



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ENGENHARIA  
DEPARTAMENTO DE ENGENHARIA QUÍMICA  
ENG07053 - TRABALHO DE DIPLOMAÇÃO EM ENGENHARIA  
QUÍMICA



# Predição de pressão de fundo em poços de petróleo via redes neurais

*Autor: Mateus Berno Motke*

*Orientador: Marcelo Farenzena*

Porto Alegre, julho de 18

## Sumário

Sumário	ii
Resumo	iii
Lista de Figuras	iv
Lista de Tabelas	v
Lista de Símbolos	vii
Lista de Abreviaturas e Siglas	viii
1 Introdução	1
2 Revisão Bibliográfica	3
2.1 Sistemas de extração e elevação de petróleo <i>offshore</i>	3
2.2 Golfadas nos sistemas de elevação de petróleo	4
2.3 Importância da medição de pressão do fundo do poço	5
2.4 Métodos computacionais aplicados	6
2.4.1 Computação em Reservatório	6
2.4.2 Analisadores Virtuais	8
2.4.3 Desenvolvimento de Analisadores Virtuais	8
2.4.4 Primeira inspeção de dados	9
2.4.5 Seleção de dados históricos	9
2.4.6 Pré-tratamento dos dados	10
2.4.7 Seleção, treinamento e validação do modelo	10
2.4.8 Manutenção do Analisador Virtual	11
2.4.9 Rede Neural	11
3 Metodologia	13
3.1 Desenvolvimento do Analisador Virtual	14
3.1.1 Primeira inspeção de dados seleção de dados históricos	14
3.1.2 Pré-tratamento dos dados	17
3.1.3 Seleção, treinamento e validação do modelo	18
4 Resultados	19
4.1 Rede Neural – Estática	19
4.1.1 Teste 1: Abertura da válvula choke e vazão do gás lift	19
4.1.2 Teste 2: Pressão de topo	20
4.1.3 Teste 3: Pressão de topo, abertura da válvula choke e vazão do gás lift	21
4.2 Rede Neural – Dinâmica	23
4.2.1 Teste 1: Abertura da válvula choke e vazão do gás lift	23
4.2.2 Teste 2: Pressão de topo	25
4.2.3 Teste 3: Pressão de topo, abertura da válvula choke e vazão do gás lift	27
5 Conclusões e Trabalhos Futuros	30
Referências	31

## Resumo

O presente trabalho apresenta a importância da medição da pressão encontrada em poços de petróleo *offshore*, o seu impacto na produção e na segurança, e como este valor pode ser predito por métodos computacionais ao preterir-se medidores físicos. A pressão em um poço de petróleo é a principal fonte de informação para indicar a produção da planta e, assim, consequentemente indica como as válvulas devem trabalhar para extrair o máximo de petróleo com segurança. Utilizaram-se dados de um modelo matemático que representa a pressão de um poço de petróleo da Petrobrás, a partir da medida física de um medidor de pressão chamado de *Downhole Pressure Gauge* (PDG). Este medidor carece de confiança por parte de muitos autores, pois como ele é instalado em uma zona de inconstância física, com variações de pressão e temperatura, o medidor pode apresentar ruídos e tende a estragar facilmente, tornando sua medida pouco confiável. Para solucionar este problema foi utilizado um método computacional chamado de rede neural, que se baseou em dados obtidos de um modelo real para predizer qual é a pressão no fundo de poço de petróleo *offshore*, baseando-se apenas na pressão de topo, da qual se tem a confiança de sua medida e nas variáveis manipuladas. O modelo obtido foi testado para diferentes variáveis do processo, por meio de rede neural estática e dinâmica e com diferentes parâmetros. Para o modelo de rede neural estática, obteve-se um coeficiente de determinação ( $R^2$ ) igual a 0,98 e para o modelo de rede neural dinâmica, obteve-se um coeficiente de determinação ( $R^2$ ) igual a 0,96.

## Lista de Figuras

<b>Figura 2.1:</b> Desenho esquemático de uma plataforma de petróleo <i>offshore</i> . Adaptado de Di Meglio et al. (2012a). .....	3
<b>Figura 2.2:</b> Exemplos de oleodutos e poços envolvidos no fenômeno de golfadas. Adaptado de Di Meglio <i>et al.</i> (2012a).....	5
<b>Figura 2.3:</b> Rede de Computação em Reservatório. (adaptado de Antonelo, 2017). .....	7
<b>Figura 2.4:</b> Algoritmo básico de um analisador virtual (FACCHIN, 2005).....	8
<b>Figura 2.5:</b> Metodologia para o desenvolvimento de um analisador virtual (adaptado de KADLEC et al., 2009).....	9
<b>Figura 2.6:</b> Representação de uma rede neural <i>feedforward</i> (adaptado de WILLIS et al. 1992) .....	12
<b>Figura 3.1:</b> Variação da pressão do topo pela abertura da válvula <i>choke</i> . .....	15
<b>Figura 3.2:</b> Matriz de correlação das variáveis para elaboração da rede neural estática, onde P_topo é a pressão de topo, P_PDG é pressão de poço medida pelo sensor PDG, vazão_gas_lift é a vazão do gás- <i>lift</i> e x_choke é a abertura da válvula <i>choke</i> .....	16
<b>Figura 3.3:</b> Matriz de correlação das variáveis para elaboração da rede neural dinâmica, onde P_topo é a pressão de topo, P_PDG é pressão de poço medida pelo sensor PDG, vazão_gas_lift é a vazão do gás- <i>lift</i> e x_choke é a abertura da válvula <i>choke</i> .....	16
<b>Figura 3.4:</b> Variação da pressão do topo pela abertura da válvula <i>choke</i> . .....	17
<b>Figura 3.5:</b> Variação da pressão do topo pela abertura da válvula <i>choke</i> , na avaliação estática das pressões para cada abertura. ....	18
<b>Tabela 4.7:</b> Valores de R <sup>2</sup> encontrados para diferentes tamanhos de lote, referentes ao Teste 2 da rede neural estática. ....	21
<b>Figura 4.1:</b> Pressão medida pelo sensor PDG comparados com o valor de pressão predita obtido pelo modelo de rede neural estática, referentes ao Teste 2.....	23
<b>Figura 4.2:</b> Pressão medida pelo sensor PDG comparados com o valor de pressão predita obtido pelo modelo de rede neural dinâmica, referentes ao Teste 3. ....	29

## Lista de Tabelas

<b>Tabela 3.1:</b> Representação das variações de abertura da válvula <i>choke</i> (%) e vazão de gás <i>lift</i> (m <sup>3</sup> / dia).....	14
<b>Tabela 4.1:</b> Valores de R <sup>2</sup> encontrados para diferentes funções de ativação, referentes ao Teste 1 da rede neural estática. ....	19
<b>Tabela 4.2:</b> Valores de R <sup>2</sup> encontrados para diferentes configurações dos parâmetros, referentes ao Teste 1 da rede neural estática.....	19
<b>Tabela 4.3:</b> Valores de R <sup>2</sup> encontrados para diferentes funções de ativação, referentes ao Teste 2 da rede neural estática. ....	20
<b>Tabela 4.4:</b> Valores de R <sup>2</sup> encontrados para diferentes tamanhos do teste da rede neural, referentes ao Teste 2 da rede neural estática.....	20
<b>Tabela 4.5:</b> Valores de R <sup>2</sup> encontrados para diferentes neurônios das camadas ocultas, referentes ao Teste 2 da rede neural estática.....	20
<b>Tabela 4.6:</b> Valores de R <sup>2</sup> encontrados para diferentes épocas, referentes ao Teste 2.....	20
<b>Tabela 4.8:</b> Valores de R <sup>2</sup> encontrados para diferentes funções de ativação, referentes ao Teste 3 da rede neural estática. ....	21
<b>Tabela 4.9:</b> Valores de R <sup>2</sup> encontrados para diferentes tamanhos do teste, referentes ao Teste 3 da rede neural estática. ....	21
<b>Tabela 4.10:</b> Valores de R <sup>2</sup> encontrados para diferentes configurações de camadas e neurônios, referentes ao Teste 3 da rede neural estática. ....	22
Para a avaliação do número de época, a melhor coeficiente de determinação obtido apresentou 3 épocas, conforme Tabela 4.11.....	22
<b>Tabela 4.11:</b> Valores de R <sup>2</sup> encontrados para diferentes épocas, referentes ao Teste 3 da rede neural estática.....	22
Por fim, a variação do tamanho do lote para 1.000 melhorou o modelo, obtendo um coeficiente de determinação igual a 0,96, conforme Tabela 4.12. ....	22
<b>Tabela 4.12:</b> Valores de R <sup>2</sup> encontrados para diferentes tamanhos de lote, referentes ao Teste 3 da rede neural estática. ....	22
<b>Tabela 4.14:</b> Valores de R <sup>2</sup> encontrados para diferentes tamanhos do teste, referentes ao Teste 1 da rede neural dinâmica. ....	24
<b>Tabela 4.15:</b> Valores de R <sup>2</sup> encontrados para diferentes números de neurônios, referentes ao Teste 1 da rede neural dinâmica. ....	24
<b>Tabela 4.16:</b> Valores de R <sup>2</sup> encontrados para diferentes tamanhos de lote, referentes ao Teste 1 da rede neural dinâmica. ....	25
<b>Tabela 4.17:</b> Valores de R <sup>2</sup> encontrados para diferentes números de épocas, referentes ao Teste 1 da rede neural dinâmica. ....	25
<b>Tabela 4.19:</b> Valores de R <sup>2</sup> encontrados para diferentes tamanhos do teste, referentes ao Teste 2 da rede neural dinâmica. ....	26
<b>Tabela 4.20:</b> Valores de R <sup>2</sup> encontrados para diferentes números de neurônios, referentes ao Teste 2 da rede neural dinâmica. ....	26

<b>Tabela 4.21:</b> Valores de $R^2$ encontrados para diferentes tamanhos de lote, referentes ao Teste 2 da rede neural dinâmica. ....	26
<b>Tabela 4.22:</b> Valores de $R^2$ encontrados para diferentes números de épocas, referentes ao Teste 2 da rede neural dinâmica. ....	26
<b>Tabela 4.24:</b> Valores de $R^2$ encontrados para diferentes tamanhos do teste, referentes ao Teste 3 da rede neural dinâmica. ....	27
<b>Tabela 4.25:</b> Valores de $R^2$ encontrados para diferentes números de neurônios, referentes ao Teste 3 da rede neural dinâmica. ....	27
<b>Tabela 4.26:</b> Valores de $R^2$ encontrados para diferentes tamanhos de lote, referentes ao Teste 3 da rede neural dinâmica. ....	28
<b>Tabela 4.27:</b> Valores de $R^2$ encontrados para diferentes números de épocas, referentes ao Teste 3 da rede neural dinâmica. ....	28

## Lista de Símbolos

$h_i$  – Vetor de saída da camada  $i$  de uma Rede Neural

$J_i$  – Transformação funcional da camada  $i$  de uma Rede Neural

$P_{sep}$  - Pressão no separador

$S$  – Função Sigmoidal

$W$  – Soma ponderada das entradas da camada  $i$  de uma Rede Neural

Relu - Unidade linear retificada

$R^2$  – Coeficiente de Determinação

$SY$  – Média do conjunto de dados

## **Lista de Abreviaturas e Siglas**

FOWM - *Fast Offshore Wells Model*

PDG - *Permanent Downhole Gauge*

SSE – Soma Quadrática do Erro

## 1 Introdução

O setor de petróleo e gás tem importância ímpar na economia mundial, suprindo a demanda energética global em proporções substancialmente grandes quando comparadas aos demais energéticos. De acordo com a Agência Internacional de Energia (IEA, 2013), o petróleo representa 31,5% do total da oferta de energia primária, seguido pelo carvão representando 28,8% e o gás natural com 21,3%. Importante notar que a predominância do petróleo já foi ainda mais pronunciada no passado, atingindo uma participação de mais da metade da oferta primária de energia. A produção média de petróleo do Brasil em 2017 cresceu 4% ante o ano anterior, para 2,622 milhões de barris por dia (bpd), de acordo com dados da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP). Ainda, as exportações são crescentes, tendo sua produção ampliada especialmente a partir da descoberta das reservas do pré-sal.

Como a quantidade de petróleo é limitada em um poço e todas as etapas que o envolvem tem alto impacto financeiro, deve-se procurar por desenvolver melhorias para atingir a máxima eficiência na extração. Segundo Diehl (2017), a principal atividade a ser explorada nesse ramo é a de *upstream*, pois é onde se contribui mais significativamente para o lucro de todo o negócio de petróleo e gás. Uma maneira de alcançar essa meta é melhorar o desempenho operacional do sistema de produção, intensificando as aplicações em tempo real das ferramentas de monitoramento, controle e otimização, que exigem modelos para prever algumas variáveis-chave ou estimar variáveis não disponíveis.

Usualmente, o sensor utilizado que indica a pressão do poço de petróleo em unidades *offshore* é o *Permanent Downhole Gauge* (PDG). Esses sensores são geralmente instalados na parte inferior do poço, proporcionando medições de temperatura e pressão. A pressão de fundo de poço medida é uma das variáveis mais importantes para monitoramento, otimização e controle da produção de poços de petróleo, sendo essencial na avaliação da dinâmica do poço de petróleo e, por ela, temos como estimar a vazão do poço, variável não medida. O problema é que, como os sensores PDG são instalados em ambientes perigosos, têm um elevado custo para manutenção ou substituição e também sua falha prematura não é incomum. Além disso, perturbações e ruídos podem afetar as medições do sensor PDG, tornando-se uma fonte de informações não confiável. Logo, a variável não disponível, ou melhor, a variável não confiável que se deseja prever é a pressão do poço de petróleo em unidades *offshore*.

Uma das maneiras de preterir o sensor PDG é substituí-lo por um método computacional, ao desenvolver um modelo dinâmico que faça a previsão da pressão de fundo do poço, utilizando como referência a pressão do topo, a abertura da válvula *choke* e a vazão do gás *lift*; como estas não sofrem influência do meio externo, tornam-se medidas seguras. Portanto, este trabalho objetiva prever a pressão do fundo do poço por outras variáveis do processo, utilizando o método de redes neurais, pois é um método dinâmico e não linear.

Este trabalho foi estruturado em 5 capítulos: o capítulo 1 é a introdução, que mostra os motivos do desenvolvimento deste trabalho; o capítulo 2 é a revisão bibliográfica, que traz informações relevantes sobre sistemas de extração e elevação de petróleo offshore, golfadas nos sistemas de elevação de petróleo, importância da medição de pressão do fundo do poço, métodos computacionais aplicados, analisadores virtuais e redes neurais;

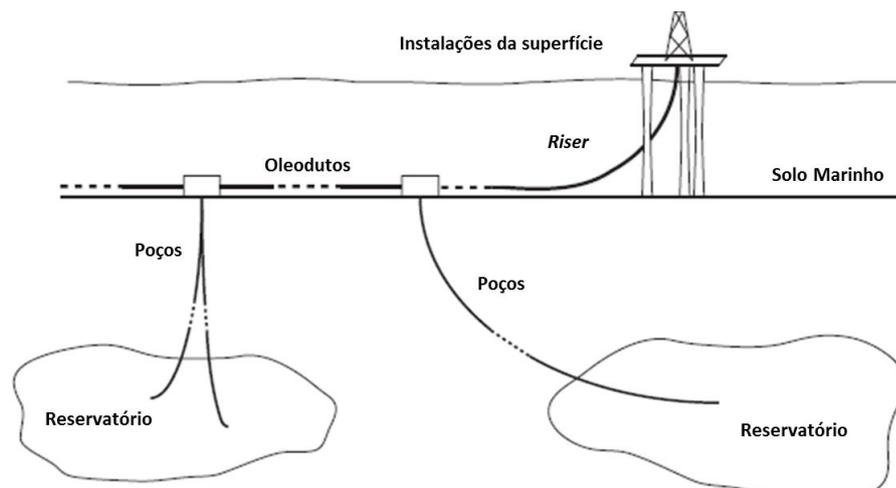
o capítulo 3 é a metodologia, que mostra com maior detalhamento o desenvolvimento da rede neural; o capítulo 4 são os resultados, mostrando os parâmetros usados no melhor resultado obtido na rede neural estática e dinâmica; e o capítulo 5 são as conclusões.

## 2 Revisão Bibliográfica

Este capítulo mostrará conceitos importantes para o entendimento do trabalho.

### 2.1 Sistemas de extração e elevação de petróleo *offshore*

No processo de extração de petróleo, uma mistura multifásica, composta do próprio petróleo mais gás e água, flui simultaneamente através dos tubos de transporte dos reservatórios até as instalações da superfície. Uma plataforma *offshore* é representado na Figura 2.1. Esta mistura multifásica flui do reservatório através dos poços para as instalações do fundo do mar. O comprimento de um poço varia de algumas centenas de metros a vários milhares. Na maioria das vezes, os poços têm uma seção horizontal em transição lenta para uma vertical. No topo do poço, uma válvula *choke*, utilizada para controlar o fluxo dos oleodutos, é acionada remotamente permite que o fluxo seja controlado. Então, a linha de fluxo reúne a produção de vários poços e os transporta, no fundo do mar, por vários quilômetros. Eventualmente, a linha de fluxo sobe para as instalações de superfície, onde as fases de gás, petróleo e água são separadas. Novamente, uma válvula *choke* ativada pode ser usada para controlar o fluxo no topo do *riser*, antes do processo de separação ocorrer. A altura do *riser* varia entre 100 m a 1 km. A mistura de hidrocarbonetos e água pode ser bifásica ou trifásica dependendo das condições de temperatura e pressão. (Di Meglio et al., 2012 a).



**Figura 2.1:** Desenho esquemático de uma plataforma de petróleo *offshore*. Adaptado de Di Meglio et al. (2012a).

Os oleodutos transportam a mistura multifásica, extraída do reservatório, pelo solo marinho, com o objetivo de reunir as produções dos diversos poços, estendendo-se por todo o campo de extração e pode atingir quilômetros de comprimento (Di Meglio et al., 2012 a).

A partir de certo ponto, os oleodutos ascendem até a estação de superfície, onde as fases são separadas e posteriormente tratadas. Novamente, uma válvula *choke* faz-se presente para o controle da produção. A seção de tubulação responsável pela elevação da mistura do solo marinho até a superfície é chamada de *riser*. Estes possuem alturas que variam entre 100 metros e um quilômetro, de acordo com a profundidade do oceano naquela região (Di Meglio et al., 2012 a).

Conforme Aamo (2004), oleodutos e poços de petróleo com fluxo altamente oscilatório constituem um problema significativo na indústria do petróleo, e os esforços para encontrar soluções baratas baseadas no controle automático aumentaram tanto na academia quanto na indústria. Existem vários fenômenos de instabilidade diferentes relacionados a oleodutos, gasodutos e poços. Mesmo com a estabilização com sucesso de regimes instáveis, que ocorrem para fluxo multifásico em *risers* verticais, usando técnicas convencionais de controle linear, ainda, esses sistemas de controle contam com medições de fundo de poço que, na melhor das hipóteses, não são confiáveis, se disponíveis.

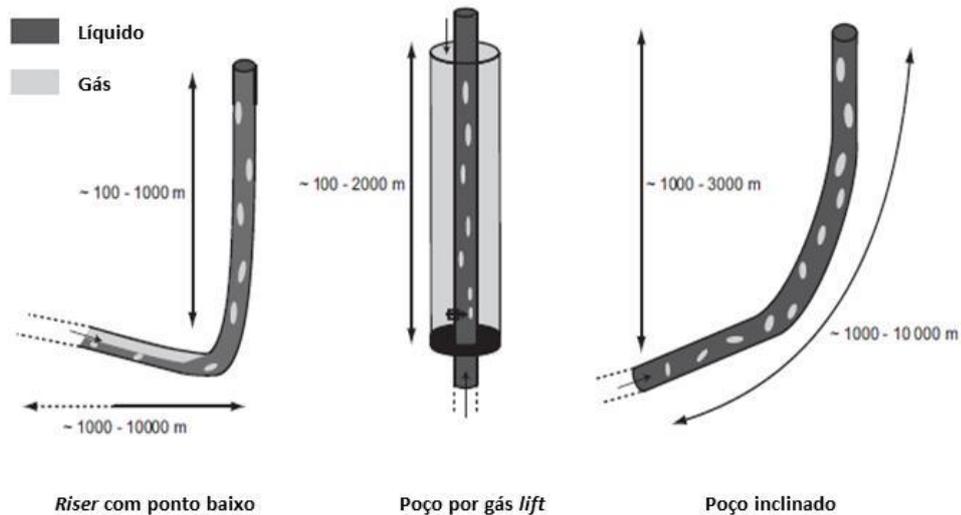
Uma característica comum na produção de petróleo, de acordo com Diehl *et al.* (2017) são as irregularidades de fluxo durante o transporte de fluido do reservatório para as instalações de superfície. Quando a produção ocorre em um ambiente *offshore*, os problemas de fluxo se tornam ainda mais críticos. Na produção em águas profundas e ultraprofundas, o poço de fluxo fixo é composto por tubos longos distribuídos em vários ângulos. Essa distribuição pode criar instabilidades no fluxo multifásico, denominado golfada de terreno ou golfada de *riser*, resultando em riscos operacionais e reduções na produção (Schmidt *et al.*, 1979, 1980; Fabre *et al.*, 1990; Meglio, 2011). Os principais problemas causados por irregularidades de fluxo estão ligados ao aumento do risco operacional, redução da disponibilidade do sistema de produção e dificuldades em conduzir os poços a condições operacionais ideais.

Por fim, segundo Diehl (2017), melhorar a operação pode ser um ponto chave para otimizar o lucro do sistema de produção. Para atingir este objetivo, os esforços devem ser concentrados em proporcionar uma melhor operação do sistema de produção, aumentando o monitoramento, controle e otimização em tempo real, a fim de apoiar decisões rápidas sobre a operação.

## 2.2 Golfadas nos sistemas de elevação de petróleo

O fenômeno de golfadas é definido por Di Meglio *et al.* (2012) como um regime intermitente de fluxo bifásico ou trifásico caracterizado por uma distribuição não homogênea das fases líquida e gasosa. Dessa maneira, bolhas de gás fluem através do tubo, separadas por “golfadas” de líquido. Na saída, isso se traduz em longos períodos de produção muito baixa de líquido, alternando periodicamente com altos picos de produção, o que é problemático para o processo de separação. Além disso, a produção total é reduzida em comparação com os regimes de fluxo constante, em que o petróleo e o gás são produzidos a taxas constantes. Ainda, a compressibilidade das bolhas de gás e a variação do peso da coluna de líquido causam oscilações periódicas da pressão, em todos os lugares no tubo. Essas oscilações, que podem danificar a instalação, estão, na verdade, intimamente relacionadas à diminuição da produção de petróleo.

As golfadas podem ocorrer nos poços e nos *risers*. A Figura 2.2 representa esquematicamente os principais oleodutos e poços presentes em unidades de extração de petróleo *offshore*.



**Figura 2.2:** Exemplos de oleodutos e poços envolvidos no fenômeno de golfadas. Adaptado de Di Meglio *et al.* (2012a).

Nos *risers*, a golfada surge principalmente quando a linha de fluxo tem um ângulo de ponto baixo imediatamente antes da seção vertical. Em particular, nesses sistemas, a fase líquida atua como uma válvula no ponto mais baixo, alternadamente bloqueando e deixando passar o gás. Durante a fase de bloqueio, a pressão se acumula em um ponto crítico, onde ocorre uma “explosão”. Depois de um tempo, o líquido se acumula novamente e o ciclo se repete. As golfadas de líquido podem ser tão longas quanto o próprio *riser*, e normalmente não há mais do que uma golfada por vez.

Nos poços por gás *lift*, gás injetado em poços que apresentam baixa pressão a fim de facilitar a elevação do petróleo, um invólucro é desenvolvido em volta do poço por preenchimento de gás. O gás é então injetado através de uma válvula unidirecional no fundo do poço, baixando a densidade da coluna de líquido.

Em alguns sistemas de poços, os mecanismos do fenômeno de golfadas são mal compreendidos. Assim, na ausência de um ponto baixo ou de elevação de gás, um mesmo modelo de simulação preciso pode não prever o comportamento da golfada. Neste caso, várias golfadas podem estar presentes no *riser* ao mesmo tempo.

Segundo Codas (2016), o fenômeno de golfadas pode ser reduzido ou eliminado pelo aumento da contrapressão do oleoduto, ou seja, reduzindo a abertura da válvula *choke* ou aumentando a taxa de injeção do gás *lift*. No entanto, essas soluções não são necessariamente ideais do ponto de vista econômico.

### 2.3 Importância da medição de pressão do fundo do poço

A pressão do fundo do poço medida é uma das variáveis mais importantes para monitoramento, otimização e controle da produção de poços de petróleo, sendo essencial na avaliação da dinâmica do poço de petróleo (Antonello, 2017).

A pressão do fundo do poço usualmente é medida por um sensor denominado PDG e, a fim de entender a importância que esse sensor de pressão tem no processo de extração, segue explicação de Diehl *et al.* (2017): “existe um fenômeno importante

observado em oleodutos e poços de petróleo correspondente ao alto fluxo oscilatório ou fluxo de *slugging*. Este é geralmente o caso dos poços de petróleo que empregam a técnica de gás *lift* para extrair o óleo de poços de águas profundas ou de baixa pressão. O gás artificialmente injetado diminui a densidade do fluido do poço, o que, por sua vez, possibilita sua extração com a diferença de pressão criada. Técnicas de estabilização que abordam esses comportamentos oscilatórios em fluxos multifásicos são necessários e foram projetados por especialistas do meio acadêmico e da indústria. Estes métodos são geralmente baseados na estabilização da pressão do poço através de atuadores de estrangulamento na vazão de gás *lift* e na produção do poço. Infelizmente, os sensores PDG são instalados em ambientes agressivos e têm um custo proibitivo para manutenção ou substituição (Eck et al., 1999), e também sua falha prematura não é incomum. Além disso, perturbações e ruídos podem afetar as medições do sensor PDG, tornando-os uma fonte de informações não confiável.”

Dada a importância de medir ou estimar a pressão do poço e a falta de confiabilidade do sensor PDG, vários trabalhos que buscam criar modelos que possam estimar a pressão do poço com base em outras medições na superfície. Esses modelos preditivos, geralmente chamados de analisadores virtuais, são importantes para o controle de qualidade e segurança da produção e foram extensivamente desenvolvidos nas últimas décadas. Alguns destes analisadores usam o conhecimento da física do poço de petróleo para projetar um observador não linear para os estados do fluxo multifásico, a fim de estimar a pressão do poço, enquanto outros são baseados em abordagens de identificação do sistema de caixa preta. Enquanto a primeira abordagem pode tirar proveito do conhecimento a priori para uma análise refinada e esquemas de controle mais avançados, a última abordagem é mais rápida, não requer modelagem extensiva, sendo bem adequada para identificar modelos desconhecidos (Antonelo, 2017).

Grande parte da literatura na identificação de sistemas depende do uso de modelos NARMAX (Billings, 2013) ou de redes neurais artificiais (RNAs) para explicar comportamentos dinâmicos ou temporais em processamento. Embora seja possível introduzir dinâmicas no modelo usando uma janela de tempo de entradas anteriores, uma maneira geral mais interessante é usar Redes Neurais Recorrentes (RNNs) como aproximadores universais para sistemas dinâmicos (Funahashi & Nakamura, 1993).

Por fim, Antonelo (2017) defende estes modelos preditivos, pois modelos de analisadores virtuais apresentam vantagens baseadas em abordagens de identificação de sistemas de caixa preta, e esta abordagem é mais rápida e não requer modelagem extensiva, sendo bem adequada para identificar modelos desconhecidos.

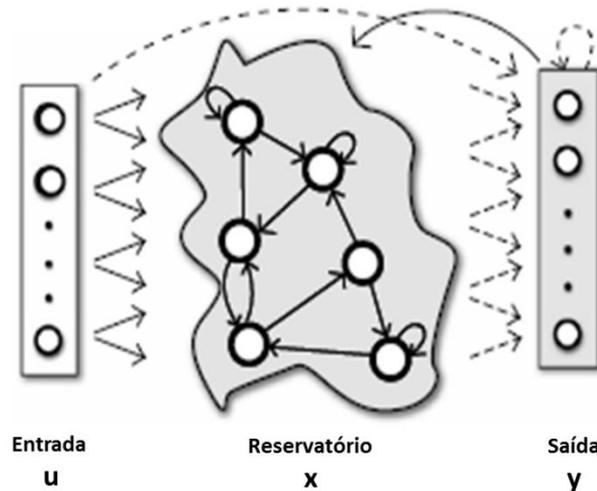
## **2.4 Métodos computacionais aplicados**

### *2.4.1 Computação em Reservatório*

Computação em Reservatório (Verstraeten, Schrauwen, D'Haene, & Stroobandt, 2007) é um termo recentemente cunhado para designar o paradigma de computação baseado em transientes de um sistema dinâmico fixo. Na Computação de Reservatório, a rede (ver Figura 2.3) deve ser composta de duas partes principais, um pool de neurônios de alta densidade recorrente, com pesos sinápticos fixos e gerados aleatoriamente, chamado reservatório e uma camada de saída de leitura adaptativa linear que projeta os estados do reservatório para a saída real do sistema. Como apenas a camada de saída precisa ser

treinada, geralmente via métodos de regressão linear, o treinamento é simplificado e a convergência global garantida.

O reservatório pode ser visto como um núcleo dinâmico não linear, projetando a entrada para um espaço dinâmico de alta dimensão, no qual a regressão linear ou classificação pode ser mais facilmente executada.



**Figura 2.3:** Rede de Computação em Reservatório. (adaptado de Antonelo, 2017).

O reservatório é um sistema dinâmico não linear usualmente composto por unidades sigmóides recorrentes. Linhas sólidas representam conexões fixas, geradas aleatoriamente, enquanto linhas tracejadas representam pesos adaptáveis ou treináveis

As motivações de Antonelo (2017) para usar a Computação em Reservatório na construção de sensores baseados em softwares de pressão de fundo são:

1. Pode ser aplicado a problemas quando o modelo é desconhecido (a maioria dos processos do mundo real não pode ser completamente modelada ou é necessário um esforço de modelagem considerável), quando comparado com uma abordagem de projeto de observador;
2. Computação em Reservatório permite a adição de novas unidades de saída na camada de saída (usando o mesmo reservatório) que podem ser treinadas separadamente, sem corromper unidades previamente treinadas, sendo útil se unidades adicionais de estimativa de saída forem necessárias com o tempo;
3. Modelos inversos podem ser facilmente construídos para que até mesmo um subconjunto das medições de entrada possa ser previsto no caso de alguns sensores se tornarem defeituosos, melhorando o desempenho geral;
4. Por fim, a Computação em Reservatório fornece um treinamento rápido e eficiente para as Redes Neurais Recorrentes, quando comparado aos métodos baseados em gradiente descendente.

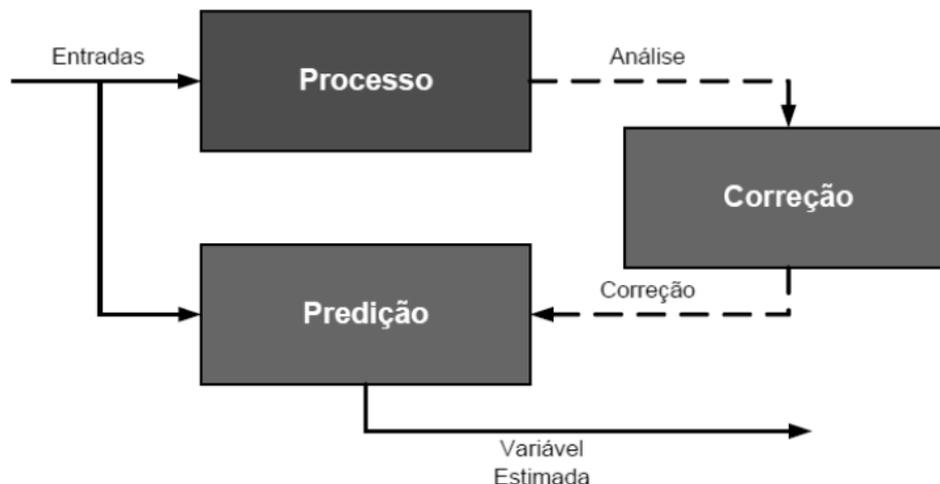
### 2.4.2 Analisadores Virtuais

Analisadores virtuais são sistemas que utilizam algoritmos matemáticos para a obtenção de estimativas em tempo real de variáveis que não são medidas por sensores, utilizando para isso as suas correlações com dados disponíveis por medições em processo (FORTUNA et al. 2005).

Dentre as vantagens dos analisadores virtuais, segundo FORTUNA et al. (2005), destacam-se as seguintes:

- Oferecem uma alternativa de baixo custo, comparados a sensores físicos caros;
- Podem trabalhar em paralelo com sensores físicos, fornecendo informação útil na identificação de falhas;
- Podem ser facilmente implementados em hardware existente, como micro-controladores, e calibrados de acordo com as mudanças nos parâmetros do sistema;
- Permitem a estimação de dados em tempo real, superando em desempenho análises lentas, como as de cromatografia gasosa.

Segundo Facchin (2005), os analisadores virtuais consistem em algoritmos compostos basicamente por três blocos (Figura 2.4): o bloco processo contém as variáveis do processo que serão utilizadas no modelo; o bloco predição representa o modelo matemático usado para relacionar as variáveis do processo que buscam atingir a variável estimada; e o bloco correção contém uma estratégia de adaptação do modelo de predição.

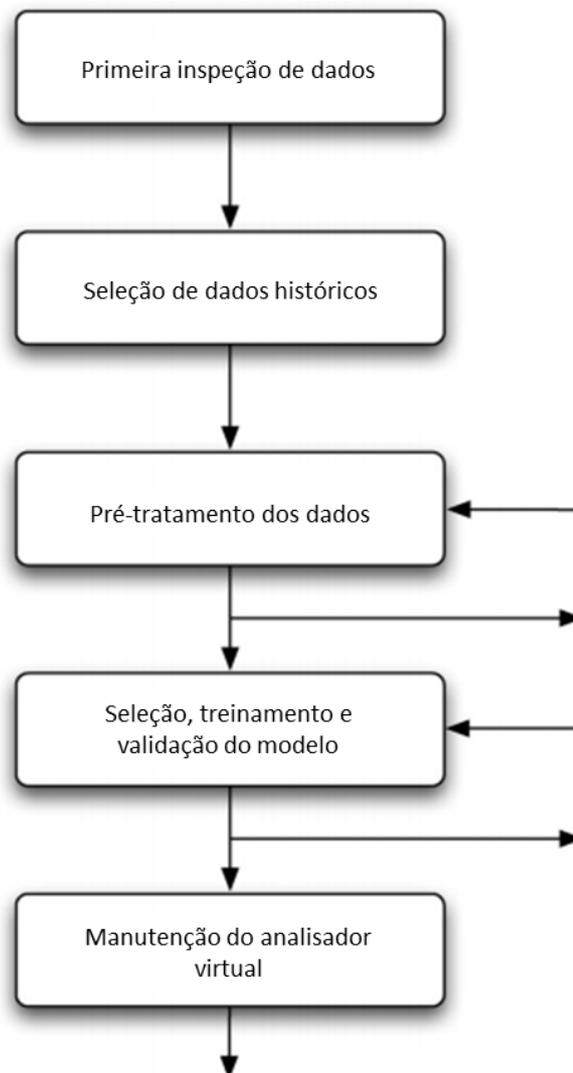


**Figura 2.4:** Algoritmo básico de um analisador virtual (FACCHIN, 2005).

### 2.4.3 Desenvolvimento de Analisadores Virtuais

Segundo Facchin (2005), para desenvolver um analisador virtual é necessário, usualmente, seguir uma sequência de procedimentos que envolvem, por exemplo, desde a seleção da técnica de modelagem até a estratégia de correção a ser aplicada no modelo desenvolvido.

KADLEC *et al.* (2009), portanto, sintetizam a estrutura básica da metodologia de desenvolvimento de analisadores virtuais, proposto por autores, por meio da figura 2.5.



**Figura 2.5:** Metodologia para o desenvolvimento de um analisador virtual (adaptado de KADLEC *et al.*, 2009).

#### 2.4.4 Primeira inspeção de dados

O objetivo dessa etapa é obter uma visão geral da estrutura dos dados e identificar quaisquer problemas óbvios que possam ser tratados neste estágio inicial (por exemplo, variáveis bloqueadas com valor constante, etc.), e avaliar os requisitos para a complexidade do modelo. Ainda, deve ser verificado se há variação suficiente na variável de saída, a fim de avaliar se é possível fazer um modelo (KADLEC *et al.* 2009).

#### 2.4.5 Seleção de dados históricos

Nessa etapa, os dados são selecionados para serem usados no treinamento e na avaliação do modelo. Em seguida, as partes estacionárias dos dados devem ser identificadas e selecionadas. Na maior parte dos casos, a modelagem adicional tratará apenas dos estados estacionários do processo. No caso de processos dinâmicos, geralmente não há estados estacionários e, portanto, o modelo se concentra na seleção

de lotes representativos e não na identificação de estados estacionários (KADLEC et al. 2009).

#### 2.4.6 Pré-tratamento dos dados

O objetivo desta etapa é transformar os dados, a fim de que possam ser processados de forma mais efetiva pelo modelo real. Um exemplo de uma etapa típica de pré-processamento é a normalização dos dados para a média zero e a variância unitária.

Ainda, deve-se procurar por dados perdidos, detecção e substituição de *outliers*, seleção de variáveis relevantes para a construção do modelo, manipulação de dados de derivação e detecção de atrasos entre as variáveis específicas.

Essa é a etapa que requer uma grande quantidade de trabalho manual e conhecimento especializado sobre o processo. (KADLEC et al. 2009).

#### 2.4.7 Seleção, treinamento e validação do modelo

Segundo KADLEC *et al.* (2009), esta fase é crítica para o desempenho final do Analisador Virtual. Como o modelo é o “motor” do Analisador Virtual, a seleção do tipo ideal é crucial para o seu desempenho. Não existe uma abordagem teórica unificada para esta tarefa e, portanto, o tipo de modelo e seus parâmetros são frequentemente selecionados de maneira específica para cada Analisador Virtual.

Depois de encontrar a estrutura do modelo ideal e treinar o modelo, o Analisador Virtual treinado deve ser avaliado em dados independentes novamente. Existem várias ferramentas para a avaliação do desempenho do modelo. No caso da avaliação numérica de desempenho, o mais popular é o erro médio quadrático (*Mean Squared Error - MSE*), que mede a distância quadrada média entre o valor previsto e o valor correto.

Além da escolha do modelo em si, a rede neural exige conhecimento da aplicação dos seus parâmetros e a influência que eles representam no resultado final. Em vista disso, segue uma breve explicação destes parâmetros:

- **Função de ativação:** é um elemento extremamente importante das redes neurais. Elas basicamente decidem se um neurônio deve ser ativado ou não. Ou seja, se a informação que o neurônio está recebendo é relevante ou deve ser ignorada.
- **Camada oculta:** é a camada que recebe os dados da camada de entrada, gera o conjunto de treinamento e gera os dados para a camada de saída. Foram testadas 1 e 2 camadas ocultas para cada caso.
- **Nós da camada oculta:** Eles executam cálculos e transferem informações dos nós de entrada para os nós de saída. Não há uma regra para seu valor e, por isso, variou-se conforme cada situação.
- **Tamanho do teste:** uma parte dos dados deve ser usada para calcular os pesos mais adequados que serão utilizados no restante dos dados, para que se possa prever a propriedade desejada. Normalmente, recomenda-se utilizar 20% dos dados para teste, quando o conjunto de dados é extenso, e 50% para a situação contrária.

- Otimizador: é o algoritmo que gera as mudanças dos pesos e do *bias*, durante o treinamento. A variação deste algoritmo não trouxe variações significativas.
- Função de erro e perda: é o objetivo que o modelo tenta minimizar. O erro é calculado como a diferença quadrática entre a saída real e a saída prevista. A função que é usada para calcular esse erro é conhecida como Função de Perda. Diferentes funções de perda darão erros diferentes para a mesma previsão e, portanto, terão um efeito considerável no desempenho do modelo. Uma das funções de perda mais utilizadas é o erro quadrático médio, que calcula o quadrado da diferença entre o valor real e o valor previsto. Diferentes funções de perda são usadas para lidar com diferentes tipos de tarefas, ou seja, regressão e classificação. Como este trabalho se trata de uma regressão, a função de perda necessária para o modelo Sequencial é a do erro quadrático médio.
- Tamanho do lote: define o número de amostras que serão propagadas pela rede. Em geral, um tamanho de lote maior resulta em treinamento mais rápido, mas nem sempre converge rapidamente. Um tamanho de lote menor é mais lento no treinamento, mas pode convergir mais rapidamente. O tamanho do lote definitivamente depende da situação e foi necessário experimentar alguns valores diferentes para alcançar o melhor ajuste. Este foi o parâmetro que teve maior impacto nos resultados.
- Época: é uma iteração em todos os dados de treinamento. Foram utilizados valores entre 1 e 5 épocas, valores maiores não trouxeram melhoras no modelo.

#### 2.4.8 Manutenção do Analisador Virtual

Depois de implementado, o Analisador Virtual deve ser mantido e ajustado regularmente. A manutenção é uma necessidade devido aos desvios e outras alterações dos dados que causam a deterioração do desempenho do Analisador Virtual e devem ser compensados pela adaptação ou desenvolvimento do novo modelo (KADLEC *et al.*, 2009).

Dessa forma, segundo Facchin (2005), é importante que o modelo matemático passe por um processo constante de adaptação, mantendo-se fiel ao processo, para garantir um alto grau de confiança no Analisador Virtual.

Portanto, segundo KADLEC *et al* (2009)., o operador do modelo desempenha um papel importante, pois é seu julgamento e conhecimento do processo subjacente que decide sobre a forma como os parâmetros dos métodos de adaptação individuais são selecionados.

#### 2.4.9 Rede Neural

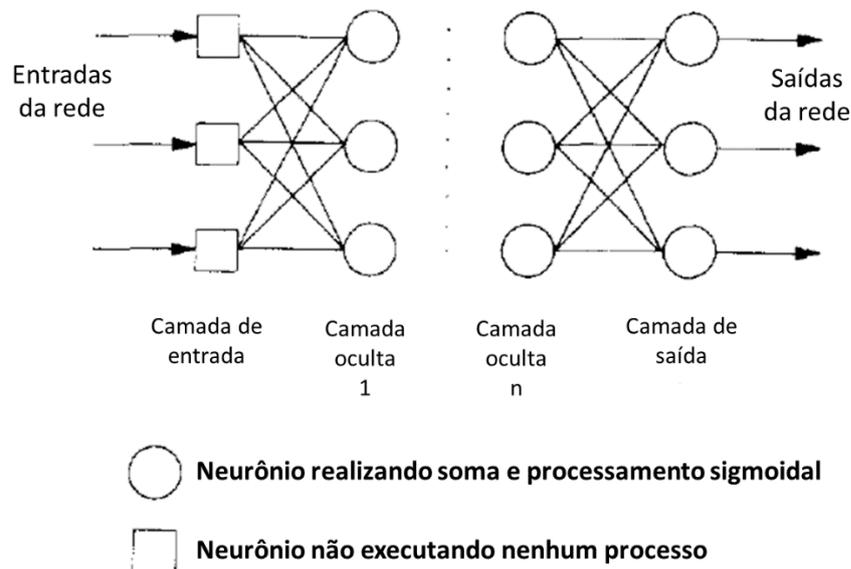
Analisadores Virtuais podem ser projetados com base em um modelo analítico ou introduzindo abordagens de identificação de caixa preta ou cinza. Devido à complexidade dos fenômenos envolvidos, a modelagem física pode ser muito demorada e os parâmetros significativos são geralmente desconhecidos. Pelo contrário, a grande quantidade de dados históricos, geralmente necessários para fins de monitoramento, permite a identificação não linear de modelos de processos em caixa preta ou cinza. As Redes Neurais podem ser usadas para implementar os modelos não lineares requeridos (L. Fortuna, 2004).

Segundo D. Verstraeten (2007), redes neurais oferecem um método atraente para resolver tarefas complicadas de engenharia. As vantagens das redes neurais *feedforward* incluem robustez, aprendizado pelo exemplo e a capacidade de modelar sistemas altamente não lineares e, adicionado a isso, uma capacidade de processamento temporal inerente. As possíveis - e reais - aplicações são múltiplas, incluindo o aprendizado de linguagens livres de contexto e sensíveis ao contexto, controle e modelagem de sistemas dinâmicos complexos e reconhecimento de fala.

As redes neurais podem fornecer um tipo de computação dependente do estado muito semelhante ao funcionamento cortical no cérebro (Buonomano & Maass, 2009), onde a trajetória de um sistema dinâmico de alta dimensão reflete tanto a entrada atual quanto os estímulos de entrada recebidos anteriormente.

Especificamente, segundo WILLIS et al. (1992), a rede neural *feedforward* é o tipo de rede mais amplamente aplicada, ainda que várias arquiteturas de redes neurais tenham sido propostas. Cybenko (1989) afirmou que qualquer função contínua pode ser aproximada arbitrariamente bem em um conjunto compacto por uma rede neural *feedforward*, compreendendo duas camadas ocultas e uma não linearidade contínua fixa. Esse resultado essencialmente afirma que uma rede neural *feedforward* poderia ser usada para modelar uma ampla gama de relacionamentos não lineares.

Uma rede neural *feedforward* é constituída de elementos semelhantes a neurônios, chamados nós. Esses nós são organizados em camadas, conforme Figura 2.6.



**Figura 2.6:** Representação de uma rede neural *feedforward* (adaptado de WILLIS et al. 1992)

Geralmente, a rede neural *feedforward* é usada para aproximar um mapeamento não linear entre entradas e saídas do sistema. Assim, a rede é composta de dados de entrada,  $u(t)$ , e saída,  $y(t)$ . Por definição, a transformação funcional de cada camada de uma rede, definida por  $J$ , pode ser representada pela composição de uma transformação afim, como uma soma ponderada das entradas para a camada posterior ( $W_i$ ), com um mapeamento não linear, geralmente utilizando uma função sigmoidal ( $S$ ). Os vetores de saída da primeira e segunda classes internas da Rede Neural são  $h_1$  e  $h_2$ , respectivamente, e o

vetor de saídas da rede e “.” o operador de montagem, a equação do problema é dado a seguir:

$$h_1 = J_1(u(t), y(t - \tau)) = S. W_1(u(t), y(t - \tau)) \quad (3.8)$$

$$h_2 = J_2(h_1(t)) = S. W_2(h_1(t)), \quad (3.9)$$

$$y(t) = J_0(h_2(t)) = S. W_0(h_2(t)) \quad (3.10)$$

Uma aproximação ao mapeamento não linear original por uma rede neural com duas camadas ocultas é, portanto, dada por:

$$y(t) = J_0. J_2. J_1(u(t), y(t - \tau)) \quad (3.11)$$

Segundo Facchin (2005), existem índices de ajustes dos dados que são usados para determinar qual modelo é o mais adequado. O principal índice utilizado é o da soma quadrática do erro (SSE), que mede os desvios dos dados entre os dados do modelo pelos dados originais, que combinado ao coeficiente de determinação ( $S_{yy}$ ), obtém-se a expressão final do cálculo do coeficiente de determinação, também referenciado como  $R^2$ . As equações 2.1, 2.2 e 2.3 demonstram o cálculo destes índices:

$$SSE = \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

$$S_{yy} = \sum_{i=1}^N (y_i - \bar{y}_i)^2$$

$$R^2 = 1 - \frac{SSE}{S_{yy}}$$

Onde  $y_i$  são os valores gerados pelo modelo,  $\hat{y}_i$  os dados originais utilizados para elaboração do modelo e  $\bar{y}$  o valor médio do conjunto de dados originais.

A rede neural deve ser treinada com os dados de treinamento de entrada e saída, com os dados sendo propagados pela rede de modo a ajustar os pesos internos de cada neurônio em cada camada. O procedimento é realizado com o objetivo de minimizar o erro quadrático entre a saída obtida pela Rede Neural e o valor da variável de resposta original, sendo possível utilizar diversos algoritmos de otimização para tal tarefa. Com o modelo obtido, a Rede Neural é validada através da utilização dos dados de validação. Sobre o treinamento da rede, os dados são divididos em conjuntos de dados de treinamento e teste. Dessa forma, aplica-se um procedimento envolvendo treino, teste e validação. Os conjuntos de dados de treinamento são usados para obter os pesos da rede, enquanto os conjuntos de dados de teste são usados para validar o modelo de rede (WILLIS et al., 1992).

### 3 Metodologia

Este capítulo mostra as etapas do desenvolvimento do Analisador Virtual, que segue a estratégia de implementação descrita no capítulo anterior e a explicação da Rede Neural Artificial escolhida e de seus parâmetros.

### 3.1 Desenvolvimento do Analisador Virtual

A consolidação das informações e o desenvolvimento do Analisador Virtual foram gerados em linguagem de programação Python.

Este trabalho usou como referência as informações do poço de petróleo A, extraídas de um modelo dinâmico semiempírico simplificado desenvolvido por Diehl (2017), chamado FOWM (*Fast Offshore Wells Model*). Este modelo foi criado para aplicações de controle e tempo real em sistemas de produção *offshore* de águas profundas e ultraprofundas.

#### 3.1.1 Primeira inspeção de dados seleção de dados históricos

As variáveis de interesse para o desenvolvimento deste trabalho são a pressão de topo, a pressão do separador, a abertura da válvula *choke* e a vazão do gás *lift*, todas estas obtidas nas instalações do topo, e a pressão do poço medida pela PDG, obtida na saída do poço.

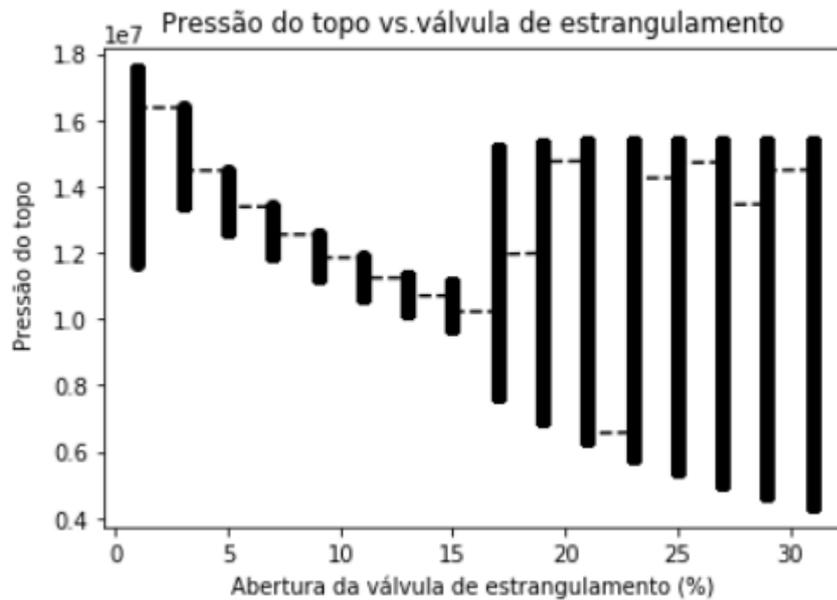
Foram coletadas 2.090.000 medidas do FOWM, com 16 variações de abertura da válvula *choke* para 13 variações de vazão do gás *lift*, conforme Tabela 3.1. Todas estas combinações foram geradas e extraídas do Matlab, armazenando-as no Microsoft Excel.

Abertura da válvula <i>choke</i> (%)	Vazão de gás <i>lift</i> (m <sup>3</sup> / dia)
1	145.000
3	150.000
5	155.000
7	160.000
9	165.000
11	170.000
13	175.000
15	180.000
17	185.000
19	190.000
21	195.000
23	200.000
25	205.000
27	
29	
31	

**Tabela 3.1:** Representação das variações de abertura da válvula *choke* (%) e vazão de gás *lift* (m<sup>3</sup>/ dia).

O valor da pressão no separador ( $P_{sep}$ ) foi mantido constante e igual à 1.013.300 Pa.

A fim de entender o comportamento do poço conforme abertura da válvula *choke*, segue a Figura 3.1, que mostra a variação da pressão para diferentes aberturas da válvula. Pode-se observar que há uma oscilação de pressão a cada abertura de válvula até a estabilização. Este comportamento se repete até acontecer o fenômeno de golfadas, a partir de 17% de abertura de válvula *choke*.



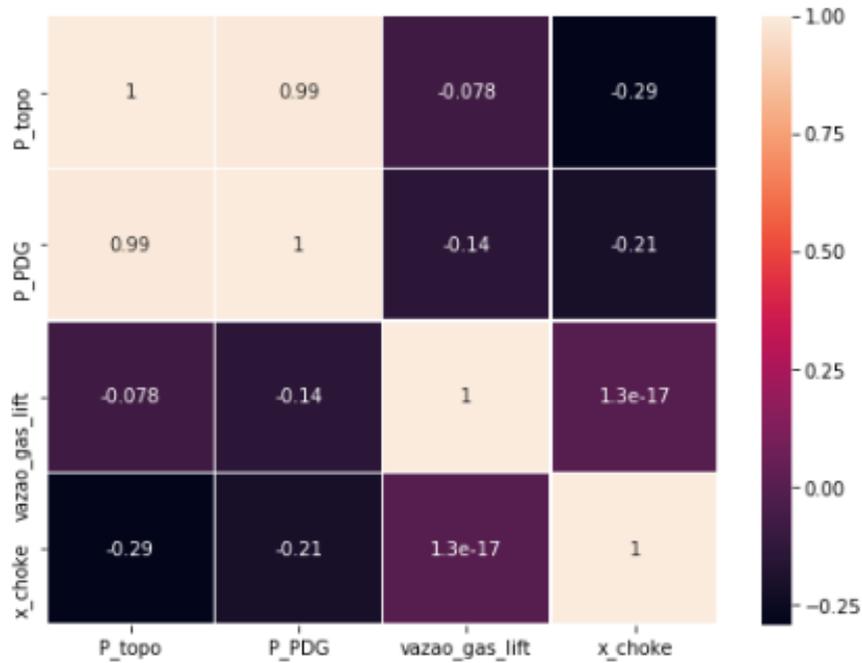
**Figura 3.1:** Variação da pressão do topo pela abertura da válvula *choke*.

Como o comportamento da pressão é dinâmico e por vezes oscilatório, é proposta inicialmente a elaboração de uma rede neural estática, ou seja, para cada estabilização da pressão, dada uma abertura de válvula *choke*, foi utilizado um valor médio da pressão como referência desta abertura da válvula *choke*.

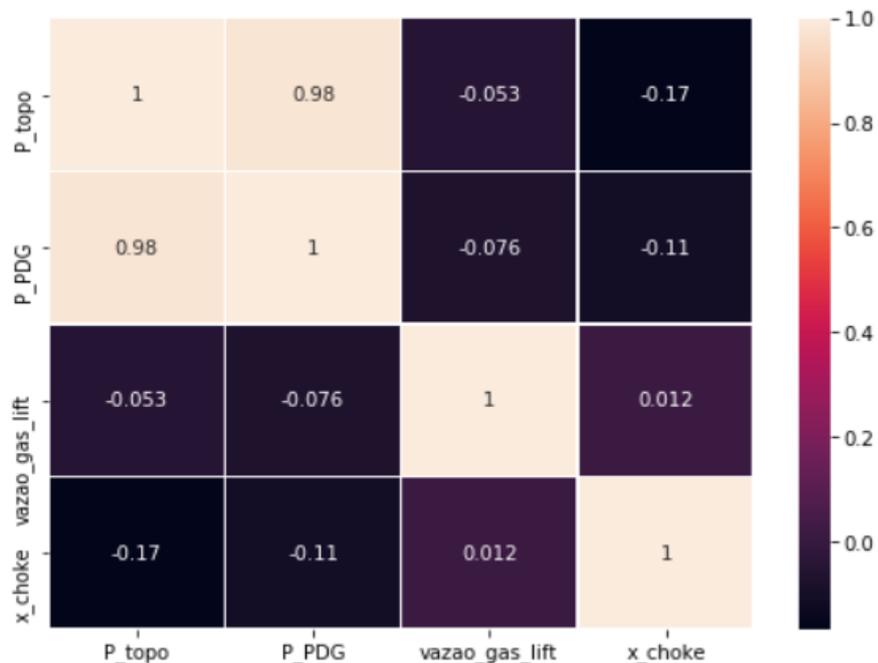
Para entender melhor como as variáveis do poço estão associadas nessa condição estática, foi gerada uma matriz de correlações (Figura 3.2), onde  $P_{\text{topo}}$  é a pressão de topo,  $P_{\text{PDG}}$  é pressão de poço medida pelo sensor PDG,  $\text{vazão}_{\text{gas\_lift}}$  é a vazão do gás-*lift* e  $x_{\text{choke}}$  é a abertura da válvula *choke*. Esta matriz tem por objetivo mostrar como estão correlacionadas as variáveis para, então, escolhê-las na maneira mais adequada para a predição da pressão de fundo do poço.

Importante notar que as os pares das variáveis na figura 3.2 tem como resultado valor igual a 1 ( $P_{\text{topo}} - P_{\text{topo}} = 1$ ), ou seja, significa que tem correlação direta. Assim, quanto mais próximo de 1, maior é a correlação entre variáveis. Dessa maneira, pode-se ver que o único par de variáveis diferentes que se correlacionam fortemente é a pressão de topo ( $P_{\text{topo}}$ ) e a pressão do poço medida pelo sensor PDG ( $P_{\text{PDG}}$ ) com valor igual a 0,98, já as demais são praticamente nulas.

Em seguida, modelou-se uma rede neural dinâmica, considerando todos os dados do poço, a fim de aproximá-lo o máximo possível da realidade. Com o mesmo objetivo explicado acima, também foi gerada uma matriz de correlações para compreensão da associação das variáveis (Figura 3.3). O resultado foi o mesmo para a matriz de correlações dos dados estáticos.



**Figura 3.2:** Matriz de correlação das variáveis para elaboração da rede neural estática, onde P\_topo é a pressão de topo, P\_PDG é pressão de poço medida pelo sensor PDG, vazão\_gas\_lift é a vazão do gás-lift e x\_choke é a abertura da válvula choke.



**Figura 3.3:** Matriz de correlação das variáveis para elaboração da rede neural dinâmica, onde P\_topo é a pressão de topo, P\_PDG é pressão de poço medida pelo sensor PDG, vazão\_gas\_lift é a vazão do gás-lift e x\_choke é a abertura da válvula choke.

Apesar das matrizes de correlações mostrarem que apenas a pressão de topo está relacionada com a pressão do poço, o uso conjunto das variáveis pode ser positivo para a predição da pressão do poço, diferentemente das variáveis serem analisadas

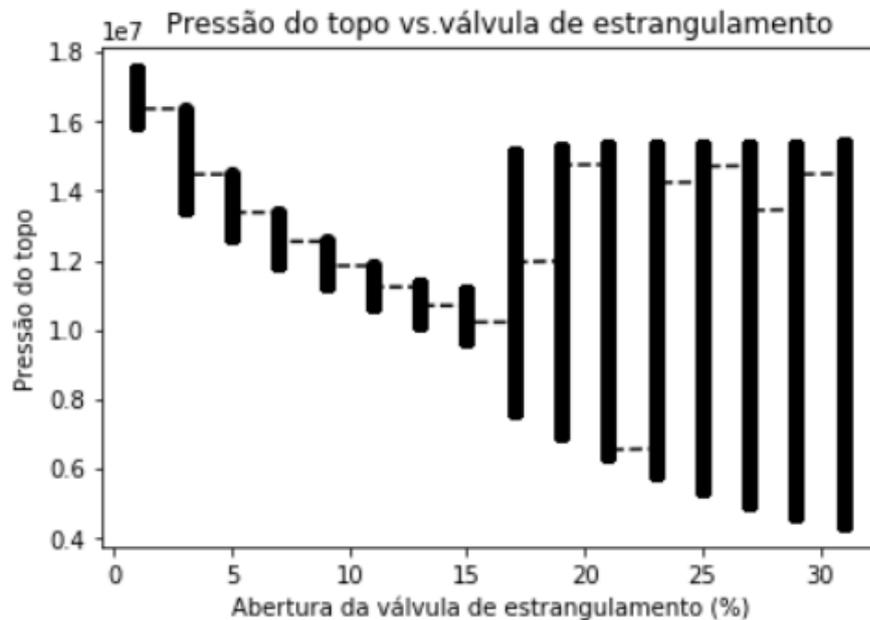
separadamente. Portanto, a fim de encontrar o melhor resultado, foram testados três conjuntos diferentes de variáveis para prever a pressão do poço, tanto para a rede neural estática quanto para a dinâmica:

- Teste 1: Abertura da válvula *choke* e vazão do gás *lift*;
- Teste 2: Pressão de topo;
- Teste 3: Pressão de topo, abertura da válvula *choke* e vazão do gás *lift*.

### 3.1.2 Pré-tratamento dos dados

O pré-tratamento dos dados foi realizado todo via Python, com conexão ao Microsoft Excel.

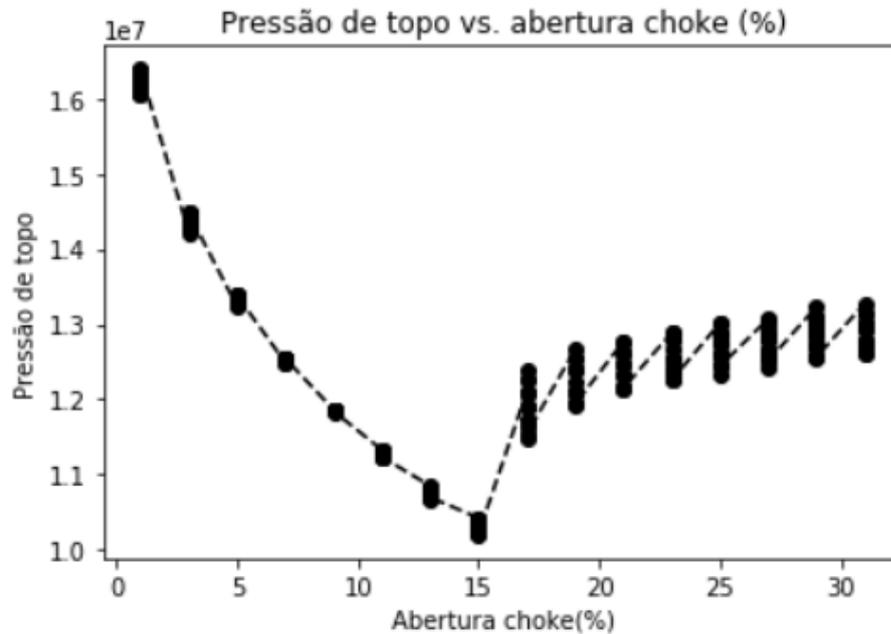
As primeiras informações da base de dados tiveram de ser desconsideradas para a resolução do modelo, pois trata-se da resposta transiente inicial que ocorre logo ao abrir a válvula *choke*, abertura igual a 1%, visto que a condição inicial não é a referente ao estado estacionário do modelo, para esta condição de planta. Neste período, onde ocorre uma grande oscilação inicial de pressão até a sua estabilização. Assim, a Figura 3.4 apresenta apenas o comportamento dos dados relevantes para o desenvolvimento deste trabalho.



**Figura 3.4:** Variação da pressão do topo pela abertura da válvula *choke*.

Os dados utilizados para a rede neural estática tiveram que ser gerados a partir da base total de dados. Assim, para cada abertura de válvula, pegou-se o valor médio de pressão de topo e pressão medida pelo sensor PDG, obtidas pelas diferentes vazões de gás *lift*.

Não foi observada nenhuma alteração do comportamento da pressão, ao comparar a Figura 3.5, referente à base de dados gerada para a rede neural estática, com a Figura 3.4, referente à base de dados total.



**Figura 3.5:** Variação da pressão do topo pela abertura da válvula *choke*, na avaliação estática das pressões para cada abertura.

### 3.1.3 Seleção, treinamento e validação do modelo

A rede neural *feedforward* foi escolhida e desenvolvida com auxílio da biblioteca Keras, que é uma biblioteca usada para o desenvolvimento de redes neurais de código aberto escrita em Python. Para este trabalho, utilizaram-se camadas densas, funções de ativação, métricas e otimizadores dessa biblioteca.

Após seleção dos dados e antes de treinar a rede, fez-se a padronização dos dados, de modo que a média dos valores observados seja 0 e o desvio padrão seja 1. Essa padronização é necessária em algoritmos de aprendizado de máquina quando seus dados possuem valores de entrada com escalas diferentes e garante resultados mais confiáveis. A padronização assume que os dados se ajustem a uma distribuição gaussiana com uma média e desvio padrão adequados.

Uma análise preliminar foi realizada a fim de identificar a melhor configuração para o presente trabalho. Assim, inicialmente escolheu-se um dos parâmetros para ajustar, enquanto os demais eram fixados. Essa metodologia foi utilizada para cada teste de cada rede neural, mostradas no capítulo seguinte com maior detalhamento.

## 4 Resultados

Conforme explicado no capítulo anterior, os resultados serão apresentados seguindo a metodologia de ajuste de cada parâmetro da rede neural, buscando pelo melhor coeficiente de determinação do teste da rede neural. Ainda, os resultados de coeficientes de determinação apresentados são sobre o a base de treino.

### 4.1 Rede Neural – Estática

Vale ressaltar que a base de dados gerada para esta situação contempla 208 linhas, pois contém apenas valores médios de pressão para situações de estabilidade já mencionadas.

#### 4.1.1 Teste 1: Abertura da válvula choke e vazão do gás lift

Para a determinação da função de ativação, o melhor coeficiente de determinação foi igual a 0,08 para a função Relu (Unidade linear retificada), conforme Tabela 4.1.

Para a determinação da melhor configuração dos demais parâmetros, foi necessário fazer combinações sistemáticas, pois a análise individual não trouxe variações significativas de desempenho. Assim, todos os parâmetros tiveram que ser elevados a grandes números para conseguir chegar a resultados mais expressivos. Por fim, obteve-se um valor de coeficiente de determinação igual a 0,26, muito insatisfatório, conforme Tabela 4.2.

**Tabela 4.1:** Valores de  $R^2$  encontrados para diferentes funções de ativação, referentes ao Teste 1 da rede neural estática.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Tangente hiperbólica	40	200	200	3	1.000	0
Linear	40	200	200	3	1.000	-0,01
Sigmoide	40	200	200	3	1.000	-0,06
<b>Relu</b>	<b>40</b>	<b>200</b>	<b>200</b>	<b>3</b>	<b>1.000</b>	<b>0,08</b>
Softmax	40	200	200	3	1.000	-1,05

**Tabela 4.2:** Valores de  $R^2$  encontrados para diferentes configurações dos parâmetros, referentes ao Teste 1 da rede neural estática.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Relu	80	200	200	3	1.000	0,09
Relu	80	400	400	3	10.000	0,11
Relu	80	400	400	5	50.000	0,18
Relu	80	500	500	5	50.000	0,2
<b>Relu</b>	<b>80</b>	<b>1000</b>	<b>1000</b>	<b>5</b>	<b>50.000</b>	<b>0,26</b>
Relu	80	5000	5000	5	50.000	0,23

#### 4.1.2 Teste 2: Pressão de topo

Inicialmente, verificou-se que função de ativação linear apresenta o melhor coeficiente de determinação, conforme Tabela 4.3.

**Tabela 4.3:** Valores de  $R^2$  encontrados para diferentes funções de ativação, referentes ao Teste 2 da rede neural estática.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Tangente hiperbólica	40	200	200	3	1.000	0,73
<b>Linear</b>	<b>40</b>	<b>200</b>	<b>200</b>	<b>3</b>	<b>1.000</b>	<b>0,97</b>
Sigmoide	40	200	200	3	1.000	-0,06
Relu	40	200	200	3	1.000	0,14
Softmax	40	200	200	3	1.000	-1,05

Para a avaliação do tamanho do conjunto de dados de teste, a sua variação não alterou o coeficiente de determinação, conforme Tabela 4.4.

**Tabela 4.4:** Valores de  $R^2$  encontrados para diferentes tamanhos do teste da rede neural, referentes ao Teste 2 da rede neural estática.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Linear	20	200	200	3	1.000	0,97
Linear	30	200	200	3	1.000	0,97
Linear	40	200	200	3	1.000	0,97
Linear	50	200	200	3	1.000	0,97

Para a avaliação do número de neurônios e camadas, a melhor configuração foi a de 2 camadas com 200 neurônios cada, conforme Tabela 4.5.

**Tabela 4.5:** Valores de  $R^2$  encontrados para diferentes neurônios das camadas ocultas, referentes ao Teste 2 da rede neural estática.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Linear	20	100	100	3	1.000	0,76
Linear	20	200	0	3	1.000	0,16
<b>Linear</b>	<b>20</b>	<b>200</b>	<b>200</b>	<b>3</b>	<b>1.000</b>	<b>0,97</b>
Linear	20	400	400	3	1.000	0,88

Para a avaliação do número de épocas, o melhor coeficiente de determinação foi obtido com 3 épocas, conforme Tabela 4.6.

**Tabela 4.6:** Valores de  $R^2$  encontrados para diferentes épocas, referentes ao Teste 2

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
--------------------	----------------------	-----------------------	-----------------------	-------	------	-------

Linear	20	200	200	1	1.000	0,46
Linear	20	200	200	3	1.000	0,76
<b>Linear</b>	<b>20</b>	<b>200</b>	<b>200</b>	<b>5</b>	<b>1.000</b>	<b>0,83</b>

Para a avaliação do número de lote, o melhor coeficiente de determinação obtido foi com 10.000 lotes, conforme Tabela 4.7.

**Tabela 4.7:** Valores de  $R^2$  encontrados para diferentes tamanhos de lote, referentes ao Teste 2 da rede neural estática.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Linear	20	200	200	5	1.000	0,97
Linear	20	200	200	5	5.000	0,97
<b>Linear</b>	<b>20</b>	<b>200</b>	<b>200</b>	<b>5</b>	<b>10.000</b>	<b>0,98</b>
Linear	20	200	200	5	50.000	0,98

#### 4.1.3 Teste 3: Pressão de topo, abertura da válvula choke e vazão do gás lift

Inicialmente, verificou-se que a função de ativação linear apresenta o melhor coeficiente de determinação, conforme Tabela 4.8.

**Tabela 4.8:** Valores de  $R^2$  encontrados para diferentes funções de ativação, referentes ao Teste 3 da rede neural estática.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Tangente hiperbólica	40	200	200	3	1.000	0,75
<b>Linear</b>	<b>40</b>	<b>200</b>	<b>200</b>	<b>3</b>	<b>1.000</b>	<b>0,94</b>
Sigmoid	40	200	200	3	1.000	-0,06
Relu	40	200	200	3	1.000	0,27
Softmax	40	200	200	3	1.000	-1,05

Para a avaliação do tamanho de teste, o melhor coeficiente de determinação obtido foi de 30%, conforme Tabela 4.9.

**Tabela 4.9:** Valores de  $R^2$  encontrados para diferentes tamanhos do teste, referentes ao Teste 3 da rede neural estática.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Linear	20	200	200	3	1.000	0,92
<b>Linear</b>	<b>30</b>	<b>200</b>	<b>200</b>	<b>3</b>	<b>1.000</b>	<b>0,96</b>
Linear	35	200	200	3	1.000	0,95
Linear	40	200	200	3	1.000	0,944
Linear	50	200	200	3	1.000	0,92

Para a avaliação do número de neurônios e camadas, a melhor configuração obtida apresentou de 2 camadas com 200 neurônios cada foi escolhida, conforme Tabela 4.10.

**Tabela 4.10:** Valores de  $R^2$  encontrados para diferentes configurações de camadas e neurônios, referentes ao Teste 3 da rede neural estática.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Linear	30	100	0	3	1.000	0,17
Linear	30	100	100	3	1.000	0,53
Linear	30	200	0	3	1.000	0,14
Linear	30	200	100	3	1.000	0,83
<b>Linear</b>	<b>30</b>	<b>200</b>	<b>200</b>	<b>3</b>	<b>1.000</b>	<b>0,96</b>
Linear	30	200	400	3	1.000	0,95
Linear	30	400	400	3	1.000	0,84

Para a avaliação do número do número de época, a melhor coeficiente de determinação obtido apresentou 3 épocas, conforme Tabela 4.11.

**Tabela 4.11:** Valores de  $R^2$  encontrados para diferentes épocas, referentes ao Teste 3 da rede neural estática.

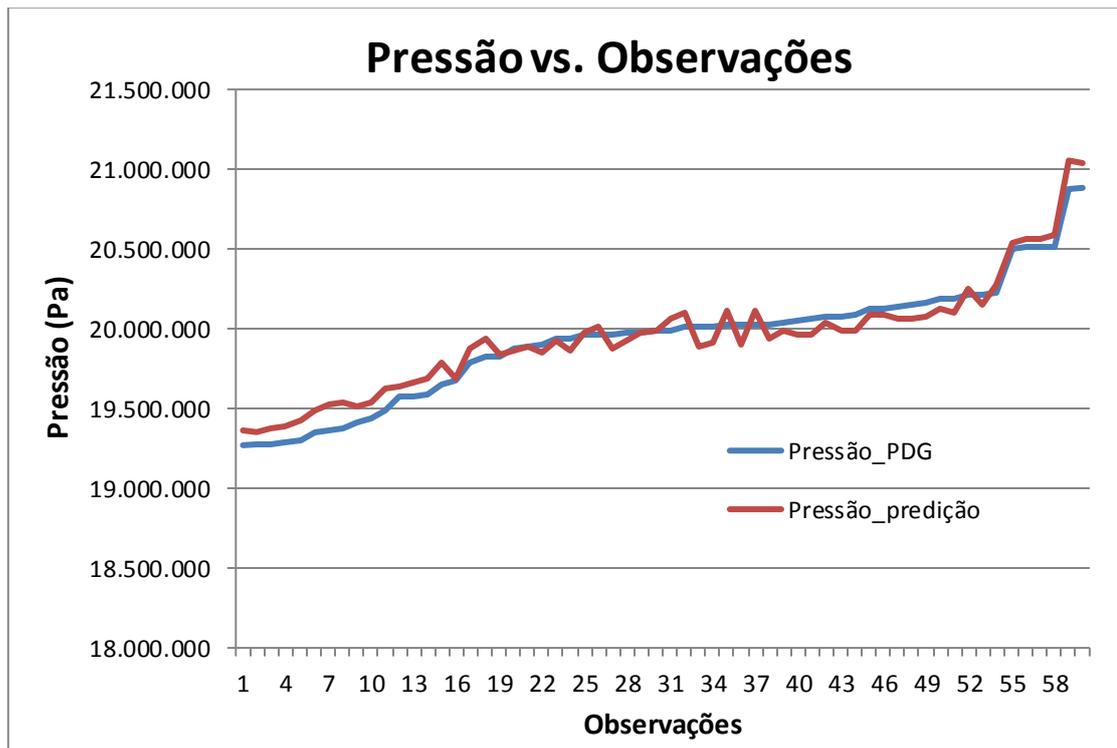
Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Linear	30	200	200	1	1.000	0,51
<b>Linear</b>	<b>30</b>	<b>200</b>	<b>200</b>	<b>3</b>	<b>1.000</b>	<b>0,96</b>
Linear	30	200	200	5	1.000	0,93

Por fim, a variação do tamanho do lote para 1.000 melhorou o modelo, obtendo um coeficiente de determinação igual a 0,96, conforme Tabela 4.12.

**Tabela 4.12:** Valores de  $R^2$  encontrados para diferentes tamanhos de lote, referentes ao Teste 3 da rede neural estática.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Linear	30	200	200	3	500	0,92
<b>Linear</b>	<b>30</b>	<b>200</b>	<b>200</b>	<b>3</b>	<b>1.000</b>	<b>0,96</b>
Linear	30	200	200	3	5.000	0,92

Por fim, A Figura 4.1 apresenta alguns resultados da pressão predita pelo melhor coeficiente de determinação ( $R^2 = 0,98$ ) obtida pelo modelo de rede neural estática, referentes ao Teste 2, comparados com as medidas de pressão correspondentes medidas pelo sensor PDG.



**Figura 4.1:** Pressão medida pelo sensor PDG comparados com o valor de pressão predita obtido pelo modelo de rede neural estática, referentes ao Teste 2.

## 4.2 Rede Neural – Dinâmica

Para a implementação do modelo dinâmico, pode-se usar todos os dados possíveis, tornando-se um modelo preditivo adequado para uma situação real.

### 4.2.1 Teste 1: Abertura da válvula choke e vazão do gás lift

Para este teste obteve-se um coeficiente de determinação de 0,23. Dado a quantidade de dados e a baixa correlação entre as variáveis, esse resultado ruim já era esperado de antemão.

Inicialmente, verificou-se que função de ativação tangente hiperbólica apresenta o melhor coeficiente de determinação, conforme Tabela 4.13.

**Tabela 4.13:** Valores de  $R^2$  encontrados para diferentes funções de ativação, referentes ao Teste 1 da rede neural dinâmica.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
<b>Tangente hiperbólica</b>	<b>40</b>	<b>200</b>	<b>200</b>	<b>3</b>	<b>1.000</b>	<b>0,22</b>
Linear	40	200	200	3	1.000	0,01
Sigmoide	40	200	200	3	1.000	0,11
Relu	40	200	200	3	1.000	0,12
Softmax	40	200	200	3	1.000	-0,99

Para a avaliação do tamanho do teste, escolheu-se o valor de 15%, pois foi o valor intermediário encontrado para resultados semelhantes de coeficiente de determinação iguais a 0,22, conforme Tabela 4.14.

**Tabela 4.14:** Valores de  $R^2$  encontrados para diferentes tamanhos do teste, referentes ao Teste 1 da rede neural dinâmica.

Função de ativação	Tamanho do teste (%)	Neurônios - 1º camada	Neurônios - 2º camada	Época	Lote	$R^2$
Tangente hiperbólica	10	200	200	3	10.000	0,22
<b>Tangente hiperbólica</b>	<b>15</b>	<b>200</b>	<b>200</b>	<b>3</b>	<b>10.000</b>	<b>0,22</b>
Tangente hiperbólica	20	200	200	3	10.000	0,22
Tangente hiperbólica	30	200	200	3	10.000	0,21
Tangente hiperbólica	50	200	200	3	50.000	0,21

Para a avaliação do número de neurônios e camadas, foram obtidos resultados semelhantes, mas por ser mais rápido que os demais, a configuração de 2 camadas com 200 neurônios cada foi escolhida, conforme Tabela 4.15.

**Tabela 4.15:** Valores de  $R^2$  encontrados para diferentes números de neurônios, referentes ao Teste 1 da rede neural dinâmica.

Função de ativação	Tamanho do teste (%)	Neurônios - 1º camada	Neurônios - 2º camada	Época	Lote	$R^2$
Tangente hiperbólica	15	100	100	3	10.000	0,21
<b>Tangente hiperbólica</b>	<b>15</b>	<b>200</b>	<b>200</b>	<b>3</b>	<b>10.000</b>	<b>0,22</b>
Tangente hiperbólica	15	300	300	3	10.000	0,22
Tangente hiperbólica	15	400	400	3	10.000	0,22

Para a avaliação do tamanho de lote, escolheu-se o tamanho de 10.000, pois este apresentou o mesmo resultado que o de 5.000, porém o primeiro foi mais rápido, conforme Tabela 4.16.

**Tabela 4.16:** Valores de  $R^2$  encontrados para diferentes tamanhos de lote, referentes ao Teste 1 da rede neural dinâmica.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Tangente hiperbólica	15	200	200	3	5.000	0,22
<b>Tangente hiperbólica</b>	<b>15</b>	<b>200</b>	<b>200</b>	<b>3</b>	<b>10.000</b>	<b>0,22</b>
Tangente hiperbólica	15	200	200	3	50.000	0,16

Por fim, para a avaliação do número de épocas, a que apresentou melhor desempenho por ser mais rápida, foi a de 3 épocas, conforme Tabela 4.17.

**Tabela 4.17:** Valores de  $R^2$  encontrados para diferentes números de épocas, referentes ao Teste 1 da rede neural dinâmica.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Tangente hiperbólica	15	200	200	1	10.000	0,19
<b>Tangente hiperbólica</b>	<b>15</b>	<b>200</b>	<b>200</b>	<b>3</b>	<b>10.000</b>	<b>0,22</b>
Tangente hiperbólica	15	200	200	5	10.000	0,22
Tangente hiperbólica	15	200	200	10	10.000	0,22

#### 4.2.2 Teste 2: Pressão de topo

Para este teste, obteve-se um coeficiente de determinação de 0,96. Inicialmente, para determinação da melhor função de ativação foram utilizadas 2 camadas de neurônios, porém nenhuma função convergiu. Portanto, com 1 camada de neurônios a função de ativação linear obteve o melhor coeficiente de determinação, conforme Tabela 4.18.

**Tabela 4.18:** Valores de  $R^2$  encontrados para diferentes funções de ativação, referentes ao Teste 2 da rede neural dinâmica.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Tangente hiperbólica	20	200	0	3	1.000	0,8
<b>Linear</b>	<b>20</b>	<b>200</b>	<b>0</b>	<b>3</b>	<b>1.000</b>	<b>0,96</b>
Sigmoide	20	200	0	3	1.000	0,34
Relu	20	200	0	3	1.000	0,28
Softmax	20	200	0	3	1.000	-1

**Tabela 4.19:** Valores de  $R^2$  encontrados para diferentes tamanhos do teste, referentes ao Teste 2 da rede neural dinâmica.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Linear	10	200	0	3	1.000	0,96
<b>Linear</b>	<b>20</b>	<b>200</b>	<b>0</b>	<b>3</b>	<b>1.000</b>	<b>0,96</b>
Linear	40	200	0	3	1.000	0,96

Para a avaliação do número de neurônios e camadas, o coeficiente de determinação obtido foi o mesmo para todas as configurações, conforme Tabela 4.20. Escolheu-se, portanto, a configuração com 1 camada de 100 neurônios, pois é a mais simples.

**Tabela 4.20:** Valores de  $R^2$  encontrados para diferentes números de neurônios, referentes ao Teste 2 da rede neural dinâmica.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
<b>Linear</b>	<b>20</b>	<b>100</b>	<b>0</b>	<b>3</b>	<b>1.000</b>	<b>0,96</b>
Linear	20	100	100	3	1.000	0,96
Linear	20	200	0	3	1.000	0,96
Linear	20	300	0	3	1.000	0,96

Para a avaliação do tamanho de lote, escolheu-se o tamanho de 10.000, pois apresentou o mesmo resultado que os demais, porém foi mais rápido, conforme Tabela 4.21.

**Tabela 4.21:** Valores de  $R^2$  encontrados para diferentes tamanhos de lote, referentes ao Teste 2 da rede neural dinâmica.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Linear	20	100	0	3	1.000	0,96
Linear	20	100	0	3	5.000	0,96
<b>Linear</b>	<b>20</b>	<b>100</b>	<b>0</b>	<b>3</b>	<b>10.000</b>	<b>0,96</b>

Por fim, para a avaliação do número de épocas, escolheu-se a de 1 época, pois é a mais simples e teve o mesmo coeficiente de determinação que as demais, conforme Tabela 4.22.

**Tabela 4.22:** Valores de  $R^2$  encontrados para diferentes números de épocas, referentes ao Teste 2 da rede neural dinâmica.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
<b>Linear</b>	<b>20</b>	<b>100</b>	<b>0</b>	<b>1</b>	<b>10.000</b>	<b>0,96</b>
Linear	20	100	0	3	10.000	0,96
Linear	20	100	0	5	10.000	0,96

#### 4.2.3 Teste 3: Pressão de topo, abertura da válvula choke e vazão do gás lift

Para este teste, o coeficiente de determinação obtido foi igual a 0,96. A configuração inicial para o ajuste deste teste se baseou no último teste, já que a diferença entre eles são os dados que não estão fortemente correlacionados com a pressão do fundo do poço, que são a vazão do gás *lift* e a abertura da válvula *choke*. Dessa maneira, novamente a função de ativação que melhor se ajustou foi a linear, conforme Tabela 4.23.

**Tabela 4.23:** Valores de  $R^2$  encontrados para diferentes funções de ativação, referentes ao Teste 3 da rede neural dinâmica.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Tangente hiperbólica	20	200	0	3	1.000	0,81
<b>Linear</b>	<b>20</b>	<b>200</b>	<b>0</b>	<b>3</b>	<b>1.000</b>	<b>0,96</b>
Sigmoide	20	200	0	3	1.000	0,34
Relu	20	200	0	3	1.000	0,35
Softmax	20	200	0	3	1.000	-1

Para a avaliação do tamanho do teste, escolheu-se o valor de 20%, pois foi o valor intermediário encontrado para resultados de coeficiente de determinação iguais a 0,96, conforme Tabela 4.24.

**Tabela 4.24:** Valores de  $R^2$  encontrados para diferentes tamanhos do teste, referentes ao Teste 3 da rede neural dinâmica.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Linear	10	200	0	3	1.000	0,96
Linear	20	200	0	3	1.000	0,96
Linear	40	200	0	3	1.000	0,96

Para a avaliação do número de neurônios e camadas, testaram-se as configurações presentes na Tabela 4.24, mas como todas apresentaram o mesmo resultado, escolheu-se a configuração de 1 camada com 100 neurônios, pois é a mais simples, conforme Tabela 4.25.

**Tabela 4.25:** Valores de  $R^2$  encontrados para diferentes números de neurônios, referentes ao Teste 3 da rede neural dinâmica.

Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
<b>Linear</b>	<b>20</b>	<b>100</b>	<b>0</b>	<b>3</b>	<b>1.000</b>	<b>0,96</b>
Linear	20	100	100	3	1.000	0,96
Linear	20	200	0	3	1.000	0,96
Linear	20	200	200	3	1.000	0,96
Linear	20	300	0	3	1000	0,96

Para a avaliação do tamanho de lote, escolheu-se o tamanho de 10.000, pois apresentou o mesmo resultado que os demais, conforme Tabela 4.26.

**Tabela 4.26:** Valores de  $R^2$  encontrados para diferentes tamanhos de lote, referentes ao Teste 3 da rede neural dinâmica.

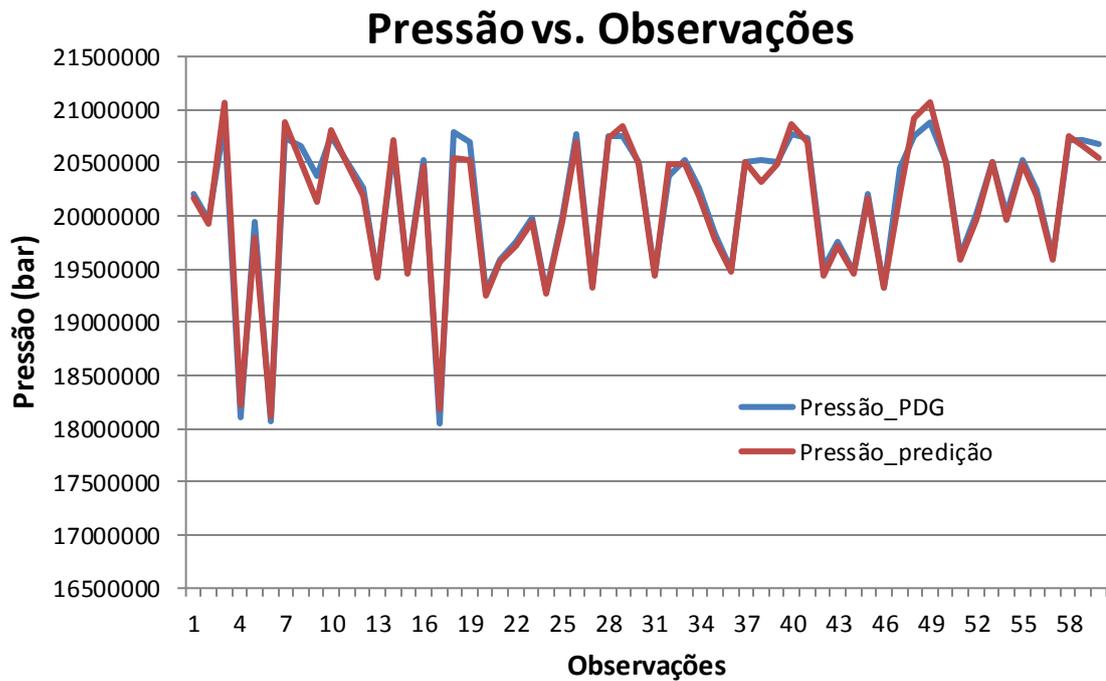
Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
Linear	20	100	0	3	1.000	0,96
Linear	20	100	0	3	5.000	0,96
Linear	20	100	0	3	10.000	0,96
Linear	20	100	0	3	50.000	0,96

Por fim, para a avaliação do número de épocas, como as épocas testadas obtiveram o mesmo coeficiente de determinação, escolheu-se por 1 época, por ser a mais simples, conforme Tabela 4.27.

**Tabela 4.27:** Valores de  $R^2$  encontrados para diferentes números de épocas, referentes ao Teste 3 da rede neural dinâmica.

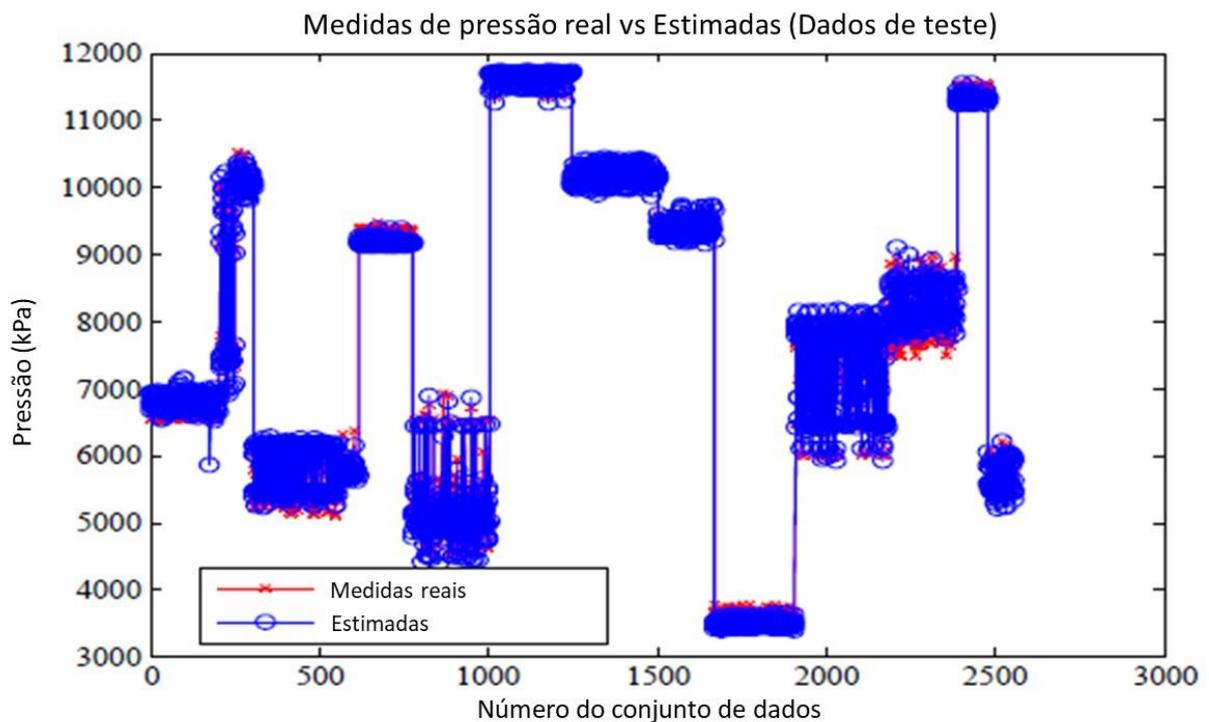
Função de ativação	Tamanho do teste (%)	Neurônios - 1ª camada	Neurônios - 2ª camada	Época	Lote	$R^2$
<b>Linear</b>	<b>20</b>	<b>100</b>	<b>0</b>	<b>1</b>	<b>10.000</b>	<b>0,96</b>
Linear	20	100	0	3	10.000	0,96
Linear	20	100	0	5	10.000	0,96

Por fim, A Figura 4.2 apresenta alguns resultados da pressão predita pelo melhor coeficiente de determinação ( $R^2 = 0,96$ ) obtida pelo modelo de rede neural dinâmica, referentes ao Teste 3, comparados com as medidas de pressão correspondentes medidas pelo sensor PDG.



**Figura 4.2:** Pressão medida pelo sensor PDG comparados com o valor de pressão predita obtido pelo modelo de rede neural dinâmica, referentes ao Teste 3.

A fim de comparar os resultados obtidos, a Figura 4.3 mostra os resultados obtidos por M. Awadalla, *et al.* (2016), que utilizou também um rede neural *feedforward* para prever a pressão de fundo de um poço de petróleo, obtendo um coeficiente de determinação igual a 0,99.



**Figura 4.3:** Medições de pressão e estimativas do modelo obtido pela Rede Neural *Feedforward*, adaptado de M. Awadalla, *et al.* (2016).

## 5 Conclusões e Trabalhos Futuros

No presente trabalho, o modelo de rede neural *feedforward* desenvolvido foi capaz de prever a pressão do fundo de um poço de petróleo, a partir de variáveis medidas usualmente. Os melhores resultados das redes neurais dinâmica e estática foram obtidos pelos testes que fizeram uso da pressão de topo unicamente (Teste 2), ou pela pressão de topo combinada com a vazão do gás *lift* e a abertura da válvula *choke* (Teste 3).

O modelo de rede neural estática que utilizou como referência a pressão de topo para a predição, apresentou um coeficiente de determinação ( $R^2$ ) igual a 0,98, já para o modelo de rede neural dinâmica que utilizou como referência a combinação de pressão de topo, vazão de gás *lift* e abertura da válvula *choke*, apresentou um coeficiente de determinação ( $R^2$ ) igual a 0,96, provando que é possível a utilização de um analisador virtual do tipo rede neural *feedforward* para a predição de pressão de fundo de poços de petróleo.

Sugere-se para trabalhos futuros a modelagem e teste de outros tipos de redes neurais, como a *echo state* utilizada por Antonelo (2009), outros tipos de polinômios e predição de outras variáveis do processo.

## Referências

AAMO, O.M. et al. Observer design for multiphase flow in vertical pipes with gas-lift-theory and experiments. *Journal of Process Control*, v.15, n.3, p. 247-257, 2005.

A. Coates H. Lee and A. Y. Ng "An analysis of single-layer networks in unsupervised feature learning " in AISTATS 14 2011.

Andres Cudas, Esmail Jahanshahi, Bjarne Foss. A two-layer structure for stabilization and optimization of an oil gathering network. Department of Engineering Cybernetics, Norwegian University of Technology, 7491 Trondheim, Norway. 2016.

Antonelo, E. A., Camponogara, E. and Foss, B. (2017). Echo State Networks for data-driven downhole pressure estimation in gas-lift oil wells. *Neural Networks* 85, 106-117.

Billings, S. A. (2013). *Nonlinear system identification: NARMAX methods in the time, frequency, and spatio-temporal domains*. Wiley.

D.Verstraeten, B.Schrauwen, M.D’Haene, D.Stroobandt - An experimental unification of reservoir computing methods. *Neural Networks*, Volume 20, Issue 3, April 2007, Pages 391 - 403

DI MEGLIO, F. et al. Stabilization of slugging in oil production facilities with or without upstream pressure sensors. *Journal of Process Control* 22. p 809-822. 2012 a

DI MEGLIO, F. et al. Model-based control of slugging: Advances and challenges. 2012 b, PART 1.p109-115.

Diehl, Fabio & K. Anzai, Thiago & S. Almeida, Cristina & F. Von Meien, Oscar & S. Neto, Saul & R. Rosa, Vinicius & C.M.M. Campos, Mario & Reolon, Filipe & Gerevini, Giovanni & Ranzan, Cassiano & Farenzena, Marcelo & Trierweiler, Jorge. (2017). Fast Offshore Wells Model (FOWM): A practical dynamic model for multiphase oil production systems in deepwater and ultra-deepwater scenarios. *Computers & Chemical Engineering*. 99. 10.1016/j.compchemeng.2017.01.036.

FACCHIN, S. Universidade federal do rio grande do sul técnicas de análise multivariável aplicadas ao desenvolvimento de analisadores virtuais técnicas de análise multivariável aplicadas ao desenvolvimento de analisadores virtuais. 2005.

FORTUNA, L.; GRAZIANI, S.; XIBILIA, M. G. Soft sensors for product quality monitoring in debutanizer distillation columns. *Control engineering practice*, 2005. v. 13, n. 4, p. 499–508.

KADLEC, P.; GABRYS, B.; STRANDT, S. Data-driven soft sensors in the process industry. 2009. v. 33, p. 795–814.

Teixeira, B. O., Castro, W. S., Teixeira, A. F., & Aguirre, L. A. (2014). Data-driven soft sensor of downhole pressure for a gas-lift oil well. *Control Engineering Practice*, 22, 34–43.

Tham, M. T., Montague, C. A., Morris, A. J., & Lant, P. A. (1991). Soft sensors for process estimation and inferential control. *J. Process Control.*, 1, 3.

WILLIS, M. J. et al. Artificial neural networks in process estimation and control \*. 1992. v. 28, n. 6, p. 1181–1187.