



Universidade Federal da Bahia
Escola Politécnica
Colegiado do Curso de Eng. de Controle e
Automação



Gabriel Azevedo Anuniação

ANÁLISE COMPARATIVA DE ESTRUTURAS DE REDES NEURAIIS ARTIFICIAIS PARA MODELAGEM BASEADA EM DADOS DO BOMBEIO CENTRÍFUGO SUBMERSO

Orientador(a): Prof. Dr. Raony Maia Fontes

Salvador, BA

2023

Gabriel Azevedo Anunciação

**ANÁLISE COMPARATIVA DE ESTRUTURAS DE
REDES NEURAIS ARTIFICIAIS PARA MODELAGEM
BASEADA EM DADOS DO BOMBEIO CENTRÍFUGO
SUBMERSO**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Controle e Automação de Processos da Universidade Federal da Bahia, como requisito parcial para a obtenção do título de Engenheiro de Controle e Automação.

Orientador(a): Prof. Dr. Raony Maia Fontes

Salvador, BA

2023

UNIVERSIDADE FEDERAL DA BAHIA
CURSO DE GRADUAÇÃO ENGENHARIA DE CONTROLE E
AUTOMAÇÃO DE PROCESSOS

FOLHA DE APROVAÇÃO

Gabriel Azevedo Anuniação

ANÁLISE COMPARATIVA DE ESTRUTURAS DE REDES NEURAS ARTIFICIAIS
PARA MODELAGEM BASEADA EM DADOS DO BOMBEIO CENTRIFUGO
SUBMERSO

Trabalho final de conclusão de curso apresentado ao curso de Engenharia de Controle e Automação de Processos da Universidade Federal da Bahia como requisito parcial para obtenção do grau de Bacharel em Engenharia de Controle e Automação de Processos

Orientador: Dr. Raony Maia Fontes

Aprovado em: 15 de dezembro de 2023.

Banca Examinadora

Prof. Dr. Raony Maia Fontes

Prof Dr Daniel Diniz Santana

Prof Dr Leonardo Silva Souza

Agradecimentos

Agradeço a Deus pela vida, pela saúde, pelo seu imenso amor, por me ajudar em todos os momentos e em todas as áreas da minha vida. Por ser um pai, um amigo, um guarda fiel, um bálsamo consolador, a minha Luz, o meu Senhor e Salvador.

Aos meus pais Paulo Silas e Noemi, pelo amor e carinho, pela excelente educação, pelo acesso à educação, pelo apoio e incentivo à busca do conhecimento.

À minha esposa Sinara pelo apoio, pelo amor, pela cumplicidade e por tornar tudo melhor e mais colorido.

Ao meu orientador Prof. Dr. Raony Fontes pela excelente orientação e paciência, ao meu professor e coordenador de curso Prof. Dr. Daniel Santanta e aos demais professores da Escola Politécnica.

Aos meus colegas de curso Valter Lucas, João Félix, Regiane, Silmara, Ícaro Pedrão, Ricardo Grael, Gustavos, Gerald, Lara, por deixarem a experiência da graduação mais leve desde o início.

Resumo

Este trabalho propõe uma comparação das estruturas de redes neurais artificiais com o objetivo de desenvolver um modelo substituto baseado em dados, oferecendo uma alternativa aos modelos fenomenológicos. O modelo visa prever variáveis de interesse, como vazão e pressão na válvula *choke*, e nível do anular em um sistema de elevação artificial por Bombeio Centrífugo Submerso (BCS), utilizando informações como a frequência do motor da bomba, abertura da válvula *choke*, pressão de fundo e do reservatório. Os dados para o treinamento e validação do modelo são gerados a partir de um simulador da planta piloto do BCS no Laboratório de Elevação Artificial (LEA) da Universidade Federal da Bahia (UFBA). A avaliação das diferentes estruturas de redes neurais considera métricas de desempenho como *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), velocidades de treinamento e estimação da saída com novos dados, além do critério de Akaike, proporcionando uma análise abrangente e criteriosa.

Palavras-chave: BCS. Redes neurais artificiais. Modelagem. Comparação.

Abstract

This work proposes a detailed comparison of artificial neural network structures with the aim of developing a data-driven surrogate model, providing an alternative to phenomenological models. The model aims to predict variables of interest, such as flow rate and pressure in the choke valve, and annular level in a *Electric Submersible Pump (ESP)*, using information such as pump motor frequency, choke valve opening, bottom hole and reservoir pressure. The data for training and validating the model are generated from a simulator of the ESP pilot plant at the Artificial Lift Laboratory (LEA) of the Federal University of Bahia (UFBA). The evaluation of the different neural network structures considers performance metrics such as [RMSE](#), [MAE](#), training speed, estimation of outputs with new data speed, and the Akaike criterion, providing a comprehensive and thorough analysis.

Keywords: ESP. Artificial neural network. Modeling. Comparison.

Lista de ilustrações

Fig. 1 – Poço de Petróleo operado por BCS.	21
Fig. 2 – Curva característica da bomba.	22
Fig. 3 – Impulsor e difusor da bomba.	22
Fig. 4 – Representação do BCS LEA.	23
Fig. 5 – Produção de Petróleo (barris por dia).	24
Fig. 6 – Dados relacionados a indústria de Petróleo e Gás Natural.	24
Fig. 7 – Neurônio Artificial.	27
Fig. 8 – Função Sigmóide.	28
Fig. 9 – Função Tangente Hiperbólica.	29
Fig. 10 – Estrutura de Rede Neural.	30
Fig. 11 – a) Redes de Alimentação direta b) Redes Recorrentes.	31
Fig. 12 – TDNN com 2 atrasos.	32
Fig. 13 – Layer Recurrent Neural Network com 2 atrasos.	32
Fig. 14 – Distributed Delay Neural Network com 2 atrasos na entrada e na camada oculta.	33
Fig. 15 – Estrutura da Rede NARX.	33
Fig. 16 – Fluxograma da Metodologia.	35
Fig. 17 – Entradas do Modelo – Dados de Validação.	39
Fig. 18 – Visualização Gráfica – Estimação do Nível do Anular.	40
Fig. 19 – Visualização Gráfica – Estimação do Nível do Anular (Zoom +).	41
Fig. 20 – Visualização Gráfica – Estimação do Nível do Anular (Zoom +).	41
Fig. 21 – Gráfico de Resíduos.	43
Fig. 22 – Visualização Gráfica – Estimação da Pressão na Válvula <i>Choke</i>	43
Fig. 23 – Visualização Gráfica – Estimação da Pressão na Válvula <i>Choke</i> . (Zoom+	44
Fig. 24 – Visualização Gráfica – Estimação da Pressão na Válvula <i>Choke</i> . (Zoom+	45
Fig. 25 – Visualização Gráfica – Estimação da Pressão na Válvula <i>Choke</i> . (Zoom+	45
Fig. 26 – Gráfico de Resíduos.	46
Fig. 27 – Visualização Gráfica – Estimação da Vazão na Válvula <i>Choke</i>	47
Fig. 28 – Visualização Gráfica – Estimação da Vazão na Válvula <i>Choke</i> (Zoom+).	48
Fig. 29 – Visualização Gráfica – Estimação da Vazão na Válvula <i>Choke</i> (Zoom+).	48
Fig. 30 – Visualização Gráfica – Estimação da Vazão na Válvula <i>Choke</i> (Zoom+).	49
Fig. 31 – Gráfico de Resíduos.	50

Lista de tabelas

Tab. 1 – Métricas de desempenho dos modelos na estimação do Nível do Anular. .	42
Tab. 2 – Métricas de desempenho dos modelos na estimação da Pressão na Válvula Choke.	46
Tab. 3 – Métricas de desempenho dos modelos na estimação da Vazão na Válvula Choke.	49

Lista de abreviaturas e siglas

AIC *Akaike Index Criteria*

ANP Agência Nacional de Petróleo

BCS Bombeio Centrífugo Submerso

CTAI Centro Tecnológico em Automação Industrial

ESP *Electric Submersible Pump*

FFNN *Feedforward Neural Network*

IA Inteligência Artificial

LEA Laboratório de Elevação Artificial

LRNN *Layer Recurrent Neural Network*

MAE *Mean Absolute Error*

NARX *Nonlinear Autoregressive with External Input*

RNA Redes Neurais Artificiais

RNN *Recurrent Neural Network*

RMSE *Root Mean Squared Error*

TDNN *Time Delay Neural Network*

UFBA Universidade Federal da Bahia

Sumário

1	INTRODUÇÃO	19
1.1	Descrição do Processo	20
1.2	Justificativa	24
1.3	Objetivos	25
1.3.1	Objetivos Específicos	25
1.4	Estrutura do Trabalho	26
2	FUNDAMENTAÇÃO TEÓRICA	27
2.1	Redes Neurais Artificiais	27
2.1.1	Redes Neurais de Alimentação Direta	31
2.1.2	<i>Redes Neurais Recorrentes</i>	31
2.1.2.1	<i>Time Delay Neural Network</i>	32
2.1.2.2	<i>Layer Recurrent Neural Network</i>	32
2.1.2.3	<i>Distributed Delay Network</i>	33
2.1.2.4	<i>Nonlinear Autoregressive Neural Network with External Input</i>	33
3	METODOLOGIA	35
3.1	Aquisição dos Dados	35
3.2	Pré-processamento dos Dados	36
3.3	Desenvolvimento dos Modelos	36
3.4	Treinamento dos Modelos	36
3.5	Ajuste dos hiperparâmetros	36
3.6	Seleção dos Modelos	37
3.7	Validação dos Modelos	38
3.8	Comparação entre os Modelos	38
4	RESULTADOS	39
4.1	Nível do Anular	40
4.2	Pressão na Válvula <i>Choke</i>	43
4.3	Vazão na Válvula <i>Choke</i>	47
5	CONCLUSÃO	51
5.1	Trabalhos Futuros	51
	REFERÊNCIAS	53

1 INTRODUÇÃO

O setor de Petróleo e Gás tem grande importância social e econômica no Brasil, sendo o 3º no ranking das principais atividades econômicas (IBP, 2019). Portanto, muitos recursos são alocados para pesquisa e desenvolvimento com objetivo de geração de novas tecnologias, a exemplo da otimização de processos, para redução dos custos envolvidos.

Na produção de petróleo, são utilizados métodos de elevação artificial em casos em que a pressão do reservatório não é suficiente para elevar o fluido até a superfície. Dentre as técnicas utilizadas está o Bombeio Centrífugo Submerso (BCS), foco deste trabalho. Devido a sua capacidade de elevar altas vazões de fluido em grandes profundidades sob diferentes condições dinâmicas de escoamento, o uso deste método tem crescido nos últimos anos, como afirma Souza (2014).

Para o acompanhamento da produção de petróleo, e possibilitando, entre outros, a utilização de sistemas de controle, são utilizadas cartas de registro de corrente; realizados testes de produção, nos quais são medidos (THOMAS et al., 2004): a pressão na cabeça do poço, vazão; e, em poços mais modernos, um conjunto de instrumentação composta de sensores (e.g. de pressão, temperatura de fundo), e dispositivos finais de controle (e.g. válvulas, inversores de frequência). A exemplo da planta piloto do BCS no LEA do Centro Tecnológico em Automação Industrial (CTAI) na UFBA, planta esta utilizada na aquisição de dados na elaboração deste trabalho, ela é composta por uma série de instrumentos de medição que permitem o acompanhamento da elevação de óleo (SOUZA, 2014).

No entanto, sensores físicos utilizados com o objetivo de monitoramento e controle em poços de petróleo tendem a obter crescentes incertezas com o tempo, além disso há o agravante dos altos custos de manutenção e substituição (GRAHAM, 2015), e também pelas condições extremas no ambiente (LESKENS et al., 2008).

Portanto, uma alternativa aos sensores físicos para obter informações sobre o valor das variáveis do processo são os modelos matemáticos, os quais representam o comportamento físico do sistema através de formulações matemáticas, descrevendo os fenômenos envolvidos no processo. Segundo (BIKMUKHAMETOV; JÄSCHKE, 2020), os modelos matemáticos são divididos em: (i) modelos fenomenológicos, (ii) modelos baseados em dados e (iii) modelos híbridos. No primeiro são utilizadas leis de conservação e equações constitutivas, aplicando o conhecimento físico para o desenvolvimento do modelo. No segundo, são utilizados dados históricos do processo para o desenvolvimento de um modelo parametrizado, encontrando relações “diretas” entre as variáveis de entradas e de saídas do sistema, sendo essa a sua principal vantagem. No terceiro, são utilizadas as duas técnicas de forma complementar. Os principais passos no processo de desenvolvimento de um modelo

baseado em dados são: coleta e pré-processamento dos dados, desenvolvimento do modelo, predição em novos dados.

Em se tratando de poços de produção de petróleo, estes possuem dinâmicas complexas, dificultando o desenvolvimento de modelos fenomenológicos. Como afirma (ZHU; ZHANG, 2018), ainda não se tem entendimento do efeito físico do fluxo multifásico no desempenho hidráulico no BCS. Mecanismos de coalescência e rompimento de bolhas de ar dentro do BCS, os quais afetam de forma significativa as características do fluxo multifásico, ainda não são claros. Além disso, a geometria compacta do BCS dificulta a visualização do fluxo e o movimento das bolhas dentro da bomba, o que poderia facilitar modelos analíticos de primeiros princípios. Por isso, os modelos baseados em dados são utilizados como alternativa a modelos fenomenológicos (ZHU; ZHANG, 2018).

Dessa forma, o objetivo deste trabalho é o estudo e comparação de diferentes estruturas de Redes Neurais Artificiais (RNA) para estimação, em tempo real, de variáveis de interesse na elevação artificial de petróleo em poços governados por BCS, como alternativa a modelos fenomenológicos. O simulador da planta piloto do BCS no LEA da UFBA é a fonte de dados, bem como o ambiente de aplicação e validação dos modelos desenvolvidos.


1.1 Descrição do Processo

O BCS, visto na Figura 1, é um método de elevação artificial caracterizado pelo uso das bombas de centrífugas submersas. Os componentes usados nesse método de elevação podem ser divididos em equipamentos de subsuperfície e superfície. Os Principais componentes de subsuperfície são: bomba centrífuga submersa, motor elétrico, protetor, cabo elétrico, separador de gás, admissão da bomba. Enquanto que os principais componentes de superfície são: quadro de comandos, transformador, cabeça de produção, válvula de retenção, válvula de drenagem ou de alívio, sensores de pressão e temperatura de fundo. (BRASIL, 2010).

Como afirma Thomas et al. (2004) a capacidade de operação da bomba é dada por cada fabricante através da curva característica (Figura 2), sendo conveniente a escolha da bomba que operam somente nos intervalos de vazão recomendados. Importante salientar que o método de ensaio hidrostático que os fabricantes utilizam, consideram o bombeio de água, logo, fluidos com densidade e viscosidades diferentes alteram as informações do gráfico.

A bomba é composta, internamente, como apresenta Thomas et al. (2004) na figura 3, por um par de impulsor, ou impelidor, e difusor. O impulsor é acoplado ao eixo da bomba e gira no mesmo sentido, diminuindo, assim, a pressão, fazendo com que o fluido seja succionado. O difusor é um elemento estacionário, ele faz a conversão de energia cinética em pressão, elevando o fluido para o próximo estágio, cada estágio é formado de

Fig. 1 – Poço de Petróleo operado por BCS.



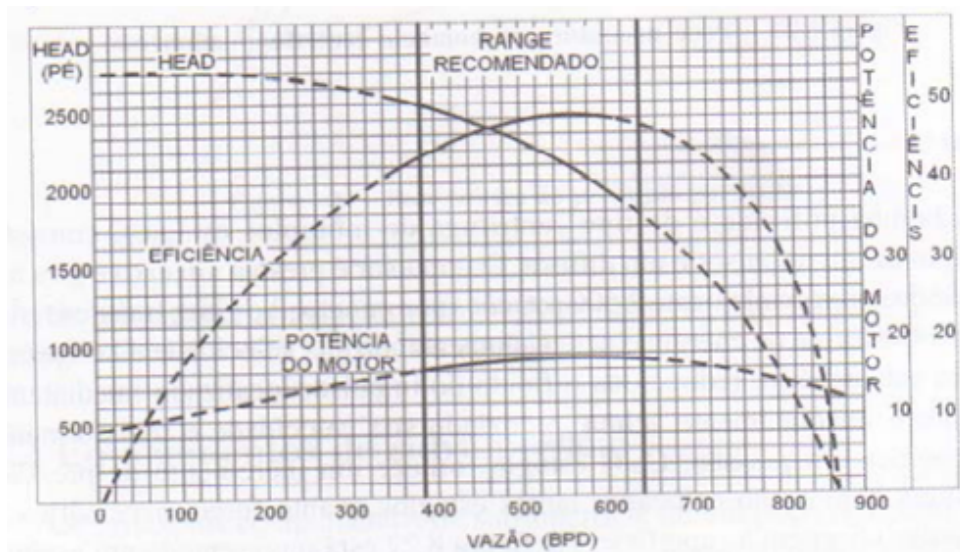
Fonte: (THOMAS et al., 2004).

um par impulsor e difusor. O número de estágios em uma bomba centrífuga é diretamente proporcional à sua capacidade de elevação (*head*), enquanto que as dimensões do impulsor e difusor estão relacionadas à vazão do fluido.

O protetor é um componente que liga o motor elétrico à bomba por meio de um eixo, a sua principal função é proteger o motor elétrico, impedindo que o fluido bombeado o atinja. A admissão da bomba pode ser da forma simples, ou seja, sem separador de gás, ou com o separador de gás, que por sua vez pode ser estacionário, separando o gás por meio de uma mudança de caminho, pela diferença de densidade entre o óleo e o gás produzido, o separador estacionário possui dois caminhos, o que leva à bomba, caminho do óleo, e o outro que leva ao anular, caminho do gás. Há também o separador centrífugo que usa a força centrífuga para fazer a separação das fases (THOMAS et al., 2004).

Há a criação de duas zonas de pressão diferenciadas, uma de baixa pressão, chamada de sucção; e outra de alta pressão, esta chamada de recalque. Para que aconteça a formação

Fig. 2 – Curva característica da bomba.




Fonte: (THOMAS et al., 2004).

destas duas zonas de pressão distintas, é necessário que haja, na parte interna da bomba, a transformação da energia mecânica (de potência), fornecida pela máquina motriz, neste caso, um motor (BRASIL, 2010).

O acompanhamento da produção no método do BCS é feito através de testes de

Fig. 3 – Impulsor e difusor da bomba.




Fonte: (THOMAS et al., 2004).

produção, das cartas de corrente e de sensores de fundo, caso hajam. São medidos vazões, pressões, nível do anular, razão gás-líquido etc. A eficiência de operação do sistema é inferida ao comparar essas informações com a curva de desempenho da bomba.

Para representar o sistema do BCS presente no LEA (Figura 4), foram definidas quatro variáveis de entrada e três variáveis de saída dos modelos de RNA, sendo as de entrada: (i) frequência do motor da bomba, (ii) abertura da válvula *choke*, (iii) pressão de *manifold* (iv) e pressão de fundo. As saídas: (i) nível de óleo na região do anular, (ii) pressão na válvula *choke* e (iii) vazão na válvula *choke*. A planta piloto do BCS no LEA,

Fig. 4 – Representação do BCS LEA.




Fonte: (COSTA, 2019).

ambiente de coleta de dados e aplicação deste trabalho, possui altura do poço (h_{bh}) de 32 metros, a altura da bomba (h_p) de 22,7 metros (altura da coluna de fluido), e conjunto de instrumentação para medição das variáveis de interesse, tais como nível do anular, pressão na válvula choke, vazão na válvula *choke*, pressão no *manifold*, pressão de reservatório entre outras.

1.2 Justificativa

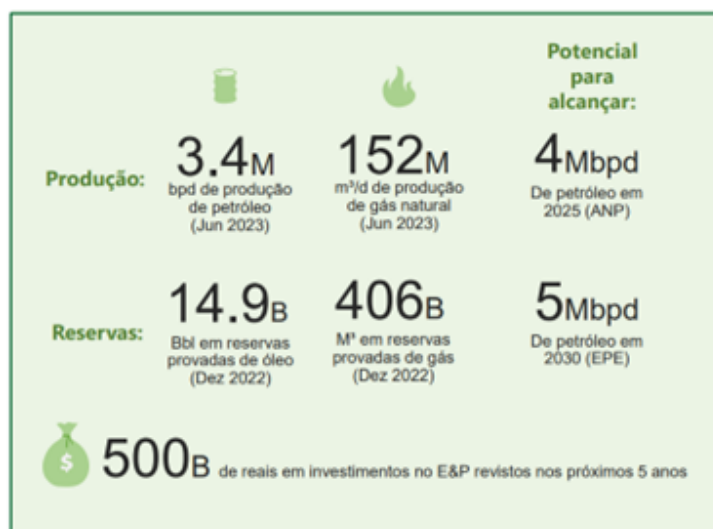
Devido a magnitude da produção de petróleo e gás natural, em uma constante crescente nos últimos anos (Figura 5) sendo a previsão de produção, de acordo com a Agência Nacional de Petróleo (ANP) (SABOIA, 2023), para o ano de 2025 igual a, aproximadamente, 4 Mbpd (Milhões de barris por dia) de petróleo, dando um total de, aproximadamente, 1,46B de barris no ano (Figura 6).

Fig. 5 – Produção de Petróleo (barris por dia).



Fonte: (SABOIA, 2023).

Fig. 6 – Dados relacionados a indústria de Petróleo e Gás Natural.



Fonte: (SABOIA, 2023).

O desenvolvimento de pesquisas relacionadas a otimização da produção de petróleo e gás natural tem um efeito considerável. Portanto a aquisição de dados das variáveis do processo, o que permite o desenvolvimento de sistema de controle, análises e predição (BAKHTADZE et al., 2007) têm um papel significativo no aumento da produção. No entanto, devido à profundidade dos poços e a complexidade do procedimento de parada do funcionamento do BCS na produção de petróleo, as atividades de manutenção, substituição e/ou instalação de sensores de fundo podem ser economicamente inviáveis, como afirma COSTA (2020).

Além disso, como destaca Takács (2009), os sensores físicos são sujeitos a altas pressões e temperaturas, condições prejudiciais ao funcionamento e à vida útil dos equipamentos. Dessa forma, a utilização de modelos matemáticos representativos é uma alternativa aos sensores físicos para o monitoramento da produção. Ademais, as propriedades do óleo, tal como a viscosidade, em muitos casos são obtidas por meio de ensaios de laboratório ou analisadores em linha que apresentam baixa frequência de amostragem, isso dificulta sua utilização em sistemas de controle em tempo real (ITO, 2014).

Portanto, a utilização de modelos matemáticos se apresenta como uma alternativa para inferência em tempo real. Segundo COSTA (2019a), os modelos baseados em dados são utilizados na modelagem de sistemas dinâmicos quando a construção de um modelo fenomenológico é complexa ou impraticável. Portanto, devido à complexidade de operação de manutenção e instalação de sensores físicos no fundo do poço, bem como a complexidade envolvida na modelagem fenomenológica dos fenômenos envolvidos que podem exigir tempos elevados para cômputo, os modelos baseados em dados se apresentam como alternativa para inferência das variáveis de processo.

A proposta deste trabalho é o desenvolvimento de comparação de diferentes estruturas de RNA para estimação de variáveis de interesse da planta piloto do BCS/LEA na UFBA a partir de variáveis secundárias.

1.3 Objetivos

Comparar diferentes estruturas de RNA no desenvolvimento de modelos baseados em dados para predição do nível do anular, pressão e vazão da válvula *choke* do BCS do LEA na UFBA.

1.3.1 Objetivos Específicos

- Coletar e montar base de dados gerados a partir do simulador da planta piloto do BCS no LEA da UFBA para o treinamento e validação dos modelos;
- Desenvolver um modelo substituto baseado em dados usando diferentes estruturas

de [RNA](#) para prever as seguintes variáveis: vazão e pressão na válvula *choke* e nível do anular em um sistema de [BCS](#);

- Comparar as diferentes estruturas de [RNA](#) considerando métricas de desempenho como [RMSE](#), [MAE](#), velocidade de treinamento e estimação da saída com novos dados, além do critério de Akaike.

1.4 Estrutura do Trabalho

O Capítulo 1 trouxe uma breve contextualização a respeito dos problemas de acompanhamento da produção de petróleo, apresentou o Sistema, justificou este trabalho indicando o método de solução pretendido, além disso, foi apresentado o detalhamento das métricas utilizada para comparar o desempenho dos modelos.

A fundamentação teórica encontra-se no Capítulo 2, onde é explicado em detalhes a história, aplicações e como funcionam as [RNA](#). Além de diferenciar as arquiteturas de redes de alimentação direta e redes recorrentes, essa última dividida em diferentes estruturas.

No Capítulo 3, é apresentado a metodologia de aquisição de dados e ferramentas utilizadas para desenvolvimento dos modelos.

A comparação entre os modelos e os resultados são expostos no Capítulo 4. Então, é apresentado o desempenho de cada modelo na estimação das variáveis.

No Capítulo 5 é feita a conclusão, onde contém a análise em relação às respostas obtidas com base nos objetivos estabelecidos, bem como a sugestão de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Redes Neurais Artificiais

As redes neurais artificiais são um ramo da Inteligência Artificial (IA), pode ser descrita como um algoritmo desenvolvido para executar uma tarefa de maneira similar ao cérebro humano, tendo a capacidade de reconhecer padrões, extrair relações entre as entradas e saídas dos dados apresentados a elas, além de estimar sistemas não lineares dinâmicos, o que torna possível a sua aplicação neste trabalho.

Segundo Haykin (2001), uma rede neural artificial pode ser definida como um processador distribuído de forma paralela, composta por unidades de processamento simples, chamadas de neurônios, que armazenam conhecimento experimental e o tornam disponível para uso. A sua semelhança com o cérebro humana se dá em dois aspectos: (1) o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; (2) forças de conexão entre neurônios (os pesos sinápticos) são utilizadas para armazenar o conhecimento adquirido.

As redes neurais são compostas de unidades, chamadas de neurônios (Figura 7) e conexões entre eles, o neurônio representa o processamento de informações, seus elementos são: (i) peso, o qual pondera o sinal dos neurônios da camada anterior; (ii) função de soma, que soma todos os sinais dos neurônios da camada anterior ponderados com os seus respectivos pesos; (iii) função de transferência ou função de ativação.

Fig. 7 – Neurônio Artificial.



Fonte: (TAFNER; XEREZ; FILHO, 1995).

Os pesos, representados pela letra w que vem do inglês *weight*, são a ponderação das conexões entre os neurônios, os quais são alterados durante o processo de treinamento das redes, com o objetivo de reduzir o desvio entre a saída real e a estimada pelo modelo.

A função soma tem como saída a soma de todos os sinais dos neurônios da camada anterior ponderados com os seus respectivos pesos, ela tem o seguinte formato:

$$y_j = \sum_i w_{ij}x_i \quad (2.1)$$


Onde y_j é o resultado da função soma do neurônio j , x_i é a saída do neurônio i da camada anterior e w_{ij} é o peso entre a conexão do neurônio i da camada anterior e o neurônio j .

A função de transferência, por sua vez, que pode ser também chamada de função de ativação, limita a amplitude da saída do neurônio em um intervalo geralmente definido entre 0 e 1 $[0,1]$ ou entre -1 e 1 $[-1,1]$ (MELLO, 2004). Algumas funções utilizadas como função de ativação são:

- Função sigmóide: Assume valores em um intervalo contínuo entre 0 e 1 (Figura 8), a sua formula é a seguinte:

$$S(x) = \frac{1}{1 + e^{-x}} \quad (2.2)$$

Fig. 8 – Função Sigmóide.




Fonte: Autoria Própria.

- Função tangente hiperbólica: Assume valores em um intervalo contínuo entre -1 e 1 (Figura 9), a sua formula é a seguinte:

$$\tanh(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (2.3)$$

Fig. 9 – Função Tangente Hiperbólica.



Fonte: Autoria Própria.

Além dos elementos básicos que compõem um neurônio artificial, ele ainda pode apresentar um *bias*, que é somado ou subtraído na função soma com objetivo de aumentar ou diminuir a entrada líquida da função de ativação (HAYKIN, 2001), agindo como um peso extra nas conexões dos neurônios com entrada unitária (FAUSETT, 1994).

Portanto, a saída dos neurônios são representadas pelo resultado da função de ativação da multiplicação entre cada neurônio e seus pesos respectivos somados do *bias*:

$$y_k = \sigma\left(\sum_{i=1}^n (w_{ij}x_i) + b_k\right) \quad (2.4)$$

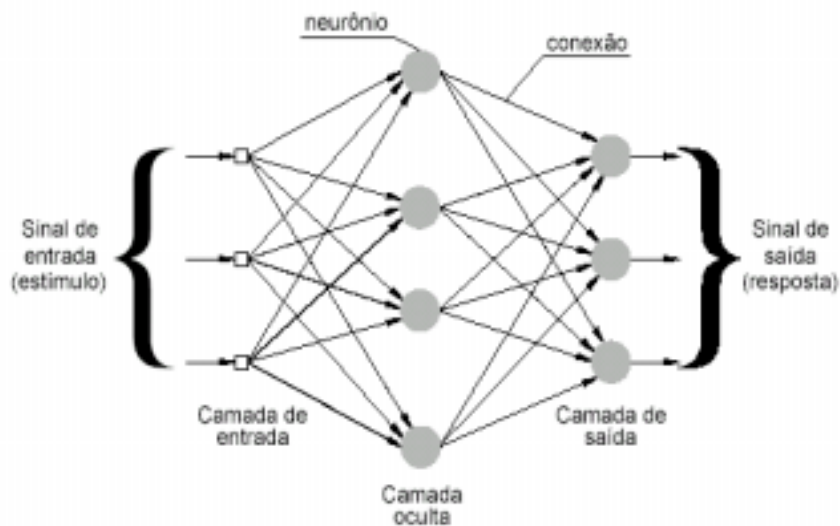
O processo de treinamento da rede neural se dá pelo ajustes dos seus parâmetros, a saber, os pesos e *bias*, e é realizado a partir do chamado algoritmo de aprendizado. O *backpropagation* é o algoritmo mais popular no treinamento de RNA, o seu funcionamento consiste na retropropagação da diferença entre a saída real e a saída estimada pelo modelo, chamada de erro, a partir da camada de saída em direção à camada de entrada, com isso os parâmetros da rede neural são ajustados com objetivo de reduzir o erro (ARTERO, 2009). O cálculo do erro é dado pela seguinte expressão:

$$E(n) = \frac{1}{2} \sum_{k=1}^M (d_k(n) - y_k(n))^2, \quad (2.5)$$

em que as conexões entre os neurônios formam uma estrutura chamada de rede neural, que é composta por camadas (MELLO, 2004), as quais agrupam neurônios por níveis, há três níveis de camadas de neurônios (Figura 10):

1. **Camada de entrada:** onde os dados de entradas (características) são apresentados à rede;
2. **Camada oculta (intermediárias):** Onde a maior parte do processamento é feita, são consideradas como extratoras de características dos dados;
3. **Camada de saída:** cuja saída representa o resultado esperado.

Fig. 10 – Estrutura de Rede Neural.




Fonte: (ALVES, 2001).

A forma como os neurônios são interligados é chamada de arquitetura da rede, o procedimento que torna possível a transferência de conhecimento à rede é chamado de algoritmo de aprendizagem. Assim, a arquitetura da rede e o algoritmo de aprendizagem, são responsáveis pela conclusão do que a rede tem como objetivo. Portanto devem ser definidos de forma a observar qual é o problema que a rede deve resolver, seja um problema de classificação, ou de regressão, por exemplo.

A arquitetura das redes neurais pode ser dividida em duas partes (Figura 11), as redes de alimentação direta (*Feedforward Neural Network (FFNN)*), ou seja, sem realimentação, e as redes recorrentes (*Recurrent Neural Network (RNN)*), ou seja, com realimentação. A rede com alimentação direta e a recorrente se diferenciam entre si pois, a rede de alimentação direta tem o fluxo de informação seguindo em uma única direção, da entrada para a saída, já na rede recorrente há pelo menos um laço de realimentação, seja da entrada, das camadas intermediárias ou da saída (MELLO, 2004).

Fig. 11 – a) Redes de Alimentação direta b) Redes Recorrentes.



Fonte: (ARAÚJO, 2022).

2.1.1 Redes Neurais de Alimentação Direta

As redes neural de alimentação direta, também podem ser chamadas de *Multilayer Perceptron*, pois trata de uma rede *perceptron* com a adição de uma ou mais camadas ocultas, entre a camada de entrada e a camada de saída, sendo completamente conectada, ou seja, todos os neurônios de uma camada são conectados com todos os neurônios da camanda posterior. Nesta arquitetura, o fluxo de informação se dá apenas em um sentido (da entrada para a saída).

Embora muito poderosa, as redes de alimentação direta tem limitações na modelagem de sistemas dinâmicos, portanto, para lidar com sistemas dessa natureza, faz-se necessário a utilização de arquiteturas com realimentação dos dados de saída (ARAÚJO, 2022).

2.1.2 Redes Neurais Recorrentes

Bikmukhametov e Jäschke (2020) afirmam que há diferentes modificações na técnica de redes neurais artificiais capazes de modelar fenômenos transientes. Um exemplo são as redes neurais recorrentes. A principal ideia por trás dessa abordagem é usar dados passados para prever o valor atual de dada variável de interesse. Por exemplo, em casos de sensores virtuais de fluxo, as medidas de temperatura e pressão em tempos anteriores são utilizadas para estimar o fluxo no tempo atual, assim as redes neurais recorrentes têm sido usadas na estimação de fluxo em sensores virtuais. Um exemplo de aplicação das redes neurais recorrentes na literatura é o trabalho de Andrianov (2018), em que foi usado uma rede neural recorrente, usando dados de teste de poço sintético, mostrando a capacidade das redes recorrentes não apenas na estimação, mas também na predição de valores de fluxo em tempo futuro.


Os laços de realimentação, demandam a utilização de elementos de atraso, agregando à rede a capacidade de memória, o que torna possível a modelagem de sistemas dinâmicas, sendo ela classificada como rede neural dinâmica (SEIDL; LORENZ, 1991).

O tipo de realimentação das redes neurais caracterizam diferentes estruturas, as quais serão utilizadas neste trabalho. Abaixo serão descritas algumas estruturas de redes neurais recorrentes com diferentes formas de realimentação dos dados.

2.1.2.1 Time Delay Neural Network

A estrutura de rede neural *Time Delay Neural Network* (TDNN) (Figura 12) tem uma arquitetura distinta das redes de alimentação direta (*Multilayer Perceptron*), devido ao fato de ser uma rede neural recorrente. Ela se destaca pela capacidade de incorporar informações dos dados de entrada em instantes temporais anteriores, o que é conhecido como atraso. Isso permite que os neurônios da rede capturem relações entre a entrada atual e entradas anteriores. Na configuração da rede, é possível definir o atraso, ou seja, quantos instantes anteriores serão considerados em conjunto com o instante atual da entrada.

Fig. 12 – TDNN com 2 atrasos.




Fonte: Autoria Própria.

2.1.2.2 Layer Recurrent Neural Network

As redes *Layer Recurrent Neural Network* (LRNN) (Figura 13) são similares às redes TDNN, no entanto, as redes LRNN possuem realimentação de cada camada oculta na entrada da rede, permitindo que a rede neural apresente respostas dinâmicas a dados de entrada do tipo séries temporais (MATLAB... , 2023).

Fig. 13 – Layer Recurrent Neural Network com 2 atrasos.




Fonte: Autoria Própria.

2.1.2.3 Distributed Delay Network

Essa rede é similar a TDNN e a LRNN, porém na arquitetura das redes neurais Distributed Delay Networks (Figura 14) contém, além do atraso das entradas, o atraso das camadas ocultas para camada de saída.

Fig. 14 – Distributed Delay Neural Network com 2 atrasos na entrada e na camada oculta.

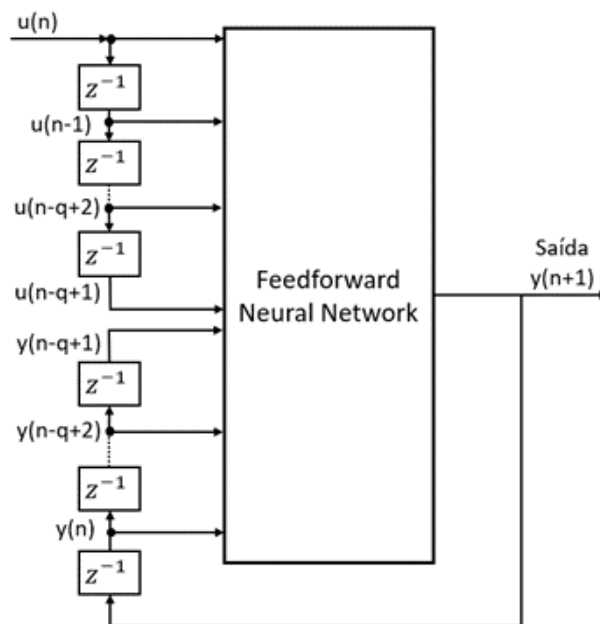


Fonte: Autoria Própria.

2.1.2.4 Nonlinear Autoregressive Neural Network with External Input

As redes *Nonlinear Autoregressive with External Input* (NARX) (Figura 15) são redes não lineares autoregressivas com entradas exógenas. Isso significa que a variável de saída depende de seus próprios valores em instantes passados, tornando as saídas passadas também entradas da rede. Além disso, a rede recebe não apenas os valores das entradas no instante atual, mas também os valores das entradas em instantes anteriores, graças à inclusão de uma linha de atraso entre as entradas e a rede (ARAÚJO, 2022).

Fig. 15 – Estrutura da Rede NARX.



Fonte: Autoria Própria.

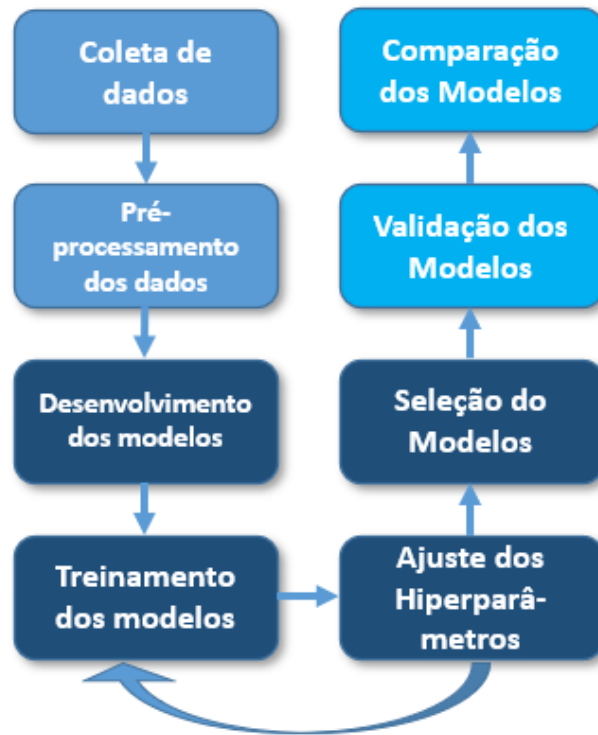
A saída das redes **NARX** segue a seguinte função:

$$y(n+1) = F(y(n), \dots, y(n-q+1), u(n), \dots, u(n-q+1)) \quad (2.6)$$

Onde y é a saída, n é o instante atual, u é a entrada e q é a quantidade de atrasos da saída e das entradas.

3 METODOLOGIA

Fig. 16 – Fluxograma da Metodologia.



Fonte: Autoria Própria.

O desenvolvimento deste trabalho seguiu os seguintes passos: i) coleta dos dados, ii) pré-processamento dos dados iii) desenvolvimento dos modelos, iv) treinamento dos modelos, v) ajuste dos hiperparâmetros, vi) seleção dos modelos, vii) validação dos modelos e viii) comparação entre os modelos. Mantendo um padrão em todos os passos, buscando garantir uma comparação justa, na tentativa de mitigar os vieses existentes. Dessa forma, todos os modelos foram treinados com os mesmos dados de treinamento e avaliados com os mesmos dados de validação. Além disso a definição dos parâmetros das redes neurais foi realizada padronizando o algoritmo de aprendizagem (Levenberg-Maquardt) e o método de seleção do número de neurônios da camada oculta foi baseado no menor erro médio quadrático.

3.1 Aquisição dos Dados

A aquisição dos dados de treinamento e validação das redes neurais artificiais foi realizada por meio de um simulador que representa a planta piloto do BCS no LEA, desenvolvido no software MATLAB por um docente da UFBA (COSTA, 2019b). O intervalo

de amostragem utilizado foi de 6 segundos, resultando em 18539 linhas de dados que incluem frequência do motor, abertura da válvula *choke*, pressão no *manifold*, pressão de fundo, nível do anular, pressão e vazão da válvula *choke*. Esses dados foram gerados a partir de 6 experimentos, nos quais a frequência do motor e a abertura da válvula *choke* foram variadas para analisar o comportamento do nível no anular, da pressão e da vazão da válvula *choke*.

A perturbação da planta foi feita através da aplicação de rampas nos sinais das entradas: frequência do motor e abertura da válvula *choke*, respeitando os seus limites de variação, e explorando entre os valores máximo e mínimo de cada variável.

3.2 Pré-processamento dos Dados

Os dados adquiridos foram divididos em conjuntos de treinamento, que compreendem aproximadamente 83% dos dados (5 experimentos), e de validação, que representam cerca de 17% do total (1 experimento). Além disso, os dados foram normalizados para o intervalo entre -1 e 1.

3.3 Desenvolvimento dos Modelos

O software MATLAB foi empregado para desenvolver os códigos de criação, treinamento e predição de novos dados para os modelos de redes neurais com diferentes estruturas, utilizando a Neural Networks Toolbox, que incorpora diversas estruturas de redes neurais artificiais.

Foram desenvolvidos modelos para cada uma das estruturas, totalizando 6 modelos (incluindo 2 versões da rede [NARX](#)) para cada saída, resultando em um total de 18 modelos. Todos esses modelos possuem 4 entradas e 1 saída.

3.4 Treinamento dos Modelos

Os modelos foram treinados com os mesmos dados de treinamento, utilizando o algoritmo de aprendizado Levenberg-Marquardt, com a condição de parada estabelecida em 1000 épocas de treinamento ou um limite do gradiente igual a 10^{-7} , ou seja, quando a variação dos parâmetros for aproximadamente nula.

3.5 Ajuste dos hiperparâmetros

O ajuste dos hiperparâmetros foi simplificado para o ajuste do número de neurônios na camada oculta, mantendo os demais hiperparâmetros fixos. Para isso, o modelo foi

treinado variando o número de neurônios e registrando o desempenho do modelo para cada configuração, utilizando a raiz quadrada do erro médio quadrático como métrica de comparação de desempenho.

3.6 Seleção dos Modelos

A seleção dos modelos seguiu o critério de número de neurônios com menor valor da raiz quadrada do erro médio quadrático após ajuste dos hiperparâmetros. Buscando o número ótimo de neurônios na camada oculta pelo método do menor **RMSE**. Com isso, os seguintes modelos foram selecionados:

O modelo da rede **FFNN** foi desenvolvido com 1 neurônio na camada oculta para predição do nível do anular, 5 neurônios na camada oculta para predição da pressão na válvula *choke* e 20 neurônios na camada oculta para predição da vazão na válvula *choke*.

Os modelos da rede **TDNN** foram desenvolvidos com 2 atrasos na entrada. Para predição do nível do anular foi utilizado 1 neurônio na camada oculta, para predição da pressão na válvula *choke* foram utilizados 4 neurônios na camada oculta e para predição da vazão na válvula *choke* foram utilizados 7 neurônios na camada oculta.

Os modelos da rede **LRNN** foram desenvolvidos com realimentação de 2 instantes na camada oculta. Para predição do nível do anular foram utilizados 8 neurônios na camada oculta, para predição da pressão na válvula *choke* foram utilizados 2 neurônios na camada oculta e para predição da vazão na válvula *choke* foram utilizados 7 neurônios na camada oculta.

Os modelos da rede *Distributed Delay* foram desenvolvidos com 2 atrasos na entradas e 2 atrasos na camada oculta. Para predição do nível do anular foi utilizado 1 neurônio na camada oculta, para predição da pressão na válvula *choke* foram utilizados 3 neurônios na camada oculta e para predição da vazão na válvula *choke* foram utilizados 3 neurônios na camada oculta.

Os modelos da rede **NARX** foram configurados com duas abordagens diferentes: a primeira com realimentação de 2 instantes de saída e 1 neurônio na camada oculta para prever o nível do anular, a pressão na válvula *choke* e a vazão na válvula *choke*. A segunda, denominada **NARX v2**, apresenta realimentação de 2 instantes de saída, 2 atrasos na entrada e 1 neurônio na camada oculta para prever o nível do anular, a pressão na válvula *choke* e a vazão na válvula *choke*.

3.7 Validação dos Modelos

A validação dos modelos foi feita apresentando os dados de validação (17% dos dados) aos modelos e avaliando o seu desempenho na predição da saída a partir das entradas.

3.8 Comparação entre os Modelos

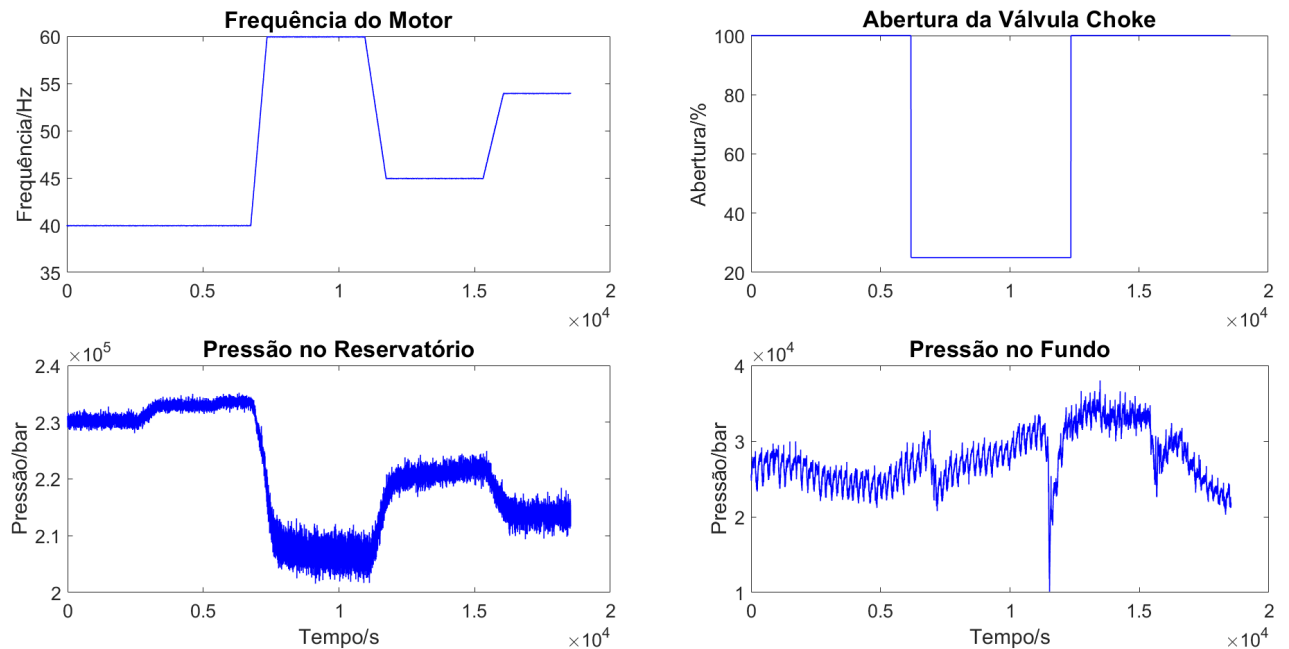
Para comparar o desempenho dos modelos desenvolvidos, foi adotada uma abordagem visual, utilizando gráficos que exibem a saída observada (observada) e a saída estimada pelos modelos. Quanto melhor o modelo, mais próxima a saída estimada estará da saída observada, ou seja, o desvio (diferença entre a saída observada e a saída estimada pelo modelo) estará mais próximo de zero.

Além disso, foram utilizadas diversas métricas para avaliar o desempenho dos modelos, incluindo a raiz do erro médio quadrático, o erro médio absoluto, a velocidade de treinamento e a velocidade de predição da saída para novos dados de entrada, bem como o critério de Akaike. Para as métricas apresentadas acima, um valor mais próximo de zero é um indicativo de um melhor desempenho do modelo.

4 RESULTADOS

Com os modelos desenvolvidos, tem-se o desempenho de cada um deles através das métricas escolhidas, além da visualização gráfica. Portanto, para os valores de entrada da: frequência no motor, abertura da válvula choke, pressão no reservatório e pressão no manifold (Figura 17), utilizados como base de dados para validação dos modelos, dados inéditos aos modelos.

Fig. 17 – Entradas do Modelo – Dados de Validação.



Fonte: Autoria Própria.

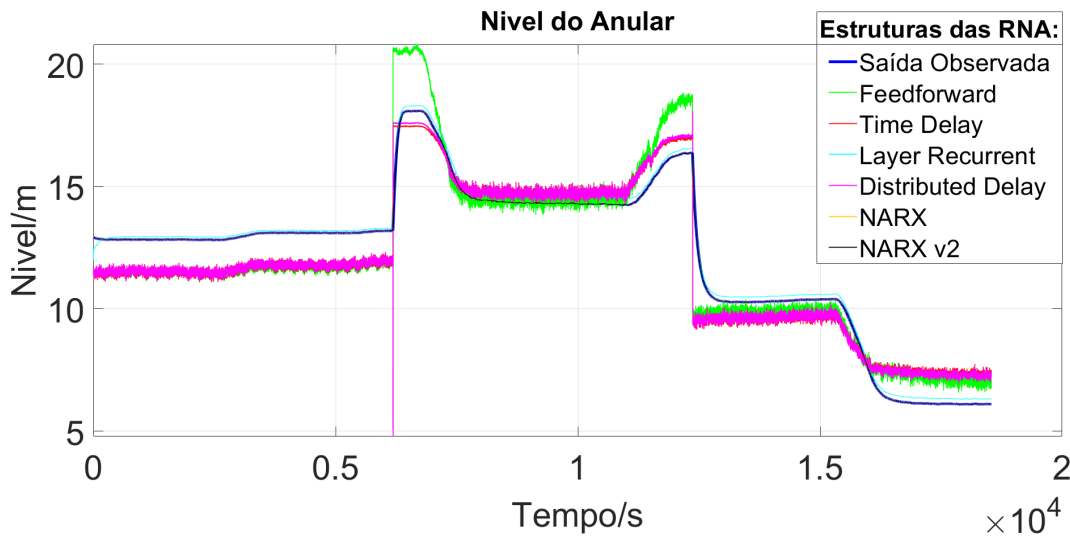
Estes dados não foram utilizados durante a etapa de treinamento dos modelos, portanto, ao utilizá-los na etapa de validação dos modelos tem-se a verificação da capacidade de extrapolação deles, estimando valores de saída para entradas desconhecidas.

Portanto, os resultados na estimação do nível do anular, pressão na válvula *choke* e vazão na válvula *choke*, podem ser vistos nas seções abaixo.

4.1 Nível do Anular

Tem-se, para estimação do nível de óleo no anular, a partir dos dados de entrada de validação, os resultados na Figura 18.

Fig. 18 – Visualização Gráfica – Estimação do Nível do Anular.



Fonte: Autoria Própria.

A partir da análise do gráfico, é possível observar que todas as estruturas de redes neurais tem a capacidade de estimar valores próximos ao valor real do nível de óleo no anular, porém há algumas estruturas cujas estimativas são mais próximas, portanto tem o melhor desempenho na tarefa de estimar o nível do anular a partir das variáveis de entrada.


Ao aproximar o gráfico acima, a visualização do comportamento do nível do anular e do nível do anular estimado por cada modelo se torna melhor (Figura 19).

É possível perceber, com a aproximação da figura 18, que na faixa de tempo selecionada, entre 4300 e 4460 segundos, o nível anular predito por alguns modelos, a saber, *Feedforward*, *Time Delay*, *Distributed Delay*, estão distantes do nível do anular real, porém a predição do nível do anular realizada pelo modelo *Layer Recurrent* está bem próximo da saída real, o nível do anular predito pelos modelos *NARX* e *NARX v2*, por sua vez, estão aproximadamente iguais ao nível do anular real.

Aproximando o gráfico (Figura 20) em outra faixa de tempo, temos o resultado:

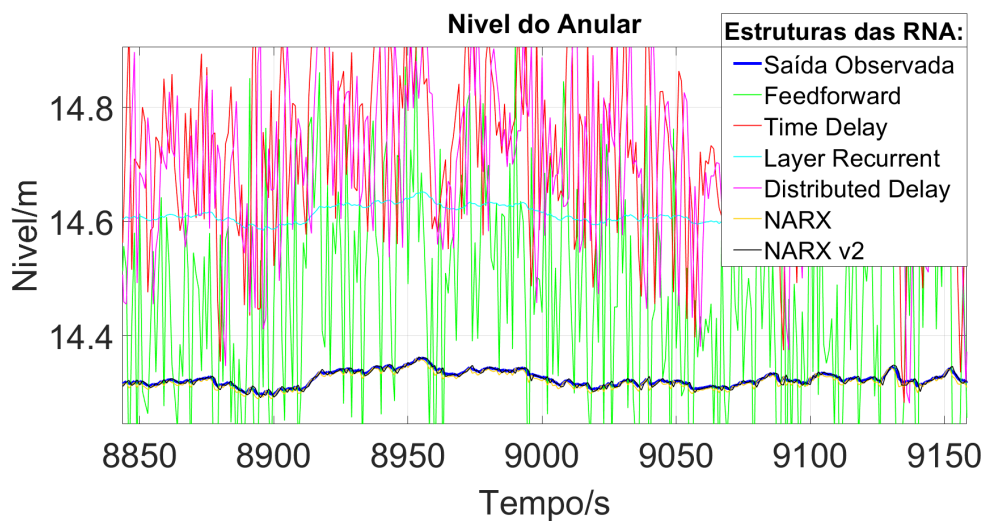
Com a aproximação do gráfico (Figura 18) na faixa de tempo selecionada, entre 8900 e 9150 segundos, o nível anular predito pelo modelos *Feedforward*, *Time Delay* e *Distributed Delay*, tem uma variação com amplitude relativamente alta em torno da saída real. O modelo *Layer Recurrent*, por sua vez, tem sua saída predita com pouca ou nenhuma variação, porém distante do nível do anular observado. Por outro lado, o nível do anular

Fig. 19 – Visualização Gráfica – Estimação do Nível do Anular (Zoom +).



Fonte: Autoria Própria.

Fig. 20 – Visualização Gráfica – Estimação do Nível do Anular (Zoom +).



Fonte: Autoria Própria.

predito pelos modelos [NARX](#) e [NARX v2](#), permanecem muito próximos do nível do anular observado.

Além da análise a partir dos gráficos da saída observada e saídas previstas pelos modelos, é possível analisar as métricas de desempenho dos modelos na estimação do nível do anular.

A partir da Tabela 1, é possível identificar que os modelos [FFNN](#), [TDNN](#) e *Time Distributed* tem valores próximos de [RMSE](#) e de [MAE](#), os quais são maiores do que os dos demais modelos; e tem valores próximos também de velocidade de treinamento, as quais são

Tab. 1 – Métricas de desempenho dos modelos na estimação do Nível do Anular.

Estrutura	RMSE	MAE	Velocidade Treinamento	Velocidade Predição	AIC
Feedforward (FFNN)	1.268	1.019	1.13s	0.02s	14.47
Time Delay (TDNN)	1.080	0.941	1.83s	0.18s	22.16
Layer Recurrent	0.203	0.189	1129s	0.11s	350.8
Distributed Delay	1.061	0.920	3.56s	0.12s	24.12
NARX	3.045e-03	1.834e-03	15.20s	0.56s	64.11
NARX v2	2.587e-03	1.577e-03	13.86s	0.32s	14.08

Fonte: Autoria Própria

menores do que as dos demais modelos, entre 1 e 3,5 segundos. A velocidade de predição para novos dados por esses modelos tem valores próximos, com exceção do modelo **FFNN**, o qual tem o menor valor entre todos os modelos. O *Akaike Index Criteria* (**AIC**) desses modelos tem valores próximos, o que indica que a relação entre o número de parâmetros estimáveis e a raiz quadrada do erro médio quadrático desses modelos são próximas.


A rede *Layer Recurrent*, por sua vez, tem valores de **RMSE** e **MAE** cerca de 5 vezes menor do que os dos modelos supracitados no parágrafo anterior, a velocidade de treinamento é a maior dentre todos os modelos, a velocidade de predição é próxima dos modelos citados no parágrafo anterior, e o critério de Akaike é o maior entre os demais modelos, o que indica que, por ter um **RMSE** relativamente baixo, há um grande número de parâmetros.

As redes **NARX** e **NARX v2** tem os valores de **RMSE** e **MAE** próximos, cerca de 100 a 1000 vezes menor do que os das redes citadas anteriormente, esses modelos, na predição do nível do anular, tiveram o melhor desempenho, pois a raiz quadrada do erro médio quadrático e o erro médio absoluto estão mais próximos de zero comparados as das outras estruturas, o que era esperado a partir da análise do gráfico (Figura 18). A velocidade de treinamento são próximas também, sendo menores do que o modelo *Layer Recurrent*, porém maiores do que as dos demais modelos.

A velocidade de predição foram maiores das dos demais modelos, sendo a da rede **NARX** a maior entre todas. O índice de Akaike, no entanto, diferiram. O da rede **NARX** teve o seu valor um pouco maior, porém a rede **NARX v2** teve o menor valores de todos, o que indica um bom desempenho em relação ao número de parâmetros.

Podemos também analisar o gráfico de resíduos:

Fig. 21 – Gráfico de Resíduos.




Fonte: Autoria Própria.

Portanto, a conclusão feita a partir dos gráficos das saídas previstas pelos modelos é ratificada com o gráfico de resíduos, visto que os modelos NARX e NARX v2 tiveram o menor somatório dos desvios, em relação aos demais modelos.

4.2 Pressão na Válvula Choke

Na tarefa de estimar a pressão na válvula *choke* os resultados das estimativas dos modelos de RNA desenvolvidos, juntamente com a saída real (observada) foram os exibidos na Figura 22.

Fig. 22 – Visualização Gráfica – Estimação da Pressão na Válvula Choke.




Fonte: Autoria Própria.

Analisando o gráfico, observa-se que, novamente, todas as estruturas de redes neurais foram capazes de estimar valores próximos ao valor observado da pressão na válvula *choke*, porém, da mesma forma que ocorreu na estimação do nível do anular, há algumas estruturas cujas estimativas são mais distantes da saída observada, enquanto há outras estruturas cujas estimativas da saída são mais próximas da saída observada, portanto tem o melhor desempenho na tarefa de estimar a pressão na válvula *choke* a partir das variáveis de entrada.

Ao aproximar o gráfico anterior no intervalo de 4200 a 5600s, tem-se o seguinte resultado:

Fig. 23 – Visualização Gráfica – Estimação da Pressão na Válvula *Choke*. (Zoom+



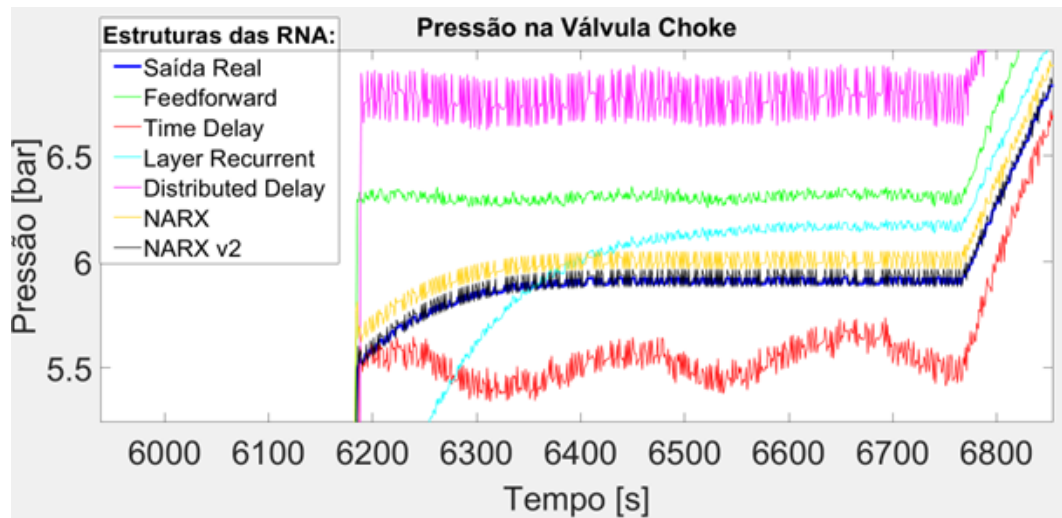
Fonte: Autoria Própria.

Com esta aproximação (Figura 23), é possível perceber que as redes [NARX](#) e [NARX v2](#) tem a predição dos valores da pressão na válvula *choke* muito próximos dos valores observados, enquanto que as redes *Feedforward*, *Layer Recurrent* e *Time Delay* tem valores próximos entre si, um pouco afastados dos valores observados. A rede *Distributed Delay*, no entanto, tem valores preditos da pressão na válvula *choke* mais afastados da saída observada, comparada às demais redes.


Ao aproximar o gráfico original (Figura 22) em outro intervalo, de 6000 a 6800s, contemplando uma região de transição entre os estados estacionários, tem-se o seguinte resultado:

Com a aproximação neste intervalo, é possível perceber que a rede [NARX](#) e, principalmente, a rede [NARX v2](#) mantém o bom desempenho mesmo na região de transição, enquanto que as demais redes permanecem afastadas da saída observada.

Após aproximar o gráfico original em outro intervalo, de 11200 a 12600s (Figura

Fig. 24 – Visualização Gráfica – Estimação da Pressão na Válvula *Choke*. (Zoom+)

Fonte: Autoria Própria.

Fig. 25 – Visualização Gráfica – Estimação da Pressão na Válvula *Choke*. (Zoom+)

Fonte: Autoria Própria.

25), contemplando uma outra região de transição entre os estados estacionários, é possível perceber que as redes **NARX** e **NARX v2** mantêm o bom desempenho na predição da pressão na válvula *choke* mesmo na região de transição, enquanto que as demais redes permanecem afastadas da saída observada.

Através da análise da Tabela 2, é possível perceber que todas as estruturas tiveram as métricas de **RMSE** e **MAE** muito próximas, com exceção das redes **NARX** e **NARX v2**, as quais tiveram o valor dessas métricas cerca de 10 vezes menor do que as demais, sendo as redes com melhores desempenhos, o que corrobora com a análise pelo gráfico. A velocidade de treinamento das redes *Distributed Delay* e, principalmente, *Layer Recurrent*,

Tab. 2 – Métricas de desempenho dos modelos na estimação da Pressão na Válvula Choke.


Estrutura	RMSE	MAE	Velocidade Treinamento	Velocidade Predição	AIC
Feedforward (FFNN)	0.553	0.363	9.05	0.01	60.82
Time Delay (TDNN)	0.246	0.189	8.32	0.17	79.20
Layer Recurrent	0.387	0.294	188.95	0.09	40.10
Distributed Delay	0.915	0.835	40.25	0.11	67.82
NARX	0.056	0.045	7.30	0.46	12.24
NARX v2	0.035	0.027	10.84	0.35	19.32

Fonte: Autoria Própria

sendo essa a de maior tempo de treinamento entre todas as redes, tiveram tempo de treinamento maior do que as demais redes, as quais tiveram valores bem próximos entre si. A velocidade de predição entre todas as redes tiveram valores próximos, variando na casa dos milissegundos, entre 10 e 460ms. O índice de Akaike dos modelos **NARX** e **NARX v2** tiveram os menores valores, logo, pelo fato de terem também os menores valores de **RMSE**, foram as redes com, além de melhor desempenho, melhor relação entre número de parâmetros e **RMSE**, principalmente a rede **NARX**, cujo desempenho foi o segundo menor com menor quantidade de parâmetros estimáveis. As demais redes tiveram valores do índice de Akaike próximos entre si, variando entre 40 e 79.

É possível, também, analisar o gráfico de resíduos:

Fig. 26 – Gráfico de Resíduos.




Fonte: Autoria Própria.

Portanto, a conclusão feita a partir dos gráficos das saídas previstas pelos modelos é ratificada com o gráfico de resíduos, visto que os modelos **NARX** e **NARX v2** tiveram o menor somatório dos desvios, em relação aos demais modelos.

4.3 Vazão na Válvula Choke

Na estimação da vazão na válvula choke, a partir dos dados de entrada de validação, os resultados são apresentados na Figura 27.

Fig. 27 – Visualização Gráfica – Estimação da Vazão na Válvula Choke.



Fonte: Autoria Própria.


A partir da análise desta figura, é possível observar que todas as estruturas de **RNA** tem a capacidade de estimar valores próximos ao valor real da vazão na válvula *choke*, porém é notável que a rede *Distributed Delay* tem valores preditos muito distantes da saída observada em dois momentos, o que tornou a visualização do gráfico demasiadamente difícil.

Portanto, após aproximar a figura 27, tem-se a visualização da figura 28:


Após a aproximação do gráfico (Figura 28), é possível ratificar que as redes cumprem o papel de prever a vazão na válvula *choke*, porém algumas com melhor exatidão, outras com menos. Na região inicial e final é possível perceber que todas as redes tem saídas preditas próximas da saída observada (Figura 29), porém na região central algumas predições se distanciam da saída observada (Figura 30).

No intervalo da aproximação do gráfico abaixo, entre cerca de 1000 e 3000 segundos, é possível perceber que todas as redes tem a predição do valor da vazão na válvula *choke* variando próximo da saída observada, com um foco especial nas redes **NARX** e **NARX v2**, as quais tem valores preditos muito próximos da saída observada.

No intervalo da aproximação do gráfico acima, entre cerca de 6000 e 14000 segundos, é possível perceber que a rede *Feedforward* tem variações aleatórias nas transições, estabilizando próximo da saída observada. A predição da rede *Time Delay* se afastou de forma significativa da saída observada. As redes *Distributed Delay* e *Layer Recurrent* tem

Fig. 28 – Visualização Gráfica – Estimação da Vazão na Válvula *Choke* (Zoom+).

Fonte: Autoria Própria.

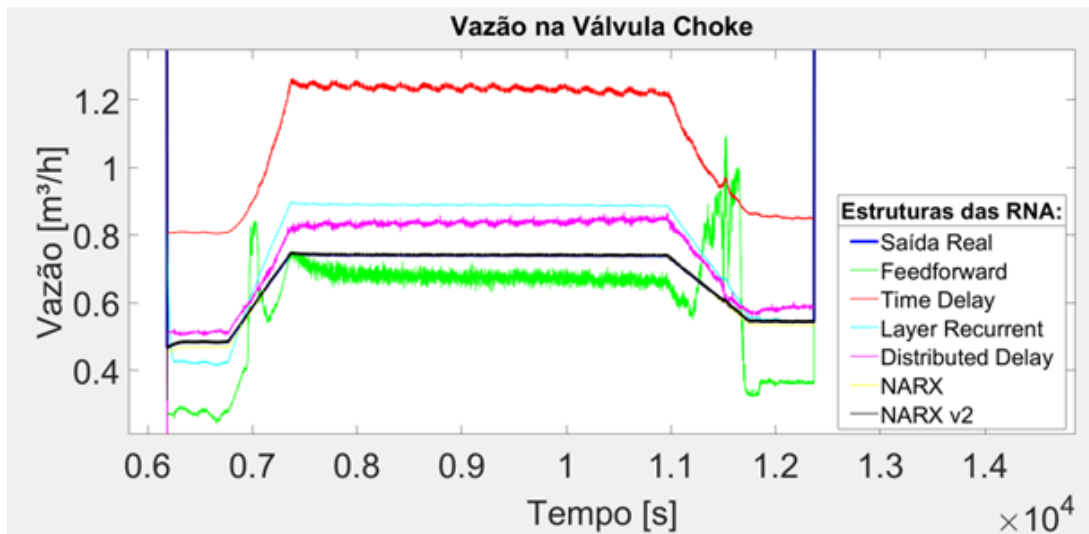
Fig. 29 – Visualização Gráfica – Estimação da Vazão na Válvula *Choke* (Zoom+).

Fonte: Autoria Própria.

resultados com uma certa aproximação da saída predita neste intervalo, porém as redes *NARX* e *NARX* v2 mantiveram a acurácia em prever valores extremamente próximos da saída observada.

As métricas de desempenho dos modelos podem ser vistas na tabela abaixo:

A partir da Tabela 3, é possível identificar que as estrutura de rede neural *FFNN*, *TDNN*, *Layer Recurrent* e *Distributed Delay* tiveram desempenho similar em consideração aos valores de *RMSE* e *MAE*, a velocidade de treinamento da *Layer Recurrent* foi a maior dentre todas as redes, seguida da rede *Distributed Delay*, as demais tiveram velocidade de

Fig. 30 – Visualização Gráfica – Estimação da Vazão na Válvula *Choke* (Zoom+).

Fonte: Autoria Própria.

Tab. 3 – Métricas de desempenho dos modelos na estimação da Vazão na Válvula Choke.

Estrutura	RMSE	MAE	Velocidade Treinamento	Velocidade Predição	AIC
Feedforward (FFNN)	0.098	0.081	18.94s	0.007s	237.35
Time Delay (TDNN)	0.255	0.159	23.05s	0.186s	139.26
Layer Recurrent	0.107	0.098	1005.22s	0.093s	277.52
Distributed Delay	0.102	0.045	69.06s	0.111s	63.43
NARX	0.009	0.004	6.12s	0.442s	8.63
NARX v2	0.008	0.004	10.92s	0.337s	16.33

Fonte: Autoria Própria

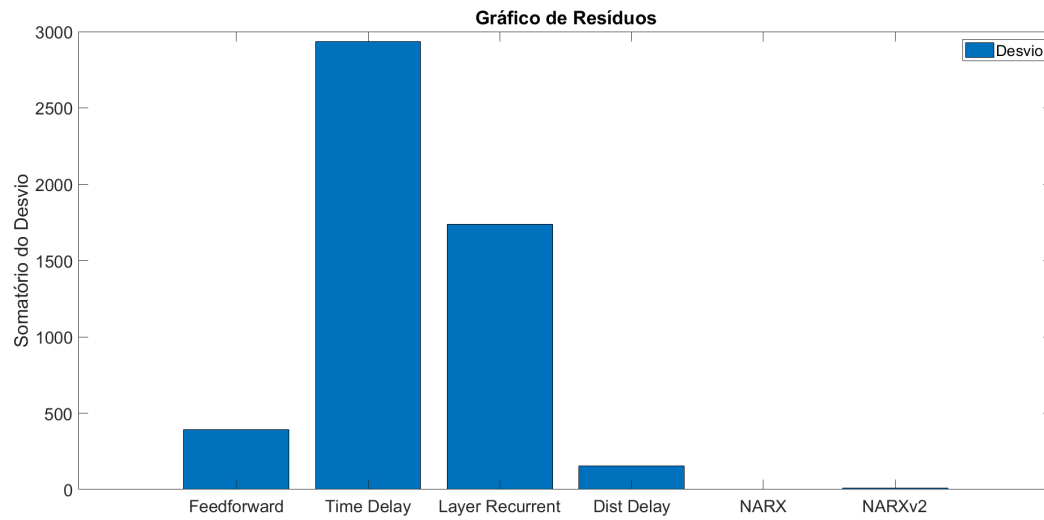
treinamento parecido, variando entre 6 a 23s. A velocidade de predição de novos dados, por sua vez, teve valores parecidos, com exceção da rede *Feedforward*, cuja velocidade foi a menor entre todas as redes.

O índice de Akaike elevado nas redes *FFNN*, *TDNN* e *Layer Recurrent* indica que as redes tiveram a necessidade de ter um elevado número de parâmetros para gerar previsões da vazão na válvula *choke* com boa acurácia, a rede *Distributed Delay* teve o índice menor do que as redes supracitadas no início deste parágrafo, porém ele foi maior do que o das redes *NARX* e *NARX v2*, as quais tiveram *RMSE* e *MAE* próximos e cerca de 50 a 200 vezes menor do que os das redes anteriores. Considerando o critério de Akaike, as redes *NARX* e *NARX v2* tiveram uma boa relação entre o número de parâmetros e o *RMSE*, o que indica uma boa eficácia desses modelos.

Podemos também analisar o gráfico de resíduos:

Portanto, a conclusão feita a partir dos gráficos das saídas preditas pelos modelos é ratificada com o gráfico de resíduos, visto que os modelos *NARX* e *NARX v2* tiveram o

Fig. 31 – Gráfico de Resíduos.



Fonte: Autoria Própria.

menor somatório dos desvios, em relação aos demais modelos.

5 Conclusão

Esse trabalho apresentou uma análise comparativa entre modelos baseados em dados com diferentes estruturas de redes neurais artificiais para predição de variáveis do método de elevação artificial chamado de bombeio centrífugo submerso, as quais são o nível no anular, a pressão e a vazão na válvula *choke*.

Durante o desenvolvimento do trabalho, foi seguida uma metodologia que se iniciou na coleta os dados a serem utilizados no processo de treinamento e validação dos modelos, sendo aproximadamente 83% dos dados para treinamento e os demais 17% para validação, os quais foram normalizados. Desenvolvimento e treinamento dos modelos com os mesmo dados, buscando o número ótimo de neurônios na camada oculta pelo método do menor **RMSE**. Após isso os modelos foram validados com os dados de testes, os quais não foram utilizados durante o processo de treinamento, portanto são dados inéditos aos modelos. Seguindo para a etapa de compração entre os modelos.

Pode-se observar, com a comparação feita entre as os modelos de **RNA** desenvolvidos com diferentes estruturas, através dos gráficos e tabelas com as métricas de cada estrutura, que todas as estruturas de modelos de redes neurais artificiais puderam estimar o comportamento de todas as variáveis (nível no anular, pressão na válvula *choke* e vazão na válvula *choke*), principalmente as redes neurais recorrentes. Foi possível perceber, com a análise dos gráficos e através das métricas, modelos de redes neurais quais modelos são mais indicados na predição de cada uma das variáveis expostas. As redes **NARX** e **NARX v2** foram capazes de predizer valores muito próximos dos observados, com um número de parâmetros relativamente pequeno, o que foi possível perceber pelo índice de Akaike, enquanto que os outros modelos tiveram, em algumas situações, predições distantes da saída observada, além de utilizarem um alto número de parâmetros.

5.1 Trabalhos Futuros

A implementação de outras estruturas de redes neurais recorrentes pode se fazer necessária para incrementar a comparação feita neste trabalho, com o objetivo de verificar a possibilidade de haver uma estrutura de modelo com o desempenho superior as demais apresentadas. Além do incremento de outras métricas de desempenho para comparação entre os modelos de estudo.

Referências

- ALVES, C. A. M. *Uma Ferramenta de Extração de Regras de Redes Neurais*. Dissertação (Dissertação de Mestrado em Ciências em Engenharia Civil) — COPPE, UFRJ, Rio de Janeiro, 2001. Citado na página 30.
- ANDRIANOV, N. A machine learning approach for virtual flow metering and forecasting. *IFAC-Pap. Online*, v. 51, p. 191–196, 2018. Disponível em: <<https://doi.org/10.1016/j.ifacol.2018.06.376>>. Citado na página 31.
- ARAUJO, T. *Estimação de Séries Temporais via Rede NARX em Aplicações Industriais*. Dissertação (Dissertação de Mestrado) — Faculdade de Engenharias, Arquitetura e Urbanismo e Geografia, Universidade Federal de Mato Grosso do Sul (UFMS), Campo Grande, MS, 2022. Citado 2 vezes nas páginas 31 e 33.
- ARTERO, A. O. *Inteligência Artificial: teórica e prática*. São Paulo: Editora Livraria da Física, 2009. Citado na página 29.
- BAKHTADZE, N. N. et al. Identification-based approach to soft sensors design. In: *Proceedings of IFAC Workshop of Intelligent Manufacturing Systems*. Alicante, Spain: [s.n.], 2007. p. 86–92. Citado na página 25.
- BIKMUKHAMETOV, T.; JÄSCHKE, J. First principles and machine learning virtual flow metering: A literature review. *Journal of Petroleum Science and Engineering*, Norway, 2020. Citado na página 19.
- BRASIL, A. N. *Apostila Máquinas Termo hidráulicas de Fluxo*. [S.l.: s.n.], 2010. Citado 2 vezes nas páginas 20 e 22.
- COSTA, E. A. e. a. *APÊNDICE A – Relatório Técnico 02 poço de BCS inteligente*. [S.l.], 2019. Citado na página 25.
- COSTA, E. A. e. a. *Descrição do Laboratório LEA-CTAI*. [S.l.], 2019. Citado na página 35.
- COSTA, E. A. e. a. *APÊNDICE B – Relatório Técnico 03 poço de BCS inteligente*. [S.l.], 2020. Citado na página 25.
- FAUSETT, L. *Fundamentals of Neural Networks – Architecture, Algorithms, and Applications*. [S.l.]: Prentice Hall International, Inc., 1994. Citado na página 29.
- GRAHAM, E. The future of flow. *Offshore Engineer*, v. 40, p. 44–45, 2015. Citado na página 19.
- HAYKIN, S. *Redes Neurais, Princípios e Prática*. 2. ed. Porto Alegre: Bookman, 2001. Citado 2 vezes nas páginas 27 e 29.
- IBP. *Estudo mostra importância do setor de petróleo e gás para a economia do Brasil*. 2019. <<https://www.ibp.org.br/noticias/estudo-mostra-importancia-do-setor-de-petroleo-e-gas-para-a-economia-do-brasil/>>. Acesso em 10 de nov de 2023. Citado na página 19.

- ITO, E. H. C. *Desenvolvimento de um Sensor Virtual de Composição em Coluna de Destilação para Aplicação em Tempo Real*. Dissertação (Dissertação de Mestrado), Rio de Janeiro, RJ, 2014. Citado na página 25.
- LESKENS, M. et al. Downhole multiphase metering in wells by means of soft-sensing. *Society of Petroleum Engineers - Intelligent Energy Conference and Exhibition: Intelligent Energy 2008*, v. 1, n. 2007, p. 271–281, 2008. Citado na página 19.
- MATLAB. Neural Network Toolbox/Functions/New Network Functions/ Layrecnet. 2023. Citado na página 32.
- MELLO, M. T. de. Aplicação de redes neurais artificiais no processo de precificação de ações. In: *Universidade Federal de Pelotas Instituto de Física e Matemática*. Pelotas: [s.n.], 2004. Citado 3 vezes nas páginas 28, 29 e 30.
- SABOIA, R. *Perspectivas para o setor de petróleo e gás: a visão do regulador*. 2023. <<https://www.gov.br/anp/pt-br/centrais-de-conteudo/apresentacoes-palestras/2023/arquivos/2023-08-23-rodolfo-saboia-perspectivas.pdf>>. Acesso em 10 de nov. de 2023. Citado na página 24.
- SEIDL, D. R.; LORENZ, R. D. A structure by which a recurrent neural network can approximate a nonlinear dynamic system. In: *IJCNN-91-Seattle International Joint Conference on Neural Networks*. [S.l.]: IEEE, 1991. p. 709–714. Citado na página 31.
- SOUZA, L. F. *Controle Avançado Aplicado ao Sistema BCS Operando com Escoamento Monofásico*. Dissertação (Dissertação de Mestrado), Salvador, BA, 2014. Citado na página 19.
- TAFNER, M. A.; XEREZ, M.; FILHO, I. R. *Redes Neurais Artificiais: Introdução e Princípios de Neurocomputação*. Blumenau: EKO, 1995. Citado na página 27.
- TAKÁCS, G. *Electrical submersible pumps manual*. USA: Gulf Professional Publishing, 2009. Citado na página 25.
- THOMAS, J. E. et al. *Fundamentos de Engenharia de Petróleo*. Rio de Janeiro, RJ: Editora Interciência, 2004. Citado 4 vezes nas páginas 19, 20, 21 e 22.
- ZHU, J.; ZHANG, H.-Q. A review of experiments and modeling of gas-liquid flow in electrical submersible pumps. *Energies*, v. 11, n. 1, p. 180, 2018. Disponível em: <<https://doi.org/10.3390/en11010180>>. Citado na página 20.