de treino simulados com o modelo FOWM.

Portanto, os gráficos mostram que, para valores baixos de Choke, existe uma diminuição não linear das pressões quando a abertura da válvula choke aumenta. Também existe uma mudança de comportamento quando a abertura da válvula é de aproximadamente igual a 17%, indicando a presença do ponto de bifurcação de Hopf.

4.2. Seleção e treinamento das redes

Para selecionar as redes utilizadas na análise presente, foram feitas diversas análises prévias, testando diferentes combinações de tamanho das redes, número de defasagens no tempo e dos hiperparâmetros da rede. As principais observações que foram obtidas a partir dessas análises são:

- Não foi simples determinar um conjunto de hiperparâmetros adequado para conseguir reproduzir o diagrama de bifurcação. Na maioria dos casos, são obtidos diagramas de bifurcação sem oscilações, onde as redes atingem o equilíbrio estável para todos os valores de choke. Heuristicamente, foi observado que as oscilações são mais comuns com um número significativo de defasagens no tempo (mais de 10 defasagens para os dados simulados) e um número de neurônios entre 50 e 150 por camada.

- A adição de camadas nas redes ANN e LSTM levou a diagramas de bifurcação mais complexos e pouco representativos. Por esse motivo, foi utilizada uma única camada para essas redes.

- O uso das funções de ativação *tanh* e ReLU teve resultados similares em termos de métricas, mas, em alguns casos, ao realizar as iterações com redes com função de ativação ReLU, os resultados divergiam para $\pm\infty$, em vez de atingir um estado estacionário estável. Por esse motivo, foi utilizada a função de ativação *tanh*.

Finalmente, para poder comparar os resultados para as diferentes redes, o mesmo número de neurônios por camada (100 neurônios) e mesma função de ativação (*tanh*) foi escolhido em todas as redes. As redes foram treinadas com os dados de treino, como foi indicado na metodologia.

4.3. Predições para os dados de teste

Após o treinamento a qualidade das predições das redes ANN, LSTM e LSTM ED foi comparada com base em duas métricas, o erro absoluto médio (MAE) e o erro quadrático médio (MSE), para os dados de teste. Os resultados das redes também foram comparados com uma predição simples, que assume que o valor futuro será igual ao atual, para estabelecer uma base de comparação para as predições. A Tabela 5 apresenta os resultados obtidos para as redes testadas.

Tabela 5 - Métricas para as predições de três variáveis nos dados de teste utilizando diferentes redes neuronais.

	ANN convencional		LSTM		LSTM ED		Predição simples	
	MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE
m_{ga}	10.260	2.247	1.394	0.994	1.177	0.738	8.143	3.814
PDG	1.420	0.470	0.155	0.302	0.186	0.274	0.799	0.602
Ptop	1.973	2.869	0.180	0.333	0.332	0.258	0.609	0.923

Para a variável de estado m_{ga} , podemos observar que a rede ANN convencional apresentou um erro significativamente maior que as outras duas redes nas duas métricas, e que o erro absoluto médio foi maior que a predição simples. No entanto, tanto a rede LSTM como a LSTM ED conseguiram uma melhora no MAE e MSE em relação à predição simples, sendo que a rede que conseguiu o melhor resultado foi a LSTM ED.

De forma similar, para a pressão na PDG, a ANN apresentou um erro maior que as outras redes, enquanto as redes LSTM e LSTM ED levaram a melhores resultados do que a predição simples. A principal diferença com o caso anterior foi que a rede LSTM levou a um resultado melhor do que a rede LSTM ED.

Finalmente, para a pressão na Ptop, a ANN convencional continuou tendo o pior resultado, com erros maiores do que a predição simples. Os modelos LSTM e LSTM ED levaram a resultados similares, com a LSTM permitindo obter um valor de MAE menor, mas um valor de MSE maior do que a rede LSTM ED.

Portanto, podemos ver que as redes com neurônios LSTM se mostraram significativamente melhores nas predições do que a rede ANN convencional. Além disso, melhoraram o resultado da predição simples, indicando que o uso dessas redes poderia ser

útil para melhorar as previsões de curto prazo dessas variáveis. A grande dificuldade das redes ANN convencionais nessa aplicação está associada à incapacidade de representar adequadamente a relação temporal entre as variáveis. Estas redes não consideram as entradas como uma sequência, mas como variáveis independentes, além de não poder utilizar diretamente a informação das previsões prévias para melhorar as previsões seguintes.

4.4. Iterações a partir das redes

A reconstrução dos diagramas de bifurcação foi feita realizando iterações a partir das redes. Para iniciar cada iteração, é necessária uma condição inicial, com os valores das defasagens no tempo da abertura da válvula choke e da variável a prever. Para entender se essa condição inicial pode afetar o diagrama de bifurcação, foram realizados alguns testes a partir de diferentes condições iniciais. Para o caso da rede LSTM ED com 100 neurônios utilizada na reconstrução do diagrama, o resultado obtido é mostrado na Figura 19. Podemos observar que a condição inicial não afetou o estado estacionário quando a abertura da choke era 10% ou 50%. Para o caso com Choke a 10%, em todos os casos a rede atingiu o mesmo estado estacionário após 200 iterações. Já para o caso com Choke a 50%, em todos os casos, após 50 iterações, a PDG oscilou com a mesma amplitude.

No entanto, as redes geradas não garantem que a solução estacionária seja única para todas as condições iniciais, isto é, o sistema pode ter mais de um atrator. De fato, foram observados alguns casos, como na Figura 20, em que o sistema atingiu mais de um estado estacionário, a depender da condição inicial. Ainda mais, a solução obtida para o primeiro ponto inicial foi estacionária, enquanto para os pontos iniciais 2 e 3, a solução foi oscilatória. Por esses motivos, é relevante levar em consideração a variação do comportamento estacionário da rede com a condição inicial na hora de escolher a melhor rede para reconstruir o diagrama de bifurcação.

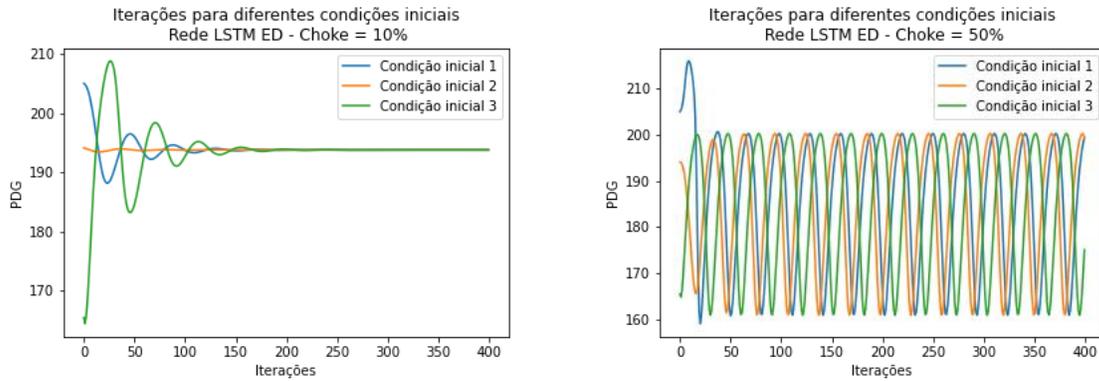


Figura 19 - Iterações a partir de uma rede LSTM ED com 100 neurônios utilizando três condições iniciais diferentes para a variável PDG.

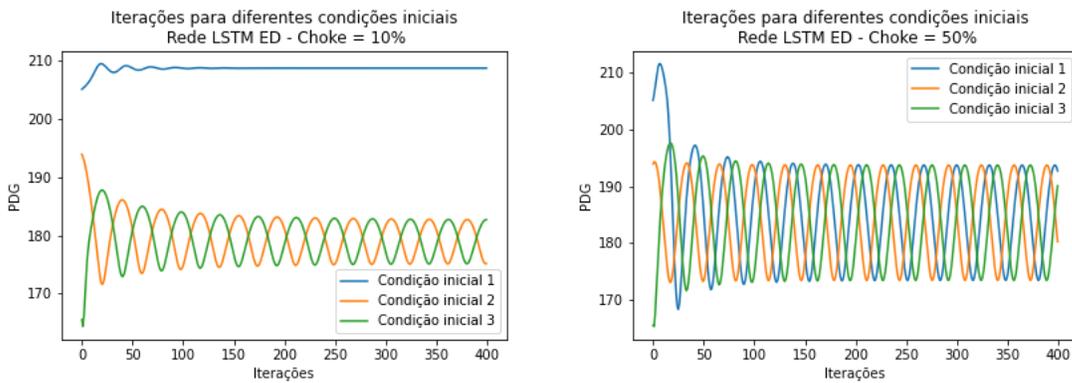


Figura 20 - Iterações a partir de rede LSTM ED com 20 neurônios utilizando três condições iniciais diferentes para a variável PDG.

4.5. Diagramas de bifurcação

Uma vez treinadas as redes e obtidas as iterações para diferentes valores de Choke, foram construídos os diagramas de bifurcação para as variáveis analisadas. Na Figura 21, Figura 22 e Figura 23, podemos observar os diagramas de bifurcação para a variável m_{ga} utilizando as redes ANN convencional, LSTM e LSTM ED, respectivamente. A partir das figuras, é possível ver que todas as redes conseguiram gerar um comportamento oscilatório, embora nem sempre de forma adequada. O diagrama gerado com a rede ANN convencional mostrou, inadequadamente, oscilações na região de baixos valores de Choke, onde deveriam ser observados estados estacionários estáveis. Além disso, os valores de máximos e mínimos para essas oscilações estão longe dos pontos simulados, indicando que a rede teve um comportamento inadequado no longo prazo. No entanto, para aberturas da válvula choke

maiores a 40%, o diagrama de bifurcação mostrou-se mais adequado, com os valores máximos e mínimos próximos aos dos valores esperados.

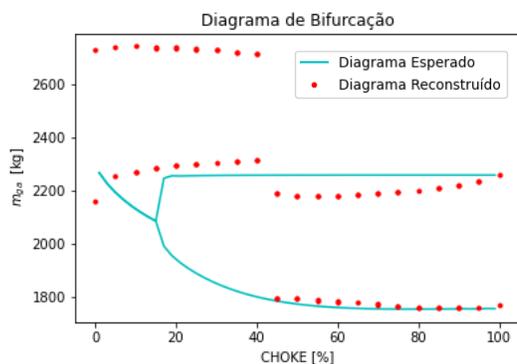


Figura 21 - Diagrama de bifurcação para m_{ga} reconstruído com rede ANN convencional

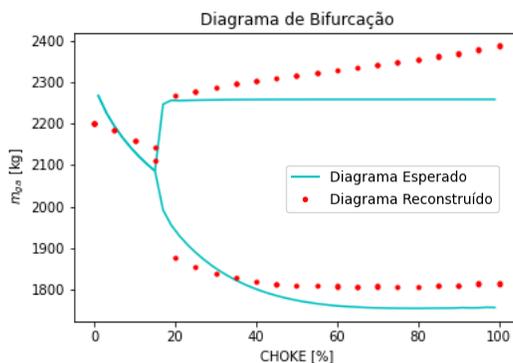


Figura 22 - Diagrama de bifurcação para m_{ga} reconstruído com rede LSTM

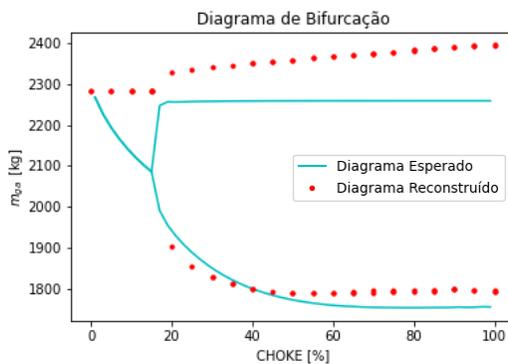


Figura 23 - Diagrama de bifurcação para m_{ga} reconstruído com rede LSTM ED

Os diagramas de bifurcação para as redes LSTM e LSTM ED foram similares. Os dois modelos identificaram uma mudança de comportamento das soluções na abertura esperada para o ponto de bifurcação de Hopf, com estados estacionários estáveis para valores

baixos de Choke. Na região oscilatória, os dois modelos geraram gráficos com uma boa aproximação para os valores mínimos, embora levemente superiores ao valor esperado. Para os valores máximos, os dois diagramas mostraram valores maiores que os esperados, com um aumento no valor do máximo ao aumentar a abertura da válvula. A principal diferença entre os dois diagramas é que aquele gerado com a rede LSTM representou melhor os estados estacionários para valores baixos de abertura da válvula. Nesses casos, a rede LSTM ED levou a valores muito altos e quase constantes no valor de m_{ga} , em vez de observar a diminuição esperada dessa variável ao aumentar a abertura da válvula. Portanto, os diagramas de bifurcação para a variável m_{ga} mostraram que as redes LSTM e LSTM ED permitiram encontrar adequadamente o ponto de bifurcação de Hopf, mas tiveram algumas dificuldades para identificar corretamente o valor adequado dos estados estacionários.

Para a pressão na PDG, os diagramas de bifurcação gerados são mostrados na Figura 24, Figura 25 e Figura 26. Podemos observar que o diagrama gerado a partir da rede ANN levou novamente ao pior resultado, com o mesmo comportamento oscilatório em valores maiores que os esperados quando a abertura da choke é menor a 40%. Após esse valor, o diagrama melhora consideravelmente, com valores máximos e mínimos próximos aos valores esperados.

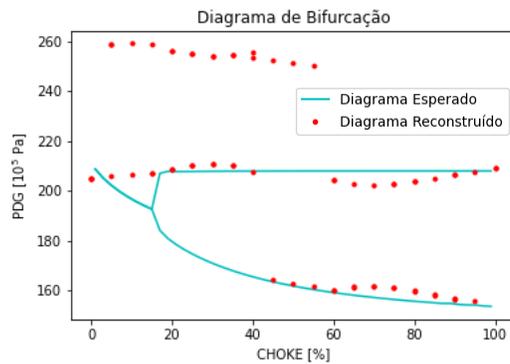


Figura 24 - Diagrama de bifurcação para a pressão na PDG reconstruído com rede ANN convencional

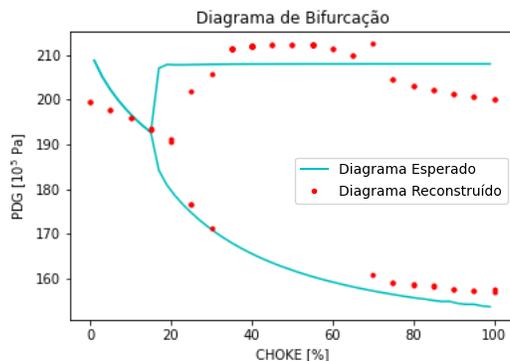


Figura 25 - Diagrama de bifurcação para a pressão na PDG reconstruído com rede LSTM

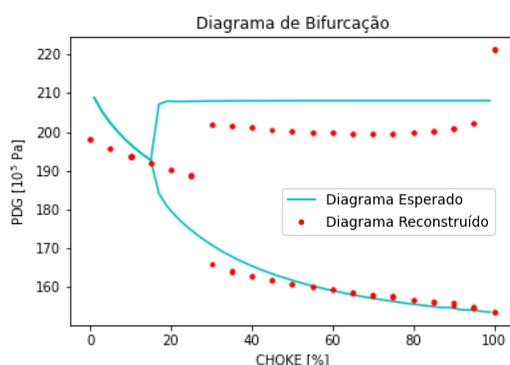


Figura 26 - Diagrama de bifurcação para a pressão na PDG reconstruído com rede LSTM ED

O diagrama gerado com a rede LSTM mostrou um comportamento estacionário para valores baixos de Choke similar ao esperado, até obter uma bifurcação de Hopf. No entanto, o ponto de bifurcação de Hopf obtido, próximo ao 21%, foi maior que o esperado, que era de 17%. Além disso, o diagrama apresentou um comportamento inadequado para valores de Choke entre 30% e 70%, onde apresentou um estado estacionário estável, em vez de oscilar. Para valores de Choke maiores, o diagrama apresenta novamente oscilações, com um valor similar ao esperado, embora com uma amplitude levemente menor.

No diagrama construído a partir da rede LSTM ED, podemos observar um comportamento estacionário até uma abertura de válvula de 30%, onde observou-se um ponto de bifurcação de Hopf. Cabe destacar que os estados estacionários obtidos não foram exatos, mas mostraram a tendência esperada. A partir do ponto de bifurcação de Hopf, o diagrama apresentou oscilações, com valores mínimos muito similares aos esperados e valores máximos levemente menores.

Finalmente, os diagramas para a pressão na Ptop são mostrados na Figura 27,

Figura 28 e Figura 29. Os resultados não foram adequados aos dados simulados para nenhuma das redes utilizadas. Para o caso da ANN convencional, o diagrama mostrou inadequadamente oscilações com valores negativos de P_{top} , além de mostrar um comportamento estacionário para valores altos de Choke. O diagrama gerado com a rede LSTM levou a um comportamento razoável para valores baixos de Choke, mas enfrentou problemas para valores de Choke maiores ao ponto de bifurcação de Hopf, com estados estacionários estáveis para Choke entre 30% e 50% e oscilações com baixa amplitude para valores altos de Choke. Por último, o diagrama obtido a partir da rede LSTM ED não apresentou oscilações e apresentou um valor muito alto de P_{top} para os estados estacionários, quando a abertura de Choke foi menor que o ponto de bifurcação de Hopf. Para valores maiores de Choke, o estado estacionário obtido estava próximo aos valores mínimos esperados para as oscilações. Dessa forma, podemos observar que a metodologia implementada teve grandes dificuldades para gerar diagramas adequados para a variável P_{top} .

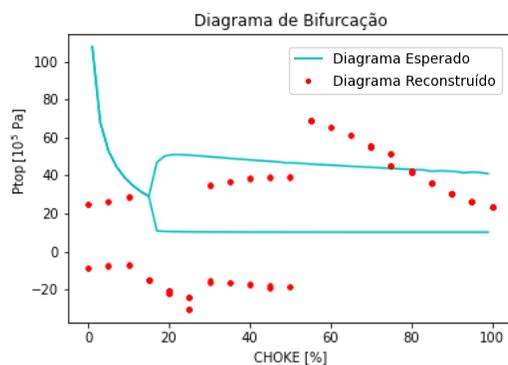


Figura 27 - Diagrama de bifurcação para a pressão P_{top} reconstruído com rede ANN convencional

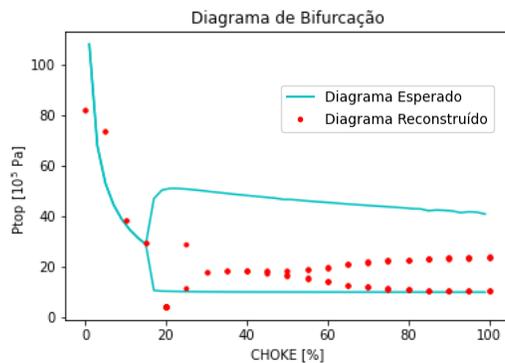


Figura 28 - Diagrama de bifurcação para a pressão P_{top} reconstruído com rede LSTM

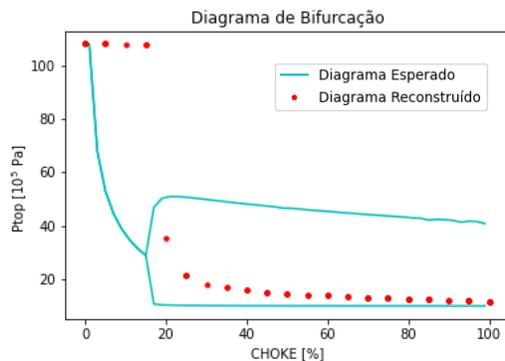


Figura 29 - Diagrama de bifurcação para a pressão P_{top} reconstruído com rede LSTM ED

Para tentar entender os motivos pelo qual a pressão P_{top} apresentou maior dificuldade na geração do diagrama de bifurcação, foi gerada a Figura 30 (a), mostrando um exemplo de oscilações da P_{top} para um valor de choke de 29%. É possível observar que as oscilações aparecem repentinamente após um período onde a pressão permanece relativamente constante. Por esse comportamento, é provável que a rede não seja o suficientemente sensível para reproduzir as pequenas variações nos dados de entrada que levam ao surgimento das oscilações.

Analisando com maior detalhe os dados do exemplo, como mostrado na Figura 30 (b), durante as oscilações existe um período de 16 min onde a pressão é de $10,31 \times 10^5$ Pa, após o qual permanece por 3 min a $10,32 \times 10^5$ Pa antes de começar um aumento drástico da pressão, que em 8 min atingem um máximo que supera os 50×10^5 Pa. Assim, ao treinar as redes existem mais exemplos onde o valor a predizer é próximo ao inicial, do que exemplos com as oscilações. Possivelmente esse também é o motivo da alta autocorrelação observada para essa variável. Logo, quando a rede itera para gerar um ponto do diagrama de bifurcação, atinge um estado estacionário em vez de oscilar.

Em resumo, os resultados para a reconstrução do diagrama de bifurcação utilizando dados simulados pelo FOWM indicaram que a escolha da variável a analisar é importante, assim como a escolha da rede neural utilizada para as predições. Foram obtidos resultados razoáveis para a variável de estado, m_{gb} e a pressão na PDG, mas a metodologia não conseguiu levar a bons resultados para a pressão P_{top} . Além disso, as redes LSTM e LSTM ED se mostraram mais adequadas do que as redes ANN convencionais para obter boas predições no curto prazo e um bom diagrama de bifurcação. Isso mostra que as redes

recorrentes conseguem melhorar as previsões, pois as previsões prévias modificam as previsões futuras, o que permite à rede aprender a relação temporal das variáveis utilizadas.

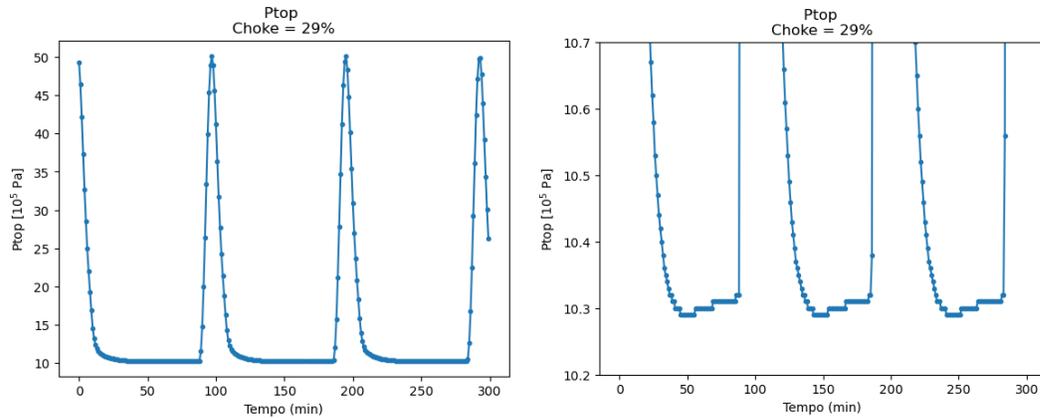


Figura 30 - Oscilações da pressão P_{top} para uma abertura da válvula choke de 29%. Na figura (a) é mostrada a escala completa e na figura (b) são mostrados os valores de pressão entre 10,2 e 10,7 10^5 Pa.

A determinação do ponto de bifurcação de Hopf foi boa para a variável m_{ga} , mas apresentou um desvio para as pressões, mostrando o ponto de bifurcação a valores de Choke maiores que o esperado. Isto pode representar uma dificuldade nos casos reais, pois no sistema não é possível medir diretamente a variável de estado m_{ga} . Logo, a técnica mostrou resultados promissores para a reconstrução do diagrama de bifurcação, especialmente utilizando redes com neurônios LSTM, mas apresenta algumas dificuldades na determinação do ponto de Hopf.

Vale destacar também que, durante a determinação da arquitetura e hiperparâmetros das redes para a realização dessa análise, foi possível observar variações significativas nos diagramas de bifurcação gerados, segundo o número de neurônios utilizados ou o número de estados prévios escolhido. Por esse motivo, seria conveniente contar com uma forma automatizada para escolher os hiperparâmetros, de modo a gerar o melhor diagrama de bifurcação.

Capítulo 5

Aplicação aos Dados Reais – Resultados e Discussões

5.1. Análise Exploratória

O conjunto de dados analisado consiste em dados históricos de 3 anos de operação, obtidos de um sistema de produção de petróleo *offshore*. As três variáveis que foram utilizadas nesse trabalho são a abertura da válvula choke, a pressão na PDG e a pressão no topo do *riser* (P_{top}). As Figura 31, Figura 32 e Figura 33 mostram o comportamento dessas variáveis ao longo do tempo.

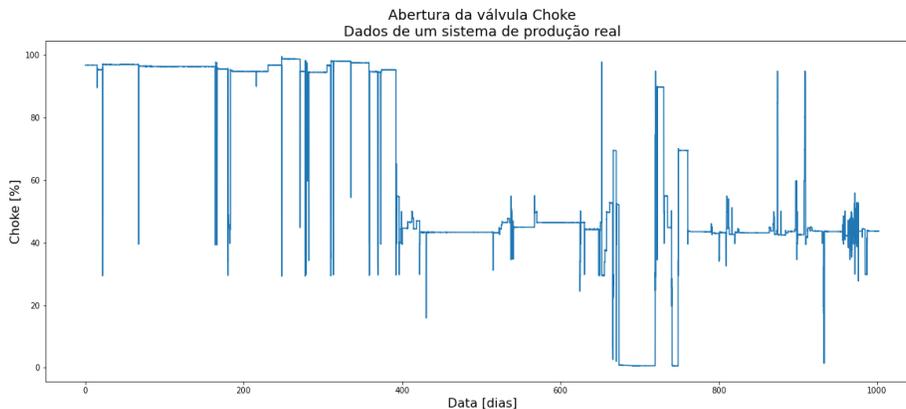


Figura 31 - Variação da abertura da válvula Choke no tempo para o sistema de produção real analisado.

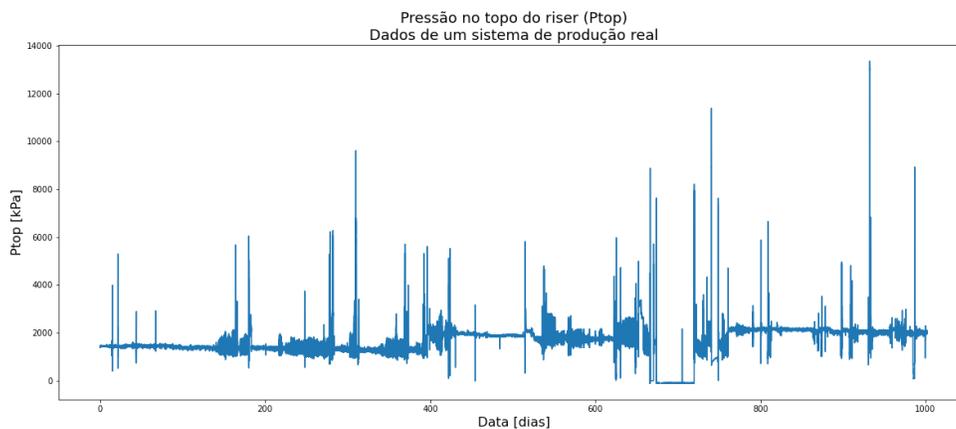


Figura 32 - Variação da abertura da pressão no topo do *riser* (P_{top}) no tempo para o sistema de produção real

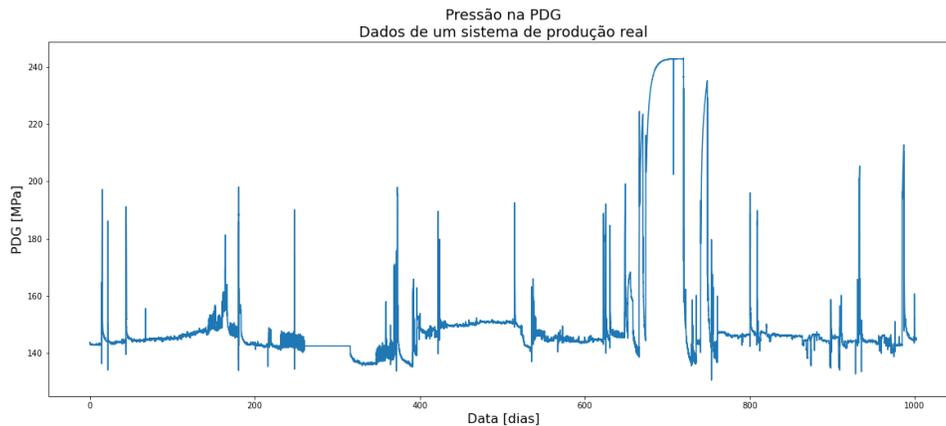


Figura 33 - Variação da abertura da pressão na PDG no tempo para o sistema de produção real analisado.

Também foram gerados histogramas e *boxplots* para compreender a distribuição das pressões PDG e Ptop no conjunto de dados completo (ver Figura 34). Podemos observar que ambas as variáveis apresentaram uma distribuição assimétrica à direita, com um número significativo de *outliers* para valores altos de pressões. Devido a essa assimetria, durante o pré-processamento dos dados é melhor utilizar a normalização robusta, que considera a mediana como medida de centralidade.

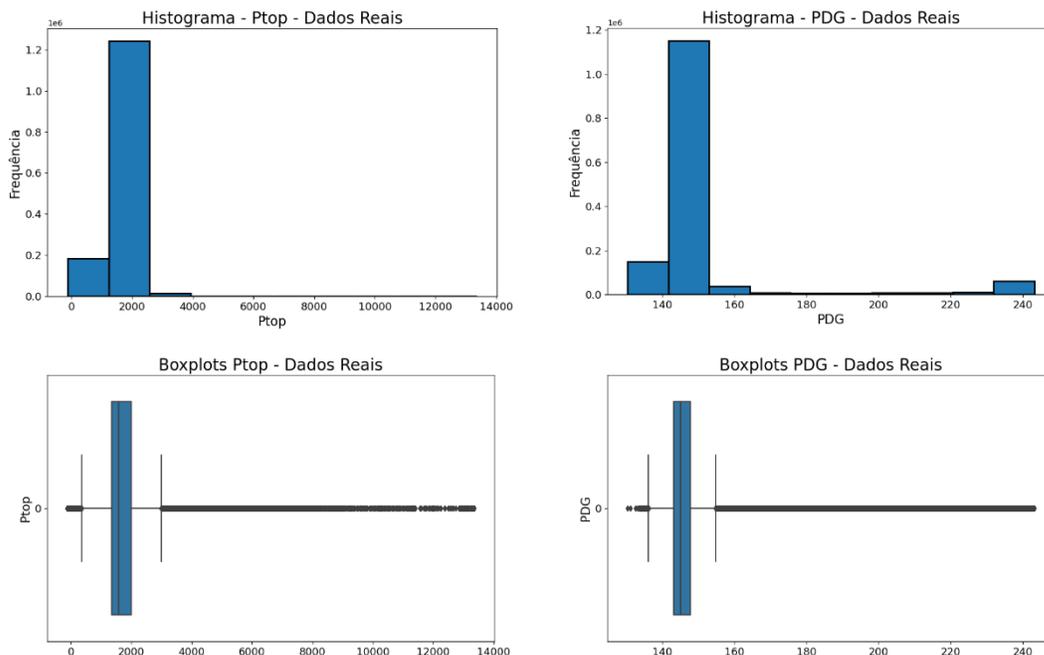


Figura 34 – Histogramas e *boxplots* das variáveis Ptop e PDG para os dados reais

Para analisar a relação entre a abertura da válvula choke e as pressões, foram gerados gráficos de dispersão. Na Figura 35(a), o gráfico de P_{top} vs Choke mostra que a pressão pode atingir valores altos para aberturas de choke entre 20% e 60%, mas que a pressão máxima diminui ao aumentar a abertura da válvula. Após abertura de cerca de 60%, a faixa de pressões fica relativamente constante. O gráfico de PDG vs Choke, mostrado na Figura 35(b), não apresenta uma tendência clara, embora seja possível observar algumas pressões maiores para valores baixos de abertura da válvula.

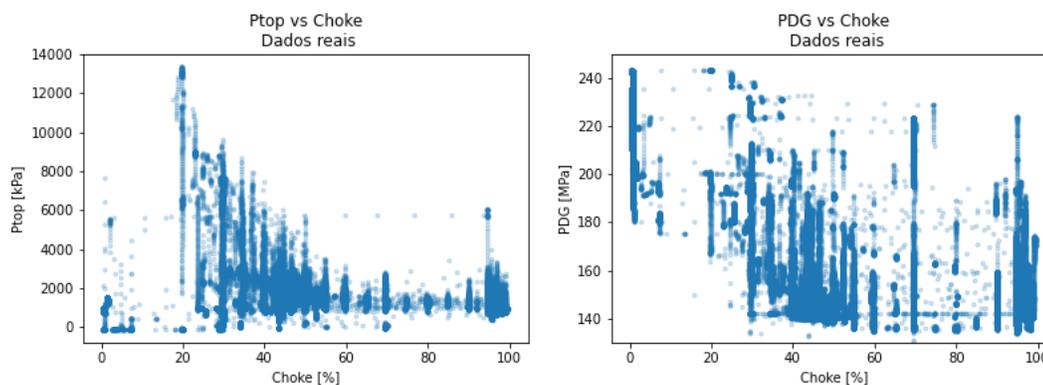


Figura 35 - Diagramas de dispersão (a) P_{top} vs Choke (b) PDG vs Choke para os dados reais.

Outra forma de analisar se existe uma relação não-linear entre essas variáveis é avaliar uma matriz de correlação Spearman, como mostrado na Figura 36. A matriz mostra que existe uma correlação moderada e negativa entre a abertura da válvula choke e a pressão na PDG, assim como entre a abertura da válvula e a P_{top} . Logo, é possível observar que a pressão no sistema geralmente diminui ao incrementar a abertura da válvula, devido ao aumento da vazão de fluidos que saem do sistema. Além disso, a correlação entre as duas pressões é fraca e positiva quando o esperável seria uma correlação moderada ou forte entre essas variáveis. Essa discrepância pode ser ocasionada pelo grande período considerado, o qual contém diferentes situações operacionais (poço fechado, períodos de teste e outros) que alteram temporariamente a relação entre as pressões, reduzindo o valor final da correlação.

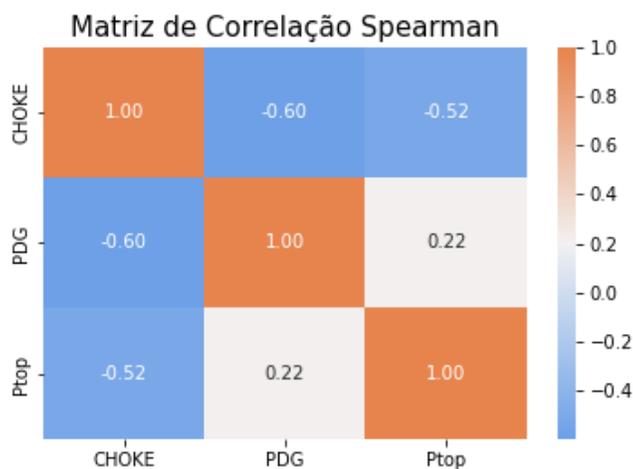


Figura 36 - Matriz de correlação Spearman para os dados reais

5.2. Seleção de períodos

Ao analisar o conjunto de dados completo, é possível observar variações significativas nas regiões de operação. Essas mudanças podem afetar a capacidade das redes de representar adequadamente os dados, além de incluir condições que não são úteis para a análise. Por esse motivo, foi decidido treinar as redes utilizando intervalos de tempos menores, onde as condições de operação fossem mais estáveis, sem grandes perturbações na vazão de *gas-lift* ou devido à abertura de outras válvulas do sistema. Além disso, os períodos escolhidos se caracterizam por apresentarem golfadas, o que permite ter um número significativo de medições com oscilações.

A Figura 37(a) mostra a variação na Ptop no período I. Podemos observar que existem oscilações com uma grande amplitude, de quase 1000 kPa, e alguns períodos de curta duração sem oscilações. Também podemos observar que a pressão aumenta significativamente na transição, desde as situações em que o sistema está oscilando a quando ele atinge um estado estacionário mais estável, possivelmente pelo fechamento rápido da válvula choke. De forma similar, o período II, na Figura 37(b), mostra uma grande quantidade de oscilações combinadas com alguns breves períodos sem golfadas. Finalmente, na Figura 37(c), é possível ver que no período III a Ptop é mais estável que nos casos anteriores, mas apresenta alguns períodos com oscilações.

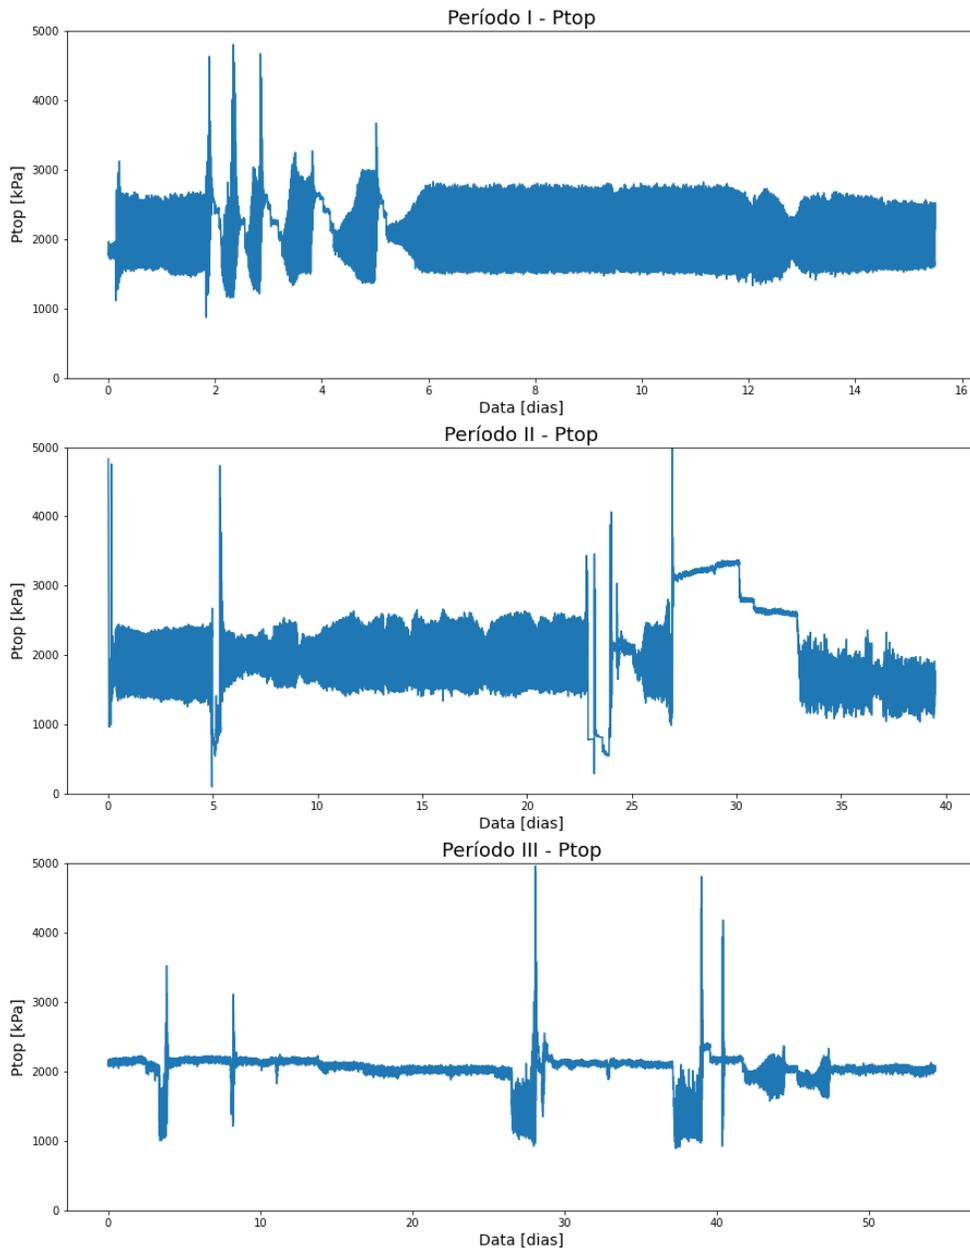


Figura 37 - Variação na pressão Ptop para (a) o período I, (b) período II e (c) período III

Para esses três períodos, foram gerados também histogramas e *boxplots* para as pressões na Ptop e PDG (ver Figura 38 e Figura 39). Podemos observar que em todos os casos as duas pressões apresentam uma distribuição assimétrica à direita, embora com uma distorção menor que a encontrada para o conjunto de dados completo.

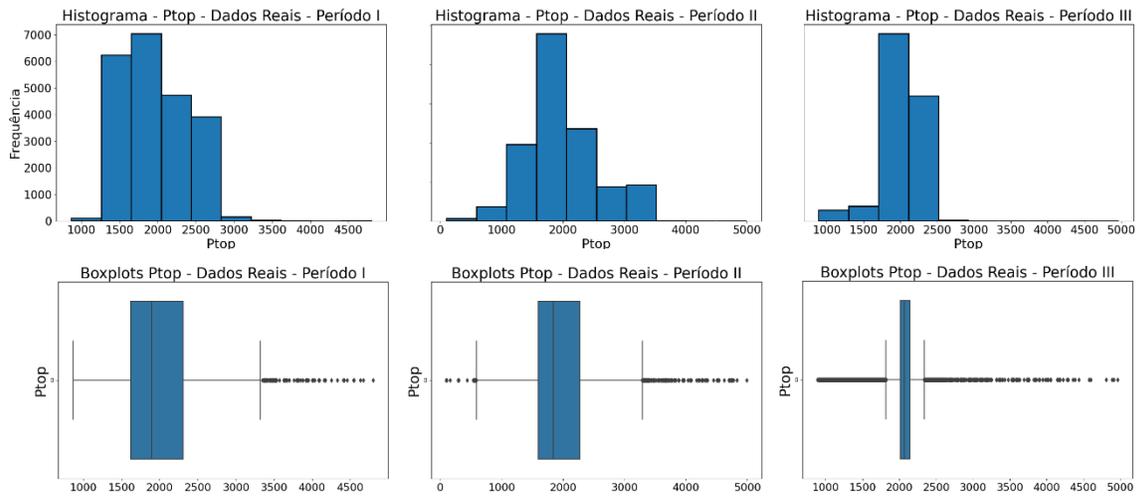


Figura 38 - Histogramas e *boxplots* da pressão Ptop para os três períodos analisados.

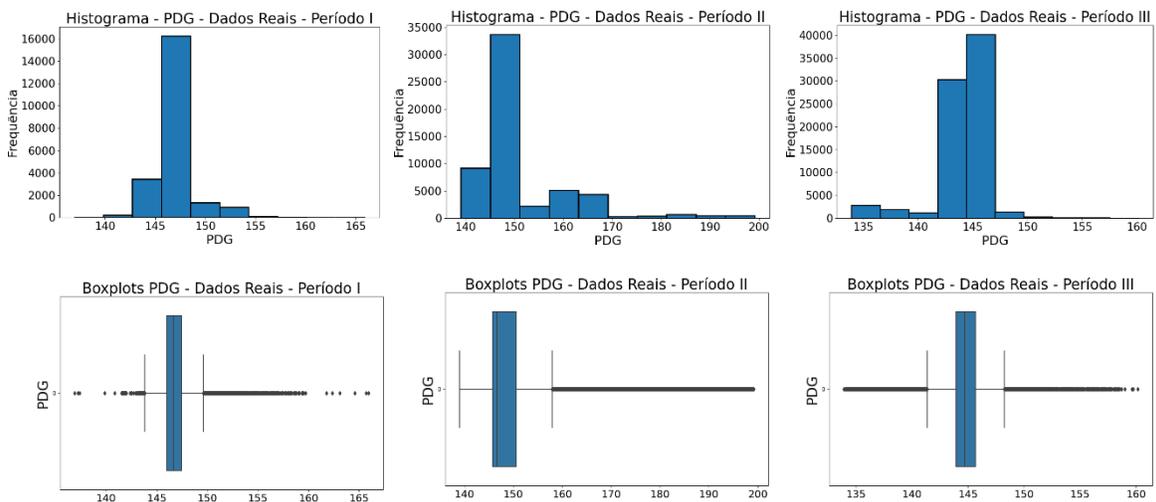


Figura 39 - Histogramas e *boxplots* para a pressão na PDG nos três períodos analisados.

Além disso, foram gerados gráficos de PDG vs Choke e Ptop vs Choke para cada período, apresentados na Figura 40 e Figura 41 respectivamente. Podemos observar que os diagramas para o período I só apresentam valores de choke até aproximadamente 60%, enquanto os outros dois conjuntos apresentam aberturas de até 100%. Em todos os casos, podemos ver uma redução na pressão ao aumentar a abertura da válvula até os 45-50%. Nos gráficos de Ptop vs Choke, pode-se perceber um aumento na variabilidade por volta de 45%, possivelmente por conta do surgimento das golfadas.

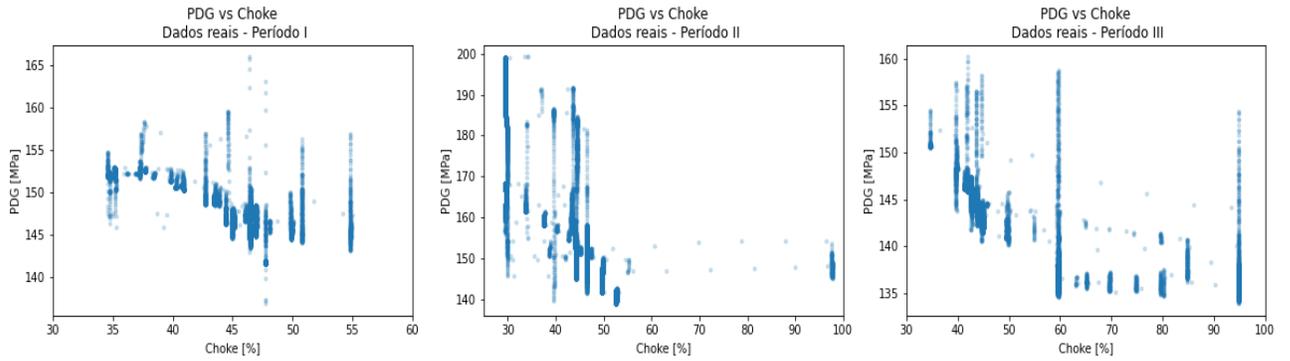


Figura 40 - Gráfico de dispersão de PDG vs Choke para os três períodos de treino utilizados.

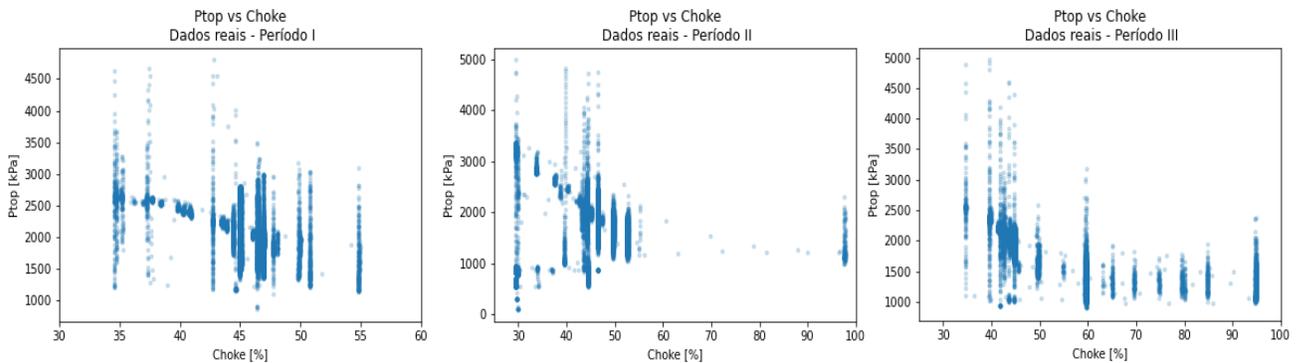


Figura 41 - Gráfico de dispersão de Ptop vs Choke para os três períodos de treino utilizados.

5.3. Treinamento das redes neuronais

As redes LSTM e LSTM ED descritas na metodologia foram treinadas utilizando cada um dos períodos analisados. Após o treino, foi feita a predição para os dados de validação e foi calculado o MAE. A Tabela 6 mostra os resultados obtidos. Podemos observar que as predições para a pressão na PDG não foram adequadas, pois a maioria das redes levou a valores de MAE maiores que os obtidos com uma predição simples. Por outro lado, para a pressão Ptop, as predições obtidas com os dois tipos de redes melhoraram significativamente a predição simples, reduzindo o valor de MAE em quase a metade. A rede LSTM levou a um resultado similar com os três períodos de treino, enquanto a rede LSTM-ED levou a um resultado melhor com o período I do que com os outros períodos.

Tabela 6 - Comparação do MAE para as predições das redes LSTM e LSTM-ED nos dados de validação para os três períodos analisados.

Dados de treino	MAE PDG [MPa]			MAE Ptop [kPa]		
	LSTM	LSTM-ED	Predição simples	LSTM	LSTM-ED	Predição simples
Período I	0.494	0.636	0.484	111.3	103.3	245.8
Período II	0.489	0.486	0.484	115.4	148.8	245.8
Período III	0.318	0.578	0.484	114.2	144.0	245.8

5.4. Diagramas de bifurcação

Uma vez treinadas as redes neuronais para os três períodos, os diagramas de bifurcação foram reconstruídos para cada um dos casos analisados. Para a pressão Ptop, os diagramas foram gerados para os dois tipos de redes, utilizando cada um dos três períodos como dados de treino (ver Figura 42).

Para esse mesmo período, a rede LSTM permitiu gerar um diagrama com um comportamento similar para valores baixos de abertura de choke, mas apresentou dificuldade de mostrar adequadamente o comportamento oscilatório. Algumas oscilações foram observadas em torno do valor de Choke de 45%, e entre 48% e 49%, mas nos pontos seguintes foi obtido um estado estacionário. A amplitude das oscilações também não foi adequada aos dados reais.

Os diagramas de bifurcação permitiram observar, também, um comportamento interessante em relação às oscilações periódicas para alguns valores de choke, onde existe mais de um valor máximo. Este comportamento apareceu tanto para a rede LSTM ED, quando a abertura da válvula choke era 46% e 52%, quanto para a rede LSTM, nos três valores de choke para os quais apresentou oscilações. A multiplicidade de valores máximos pode indicar a presença de oscilações de diferentes amplitudes nas iterações feitas com as redes ou que o número de iterações não foi suficiente para que a rede superasse o transiente inicial.

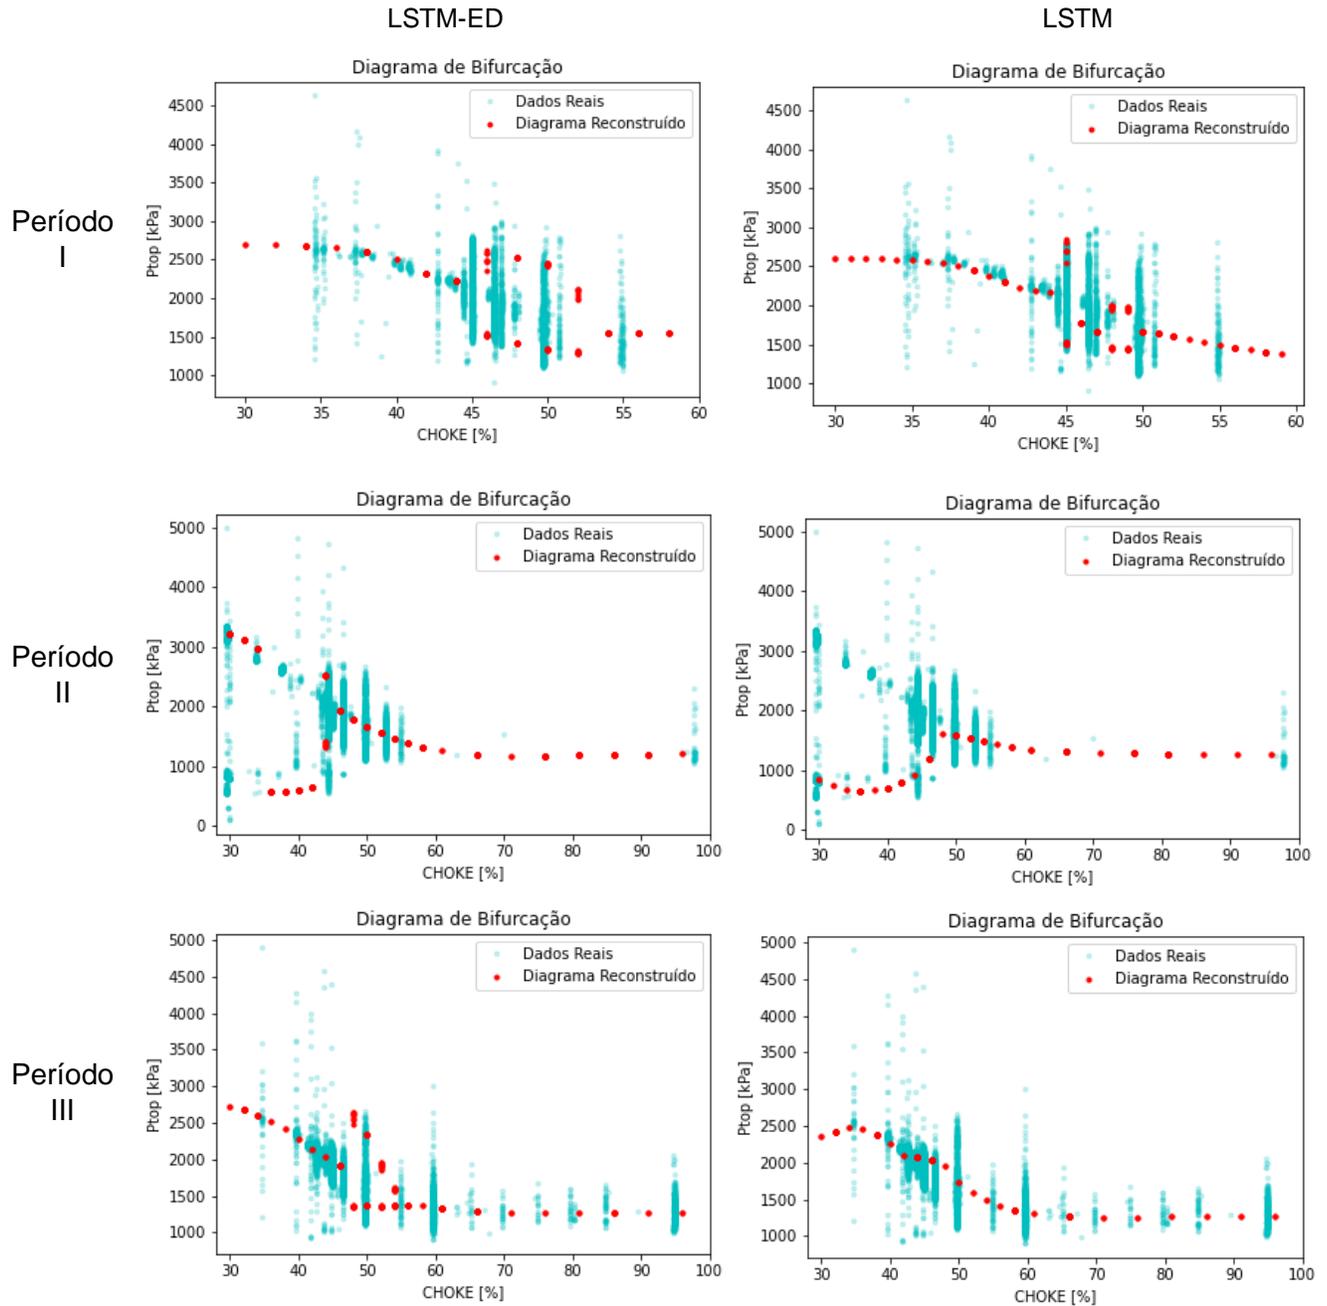


Figura 42 - Diagramas de bifurcação para a Ptop com redes LSTM ED e LSTM treinadas com os três períodos analisados

Para entender o motivo que leva a essa multiplicidade de valores máximos, são mostradas as iterações feitas com a rede LSTM ED para um valor de choke de 46% na Figura

43. É possível observar um padrão periódico complexo, que se repete após seis oscilações de diferente amplitude, indicando que o motivo não foi a falta de iterações. A partir da figura é possível ver que há múltiplos mínimos também, mas a diferença entre eles é menor, motivo pelo qual não é possível distinguir eles no diagrama de bifurcação.

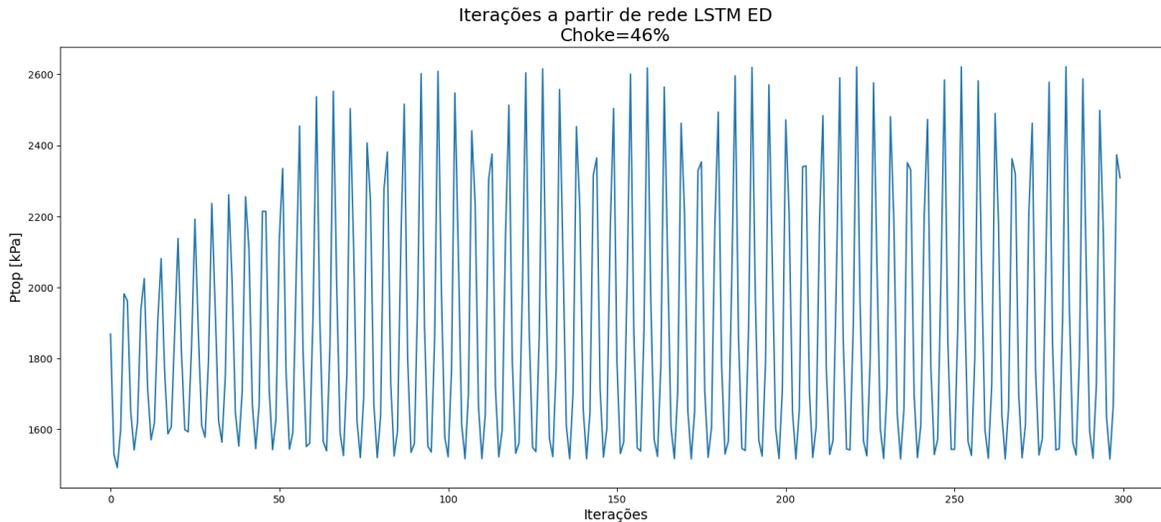


Figura 43 - Iterações a partir da rede LSTM ED para uma abertura da válvula choke de 46%

É interessante entender a razão da rede ter aprendido esse tipo de comportamento periódico. Os principais motivos podem ser que os dados possuam um comportamento similar ou que a rede acabe aprendendo esse comportamento para melhorar as previsões no curto prazo, o que leva a soluções mais complexas no longo prazo. Por esse motivo, foram observados com mais detalhe os dados de treino e foi gerada a Figura 44, que mostra um intervalo de 10hs do período I, em que a abertura da válvula é de 46.5%. Podemos observar que os dados apresentam também diferentes amplitudes, em parte devido a que a amostragem não permite observar alguns máximos corretamente. Por tanto, o comportamento periódico das redes surge ao tentar representar o comportamento dos dados reais.

Em resumo, as iterações com as redes mostraram, para alguns valores de choke, um comportamento periódico com oscilações de diferentes amplitudes, para representar de forma mais adequada os dados reais. Esse comportamento leva à multiplicidade de máximos e mínimos no diagrama de bifurcação.

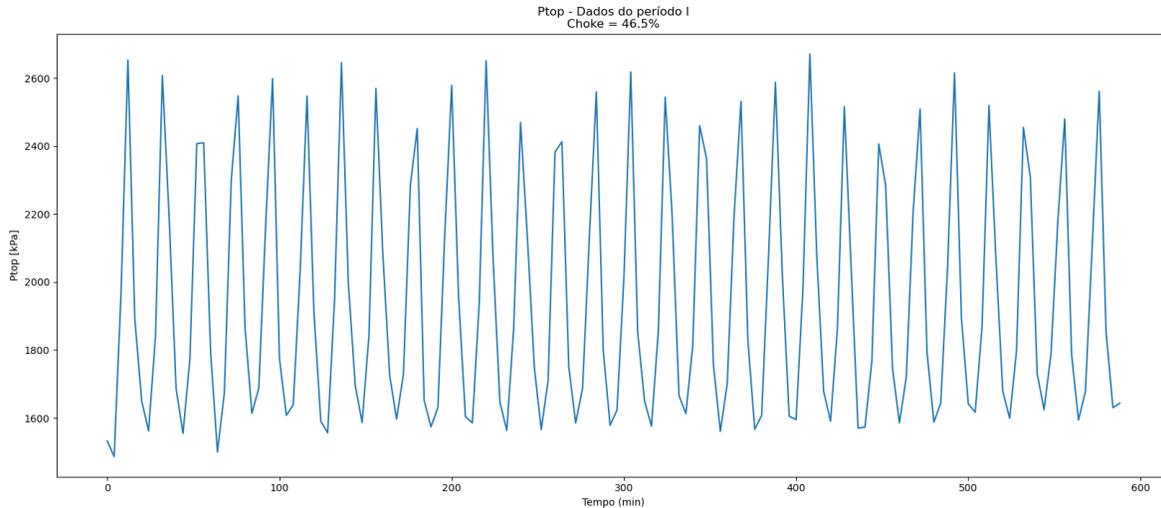


Figura 44 - Dados reais de Ptop para uma abertura da válvula choke de 46.5%

Para o segundo período, a rede LSTM ED gerou um diagrama diferente do esperado. O diagrama apresentou um comportamento estacionário para a maior parte dos pontos, salvo para uma abertura de 45%. O estado estacionário gerado parece passar pela média entre os máximos e mínimos das oscilações para valores altos de Choke. No entanto, resultou em alguns pontos inadequados para valores de Choke entre 35% e 43%, os quais apresentaram valores baixos de pressão. O diagrama gerado pela rede LSTM para esse período não mostrou qualquer oscilação e também apresentou problemas para prever adequadamente o estado estacionário para valores baixos de Choke.

No diagrama de bifurcação para o período III da rede LSTM ED, é possível observar um ponto de bifurcação de Hopf para uma abertura de 47%. A amplitude das oscilações obtidas decresce rapidamente e o diagrama reconstruído mostra um estado estacionário para valores de Choke maiores que 56%. O diagrama obtido a partir da rede LSTM não mostrou oscilações, porém os estados estacionários atingidos seguem a tendência dos dados reais.

Portanto, a rede LSTM ED mostrou-se melhor do que a rede LSTM para reconstruir os diagramas de bifurcação para a pressão Ptop, pois consegue reconstruir pontos com oscilações permanentes com maior facilidade. No entanto, os diagramas mostraram dificuldades para apresentar oscilações, quando a abertura da choke é alta. Também é importante destacar que não foi possível observar oscilações periódicas para o período II, indicando que a seleção do conjunto de dados é relevante para construir o melhor diagrama de bifurcação.

De forma similar, foram gerados os diagramas de bifurcação para a pressão na PDG (ver Figura 45). Os resultados não foram tão adequados quanto para a pressão P_{top} , uma vez que os diagramas não mostraram a bifurcação esperada. Para o período I, os diagramas gerados com as duas redes foram similares, mostrando-se adequados para valores de Choke entre 35 e 45%; porém, para valores maiores de Choke, apresentaram pressões um pouco elevadas e sem oscilações.

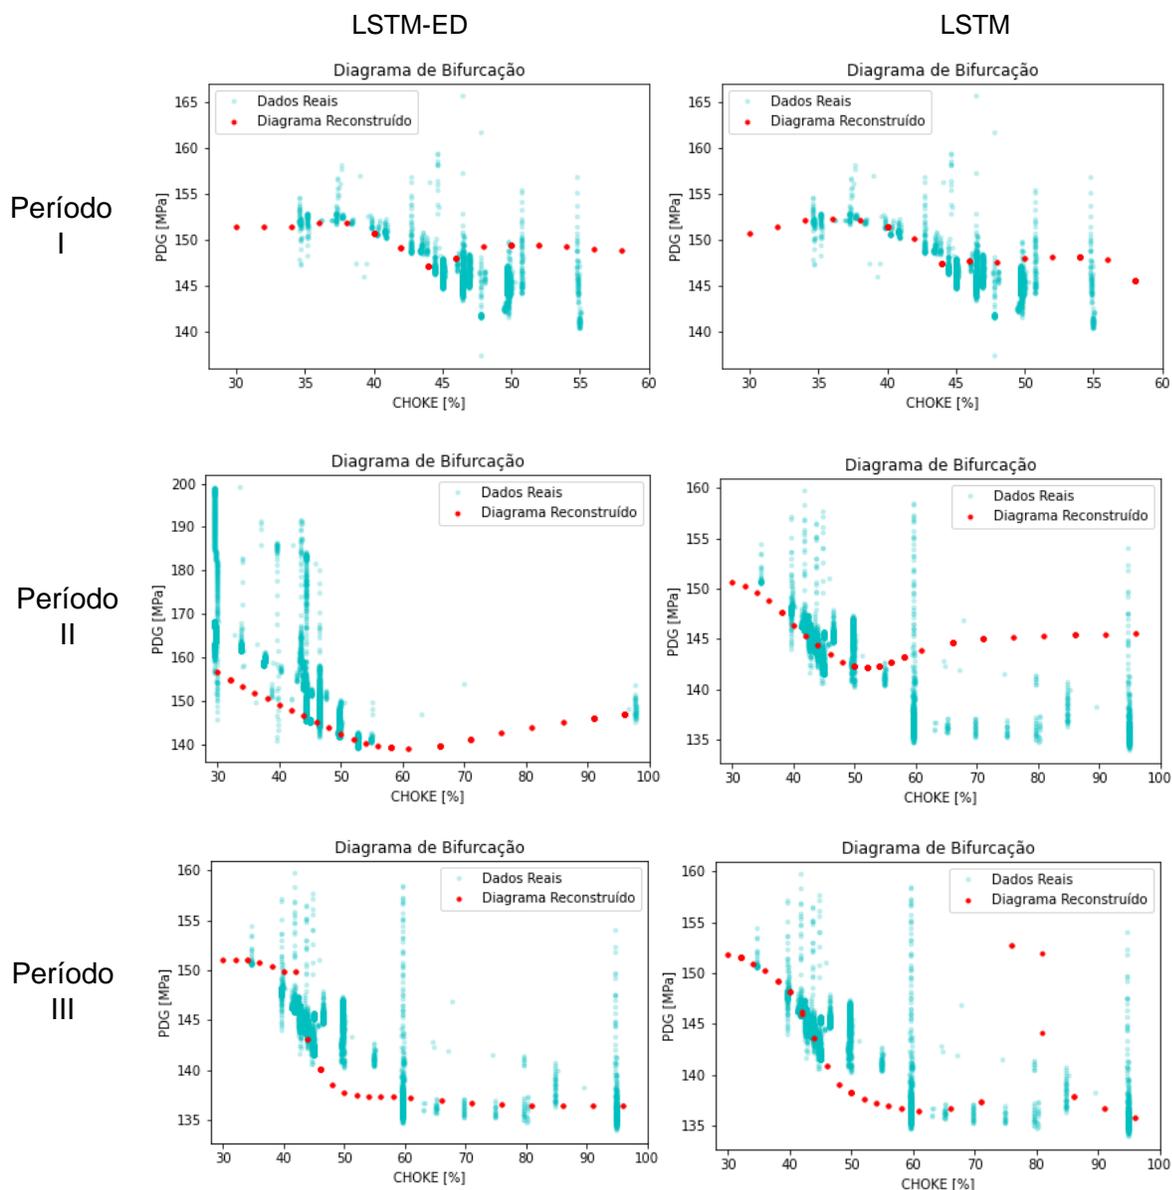


Figura 45 - Diagramas de bifurcação para a pressão na PDG com redes LSTM ED e LSTM treinadas com os três períodos analisados

O diagrama de bifurcação para o período II gerado pela rede LSTM mostrou um comportamento similar aos dos dados observados antes do ponto de bifurcação de Hopf, enquanto a rede LSTM ED resultou em estados estacionários com pressões menores que as esperadas, mas mantendo a tendência dos dados. Para valores maiores que o ponto de bifurcação de Hopf, os diagramas não apresentaram bifurcações, mas o diagrama da rede LSTM ED parece ter seguido melhor a tendência dos dados.

Para o período III, os resultados também não mostraram bifurcações e mostraram uma tendência diferente dos dados para valores de Choke entre 45% e 60%. Para valores maiores de Choke, a rede LSTM ED gerou estados estacionários próximos dos dados, enquanto a rede LSTM apresentou um desvio significativo dos dados para aberturas da válvula choke entre 70% e 85%.

Logo, a metodologia não se mostrou capaz de gerar diagramas de bifurcação adequados para a pressão na PDG a partir dos dados históricos. Em particular, a principal dificuldade foi a obtenção de oscilações para aberturas da válvula choke maiores que as do ponto de bifurcação de Hopf. Um dos possíveis motivos é o fato dessa variável não apresentar oscilações de grande amplitude. Isto faz com que a variabilidade dos dados seja similar antes e depois do ponto de bifurcação de Hopf (ver Figura 40), diferentemente do que acontece para a pressão P_{top} (ver Figura 41), em que existe uma mudança significativa na variabilidade da pressão após o ponto de bifurcação de Hopf. Desse modo, durante o treinamento para predizer a PDG, a rede tem um menor incentivo (menor redução do erro de predição) para aprender um comportamento oscilatório do que ao predizer a P_{top} .

Uma opção para tentar melhorar os resultados com esta metodologia seria eliminar os transientes para reduzir a variabilidade dos dados para valores de choke menores ao ponto de bifurcação de Hopf, o que permitiria ao modelo identificar mais facilmente a mudança de comportamento após o ponto de bifurcação de Hopf. No entanto, essa ideia geraria um conjunto de dados constituído por pequenas séries temporais, em vez de utilizar uma única série contínua. Como as redes utilizadas são recorrentes, e as predições prévias afetam as próximas predições, as mudanças de comportamento entre uma série temporal e a seguinte poderiam dificultar o treinamento da rede. Por esse motivo, essa abordagem não foi testada nesse trabalho, embora possa ser relevante para aprimorar a metodologia em trabalhos futuros.

5.5. Análise de sensibilidade

Na análise anterior foram comparados os dois tipos de redes e os períodos de treino; porém, não foi analisado o efeito do número de neurônios das camadas da rede ou dos demais hiperparâmetros. Por esse motivo, a partir da rede que gerou o melhor diagrama de bifurcação (rede LSTM ED treinada com o período I), foi feita uma análise de sensibilidade ao variar o número de neurônios por camada LSTM e o número de defasagens no tempo utilizados na entrada da rede.

Na Figura 46 podemos observar os diagramas de bifurcação construídos a partir das redes com diferentes números de defasagens no tempo. Podemos ver que, quando o número de defasagens é baixo, o diagrama tem dificuldades de representar adequadamente as oscilações. Os melhores resultados foram obtidos com 5, 6 e 7 defasagens no tempo (20, 24 e 28 min prévios), valores próximos ao período das oscilações, de aproximadamente 22 min. Isto indica que ter um número de defasagens suficientes para cobrir uma oscilação completa pode ajudar a obter bons resultados. No entanto, adicionar ainda mais valores defasados pode piorar os resultados, como mostrado no diagrama para 9 defasagens.

Para entender o efeito de mudar o número de neurônios nas camadas LSTM, foram gerados diagramas de bifurcação para uma rede LSTM ED com 6 defasagens no tempo, alterando o número de neurônios (ver Figura 47). A partir dos resultados, podemos observar que, embora o número de neurônios exerça uma grande influência no diagrama de bifurcação, não existe uma relação clara entre a qualidade do diagrama gerado e o número de neurônios. Qualitativamente, os melhores resultados foram aqueles com 10, 50, 90 e 110 neurônios, pois eles apresentam adequadamente as oscilações, com amplitudes similares às mostradas pelos dados. Dos casos analisados, o único que não conseguiu identificar as oscilações foi aquele com 130 neurônios. Portanto, a escolha do número de neurônios é relevante para a obtenção do diagrama de bifurcação; porém, é necessário realizar uma otimização desse hiperparâmetro, pois não foi possível obter uma heurística simples para determinar um valor adequado.

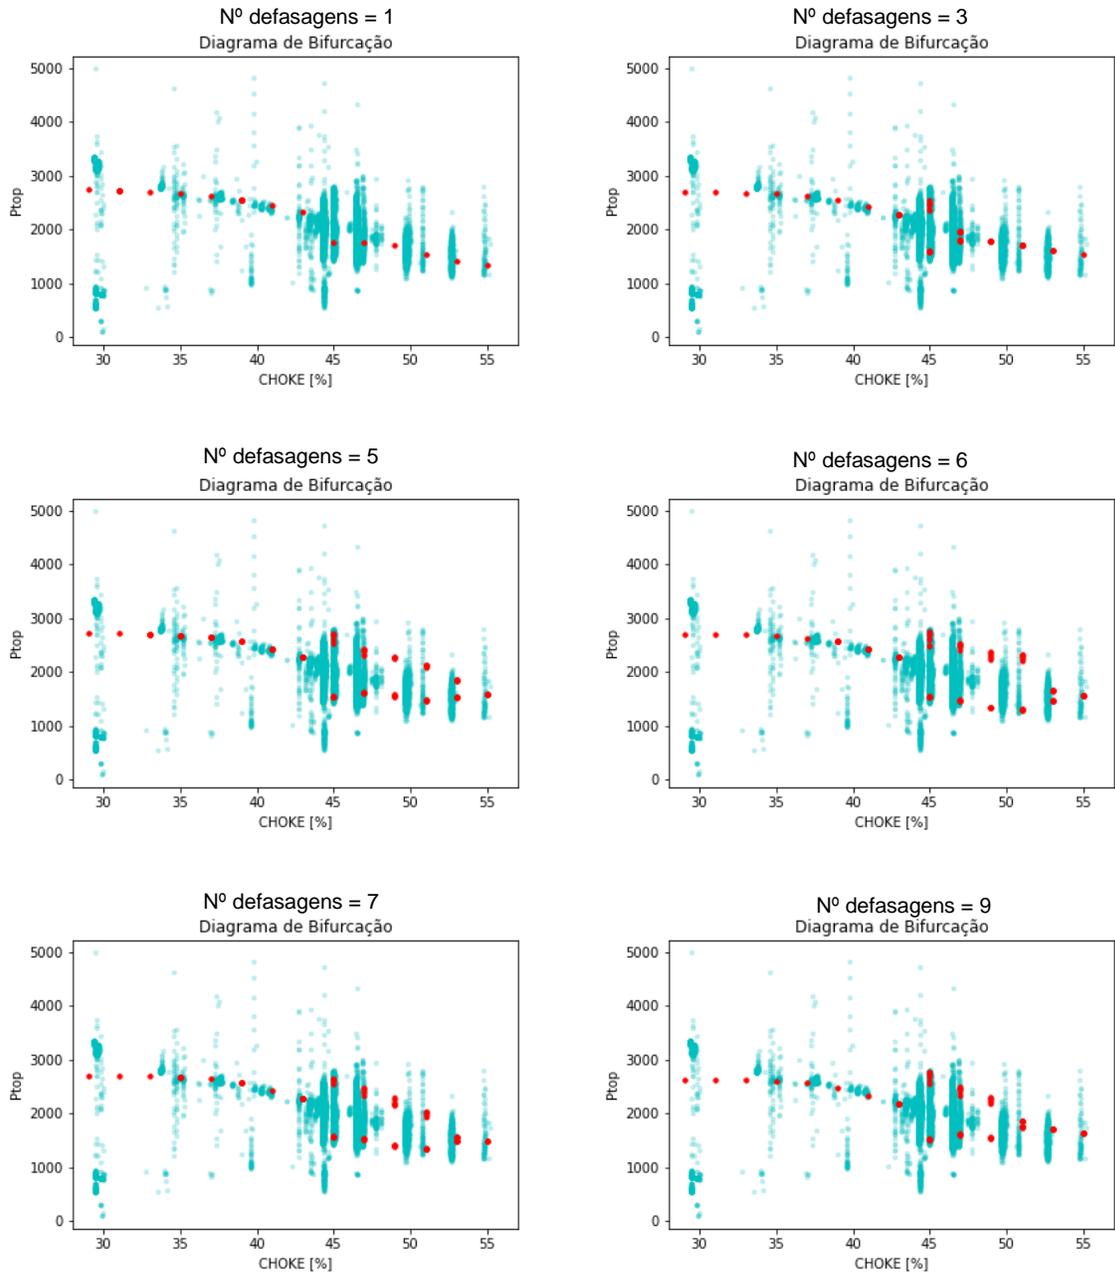


Figura 46 - Variação no diagrama de bifurcação ao alterar o número de defasagens no tempo dos dados de entrada para uma rede LSTM ED de 100 neurônios.

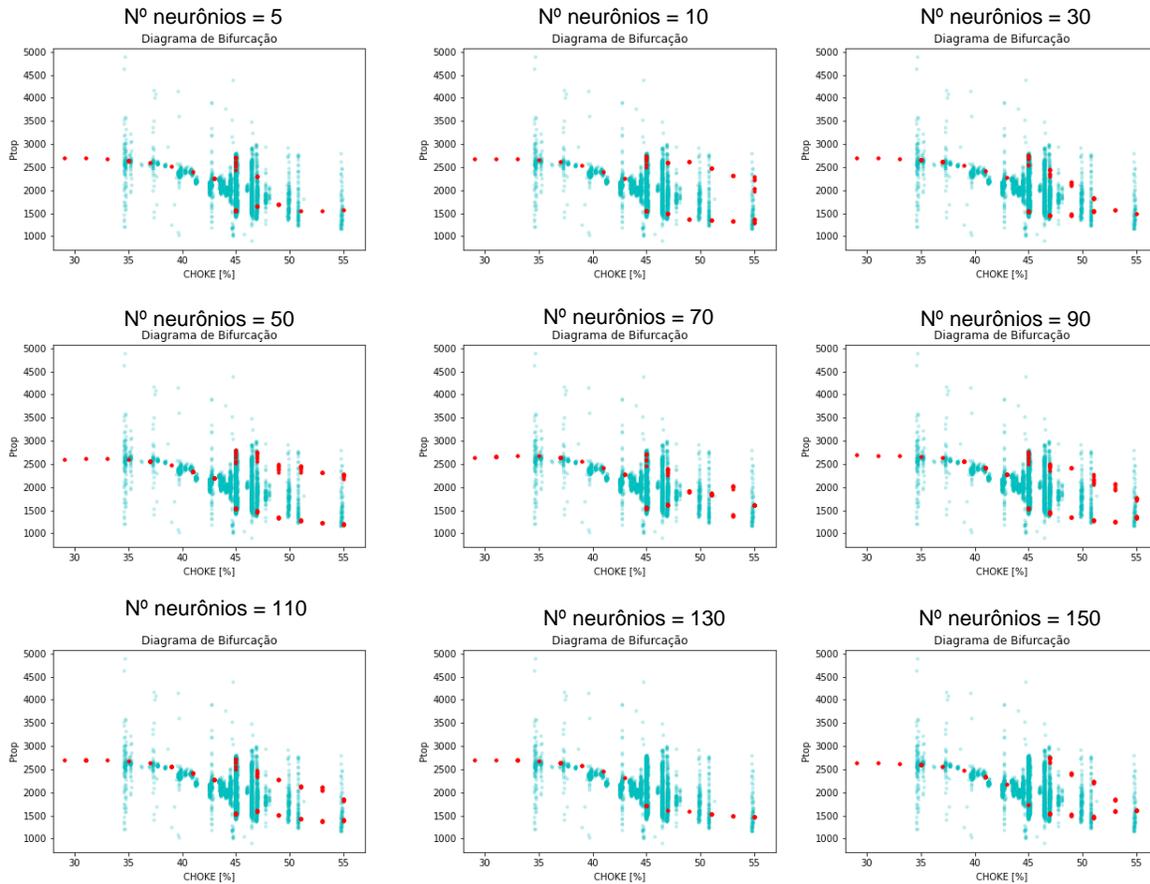


Figura 47 - Variação no diagrama de bifurcação ao mudar o número de neurônios por camada LSTM para uma rede LSTM ED com 6 lags na entrada.

5.6. Otimização de hiperparâmetros

Para determinar os melhores hiperparâmetros para a rede LSTM ED, foi realizada uma otimização com a ferramenta *Optuna* no Python. Na primeira otimização realizada, foi utilizado o valor do MAE como métrica a minimizar. Os hiperparâmetros determinados são mostrados na Tabela 7 e o diagrama de bifurcação gerado a partir da rede com hiperparâmetros otimizados é mostrada na Figura 48. Podemos observar que a rede apresenta um número relativamente baixo de defasagens no tempo, diferente do que sugere a análise de sensibilidade obtida anteriormente. No entanto, esse número baixo de defasagens pode ser a causa de que o diagrama de bifurcação só apresente oscilações na faixa de 43-48% e volte rapidamente a apresentar valores estacionários. Portanto, apesar de reduzir o erro de predição no curto prazo, dado pelo MAE, os hiperparâmetros escolhidos não levaram ao diagrama de bifurcação que melhor representa os dados reais.

Tabela 7 - Hiperparâmetros obtidos para a rede LSTM-ED a partir das três otimizações realizadas com a biblioteca *Optuna*.

	Otimização I	Otimização II	Otimização III
Hiperparâmetros	W = 0	W = 300	W = 3000
Função de ativação	<i>Tanh</i>	<i>Tanh</i>	<i>Tanh</i>
Nº de neurônios por camada	28	108	114
Nº defasagens	2	6	6
Fator de regularização L1	0.00061	0.00014	0.00032
Otimizador	Adamax	Adamax	Adamax
Função objetivo	227.295	254.261	263.412

Para uma melhor otimização dos hiperparâmetros, que leve em conta o diagrama de bifurcação gerado, foi adicionado um termo na função objetivo, como descrito no Capítulo 3. Com essa nova função objetivo, foram feitas duas otimizações, com valores do peso para o novo termo iguais a $w=300$ e $w=3000$. Os hiperparâmetros obtidos são mostrados na Tabela 7 e os diagramas de bifurcação são mostrados na

Figura 49 e Figura 50. Podemos ver que nesses casos o número de defasagens no tempo aumentou em relação à otimização inicial, assim como o número de neurônios. O diagrama de bifurcação para a segunda otimização não foi totalmente adequado. Embora tenha mostrado um maior número de pontos com oscilações, apresentou um ponto com estado estacionário para um valor de Choke de 48%, que não condiz com os resultados esperados. Por outro lado, o diagrama de bifurcação para a otimização III mostrou-se adequado, apresentando oscilações para todos os pontos exibidos após o ponto de bifurcação de Hopf. Além disso, nesse diagrama as oscilações têm uma amplitude similar à mostrada pelos dados reais. Em comparação com a primeira otimização, podemos ver um aumento de 16% no valor final da função objetivo, indicando que houve uma certa redução na qualidade das predições a curto prazo.

Em resumo, os hiperparâmetros da rede LSTM ED podem afetar significativamente os diagramas de bifurcação gerados. Para determinar os melhores hiperparâmetros, foi possível realizar uma otimização bayesiana com uma modificação na função objetivo para adicionar informação sobre os diagramas gerados. As redes com os hiperparâmetros

otimizados permitiram gerar um diagrama de bifurcação que reflete adequadamente o comportamento do sistema real.

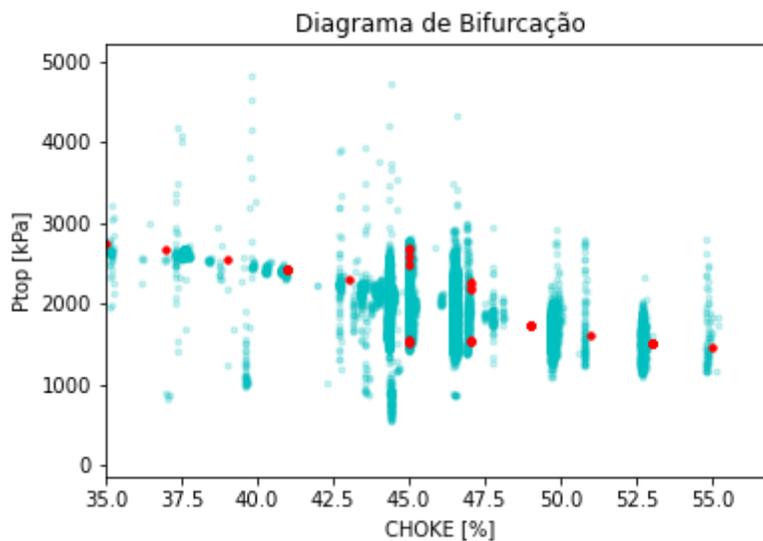


Figura 48 - Diagrama de bifurcação obtido a partir de uma rede LSTM-ED com hiperparâmetros determinados na otimização I

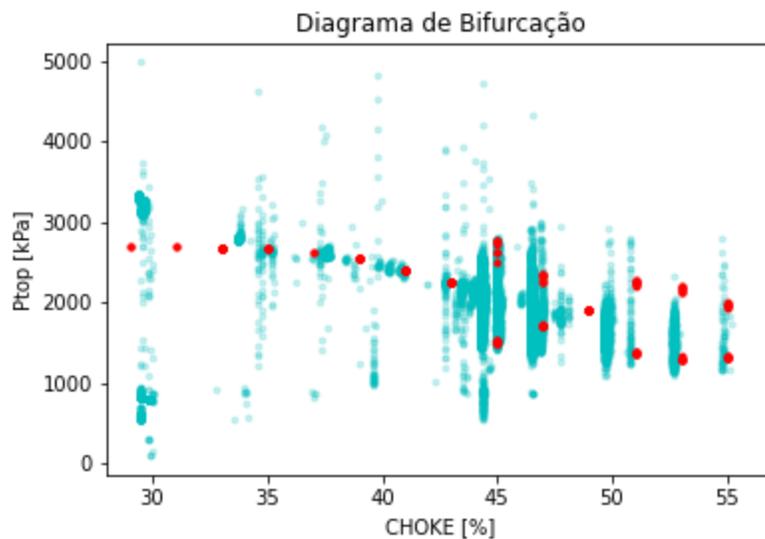


Figura 49 - Diagrama de bifurcação obtido a partir de uma rede LSTM-ED com hiperparâmetros determinados na otimização II

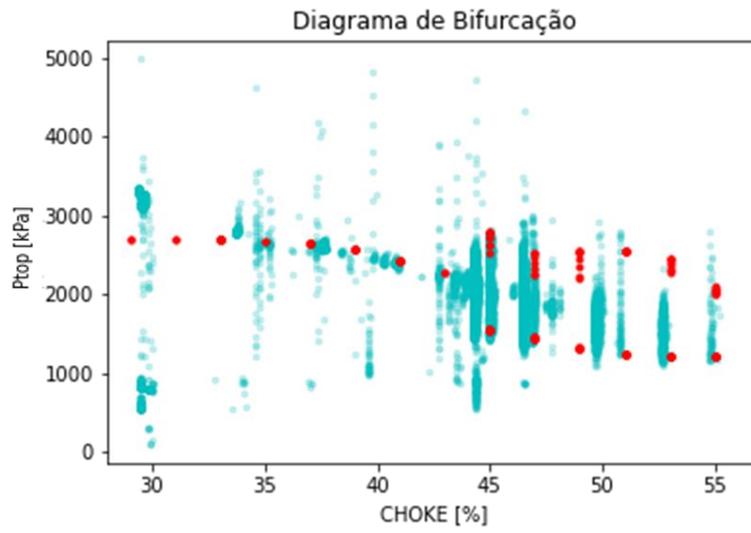


Figura 50 - Diagrama de bifurcação obtido a partir de uma rede LSTM-ED com hiperparâmetros determinados na otimização III

Capítulo 6

Conclusões e Perspectivas Futuras

O presente trabalho avaliou o uso de redes neurais ANN, LSTM e LSTM ED para a reconstrução de diagramas de bifurcação para sistemas de produção de petróleo *offshore* com problemas de golfadas, tanto a partir de dados simulados, como a partir de dados históricos de operação de um sistema real.

Os resultados indicam que as redes LSTM e LSTM ED mostraram-se mais adequadas do que as redes convencionais, tanto para modelar as previsões a curto prazo quanto na geração dos diagramas para os dados simulados. Além disso, a qualidade dos dados utilizados foi relevante para a reconstrução, especialmente a escolha da variável utilizada para o diagrama. Para os dados simulados, os melhores resultados foram obtidos para a pressão na PDG, pois a pressão P_{top} representou um desafio para as redes devido à forma das oscilações, com períodos relativamente estáveis seguidos de mudanças rápidas na pressão. Pelo contrário, para os dados reais a pressão na PDG apresentou um resultado menos adequado do que a P_{top} , devido à baixa amplitude das oscilações. Isto dificultou a capacidade das redes de reproduzir adequadamente as oscilações. Aliás, foi possível gerar diagramas que mostram uma bifurcação de Hopf tanto para os dados simulados quanto para os dados reais, sendo que a localização do ponto de bifurcação de Hopf foi apropriada para o caso dos dados reais, apesar de apresentar alguns desvios para os dados simulados.

Outro fator importante para a reconstrução dos diagramas de bifurcação foi a escolha dos hiperparâmetros da rede. Foi mostrado que a otimização desses hiperparâmetros é complexa, pois precisam ser levados em conta tanto o comportamento no curto quanto no longo prazo das previsões. Por esse motivo, foi necessário gerar uma função objetivo para a otimização de hiperparâmetros que levasse em conta o tipo de soluções (estacionárias ou oscilatórias) que são geradas pelas redes para as diferentes aberturas da válvula choke. Com essa nova função objetivo, a otimização de hiperparâmetros permitiu a construção de diagramas de bifurcação que representam adequadamente o comportamento da pressão P_{top} para os dados reais.

Portanto, a metodologia mostrou-se capaz de reconstruir diagramas de bifurcação para a pressão P_{top} de um sistema de produção de petróleo *offshore* com problemas de golfadas a partir dos dados históricos. O pré-processamento dos dados é relativamente simples, focando principalmente na seleção de um período que tenha apresentado golfadas e não tenha grandes perturbações de outras variáveis externas, e o treinamento e seleção de hiperparâmetros pode ser facilmente automatizado. Por esse motivo, seria viável a aplicação dessa metodologia para outros poços de petróleo *offshore*.

Como perspectivas futuras, seria importante adicionar à metodologia de reconstrução de diagramas de bifurcação a curva de equilíbrio instável, devido à sua importância para os sistemas de controle. Além disso, a adição de informação referente à física do problema real pode melhorar os resultados obtidos a partir das redes neuronais, como mostrado com o uso da nova função objetivo para a escolha dos hiperparâmetros da rede. Por esse motivo, seria interessante avaliar outras formas de adicionar informação sobre o sistema real nas redes. Algumas possibilidades são o aprimoramento da função objetivo, trazendo mais informação do diagrama de bifurcação, o uso de redes neuronais informadas pela física (PINNs) ou a adição de novas variáveis relacionando as variáveis medidas entre outros.

Seria interessante também a aplicação de técnicas de pré-processamento dos dados para diminuir a influência dos transientes e fornecer a pressão estática do sistema, que dificilmente é atingida durante a operação. Também é necessária a realização de testes aplicando a metodologia para outros poços de petróleo reais.

Em relação às redes neurais utilizadas, pode ser útil testar redes com arquiteturas mais complexas ou um número maior de camadas ocultas, para ver se a rede consegue prever ainda melhor o comportamento do sistema. O uso de um número maior de dados selecionados adequadamente como entrada das redes, também pode ajudar a melhorar os resultados obtidos.

Referências

AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCOMBUSTÍVEIS

(ANP). Boletim da Produção de Petróleo e Gás Natural nº133, setembro 2021.

AKIBA, T., SANO, S., YANASE, T., OHTA, T., KOYAMA, M. "Optuna: A Next-Generation Hyperparameter Optimization Framework". In: **25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining**, p. 2623–2631, New York, 2019.

ANDRIANOV, N. "Machine Learning Approach for Virtual Flow Metering and Forecasting", **IFAC PapersOnLine** 51-8, pp.191–196, 2018.

ANTONELO, E., CAMPONOVARA, E., FOSS, B. "Echo State Networks for Data-driven Downhole Pressure Estimation in Gas-lift Oil Wells", **Neural Networks** v.85, pp.106-117, 2017.

ARTUSI, R., VERDERIO, P., MARUBINI, E. "Bravais-Pearson and Spearman correlation coefficients: meaning, test of hypothesis and confidence interval", **The International Journal of Biological Markers** v.17, 2, pp. 148-151, 2002.

BAGARINAO, E., PAKDAMAN, K., NOMURA, T. SATO, S. "Reconstructing bifurcation diagrams of dynamical systems using measured time series", **Methods Inf. Med.** v.39, 146, 2000.

BALIÑO, J. L. "Modelling and simulation of severe slugging in air-water systems including inertial effects", **Journal of Computational Science**, v.5(3), pp. 482-495.

BASU, J. K., BHATTACHARYYA, D., KIM, T. "Use of Artificial Neural Network in Pattern Recognition", **International Journal of Software Engineering and Its**

- Applications**, v.4, n.2, pp. 23–34, 30 abr. 2010. Disponível em: <https://www.earticle.net/Article/A118913>.
- BENDLKSEN, K.H., MALNES, D., MOE, R., NULAND, S. “The Dynamic Two-Fluid Model OLGA: Theory and Application”, **SPE Production Engineering**, pp. 171-180, 1991.
- BIKMUKHAMEDOV, T., JÄSCHKE J. “First Principles and Machine Learning Virtual Flow Metering: A Literature Review”, **Journal of Petroleum Science and Engineering**, v.184, 106487, 2020.
- BRADLEY, E., KANTZ, H. "Nonlinear time-series analysis revisited", **Chaos: An Interdisciplinary Journal of Nonlinear Science**, v. 25, n. 9, p. 97610, 13 abr. 2015.
- BROWNLEE, J. “How to scale data with outliers for Machine Learning” **Machine Learning Mastery**, 2020. Disponível em: <https://machinelearningmastery.com/robust-scaler-transforms-for-machine-learning>. Acesso em 15 ago. 2022.
- CESTNIK, R., ABEL, M. "Inferring the dynamics of oscillatory systems using recurrent neural networks", 2019. DOI: 10.1063/1.5096918. Disponível em: <https://arxiv.org/abs/1904.03026>. Acesso em: 3 jul. 2022.
- DI MEGLIO, F. **Dynamics and control of slugging in oil production**. 2011. École Nationale Supérieure des Mines de Paris, 2011.
- DI MEGLIO, F., PETIT, N., ALSTAD, V., et al. "Stabilization of slugging in oil production facilities with or without upstream pressure sensors", **Journal of Process Control**, v. 22, n. 4, p. 809–822, 2012.
- DIEHL, F.C., ALMEIDA, C.S., ANZAI, T.K., GEREVINI, G., NETO, S.S., VON MEIEN, O.F., CAMPOS, M., FARENZENA, M., TRIERWEILER, J.O. “Oil production

- increase in unstable gas lift systems through nonlinear model predictive control”, **Journal of Process Control**, v.69, p. 58-69, 2018.
- DIEHL, F.C., ANZAI, T.K., ALMEIDA, C.S., VON MEIEN, O.F., NETO, S.S., ROSA, V.R., CAMPOS, M., REOLON, F., GEREVINI, G., RANZAN, C., FARENZENA, M., TRIERWEILER, J.O. “Fast Offshore Wells Model (FOWM): A practical dynamic model for multiphase oil production systems in deepwater and ultra-deepwater scenarios”, **Computers and Chemical Engineering**, v.99, p. 304-313, 2017.
- DIEHL, F. C., GEREVINI, G. G., MACHADO, T. O., et al. "Anti-slug control design: Combining first principle modeling with a data-driven approach to obtain an easy-to-fit model-based control", **Journal of Petroleum Science and Engineering**, v. 207, 2021.
- DIEHL, F.C., MACHADO, T.O., ANZAI, T.K., ALMEIDA, C.S., MOREIRA, C.A., NERY, G.A., CAMPOS, M., FARENZENA, M., TRIERWEILER, J.O. “10% increase in oil production through a field applied APC in a Petrobras ultra-deepwater well”, **Control Engineering Practice**, v.91, 104108, 2019.
- DOGO, E. M., AFOLABI, O. J., NWULU, N. I., et al. "A Comparative Analysis of Gradient Descent-Based Optimization Algorithms on Convolutional Neural Networks". In: **2018 International Conference on Computational Techniques, Electronics and Mechanical Systems**, p. 92–99, 2018.
- EHINMOWO, A.B., CAO Y. “Stability analysis of slug flow control”, **Systems Science & Control Engineering**, v.4, p. 183-191, 2016.

- EIKREM, G. O., AAMO, O. M., FOSS, B. A. "On Instability in Gas Lift Wells and Schemes for Stabilization by Automatic Control", **SPE Production & Operations**, v. 23, n. 02, p. 268–279, 2008.
- GARCÍA, A., ALMEIDA, I., SINGH, G., et al. An Implementation of On-line Well Virtual Metering of Oil Production. **SPE Intelligent Energy Conference and Exhibition**. Disponível em: <https://doi.org/10.2118/127520-MS>, 2010
- GIBSON, J. F. "An analytic approach to practical state space reconstruction", **Physica. D, Nonlinear phenomena**, v. 57, n. 1–2, p. 1–30, 1992.
- GOODFELLOW, IAN; BENGIO, YOSHUA; COURVILLE, AARON. **Deep Learning**. MIT Press, 2016.
- GREESHMA, K. V., SREEKUMAR, K. "Hyperparameter optimization and regularization on fashion-MNIST classification", **International Journal of Recent Technology and Engineering**, v. 8, n. 2, p. 3713–3719, 1 jul. 2019.
- HAVRE, K., DALSMO, M. Active Feedback Control as the Solution to Severe Slugging. **SPE Annual Technical Conference and Exhibition**. [S.l: s.n.]. Disponível em: <https://doi.org/10.2118/71540-MS>, 2001.
- HECHT-NIELSEN, R. "Theory of the Backpropagation Neural Network", *Neural Networks for Perception*, p. 65–93, 1992. DOI: 10.1016/B978-0-12-741252-8.50010-8.
- HEWAMALAGE, H., BERGMEIR, C., BANDARA, K. "Recurrent Neural Networks for Time Series Forecasting: Current status and future directions", **International Journal of Forecasting**, v.37, p.388-427, 2021.
- HOCHREITER, S., SCHMIDHUBER, J. "Long Short-Term Memory", *Neural Computation*, v. 9, n. 8, p. 1735–1780, 1997.

- ITOH, Y., TADA, Y., ADACHI, M. “Reconstructing bifurcation diagrams with Lyapunov exponents from only time-series data using an extreme learning machine” **Nonlinear Theory Appl. IEICE** v.8(1), pp.2–14, 2017.
- JAHANSHAHI, E.. **Control Solutions for Multiphase Flow – Linear and Nonlinear Approaches to Anti-slug Control**. Doctorate Thesis - Norwegian University of Science and Technology, 2013.
- JAHANSHAHI, E., SKOGESTAD, S. "Nonlinear control solutions to prevent slugging flow in offshore oil production", *Journal of Process Control*, v. 54, p. 138–151, 1 jun. 2017.
- JORDANOU, J.P., ANTONELLO, E., CAMPONOGARA, E. “Online learning control with Echo State Networks of an oil production platform”, **Engineering Applications of Artificial Intelligence**, v.85, pp. 214-228, 2019.
- KERAS. Version 2.4.3. [S.l]: Keras SIG, 2020. Disponível em: <https://keras.io/>
- KRISHNAIAH, J., KUMAR, C.S., FARUQUI, M.A. “Constructing bifurcation diagram for a chaotic time-series data through a recurrent neural network model” **Proceedings of the 9th International Conference on Neural Information Processing**, 2002.
- LAUBSCHER, R. "Time-series forecasting of coal-fired power plant reheater metal temperatures using encoder-decoder recurrent neural networks", **Energy**, v. 189, p. 116187, 15 dez. 2019.
- LI, Y., TONG, Z. "Model predictive control strategy using encoder-decoder recurrent neural networks for smart control of thermal environment", **Journal of Building Engineering**, v. 42, p. 103017, 1 out. 2021. DOI: 10.1016/J.JOBE.2021.103017.
- LU, Z., HUNT, B. R., OTT, E. "Attractor reconstruction by Machine Learning", **Chaos: An Interdisciplinary Journal of Nonlinear Science**, v. 28, n. 6, p. 61104, 1 jun. 2018.

- LUO, G., TIAN, Y., BYCHINA, M., *et al.*, "Production Optimization Using Machine Learning in Bakken Shale". **Unconventional Resources Technology Conference**, Houston, Texas, USA, 23-25 July 2018.
- MELO, A., FIDALGO J., LIMA, J.C., CAMPOS, L. F., CLAVIJO, N., LEMOS, T., FERREIRA, W., PINTO, J.C. COPPETEC. **Análise Dinâmica de Processos Baseada em Dados - Aplicações na Exploração de Petróleo - Relatório Técnico Parcial 1**, 2020.
- MELO, P. Jr., PINTO, J.C. **Introdução à Modelagem Matemática e Dinâmica Não-Linear de Processos Químicos**. Rio de Janeiro: Escola Piloto Virtual Giulio Massarani, 2008.
- MUKHAMEDIEV, R. I., SYMAGULOV, A., KUCHIN, Y., *et al.* "From Classical Machine Learning to Deep Neural Networks: A Simplified Scientometric Review", **Applied Sciences**, v. 11, n. 12, 2021. DOI: 10.3390/app11125541. Disponível em: <https://www.mdpi.com/2076-3417/11/12/5541>.
- MONTESINOS LÓPEZ, O. A., MONTESINOS LÓPEZ, A., CROSSA, J., "Fundamentals of Artificial Neural Networks and Deep Learning BT - Multivariate Statistical Machine Learning Methods for Genomic Prediction". In: MONTESINOS LÓPEZ, O. A., MONTESINOS LÓPEZ, A., CROSSA, J. (Org.), Cham, Springer International Publishing, 2022. p. 379–425. DOI: 10.1007/978-3-030-89010-0_10. Disponível em: https://doi.org/10.1007/978-3-030-89010-0_10.
- OLGA: Dynamic Multiphase Flow Simulator. Version: 2021.1. [s.l]: Slumberger, 2021.
- OLIVARES, G., ESCALONA, C., GIMENEZ, E. Production Monitoring Using Artificial Intelligence, APLT Asset. **SPE Intelligent Energy International**, 2012.

- PACKARD, N. H. "Geometry from a Time Series". **Phys. Rev. Lett.**, v.45, n.9, pp.712–716, 1980.
- PASCANU, R., MIKOLOV, T., BENGIO, Y. "On the difficulty of training Recurrent Neural Networks", 21 nov. 2012. DOI: 10.48550/arxiv.1211.5063. Disponível em: <https://arxiv.org/abs/1211.5063>. Acesso em: 15 ago. 2022.
- PEDERSEN, S., DURDEVIC, P., YANG, Z. "Review of Slug Detection, Modeling and Control Techniques for Offshore Oil & Gas Production Processes", **IFAC-PapersOnLine**, v. 48, n. 6, p. 89–96, 2015.
- SALAHSHOOR, K., ZAKERI, S., HAGHIGHAT SEFAT, M. "Stabilization of gas-lift oil wells by a nonlinear model predictive control scheme based on adaptive neural network models", **Engineering Applications of Artificial Intelligence**, v. 26, n. 8, p. 1902–1910, 2013.
- SARKER, I. H. "Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions", **SN Computer Science**, v. 2, n. 6, p. 420, 2021. DOI: 10.1007/s42979-021-00815-1. Disponível em: <https://doi.org/10.1007/s42979-021-00815-1>.
- SAUER, T., YORKE, J. A., CASDAGLI, M. "Embedology", **Journal of statistical Physics**, v.65, n.3–4, pp.579–616, 1991.
- SAVI, Marcelo Amorim. **Dinâmica Não-linear e Caos**. E-papers Serviços Editoriais, Rio de Janeiro 2017.
- SHARMA, A., JOHNSON, R., MOSES, A., KESSLER, A. "Deep Learning for Scalable Chemical Kinetics" **AIAA Scitech 2020 Forum**, 2020.

- SHOEIBI OMRANI, P., DOBROVOLSKI, I., BELFROID, S., et al. Improving the Accuracy of Virtual Flow Metering and Back-Allocation through Machine Learning. **Abu Dhabi International Petroleum Exhibition & Conference**, 2018.
- SINÈGRE, L. **Dynamic study of unstable phenomena stepping in gas-lift activated systems**. Tese (Doctor of Philosophy) - Ecole des Mines de Paris, 2006.
- SPINDOLA RANGEL DIAS, A.C., ROJAS SOARES, F., JÄSCHKE, J., BEZERRA DE SOUZA, M., PINTO, J.C. Extracting Valuable Information from Big Data for Machine Learning Control: An Application for a Gas Lift Process. **Processes**, v.7, n.5, 2019.
- STORKAAS, E., SKOGESTAD, S., ALSTAD, V. "Stabilization of desired flow regimes in pipelines." In: **AICHE ANNUAL MEETING, 2001**. Reno. 2001.
- STORKAAS, E., SKOGESTAD, S., "Stabilization of severe slugging based on a low-dimensional nonlinear model." In: **AICHE ANNUAL MEETING, 2002**. Indianapolis. 2002.
- SUN, J., MA, X., KAZI, M. Comparison of Decline Curve Analysis DCA with Recursive Neural Networks RNN for Production Forecast of Multiple Wells. **SPE Western Regional Meeting**, 2018
- SUTSKEVER, I. **Training Recurrent Neural Networks**. Tese (Doctor of Philosophy) - Graduate Department of Computer Science, University of Toronto. Toronto, 2013.
- SUTSKEVER, I., VINYALS, O., LE, Q. V. "Sequence to Sequence Learning with Neural Networks", Arxiv, 2014. Disponível em <https://arxiv.org/abs/1409.3215>. Acesso em: 3 jul. 2022.
- TAKENS, F. "Detecting strange attractors in turbulence" **Lecture Notes in Mathematics**, vol 898. Springer, Berlin, Heidelberg, 1981.

- TALAVERA, A. L., TÚPAC, Y. J., VELLASCO, M. M. “Controlling Oil Production in Smart Wells by MPC Strategy with Reinforcement Learning”. **SPE Latin American and Caribbean Petroleum Engineering Conference**, 2010
- TEIXEIRA, A. **Otimização da produção de poços de petróleo com gas lift contínuo**. Dissertação (Mestrado em Engenharia Química) – Programa de Pós-Graduação em Engenharia Química, COPPE, Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2013.
- TENSORFLOW. Version 2.3.0. [S.l.]:Tensorflow.org, 2020. Disponível em: https://www.tensorflow.org/versions/r2.3/api_docs/python/tf
- TOKUDA, I., TOKUNAGA, R. AIHARA, K. “Back-Propagation Learning of Infinite-Dimensional Dynamical Systems”, **Neural Networks**, 16(8), pp.1179-1193,2003.
- TOKUNAGA, R., KAJIWARA, S., MATSUMOTO, T. “Reconstructing bifurcation diagrams only from time-waveforms”, **Physica D**, v.79, pp.348–360, 1994.
- VEGA, M.P, LIMA, E.L., PINTO, J.C. “Use of bifurcation analysis for development of nonlinear models for control applications”, **Chemical Engineering Science**, v 63, pp. 5219-5140, 2008.
- VINYALS, O., LE, Q. "A Neural Conversational Model", 19 jun. 2015. DOI: 10.48550/arxiv.1506.05869. Disponível em: <https://arxiv.org/abs/1506.05869>. Acesso em: 1 jun. 2022.
- VINYALS, O., TOSHEV, A., BENGIO, S., et al. "Show and Tell: A Neural Image Caption Generator", 17 nov. 2014. DOI: 10.48550/arxiv.1411.4555. Disponível em: <http://arxiv.org/abs/1411.4555>. Acesso em: 1 jun. 2022.
- WERBOS, P. J. "Backpropagation through time: what it does and how to do it", **Proceedings of the IEEE**, v. 78, n. 10, p. 1550–1560, 1990.

ZIEGEL, E., SHIRZADI, S., WANG, S., et al. A Data-Driven Approach to Modelling and Optimization for a North Sea Asset Using Real-Time Data. **SPE Intelligent Energy Conference & Exhibition**. Disponível em: <https://doi.org/10.2118/167850-MS>. 2014

Anexo A: Modelo FOWM

O modelo FOWM (Fast Offshore Wells Model) é um modelo dinâmico simplificado que descreve sistemas de produção de petróleo multifásicos *offshore* de águas profundas e ultraprofundas. O modelo foi construído por DIEHL *et al.* (2017) a partir do acoplamento de modelos prévios presentes na literatura para poder representar simultaneamente as três partes principais do sistema: o reservatório, o poço e a linha de produção.

O modelo consiste em um sistema de seis equações diferenciais ordinárias (EDOs) baseadas na conservação de massa, representado pelas Equações (A.1)-(A.6). Por esse motivo, os seis estados do sistema representam as massas de líquido e gás em diversas seções do sistema de produção, como mostrado na Tabela A-1. O modelo assume a presença de uma válvula virtual na linha de produção para representar a formação de golfadas severas. Também é admitida a presença de uma bolha de gás na seção prévia à válvula virtual.

$$\frac{dm_{ga}}{dt} = W_{gc} - W_{iv} \quad (\text{A.1})$$

$$\frac{dm_{gt}}{dt} = W_r \alpha_{gw} + W_{iv} - W_{whg} \quad (\text{A.2})$$

$$\frac{dm_{lt}}{dt} = W_r (1 - \alpha_{gw}) - W_{whl} \quad (\text{A.3})$$

$$\frac{dm_{gb}}{dt} = (1 - E)W_{whg} - W_g \quad (\text{A.4})$$

$$\frac{dm_{gr}}{dt} = EW_{whg} + W_g - W_{gout} \quad (\text{A.5})$$

$$\frac{dm_{lr}}{dt} = W_{whl} - W_{lout} \quad (\text{A.6})$$

Tabela A-1 Descrição das variáveis de estado para o modelo FOWM.

Variável de Estado	Descrição
m_{ga}	Massa de gás no anular
m_{gt}	Massa de gás no tubo de produção
m_{lt}	Massa de líquido no tubo de produção
m_{gb}	Massa da bolha de gás na linha de produção
m_{gr}	Massa de gás na linha de produção e o riser
m_{lr}	Massa de líquido na linha de produção e o riser

As variações nas variáveis de estado dependem principalmente das vazões mássicas entre as diferentes seções. W_{gc} é a vazão mássica de *gas-lift*, enquanto W_{iv} é a vazão mássica de gás que vai do anular ao tubo de produção, que pode ser estimada pela Equação (A.7).

$$W_{iv} = K_a \sqrt{\rho_{ai}(P_{ai} - P_{tb})} \quad (\text{A.7})$$

W_r indica a vazão estimada desde o reservatório ao fundo do poço (A.8), enquanto as vazões mássicas de líquido e gás na árvore de natal foram modeladas como válvulas, de acordo com as Equações (A.9) e (A.10), respectivamente. K_r é o parâmetro linear do modelo de Vogel e K_w é o coeficiente de vazão na árvore de natal.

$$W_r = K_r \left[1 - \left(0,2 \frac{P_{bh}}{P_r} \right) - \left(0,8 \frac{P_{bh}}{P_r} \right)^2 \right] \quad (\text{A.8})$$

$$W_{whg} = K_w \sqrt{\rho_L(P_{tt} - P_{rb})} \alpha_{gt} \quad (\text{A.9})$$

$$W_{whl} = K_w \sqrt{\rho_L(P_{tt} - P_{rb})} (1 - \alpha_{gt}) \quad (\text{A.10})$$

A vazão mássica na válvula virtual está dada por W_g e as vazões de gás e líquido através da válvula choke estão dadas por W_{gout} e W_{lout} . As Equações (A.11)-(A.13) descrevem o cálculo dessas vazões mássicas. As constantes da válvula choke virtual e da

saída do sistema estão dadas por C_g e C_{out} , respectivamente, enquanto a abertura da válvula choke está dada pela variável z .

$$W_g = C_g(P_{eb} - P_{rb}) \quad (A.11)$$

$$W_{gout} = \alpha_g C_{out} z \sqrt{\rho_L(P_{rt} - P_s)} \quad (A.12)$$

$$W_{lout} = \alpha_l C_{out} z \sqrt{\rho_L(P_{rt} - P_s)} \quad (A.13)$$

As pressões e densidades utilizadas nesse modelo são descritas na Tabela A-2. O cálculo dessas pressões e densidades é descrito nas Equações (A.14)-(A.24).

Tabela A-2. Pressões e densidades utilizadas no modelo FOWM.

Variável	Descrição	Variável	Descrição
P_r	Pressão do reservatório	P_{rt}	Pressão no topo do riser
P_{bh}	Pressão no fundo do poço	P_s	Pressão no separador
P_{pdg}	Pressão na PDG	ρ_{mres}	Densidade da mistura no reservatório
P_{ai}	Pressão no ponto de injeção de gás no anular	ρ_{gt}	Densidade do gás no tubo de produção
P_{tb}	Pressão no ponto de injeção de gás do lado do tubo de produção	ρ_{mt}	Densidade da mistura no tubo de produção
P_{tt}	Pressão no topo do tubo de produção	ρ_l	Densidade do líquido
P_{rb}	Pressão na seção da linha de produção prévia à posição da bolha	ρ_{ai}	Densidade de gás no anular
P_{eb}	Pressão na bolha de gás		

$$P_{ai} = \left(\frac{RT}{V_a M} + \frac{gL_a}{V_a} \right) m_{ga} \quad (A.14)$$

$$P_{tb} = P_{tt} + \rho_{mt} g H_{vgl} \quad (A.15)$$

$$P_{bh} = P_{pdg} + \rho_{mres} g (H_t - H_{pdg}) \quad (A.16)$$

$$P_{pdg} = P_{tb} + \rho_{mres} g (H_{pdg} - H_{vgl}) \quad (A.17)$$

$$P_{tt} = \frac{\rho_{gt} RT}{M} \quad (A.18)$$

$$P_{rb} = P_{rt} + \frac{(m_{lr} + m_{L,still})g\sin(\theta)}{A_{ss}} \quad (\text{A.19})$$

$$P_{eb} = \frac{m_{gb}RT}{MV_{eb}} \quad (\text{A.20})$$

$$P_{rt} = \frac{m_{gr}RT}{M(\omega_u V_{ss} - \frac{m_{lr} + m_{L,still}}{\rho_l})} \quad (\text{A.21})$$

$$\rho_{ai} = \frac{MP_{ai}}{RT} \quad (\text{A.22})$$

$$\rho_{mt} = \frac{m_{gt} + m_{lt}}{V_t} \quad (\text{A.23})$$

$$\rho_{gt} = \frac{m_{gt}}{V_{gt}} \quad (\text{A.24})$$

Além disso, o modelo utiliza as frações mássicas de gás e líquido nas diferentes seções do sistema, descritas na Tabela A-3 e calculadas segundo as Equações (A.25)-(A.27). O modelo possui também diferentes variáveis relacionadas à geometria do sistema, incluindo a área transversal e o volume nas diferentes seções. Os cálculos para determinar essas variáveis são mostrados nas Equações (A.28)-(A.32).

Finalmente, para ajustar esse modelo a dados experimentais, é preciso estimar nove parâmetros: $m_{L,still}$, C_g , C_{out} , V_{eb} , E , K_w , K_a , K_r , ω_u .

$$\alpha_{gt} = \frac{m_{gt}}{m_{gt} + m_{lt}} \quad (\text{A.25})$$

$$\alpha_{gr} = \frac{m_{gr}}{m_{gr} + m_{lr}} \quad (\text{A.26})$$

$$\alpha_{lr} = 1 - \alpha_{gr} \quad (\text{A.27})$$

$$A_{ss} = \frac{\pi D_{ss}^2}{4} \quad (\text{A.28})$$

$$V_{ss} = \frac{\pi D_{ss}^2}{4} L_r + \frac{\pi D_{ss}^2}{4} L_{fl} \quad (\text{A.29})$$

$$V_a = \frac{\pi D_a^2}{4} L_a \quad (\text{A.30})$$

$$V_t = \frac{\pi D_t^2}{4} L_t \quad (\text{A.31})$$

$$V_{gt} = V_t - \frac{m_{lt}}{\rho_L} \quad (\text{A.32})$$

Tabela A-3. Frações mássicas e variáveis relacionadas à geometria do sistema utilizadas no modelo FOWM.

Variável	Descrição	Variável	Descrição
α_{gt}	Fração mássica de gás no tubo de produção	L_r	Comprimento do <i>riser</i>
α_{gr}	Fração mássica de gás nas condições de pressão e temperatura do reservatório	L_a	Comprimento do anular
α_{lr}	Fração mássica de líquido nas condições de pressão e temperatura do reservatório	L_t	Comprimento do tubo de produção
H_t	Distância vertical desde a árvore de natal até o fundo do poço	V_a	Volume do anular
H_{pdg}	Distância vertical desde a árvore de natal até a PDG.	V_{eb}	Volume da bolha de gás
H_{vgl}	Distância vertical desde a árvore de natal até a válvula de <i>gas-lift</i>	V_{ss}	Volume da linha de produção
$m_{L,still}$	Massa mínima de líquido na linha de produção	V_{gt}	Volume de gás no tubo de produção
θ	Inclinação média do <i>riser</i>	V_t	Volume do tubo de produção
ω_u	Parâmetro utilizado para definir a localização da bolha	D_{ss}	Diâmetro da linha de produção
A_{ss}	Área transversal da linha de produção	D_a	Diâmetro equivalente do anular
L_{ft}	Comprimento da linha de produção	D_t	Diâmetro do tubo de produção

Parâmetros do sistema de produção

O sistema de produção simulado nesse trabalho com o modelo FOWM para a geração de dados foi aquele descrito por DIEHL *et al.* (2017) como poço A. Os valores dos parâmetros do sistema necessários para o modelo são mostrados na Tabela A-4. Além disso, a Tabela A-5 mostra os parâmetros estimados após o ajuste aos dados reais.

Tabela A-4. Parâmetros do sistema de produção real (poço A) utilizados na simulação pelo modelo FOWM

Parâmetro	Valor	Unidade
ρ_L	900	kg/m ³
P_r	225	bar
P_s	10	bar
α_{gw}	0.0188	-
ρ_{mres}	892	kg/m ³
M	18	kg/kmol
T	298	K
L_r	1569	m
L_{ft}	2928	m
L_t	1639	m
L_a	1118	m
H_t	1279	m
H_{pdg}	1117	m
H_{vgl}	916	m
D_{ss}	0.15	m
D_t	0.15	m
D_a	0.14	m

Tabela A-5. Parâmetros estimados a partir dos dados reais do poço A para a simulação com o modelo FOWM.

Parâmetro	Valor	Unidade
$m_{L,still}$	900	kg/m ³
C_g	225	bar
C_{out}	10	bar
V_{eb}	0.0188	-
dE	892	kg/m ³
K_w	18	kg/kmol
K_a	298	K
K_r	1569	m
ω_u	2928	m