



Universidade Federal da Bahia  
Instituto de Computação / Escola Politécnica

Programa de Pós-Graduação em Mecatrônica

**OTIMIZAÇÃO DA PRODUÇÃO DIÁRIA  
ORIENTADA A DADOS DE POÇOS DE  
PETRÓLEO ASSISTIDOS POR GAS-LIFT**

Ezequias Santos de Matos

DISSERTAÇÃO DE MESTRADO

Salvador  
Junho de 2023



Ficha catalográfica elaborada pela Biblioteca Bernadete  
Sinay Neves, Escola Politécnica - UFBA.

---

M433 Matos, Ezequias Santos de.

Otimização da produção diária orientada a dados de poços de petróleo assistidos por gas-lift/ Ezequias Santos de Matos. – Salvador, 2023.

83f.: il. color.

Orientador: Prof. Dr. Márcio André Fernandes Martins.

Coorientador: Prof. Dr. Leonardo Silva de Souza.

Dissertação (mestrado) – Programa de Pós-Graduação em Mecatrônica, Escola Politécnica / Instituto de Computação, Universidade Federal da Bahia, 2023.

1. Gas-Lift. 2. Otimização em Tempo Real. 3. Inteligência Artificial. 4. Estimação não Linear. 5. Poços de petróleo. I. Martins, Márcio André Fernandes. II. Souza, Leonardo Silva de. III. Universidade Federal da Bahia. IV. Título.

---

CDD: 665.5


# TERMO DE APROVAÇÃO

**Ezequias Santos de Matos**

## **Otimização da produção diária orientada a dados de poços de petróleo assistidos por gas-lift**


Esta Dissertação de Mestrado foi julgada adequada à obtenção do título de Mestre em Mecatrônica e aprovada em sua forma final pelo Programa de Pós-Graduação em Mecatrônica da Universidade Federal da Bahia.

Salvador, 09 de novembro de 2023.

Documento assinado digitalmente  
 **MARCIO ANDRE FERNANDES MARTINS**  
Data: 14/11/2023 17:33:59-0300  
Verifique em <https://validar.iti.gov.br>


---

Prof. Dr. Márcio André Fernandes Martins (PPGM-UFBA)

Documento assinado digitalmente  
 **OSCAR ALBERTO ZANABRIA SOTOMAYOR**  
Data: 15/11/2023 14:55:04-0300  
Verifique em <https://validar.iti.gov.br>

---

Prof. Dr. Oscar Alberto Zanabria Sotomayor (UFS)

Documento assinado digitalmente  
 **GUILHERME AUGUSTO DE ALMEIDA GONCALVES**  
Data: 14/11/2023 10:38:51-0300  
Verifique em <https://validar.iti.gov.br>

---

Dr. Guilherme Augusto de Almeida Gonçalves (Petrobras)

## AGRADECIMENTOS

Primeiramente à **UFBA**, **PPGM**, **PRH-ANP** e a **CAPES** por esta oportunidade e pelo apoio financeiro durante à realização deste trabalho.

Ao meu orientador, **Prof. Dr. Márcio André Fernandes Martins** que acompanhou e contribuiu de forma primordial à confecção deste trabalho, enfim, por todo o conhecimento adquirido ao longo do desenvolvimento desta pesquisa, também agradeço ao meu co-orientador **Prof. Dr. Leonardo S. Souza**.

À minha mãe (**Maria José Matos**) pelo incentivo ao estudo e pelo apoio financeiro e pessoal. A minha namorada (**Karina Echeverria**), pela compreensão das horas nas quais tive de abdicar de vossa atenção e carinho, para a concretização deste árduo trabalho.

Também gostaria de agradecer ao Centro de Capacitação Tecnológica em Automação Industrial (**CTAI**), pela oportunidade de estudo e pela utilização de suas instalações e aos amigos, em especial **Orlando Vicente**, **Tiago Oliveira**, **Odilon Abreu**, **Lúcia Lago** e **Flávio Santos**.

À toda equipe do LEA que de maneira indireta ajudou nos momentos de diversão e brincadeiras.

A todo o corpo docente, discente e funcionários do PPGM, que de forma direta e indireta contribuíram para a realização da pesquisa.



## RESUMO

No presente estudo, aborda-se um problema de otimização dinâmica para produção diária de petróleo e gás por meio de uma abordagem orientada a dados. Para isso, propõe-se a utilização de uma arquitetura de rede neural artificial (RNA) como substituto do modelo fenomenológico que representa um sistema de poços produtores assistidos por injeção contínua de gás (Gas Lift). Para realizar o treinamento da RNA, é imprescindível possuir dados relevantes, principalmente no que se refere à otimização econômica. Portanto, é crucial incluir as informações sobre as vazões de óleo e gás de cada poço e também do topo do *riser*. No entanto, as medições das vazões não estão disponíveis em tempo real e o que se tem à disposição é apenas a vazão total do campo, medido nas instalações de topside (após a separador trifásico), o que não permite entender o comportamento de cada poço individualmente. Devido à indisponibilidade de medição individualizada da vazão de poços, a utilização de um estimador de horizonte móvel (MHE), suportado por um modelo fenomenológico, mostrou-se como uma solução apropriada para estimar essas variáveis, permitindo disponibilizar dados para treinamento e obter de um modelo substituto a ser utilizado na etapa de otimização dinâmica. Desta maneira, foi possível viabilizar o treinamento de uma RNA com arquitetura *Nonlinear Autoregressive with Exogenous Input* empregada neste trabalho. Esta escolha foi feita com base na constatação de que a rede foi capaz de fazer previsão de um passo à frente (um dia) de forma conveniente. Os resultados de aplicação em um poço e em campo composto por três poços e um *riser* apontaram um bom desempenho da rede neural artificial em termos de previsão temporal,

além de apresentar um tempo computacional mais eficiente na solução do problema de otimização, quando comparado ao modelo fenomenológico padrão. A solução proposta por esta abordagem abre possibilidades para implementação em problemas de grande escala, como por exemplo, na otimização da produção diária de um campo de petróleo composto por vários poços integrados por diferentes reservatórios e manifolds.

**Palavras-chave:** Otimização em Tempo Real, Gas Lift, Inteligência Artificial, Estimativa não Linear.



## ABSTRACT

The present study addresses a dynamic optimization problem formulation for daily oil and gas production through a data-driven approach. To this end, it is proposed to use an artificial neural network (ANN) architecture as a surrogate model for the phenomenological one, which represents a system of producing wells assisted by continuous gas injection (Gas Lift). To carry out ANN training, it is essential to have relevant data, especially concerning economic optimization. Therefore, including information about each well's oil and gas flow rates and the top of the *riser* is crucial. However, flow measurements are not available in real-time, and what is available is only the total flow rate of the field, measured in the topside installations (after the three-phase separator), which does not allow understanding the behavior of each well individually. Due to the unavailability of individual well's flow rate measurement, the use of a moving horizon estimator (MHE), supported by a phenomenological model, proved to be an appropriate solution to estimate these variables, allowing data to be made available for training and obtained from a substitute model to be used in the dynamic optimization stage. In this way, it was possible to train an ANN with the *Nonlinear Autoregressive with Exogenous Input* architecture used in this work. This choice was made based on the observation that the network could predict one ahead step (one day) conveniently. The application results in a well, and a field composed of three wells and a *riser* showed a good performance of the artificial neural network in terms of temporal prediction, in addition to presenting a more efficient computational time in solving the optimization problem when compared

to the standard phenomenological model. The solution proposed by this approach opens up possibilities for implementation in large-scale problems, such as optimizing the daily production of an oil field composed of several wells integrated by different reservoirs and manifolds.

**Keywords:** Real Time Optimization, Gas Lift, Artificial Intelligence; Nonlinear Estimation.

# SUMÁRIO

<b>Lista de Figuras</b>	xi
<b>Lista de Tabelas</b>	xv
<b>Capítulo 1—Introdução</b>	1
1.1 Técnica de elevação artificial <i>Gas Lift</i> (GL) . . . . .	7
1.2 Introdução à otimização em tempo real . . . . .	15
1.3 Revisão da Literatura . . . . .	20
1.4 Objetivos do trabalho . . . . .	24
1.5 Publicação . . . . .	24
1.6 Estrutura do trabalho . . . . .	25
<b>Capítulo 2—Metodologia</b>	27
2.1 Modelo fenomenológico de uma rede de poços com <i>Gas Lift</i> . . . . .	27
2.2 Métodos Numéricos Aplicados . . . . .	33
2.3 Estimador de horizonte móvel (MHE) . . . . .	39
2.4 Sistema Baseado em Dados . . . . .	41
2.5 Problema de otimização econômica . . . . .	47
2.6 materiais utilizados . . . . .	49

2.7	Comentários . . . . .	50
<b>Capítulo 3—Resultados</b>		<b>51</b>
3.1	Caso I: RTO de poço com GL usando metodologia padrão . . . . .	51
3.1.1	Otimização de um poço equipado com GL . . . . .	53
3.2	Caso II: RTO de Poço com GL usando metodologia híbrida . . . . .	54
3.2.1	Simulação em malha aberta para um poço . . . . .	54
3.2.2	Otimização de um poço equipado com GL . . . . .	59
3.3	Caso III: RTO de uma rede de poços com GL metodologia híbrida . . . . .	63
3.3.1	Simulação em malha aberta . . . . .	63
3.3.2	Otimização de uma rede de poços equipado com GL . . . . .	66
3.4	Comentários . . . . .	74
<b>Capítulo 4—Conclusões</b>		<b>75</b>
4.1	Contribuições . . . . .	75
4.2	Comentários finais . . . . .	76
4.3	Trabalhos futuros . . . . .	76
<b>Referências Bibliográficas</b>		<b>79</b>

## LISTA DE FIGURAS

1.1	Esquema simplificado de um poço equipado com GL. . . . .	2
1.2	Performance do GL. . . . .	4
1.3	Simplificação de um sistema de GL. . . . .	9
1.4	Passagem de gás através da válvula operadora. . . . .	11
1.5	Efeito da Injeção de gás no gradiente total de pressão. . . . .	12
1.6	A operação básica de um poço com <i>Gas Lift</i> intermitente. . . . .	14
1.7	Discretização <i>single shooting</i> aplicada ao problema de otimização em tempo real. . . . .	17
1.8	Discretização <i>multiple shooting</i> aplicada ao problema de otimização em tempo real. . . . .	18
1.9	Discretização total aplicada ao problema de otimização em tempo real. . . . .	19
2.1	Representação esquemática simplificado para uma rede de poço de GL. . . . .	28
2.2	Representação gráfica de uma derivada. . . . .	34
2.3	Aproximação da derivada por diferenças finitas. . . . .	36
2.4	Representação de um neurônio não linear. . . . .	42
2.5	Arquitetura simplificada de uma rede <i>feedforward</i> . . . . .	42
2.6	Visão geral da proposta aplicada ao processo de treinamento do modelo orientado a dados. . . . .	45

3.1	Caso I - Resposta do processo a partir da aplicação das soluções ótimas gerado pelo problema de otimização utilizando o modelo fenomenológico integrado pela diferenciação automática (MF) e o fenomenológico integrado pela diferenciação finita (ODE) . . . . .	54
3.2	caso I - Comparação entre os tempos computacionais . . . . .	55
3.3	Entradas para a identificação do sistema. . . . .	56
3.4	caso II -Predições das pressões de poço de um passo à frente - comparação entre os valores medido GL, sensor virtual MHE e o modelo orientado a dados RNA. . . . .	58
3.5	caso II -Predições das vazões de produção poço de um passo à frente - comparação entre os valores medido GL, sensor virtual MHE e o modelo orientado a dados RNA. . . . .	59
3.6	Caso II - Resposta do processo a partir da aplicação das soluções ótimas gerado pelo problema de otimização utilizando o modelo orientado a dados e fenomenológico. . . . .	61
3.7	caso II - Comparação entre os tempos computacionais . . . . .	62
3.8	Entradas para a identificação do sistema. . . . .	63
3.9	Entradas para a identificação do sistema. . . . .	64
3.10	Caso III - Predições das pressões de cabeça de poço de um passo à frente - comparação entre a referência GL, valores medido, sensor virtual e o modelo orientado a dados. . . . .	65
3.11	Caso III - Predições das vazões de cabeça de poço de um passo à frente - comparação entre a referência GL, sensor virtual e o modelo orientado a dados. . . . .	66
3.12	Caso III -Predições de vazões e pressão de topo do <i>riser</i> de um passo à frente - comparação entre a referência GL, valores medido, sensor virtual e o modelo orientado a dados. . . . .	67

3.13	Caso III - Resposta do processo a partir da aplicação das soluções ótimas gerado pelo problema de otimização utilizando o modelo orientado a dados e fenomenológico. . . . .	69
3.14	Caso III - Resposta do processo em relação a restrições do problema de otimização problema de otimização utilizando o modelo orientado a dados e fenomenológico. . . . .	70
3.15	Caso III - Comparação entre os tempos computacionais . . . . .	71
3.16	Caso III - Resposta do processo em relação a restrições do problema RTO utilizando o modelo orientado a dados e fenomenológico: com maior peso para o óleo . . . . .	73





## LISTA DE TABELAS

2.1	Parâmetros do modelo utilizado na simulação. . . . .	33
3.1	Caso I - Perturbações nos parâmetros econômicos e operacionais . . . . .	53
3.2	Caso II - Perturbações nos parâmetros econômicos e operacionais . . . . .	60
3.3	caso II - Soluções ótimas encontradas com o problema de otimização utilizando o modelo orientado a dados e o fenomenológico. . . . .	60
3.4	Caso III - Perturbações nos parâmetros econômicos e operacionais . . . . .	68
3.5	Caso III - Soluções ótimas encontradas com o problema de otimização utilizando o modelo orientado a dados e o fenomenológico. . . . .	68
3.6	Caso III - Perturbações nos parâmetros econômicos e operacionais (maior peso pra o óleo) . . . . .	72



## NOMENCLATURAS MATEMÁTICA

- $\mathbf{e}$  - Vetor das entradas da rede neural artificial
- $f$  - Função não linear que descreve o comportamento dinâmico do sistema
- $h$  - Função de mapeamento de  $\mathbf{x}$
- $\mathbf{h}_n$  - Vetor oculto da rede neural artificial
- $J$  - Função objetivo
- $k$  - Tempo
- $\mathbf{u}$  - Vetor das entradas do modelo fenomenológico
- $\mathbf{u}_k^{inf}$  - Vetor de limite inferior das entradas do modelo fenomenológico
- $\mathbf{u}_k^{sup}$  - Vetor de limite superior das entradas do modelo fenomenológico
- $\mathbf{x}$  - Vetor dos estados diferenciais do modelo fenomenológico
- $\mathbf{x}_k^{inf}$  - Vetor de Limite inferior dos Estados diferenciais do modelo fenomenológico
- $\mathbf{x}_k^{sup}$  - Vetor de Limite superior dos estados diferenciais
- $\mathbf{y}$  - Vetor de saída do modelo fenomenológico
- $\mathbf{y}_n$  - Vetor de saída da rede neural artificial
- $\mathbf{z}$  - Vetor das variáveis algébricas do modelo do sistema fenomenológico
- $\mathbf{z}_k^{inf}$  - Vetor de limite inferior das variáveis algébricas do modelo do sistema fenomenológico

$\mathbf{z}_k^{sup}$  - *Vetor de limite superior das variáveis algébricas do modelo do sistema fenomenológico*

### Símbolos Gregos

$\beta$  - *Preço do óleo*

$\alpha$  - *Custo por metro cúbico de gás injetado*

$\phi$  - *Função de mapeamento*

$\Phi$  - *Parâmetros de treinamento*

$\Theta$  - *Parcelas relativas aos erros de modelagem*

$\nu$  - *Vetor de ponderação diagonal das variáveis estimadas*

$\omega$  - *Matriz de ponderação diagonal das variáveis de entradas*

$\rho$  - *Massa específica do fluido*

$\varepsilon$  - *Rugosidade da tubulação*

### Siglas

BCS - *Bombeio Centrífugo Submerso*

BCP - *Bombeio por Cavidades Progressivas*

BM - *Bombeio Mecânico*

DAEs - *differential-algebraic equations*

DRTO - *dynamic real time optimization*

ERNN - *Elman Recurrent Neural-Network*

ESN - *Echo State Network*

GL - *Gas Lift*

GRU - *Gated Recurrent Unit*

LSTM - *Long Short Term Memory*

MHE - *Moving horizon estimation*

MF - *Modelo fenomenológico integrado por diferenciação automática*

NARX - *Auto-Regressive with EXogenous Inputs*

ODE - *Modelo fenomenológico integrado por diferenciação numérica*

NLP - *nonlinear programming*

PINN - *Physics-Informed Neural Networks*

RNA - *Rede Neural Artificial*

RTO - *Real-Time Optimization*



## Capítulo

# 1

*Neste capítulo, é apresentada a contextualização do problema, na qual são introduzidas as limitações de desenvolvimento de um problema de otimização em tempo real com um modelo fenomenológico, bem como a limitação do uso de modelos orientados a dados para otimização de petróleo. Em seguida, é abordado sobre a técnica de elevação artificial assistido por injeção de gás, melhor dizendo, os principais conceitos e funcionamento do GL, bem como a necessidade de aplicar otimização. Além disso, é introduzida uma breve compreensão sobre a formulação de um problema de otimização em tempo real e quais métodos podem ser aplicados para sua solução, e são introduzidos os conceitos básicos sobre as redes neurais artificiais. Posteriormente, é feito um levantamento sobre as pesquisas e discussões sobre o tema e, por fim, são apresentados os objetivos e a estrutura da dissertação.*


## INTRODUÇÃO

A operação de um processo industrial pode ser decomposta em várias camadas de decisão. Essa estrutura é implementada em níveis hierárquicos e amplamente adotada pela indústria. No primeiro nível, ou seja, na base da pirâmide, encontram-se os atuadores, sensores e o controle regulatório. Esse nível é responsável pela estabilização das variáveis de processo e pela segurança em um horizonte de tempo de segundos. No segundo nível, encontram-se as ações de correção em minutos ou horas, ou seja, a camada de controle avançado. Em seguida, na terceira camada, encontra-se a otimização em tempo real com uma escala de tempo de horas ou dias. Nessa camada, os objetivos são a maximização do lucro e a redução dos custos operacionais, que são o foco deste trabalho. Por último, no topo da pirâmide, encontra-se o sistema de planejamento e investimento, com um horizonte de tempo de meses ou anos. (CAMPOS; GOMES; PEREZ, 2013).

Neste contexto, o sistema de elevação artificial operado por injeção de gás contínua (GL - *Gas Lift*) pode ser considerado um processo industrial complexo que requer decisões

em diferentes níveis hierárquicos. O GL consiste em injetar gás pressurizado continuamente através de uma válvula, chamada válvula operadora, instalada no fundo do poço. Essa válvula conecta o espaço anular e a coluna de produção. O gás é pressurizado no espaço anular até superar a diferença de pressão no ponto de injeção e entrar na coluna de produção. Ele se mistura ao óleo produzido, reduzindo assim sua densidade e consequentemente a pressão no fundo do poço, como ilustrado na Figura 1.1. Em virtude da injeção de gás, o reservatório amplia sua capacidade de escoamento.

Esta dissertação tem como foco a técnica de injeção de gás contínua (GL), também conhecida como *continuous gas lift* em inglês.



**Figura 1.1** Esquema simplificado de um poço equipado com GL.

O GL é amplamente utilizado e considerado competitivo em relação a outros métodos



de elevação artificial, devido à sua versatilidade em terrenos (*offshore* e *onshore*), flexibilidade em diferentes trajetórias de poços (incluindo poços inclinados, horizontais e verticais), sua aplicabilidade em poços profundos, poços produtores de areia e em poços com alta relação gás-óleo. Essas características foram destacadas pelos autores Hernández (2016) e Yadua et al. (2021).

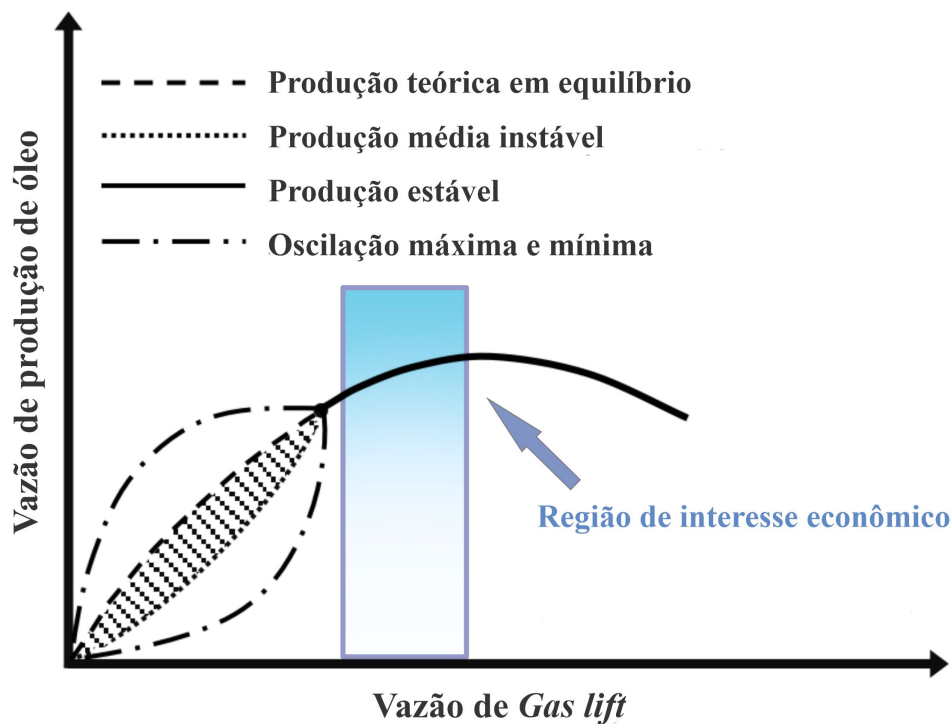
Na produção de petróleo assistida por GL, a quantidade de gás a alta pressão alocada em cada poço é relevante, visto que é necessário fornecer uma quantidade adequada de gás a alta pressão para obter a energia suficiente para elevar o petróleo. No entanto, se a quantidade de gás injetado for insuficiente, a eficiência do processo pode ser comprometida, resultando em menor produção de petróleo. Por outro lado, se a quantidade de gás for excessiva, pode ocorrer o que é conhecido como "escorregamento", onde o gás é produzido em excesso em relação ao petróleo, reduzindo a eficiência global do processo. Levando em consideração esse aspecto, é fundamental utilizar o recurso de injeção de forma mais eficiente possível.

Com base em informações disponíveis em algumas trabalhos, como por exemplo, Aamo et al. (2005), Diehl et al. (2018), Hülse e Camponogara (2014) e Krishnamoorthy, Fjalestad e Skogestad (2019) é possível alcançar uma região ótima de injeção de gás que corresponde à maximização do interesse econômico, como ilustrado na Figura 1.2. Essa região pode ser encontrada por meio de experimentos realizados com diferentes taxas de injeção de gás. No entanto, essa prática não é viável do ponto de vista econômico e operacional. Portanto, a solução para esse problema pode ser encontrada por meio de pacotes de otimização comercial, que geralmente são baseados em regime permanente, conforme indicado pelos autores. No entanto, esses pacotes podem fornecer resultados subótimos, uma vez que não levam em consideração a dinâmica do processo.

Outro aspecto a ser abordado na aplicabilidade do GL e que deve ser considerado é a ocorrência de instabilidade, conhecida como *casing heading*. Como mencionado anteriormente, o gás utilizado nessa estratégia é fornecido pela estação de compressão localizada na plataforma, no caso de instalações *offshore*. Esse gás entra no espaço anular e mantém-se com uma pressão capaz de se introduzir na coluna de produção, conforme mostrado na Figura 1.1. No entanto, quando o suprimento de gás é insuficiente ou quando a pressão na coluna de produção é alta, a pressão no espaço anular pode ser menor do que a pressão na coluna de produção, impedindo a passagem de gás. Dessa forma, o gás se acumula até que a pressão seja suficiente para permitir a injeção de gás. Em seguida, o gás injetado na coluna de produção se expande, reduzindo a pressão na coluna de produção e aumentando a vazão do reservatório. Com isso, ocorre também uma descompressão do espaço

anular e a pressão diminui, reiniciando o ciclo de bloqueio. Informações detalhadas sobre esse fenômeno de instabilidade podem ser encontradas em Diehl et al. (2018), Eikrem, Imstrand e Foss (2004) e Eikrem et al. (2002).

Em virtude dos fatos mencionados, existem impactos em operar dentro da região do instabilidade, como aponta Diehl (2022). Os principais impactos incluem riscos associados à integridade dos equipamentos de superfície, que podem levar ao desligamento e à perda de produção resultante da instabilidade. O comportamento de produção do GL segue o padrão ilustrado na Figura 1.2.



**Figura 1.2** Performance do GL.

Fonte: Adaptada de Diehl (2022).

A Figura 1.2 demonstra o desempenho de produção do GL em função da quantidade de gás injetado, além da necessidade de uma vazão mínima de gás para que o sistema alcance a estabilidade de produção. A região de interesse econômico está localizada na produção estável. No entanto, aumentar a injeção de gás sem uma estratégia adequada pode resultar em prejuízo na produção. Em outras palavras, a partir de uma certa vazão de injeção de gás, a produção de óleo tende a diminuir devido ao aumento do atrito gerado pelo escoamento do fluido.

Em última análise, são as diversas variáveis que precisam ser monitoradas e avaliadas para auxiliar na tomada de decisão. Isso é especialmente importante quando se trata de produção *offshore* envolvendo vários poços conectados a um riser. Devido a esses fatores e às informações mencionadas anteriormente, a tomada de decisão em médio prazo (dias) é complexa. A otimização dinâmica em tempo real (DRTO - *Dynamic Real Time Optimization*) é uma ferramenta essencial para garantir a maior rentabilidade na produção.

De acordo com Krishnamoorthy, Fjalestad e Skogestad (2019), além da vazão de gás injetada no anular e da instabilidade de produção, a maximização da quantidade de óleo produzida depende da correlação entre a pressão na coluna de produção, no anular e no *riser*, bem como da densidade do conjunto óleo e gás ao longo da tubulação, das propriedades do reservatório, da pressão de fundo dos poços, da relação gás-óleo e da profundidade dos poços. Por essas razões, tomar a decisão sobre o melhor ponto de operação em um determinado momento é um desafio para o operador do processo. Conforme apontado pelos autores, a otimização diária da produção de petróleo desempenha um papel essencial na maximização do lucro operacional e na redução do consumo de energia.

No entanto, a aplicação da otimização dinâmica em tempo real na prática da produção de petróleo ainda enfrenta lacunas que limitam sua utilização de forma sistemática e abrangente, devido a restrições tecnológicas e corporativas. Krishnamoorthy, Fjalestad e Skogestad (2019) relatam que, para realizar a otimização dinâmica em tempo real, é necessário ter um modelo dinâmico do processo que seja usado para resolver o problema de otimização numérica. Os modelos fenomenológicos têm sido explorados nesse sentido. No entanto, até o presente momento, a literatura identificou os principais desafios tecnológicos: i) falta de modelos fenomenológicos representativos que sejam capazes de representar o sistema dentro de um problema de otimização em tempo real (desenvolvimento de modelos offline); ii) incertezas dos parâmetros e distúrbios no modelo (atualização do modelo online); iii) robustez numérica, incluindo os problemas computacionais; iv) problema de inconsistência entre a camada de otimização e controle.

Campos et al. (2009) já afirmavam que a otimização dinâmica em tempo real exige alta velocidade computacional, o que é um problema para os modelos fenomenológicos de larga escala, principalmente quando usam diferenciação numérica para calcular as derivadas e neste contexto, ainda tem o problema de convergência numérica. Como por exemplo, ao integrar várias unidades de processo com o objetivo de expandir o escopo do problema de otimização, ou seja, envolver mais de uma unidade de processo.

Esses desafios têm sido objeto de estudo e pesquisa, visando superar as limitações e possibilitar uma aplicação mais ampla da otimização dinâmica em tempo real na produção de petróleo.

A fim de contornar os problemas enfrentados com os modelos fenomenológicos, Bikmukhametov e Jäschke (2020), Dias et al. (2019), Franklin et al. (2022) e Soares, Secchi e Souza (2022) apontam os modelos orientados a dados como uma possível alternativa nos últimos anos. Segundo os autores, a modelagem orientada a dados é uma técnica com estrutura e características que permitem associar e registrar informações de um determinado padrão, ou seja, analisar dados de um sistema e encontrar as relações entre os dados de entrada e saída.

Em uma determinada situação, a vantagem da abordagem orientada a dados é a capacidade de evitar a necessidade de uma modelagem fenomenológica detalhada de um sistema, especialmente quando a solução numérica é difícil de encontrar. Esse método depende da coleta adequada de dados e do ajuste entre os dados coletados e estimados, não exigindo a descrição exata dos parâmetros físicos do sistema. Portanto, se o modelo orientado a dados for treinado corretamente e as condições de operação estiverem dentro do intervalo de treinamento, ele poderá fazer previsões rapidamente e com um baixo custo computacional em comparação com os modelos fenomenológicos. Além disso, não apresenta problemas de instabilidade numérica, uma vez que os modelos orientados a dados não requerem um integrador numérico.

Por outro lado, o aprendizado de um modelo orientado a dados requer dados que representem o sistema. No caso das operações econômicas dos poços de petróleo, é crucial ter conhecimento das vazões de óleo e gás. No entanto, ocasionalmente, essas informações de vazão não estão disponíveis de forma individual e em tempo real, especialmente quando as operações são *offshore*.

Conforme relatam Bikmukhametov e Jäschke (2020), Góes et al. (2021) e Franklin et al. (2022), as vazões podem ser mensuradas por meio de medidores físicos instalados na cabeça dos poços. No entanto, esses medidores são caros, propensos a falhas, erosão e bloqueios, uma vez que o fluido produzido é composto por água, óleo, gás e sedimentos. Além disso, eles exigem intervenção a cada falha. Outra maneira de obter as vazões é através de testes de medição de poços. Nesse caso, a linha de produção de um poço é direcionada para um separador trifásico de teste, onde os componentes (óleo, gás e água) são separados em linhas individuais e, em seguida, medidos com medidores monofásicos. No entanto, para realizar essa medição sem interromper o campo, seria necessário ter uma linha de produção separada para cada poço. Segundo os autores, uma alternativa ao

uso do separador de teste é realizar o teste no separador de entrada. Isso significa fechar o poço de interesse e medir as vazões após o separador. Após obter as vazões, é possível fazer a dedução necessária.

Em ambos os métodos de medição citados, resultam em altos custos. Mesmo com o uso de medidores físicos instalados, são necessários testes de vazão que são utilizados como referência de calibração para os sensores físicos (BIKMUKHAMETOV; JÄSCHKE, 2020). Nesse contexto, os sensores virtuais surgem como uma alternativa para o monitoramento de áreas críticas, a fim de substituir os instrumentos que requerem alto investimento e, conseqüentemente, diminuir os custos de manutenção e calibração. Embora isso implique em um aumento da complexidade matemática e de um certo poder computacional, o uso desses sensores vem se tornando cada vez mais importante para o monitoramento de processos, devido à sua robustez em estimar sinais não medidos. Considerando os desafios mencionados para obter as vazões e ponderando que as medições de pressões e temperaturas estão disponíveis em tempo real, uma alternativa para esse problema pode ser a utilização de um sensor virtual, como um estimador de estado não linear, a partir de outras variáveis medidas.

Em resumo, apesar das lacunas e limitações enfrentadas na aplicação da otimização dinâmica em tempo real na produção de petróleo, a busca por soluções tem sido incansável. A combinação da modelagem orientada a dados com a modelagem fenomenológica emerge como uma alternativa promissora, capaz de oferecer previsões rápidas e de baixo custo computacional. No entanto, a obtenção de dados representativos do sistema continua sendo um desafio, especialmente quando se trata das operações econômicas em poços de petróleo, onde informações individuais e em tempo real sobre as vazões podem ser escassas, principalmente em operações *offshore*. Nesse contexto, os sensores virtuais surgem como uma alternativa viável, permitindo o monitoramento de áreas críticas e a estimativa de sinais não medidos. O uso de sensores virtuais, como estimadores de estado não linear, tem o potencial de superar esses obstáculos e fornecer informações valiosas para a otimização dinâmica em tempo real na produção de petróleo.

## 1.1 TÉCNICA DE ELEVAÇÃO ARTIFICIAL *GAS LIFT* (GL)

A elevação de petróleo conceitua-se no transporte dos fluidos do fundo do poço para a superfície de produção, logo quando o reservatório é capaz de fornecer energia em forma de pressão o suficiente para elevar estes fluidos, denomina-se de elevação natural, ou seja, poços surgentes no jorgão da indústria de petróleo. Contudo, muitas vezes os poços não tem essa capacidade e quando a possui, tende ao declínio ao longo de sua vida produtiva ou

talvez, não seja uma urgência economicamente viável. Então, para manter uma produção em um nível economicamente viável em algum momento esses poços necessitaram de um método de elevação artificial para suplementar essa energia e a partir deste momento intitula-se elevação artificial de produção de petróleo (HERNÁNDEZ, 2016; TAKACS, 2005).

Quando o assunto é produção de petróleo, existem várias técnicas que, assim como qualquer estratégia na engenharia, apresentam vantagens e desvantagens em sua aplicação. Entre essas técnicas, algumas se destacam, como o *Gas Lift*(GL), Bombeio por Cavidades Progressivas (BCP), o Bombeio Centrífugo Submerso (BCS), o Bombeio Mecânico (BM), entre outras. Contudo, este trabalho está focado no *Gas Lift*(GL).

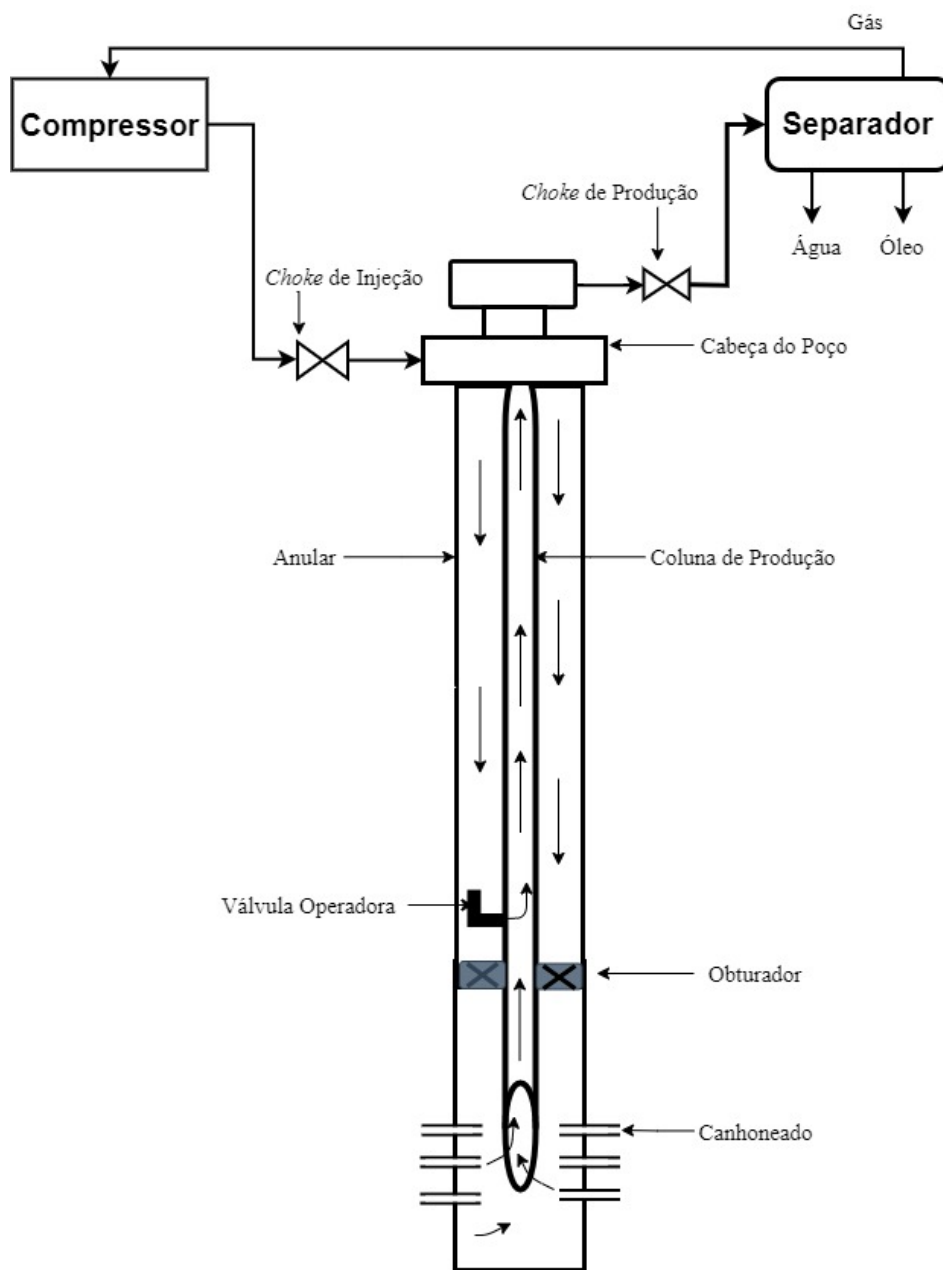
O GL pode ser compreendido como uma técnica que visa manter o fluxo contínuo de um poço, utilizando a injeção de gás a alta pressão na coluna de produção. Esse gás se mistura com o petróleo, reduzindo sua densidade como consequência. Em uma segunda análise, observa-se que a pressão hidrostática da tubulação vertical do poço está diretamente relacionada à densidade do fluido escoado. Segundo Hernández (2016), essa pressão hidrostática é responsável pela maior parte do diferencial de pressão gerado entre o poço e os canhoneados (furos no fundo do poço que se conectam ao reservatório). Portanto, é compreensível que a redução da densidade do óleo também resulte em um declínio na pressão hidrostática ao longo do poço, aumentando a capacidade de produção do reservatório. A Figura 1.3 ilustra um esquema de um sistema GL completo.

Um poço de petróleo é composto basicamente de:

i) Reservatório é composto por rochas porosas e permeáveis, conhecidas como rochas reservatórias. Essas rochas são geralmente arenosas ou calcárias, que possuem espaços vazios (poros) capazes de armazenar e transmitir fluidos, como petróleo, gás e água. A sua caracterização envolve estudos geológicos, geofísicos e engenharia de reservatórios para determinar sua capacidade de produção, estimar o volume de petróleo recuperável e identificar as melhores estratégias de extração.

ii) O revestimento é formado por tubos conectados e protege a estrutura do poço contra desmoronamento, evitando a contaminação da água potável dos lençóis freáticos, protegendo as formações de fluidos e pressões incompatíveis, e sustentando os equipamentos de segurança da cabeça do poço. Logo, o espaço entre o revestimento e a coluna de produção é denominado anular.

iii) A coluna de produção também é um conjunto de tubos conectados através dos quais o fluido flui do fundo do poço até a superfície. Ao longo da coluna de produção, são instaladas válvulas, sensores e conexões para controlar o fluxo dos fluidos e permitir



**Figura 1.3** Simplificação de um sistema de GL.

a realização de operações de monitoramento e controle.

iv) Canhoneados referem-se aos furos ou perfurações feitas na parede do poço, geralmente no trecho próximo à zona de produção ou de interesse. Esses canhoneados são realizados com o objetivo de criar conexões entre o poço e o reservatório de petróleo, permitindo que o fluido seja extraído da rocha porosa e chegue à coluna de produção.

v) obturador (*packer*) é projetado para selar o anular do poço de forma hermética,

impedindo o vazamento de fluidos, gases ou produtos químicos para o ambiente circundante. Ele desempenha um papel importante na segurança e controle de poços de petróleo durante operações de perfuração, completação, intervenção ou abandono.

vi) Cabeça de poço é uma estrutura instalada no topo de um poço de petróleo ou gás natural. Ela tem a função de conectar a coluna de produção ao equipamento de superfície, fornecer o ponto de suspensão e vedação de pressão para a coluna de revestimento. Além disso, a cabeça de poço permite o acesso para operações de intervenção e abriga os equipamentos de segurança, como válvulas e dispositivos de controle de fluxo.

vii) Separador trifásico recebe o fluido produzido pelo poço e realiza a separação das três fases presentes no fluido (água, óleo e gás). Esse equipamento é composto por câmaras ou tanques de separação, onde ocorre a sedimentação e a separação dos fluidos. O óleo é coletado na parte superior do separador, o gás é liberado na parte superior ou pode ser comprimido para uso posterior, e a água é retirada da parte inferior do equipamento

viii) *choke* de produção é uma válvula utilizada em poços de petróleo para controlar o fluxo de fluidos durante a produção. Ela é instalada na linha de produção, geralmente próxima à cabeça do poço, e permite regular a vazão dos fluidos (óleo, gás e água) que são extraídos do reservatório. A válvula *choke* pode ser operada manualmente ou pode ser controlada remotamente por meio de sistemas automatizados.

O GL é um conjunto complementar ao poço e consiste basicamente de:

i) Válvula operadora é um componente essencial para o GL. Ela é responsável por conectar o anular e a coluna de produção, permitindo o controle do fluxo de gás injetado no poço. Essa válvula é instalada no mandril, um tubo com uma cavidade lateral que permite a recuperação e manutenção da válvula operadora por meio de operações com um cabo de aço flexível, chamado *slickline*, que é introduzido no poço por meio de uma unidade de controle de superfície. Esse cabo é utilizado para operações de descida e subida, permitindo a abertura, fechamento ou substituição das válvulas operadoras localizadas no mandril do poço.


ii) Válvula *choke* de injeção é responsável por controlar o fluxo de gás injetado no anular durante o processo de elevação do fluido. Ela está localizada na linha de injeção de gás e é projetada para regular a pressão e vazão do gás. Através do ajuste da válvula *choke* de injeção, é possível otimizar a eficiência do sistema de GL, maximizando a produção de petróleo do poço.

iii) Estação de compressão é composta por equipamentos de compressão, ou seja, compressores de gás, que são responsáveis por aumentar a pressão do gás antes de ser injetado no poço. Além dos compressores, a estação de compressão também pode in-



cluír outros componentes, como filtros para remover impurezas do gás, separadores de líquidos para remover qualquer líquido presente no gás comprimido e sistemas de controle e monitoramento para garantir o funcionamento adequado do sistema.

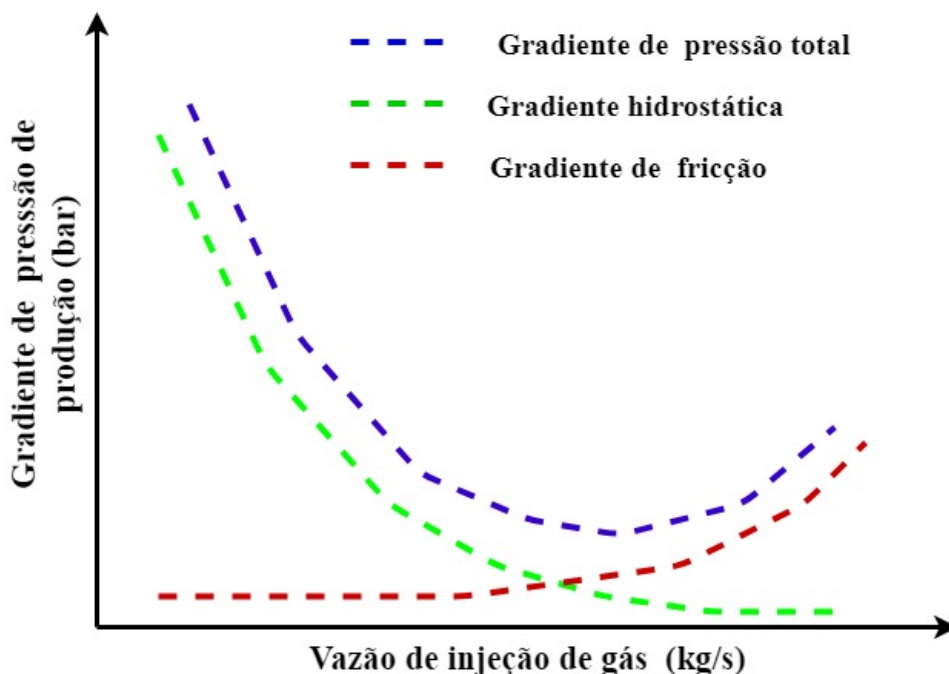
Conforme visualizado na Figura 1.3, O funcionamento do GL ocorre da seguinte maneira: o funcionamento do GL ocorre da seguinte maneira: o gás proveniente da estação de compressão é injetado no anular através de uma válvula denominada *choke* de injeção. Uma vez no anular, ele é comprimido até superar a pressão do ponto de injeção, que conecta o anular à coluna de produção por meio de uma válvula operadora de sentido único, permitindo que o gás flua. A abertura da válvula está condicionada ao diferencial de pressão entre o anular e a coluna de produção. Supondo que haja abertura, o gás se mistura com o óleo até a superfície de produção, diminuindo o gradiente de pressão (HERNÁNDEZ, 2016; TAKACS, 2005). O comportamento do gradiente de pressão em função da injeção de gás está representado na Figura 1.5.



**Figura 1.4** Passagem de gás através da válvula operadora.

Fonte: (HERNÁNDEZ, 2016)

A válvula operadora é um equipamento chave para o funcionamento do GL e influencia diretamente no desempenho do sistema. Em outras palavras, a pressão a montante da válvula operadora controla a vazão de gás que entra na coluna de produção, e a relação entre a vazão de gás injetada e a vazão de óleo produzida é um dos principais fatores que determinam o desempenho do sistema, juntamente com as propriedades do fluido, a pressão do reservatório, o comprimento do poço, entre outros (HERNÁNDEZ, 2016). Dessa forma, ao observar o sistema, nota-se que é possível controlar a vazão na válvula operadora por meio do *choke* de injeção instalado no topo do anular, uma vez que essa será responsável por controlar a pressão no anular. A Figura 1.4 enfatiza a passagem de gás na válvula operadora.



**Figura 1.5** Efeito da Injeção de gás no gradiente total de pressão.

A Figura 1.5 demonstra o efeito da injeção de gás nos gradientes de pressões do sistema. O gradiente total é representado pela linha tracejada em azul, o gradiente da hidrostática é representado pela linha tracejada em verde, e o gradiente de fricção é representado pela linha tracejada em vermelho.

O comportamento do gradiente total de pressão repercute diretamente na curva de desempenho do poço (*Well Performance Curve*), que enfatiza o comportamento da vazão de saída do poço em função da injeção de gás na coluna de produção. No entanto, sabe-se que com o aumento da injeção de gás, a velocidade do fluido (gás e óleo) dentro do tubo


de produção tende a aumentar. Em outras palavras, quanto mais gás, maior é a velocidade de escoamento. A partir de uma determinada injeção de gás, o gradiente de fricção no tubo de produção, que depende do quadrado da velocidade, aumenta rapidamente, conforme ilustrado na 1.5. Nesse ponto, qualquer acréscimo na injeção de gás é compensado pelo aumento da pressão devido ao atrito. Em vez de reduzir a pressão do sistema, ocorre um ganho, o que contribui para o declínio da vazão de saída. (CAMPONOGARA; PLUCENIO, 2007; HERNÁNDEZ, 2016).

Até o presente momento, abordamos o *Gas Lift* de injeção contínua (GLC ou GL como representada neste trabalho). No entanto, o *Gas Lift* pode ser classificado como contínuo e intermitente, sendo este último um método de elevação artificial aplicado em campos onde as pressões de formação caíram para níveis em que o fluxo contínuo não é mais sustentável. Além disso, é uma opção viável para poços com pressões de formação relativamente altas, mas baixas produtividades. O *Gas Lift* intermitente é especialmente empregado em campos maduros, oferecendo uma alternativa eficaz para manter a produção nessas condições. (TAKACS, 2005; TASMI et al., 2017).

*Gas Lift* intermitente (GLI) também utiliza gás comprimido da superfície, mas funciona de forma completamente diferente do *Gas Lift* contínuo. Nesse método, o gás é injetado periodicamente na coluna de produção, perto dos canhoneados, para deslocar uma coluna de líquido acumulada acima da válvula operadora. Esse processo pode ser dividido em dois períodos: um período de produção e um período de fechamento. No período de fechamento, a válvula operadora está fechada durante um intervalo de tempo necessário para ocorrer o acúmulo de óleo na coluna de produção; no período de produção, a válvula operadora permite a passagem de gás, elevando a coluna de óleo acumulada para a superfície (produção por golfadas). Assim, a produção do poço ocorre em ciclos repetidos ao longo do tempo, sendo o princípio principal o deslocamento físico dos volumes de líquido por meio do gás de elevação de alta pressão (TAKACS, 2005). A Figura 1.6 representa a operação básica do GLI.

Conforme a operação básica de um poço com *gas lift* intermitente ilustrada na Figura 1.6, a injeção de gás no anular ocorre por um certo período de tempo e, em seguida, é interrompida através da válvula *choke* de injeção motorizada. Durante o intervalo de tempo em que a *choke* estiver aberta, a pressão do anular aumenta continuamente até que a válvula operadora se abre e injeta gás abaixo da coluna de óleo acumulada.

O gás de alta pressão entra na tubulação em grande quantidade instantânea, criando uma grande bolha de gás abaixo da coluna de óleo (*liquid slug*) que impulsiona-o para cima ao longo da coluna de produção. Neste período de produção, a válvula de pé abaixo



**Figura 1.6** A operação básica de um poço com *Gas Lift* intermitente.

Fonte: (TAKACS, 2005).

da válvula operadora impede que o gás de alta pressão cause danos ao reservatório. Após o período de tempo determinado, a injeção de gás é interrompida, possibilitando o acúmulo de uma nova coluna de óleo impulsionada pelo reservatório e o ciclo se repete.

Além de servirem para descarga, as válvulas superiores localizadas ao longo do poço também podem injetar gás abaixo da coluna de líquido à medida que ela passa. Esse procedimento é especialmente utilizado em poços profundos e/ou em casos nos quais a pressão de injeção de gás é baixa (TAKACS, 2005).

A eficiência de produção de um poço operado por GLI depende em grande medida da forma como a injeção de gás é controlada. Quando a temporização de abertura da válvula de injeção e a pressão são adequadas, a produção de óleo pode ser maximizada. Por outro lado, a temporização e pressão impróprias podem levar a uma baixa produção ou a um excesso de produção de gás. A seleção apropriada do controle de injeção de gás

de superfície, portanto, é um requisito crucial para alcançar uma produção lucrativa, conforme apontam Takacs (2005), Hernández (2016) e Tasmi et al. (2017).

Neste trabalho, nosso foco será o *Gas Lift* Contínuo. Entretanto, é importante reconhecer que tanto o *Gas Lift* Contínuo quanto o *Gas Lift* Intermitente apresentam desafios de otimização na produção de poços. Diante disso, a necessidade de otimizar o *Gas Lift* Contínuo pode ser justificada ao considerar a relação entre a vazão de produção e a vazão de injeção de gás. Assim, torna-se fundamental encontrar o equilíbrio adequado para garantir uma produção eficiente de óleo, minimizando perdas e assegurando o aumento da vazão do poço. Além disso, a produção ótima de óleo pode ser estimada com base no problema de otimização, levando em conta também as variações nas condições operacionais ao longo do tempo e possíveis perturbações no sistema. Portanto, o processo de otimização em tempo real será responsável por fornecer condições de operação ideais, mantendo a produção dentro da região de interesse econômico.

## 1.2 INTRODUÇÃO À OTIMIZAÇÃO EM TEMPO REAL

A otimização em tempo real é necessária para atingir o máximo de rentabilidade possível em um processo. Isso pode ser obtido por meio de um algoritmo que realiza a operação ótima do processo. Segundo Duraiski (2009), a determinação de um ótimo nominal não garante que o processo atinja sua produção ótima. Isso porque distúrbios de processo e incertezas podem fazer com que o processo não permaneça otimizado durante toda a operação. Portanto, é necessário utilizar otimizadores em tempo real para manter o processo otimizado. A otimização em tempo real monitora continuamente as condições do processo e ajusta as variáveis de decisões de forma dinâmica e automatizada. Por meio de algoritmos sofisticados, o otimizador em tempo real analisa os dados em tempo real e faz correções precisas para manter o processo próximo ao seu ponto ótimo, mesmo diante de perturbações e incertezas.

A otimização dinâmica em tempo real (DRTO - *Dynamic Real-Time Optimization*) é uma aplicação que ocorre de forma recorrente e em conjunto com uma planta. Algumas técnicas de otimização exigem um modelo do sistema para formular o problema de otimização, realizar a estimação de estados, resolver o problema e implementar os perfis ótimos na planta. Outras técnicas, como as técnicas de *Extremum Seeking Control*, não dependem dessa etapa. Em suma, o DRTO minimiza um ou mais objetivos de produção, manipulando as variáveis de decisões ao longo do horizonte de otimização ou a um passo à frente, respeitando todos os limites operacionais e dos equipamentos. Na formulação do problema de otimização, definem-se as restrições que delimitam diretamente a região

viável da solução. Estas restrições podem ser de caminho, impostas ao longo das trajetórias das variáveis (dentro do horizonte de otimização), pontuais, estabelecidas em instantes de tempo determinados, ou de tempo final, que estabelecem as condições no final de uma operação (ALMEIDA, 2011; DURAIISKI, 2009) .

De modo geral, a formulação de um problema de otimização dinâmica pode ser descrita conforme as equações 1.1 a 1.6 .(ALMEIDA, 2011).

$$\min_{\mathbf{x}(t), \mathbf{u}(t)_{t_f}} J = M(\mathbf{x}(t_f), t_f) + \int_{t_0}^{t_f} L(\mathbf{x}(t), \mathbf{u}(t), t, \mathbf{p}) dt , \quad (1.1)$$

s.a :

$$\mathbf{F}(\dot{\mathbf{x}}(t), \mathbf{x}(t), \mathbf{y}(t), \mathbf{u}(t), \mathbf{p}, t) = 0 , \quad (1.2)$$

$$\mathbf{S}(\mathbf{x}(t), \mathbf{y}(t), \mathbf{u}(t), \mathbf{p}, t) \leq 0 , \quad (1.3)$$

$$\mathbf{x}^{inf} \leq \mathbf{x}(t) \leq \mathbf{x}^{sup} , \quad (1.4)$$

$$\mathbf{y}^{inf} \leq \mathbf{y}(t) \leq \mathbf{y}^{sup} , \quad (1.5)$$


$$\mathbf{u}^{inf} \leq \mathbf{u}(t) \leq \mathbf{u}^{sup} . \quad (1.6)$$

Em que, o problema consiste de uma função objetivo  $J$ , as restrições de igualdade  $\mathbf{S}$ , onde  $\mathbf{x}$ ,  $\mathbf{y}$ ,  $\mathbf{u}$  e  $\mathbf{p}$  são os vetores das variáveis diferenciais de estado, algébrica, controle e os parâmetros invariantes no tempo, respectivamente.

Conforme exposto, os problemas de otimização em tempo real de processos, sejam eles dinâmicos ou estacionários, possuem características bastante particulares. Dentre elas, destaca-se a necessidade de integração do modelo do sistema (algoritmo algébrico-diferencial) e a resolução do problema de otimização, o que exige uma metodologia capaz de combinar algoritmos para sua execução. De maneira geral, essa combinação pode ser feita de duas formas: através de algoritmos sequenciais e simultâneos. No caso sequencial, os dois problemas (modelo do sistema e o problema de otimização) são resolvidos de forma alternada e iterativa até a obtenção da solução. Já no caso simultâneo, os dois problemas são acoplados em uma única etapa de resolução (DURAIISKI, 2009; ANDERSSON et al., 2019).

Segundo Almeida (2011), os métodos diretos sequencias e simultâneos são capazes de transformar um problema de otimização em tempo real em um problema de programação não linear (NLP - *nonlinear programming*) através da parametrização de variáveis. Sabe-se que os métodos sequencias ou discretização parcial podem ser divididos em disparo simples (*single shooting*) e disparo múltiplo (*multiple shooting*).

Conforme Almeida (2011), o disparo simples corresponde a uma aproximação da trajetória da variável de decisão por meio de uma função com poucos parâmetros, mantendo as equações de estado na forma original do sistema de DAE. Logo, isso requer que as equações de estado e de sensibilidade sejam integradas simultaneamente, possibilitando fornecer os valores das funções e gradientes para o algoritmo de NLP. Em suma, a simulação e a otimização são realizadas sequencialmente, e a parametrização pode ser feita utilizando aproximação suave por partes, enquanto as DAEs são resolvidas por um integrador. A Figura 1.7 ilustra o esquema de *single shooting*.




**Figura 1.7** Discretização *single shooting* aplicada ao problema de otimização em tempo real.

Fonte: (YAHIA, 2018)

Após a integração, os estados  $\mathbf{x}(\cdot)$  são obtidos em função dos parâmetros de decisões ou controle anteriores  $\mathbf{u}(\cdot)$  e, finalmente, o problema é movido para um solucionador de NLP para encontrar a trajetória.

O método *multiple shooting* representa uma ligação entre os pontos de vista sequencial e simultâneo, sendo baseado na discretização total das variáveis de controle e estado, podendo ser chamado de abordagem híbrida. Neste método, a abordagem consiste em reduzir a dinâmica de integração, o que pode ser contraproducente para a discretização do problema de otimização em NLP. Dessa forma, é possível fazer uma limitação na integração, ou seja, utilizar curtos intervalos de tempo. Esse método realiza uma discretização por partes da entrada contínua  $\mathbf{u}(t) \in [t_i, t_{i+1}]$ , depois resolve as DAEs em cada intervalo  $[t_i, t_{i+1}]$ , começando com valores iniciais artificiais (YAHIA, 2018). A Figura 1.8 ilustra o esquema de *multiple shooting* com os valores artificiais.



**Figura 1.8** Discretização *multiple shooting* aplicada ao problema de otimização em tempo real.

Fonte: (YAHIA, 2018)


Na discretização total ou em métodos simultâneos, efetua-se a parametrização tanto da variável de decisão quanto da variável de estado, de maneira a evitar a integração das equações dinâmicas. Portanto, a discretização pode ser feita através de polinômios nos subintervalos, nos quais os coeficientes e os tamanhos dos subintervalos se transformam em variáveis de decisão em um problema de NLP maior. Quando se refere à discretização total, pode-se destacar o método de colocação ortogonal (BIEGLER, 2009; ALMEIDA, 2011).

A Figura 1.9 ilustra o método de colocação, em que temos a aproximação polinomial (curva azul), a dinâmica real do sistema (curva pontilhada azul), a derivada de estado do polinômio (linha preta), a derivada da dinâmica do sistema (linha pontilhada preta) e a entrada de controle constante por partes do intervalo (linhas azuis). Além disso, há a restrição de inclinação (seta vermelha) feita em cada ponto de colocação e a restrição de distância do *shooting* (círculo tracejado vermelho).

O método de colocação ortogonal é aproximado por polinômios ortogonais, e as variáveis de controle são descritas por funções lineares por partes. Cabe destacar que a principal diferença nesse método consiste na discretização dos estados e controles em intervalos de grade fixa com 'N' pontos de colocação intermediários em cada intervalo. Outro aspecto importante desse método é a convergência mais rápida em problemas de larga escala, pois evita simulações repetitivas do modelo durante as iterações e ainda



reduz os riscos de falhas de convergência na simulação (YAHIA, 2018).



**Figura 1.9** Discretização total aplicada ao problema de otimização em tempo real.

Fonte: (YAHIA, 2018)

No contexto do *Gas Lift*, as condições do poço e do reservatório podem mudar com frequência, exigindo otimizações em tempo real. A escolha entre o método direto sequencial e o método direto simultâneo para resolver um problema de otimização dinâmica em tempo real aplicada ao *Gas Lift* dependerá das características específicas do problema e dos requisitos de desempenho desejados. Contudo, Problemas de otimização dinâmica, como o *Gas Lift*, frequentemente envolvem restrições não lineares que variam ao longo do tempo à medida que as condições do poço e do reservatório mudam. O método direto sequencial é mais adequado para lidar com essas restrições, pois ele lida com cada intervalo de tempo individualmente e atualiza as restrições para cada etapa do processo. Isso permite que o método se adapte de forma mais flexível às mudanças dinâmicas no sistema (BIEGLER, 2009). Além disso, o método direto sequencial é mais fácil de implementar e depurar, pois envolve a resolução de subproblemas independentes e bem definidos em cada intervalo de tempo. Isso pode simplificar o desenvolvimento do código e ajudar a identificar e corrigir erros mais facilmente. Portanto, com base nessas características, o método escolhido para resolver o problema de otimização dinâmica em tempo real aplicado ao *Gas Lift* é o método direto sequencial.

### 1.3 REVISÃO DA LITERATURA

Para um projeto de otimização em tempo real, controle baseado em modelo e sensor virtual, é necessário um modelo dinâmico simples do sistema. Neste contexto, Aamo et al. (2005) apresentaram um modelo simplificado para um único poço, utilizando apenas o balanço de massa de três estados. Segundo os autores, esse modelo já havia sido comparado com o simulador multifásico OLGA-2000 no trabalho de dissertação de Imsland (2002) e, eventualmente, favoreceu alguns trabalhos futuros. Entre esses trabalhos favorecidos, cita-se Jahanshahi, Skogestad e Hansen (2012), que contribuíram ao adicionar a perda de pressão devido ao atrito e novos termos para calcular a densidade no topo do poço para o modelo de três estados de Aamo et al. (2005).

No ano seguinte, Jahanshahi (2013), em sua tese, propôs um novo modelo *offshore* de seis estados para escoamento com golfadas severas, fenômeno observado quando há inclinação na tubulação que conecta ao riser, porém não considerou o anular.

Posteriormente, Krishnamoorthy, Foss e Skogestad (2016) expandiram o modelo de Jahanshahi, Skogestad e Hansen (2012) para sete estados, abrangendo dois poços conectados a um *riser*. No entanto, eles optaram por não considerar as equações de atrito e o fenômeno de golfadas severas.

Por sua vez, Diehl et al. (2017) também apresentaram um modelo de seis estados capaz de prever as golfadas severas, mas com uma abordagem diferente da de Jahanshahi (2013), pois eles se basearam no trabalho de Di Meglio, Kaasa e Petit (2009). Neste último trabalho, o *pipeline-riser* foi modelado com apenas três estados, não considerando, no entanto, o gradiente de fricção no escoamento.

Meados dos últimos três anos, Krishnamoorthy, Fjalestad e Skogestad (2019) estenderam a aplicação do modelo de Krishnamoorthy, Foss e Skogestad (2016) para seis poços *offshore*, totalizando vinte estados de massa, além da utilização de equações simplificadas de fricção. Além disso, Santarossa (2021) aplicou as mesmas equações de atrito de Jahanshahi (2013) no modelo de Diehl et al. (2017).

No decorrer dos últimos anos, os modelos fenomenológicos de simulação para sistemas de poços *offshore* têm passado por contínuas expansões e refinamentos. As contribuições de diferentes pesquisadores, como Aamo et al. (2005), Jahanshahi, Skogestad e Hansen (2012), Jahanshahi (2013), Krishnamoorthy, Foss e Skogestad (2016), Diehl et al. (2017) e Santarossa (2021), têm permitido avanços significativos, incorporando novos estados de massa, simplificando equações de fricção e levando em conta fenômenos importantes, como as golfadas severas. Esses esforços têm impulsionado o desenvolvimento de modelos mais precisos e eficazes para a predição e controle de sistemas complexos de poços *offshore*.

Além disso, é importante destacar que os modelos orientados a dados têm ganhado espaço na modelagem de sistemas.

As redes neurais artificiais também já são exploradas há algum tempo, principalmente quando o assunto é escoamento multifásico. Qiu e Toral (1993) tentaram estimar a pressão de escoamento multifásico utilizando modelo de *Back Propagation Neural Network* (BPNN). Para essa finalidade, os autores empregaram dados de transdutores de pressão e fluxo trifásico horizontal em tubos de 3 e 4 polegadas como entrada para a rede e taxas previstas de gás-líquido como saída.

Desde então, as redes neurais artificiais têm ganhado espaço no contexto de medidores de vazão virtual, e isso se reflete na indústria de petróleo. por exemplo, AL-Qutami et al. (2017) propuseram um sensor virtual de fluxo multifásico para prever a vazão na linha de produção de um poço de petróleo utilizando uma rede neural artificial *feed-forward*. Logo após, Loh, Omrani e Linden (2018) utilizaram uma rede neural artificial dinâmica (LSTM, *Long Short Term Memory*) para fazer previsões de vazão multifásica a partir de dados de campo e de dados simulados.

Apesar de conquistar espaço ultimamente, as redes neurais ainda precisam lidar com a falta de dados ou poucos dados representativos em algumas aplicações, como na produção de óleo e gás. Com base nessa preocupação, Franklin et al. (2022) apresentam um medidor de vazão virtual utilizando uma arquitetura de rede híbrida conhecida como (PINN, *Physics-Informed Neural Networks*), adequada para aplicações com poucos dados.

No âmbito das redes neurais aplicada ao GL, Dias et al. (2019) investigaram a arquitetura de RNA recorrente chamada de "*Echo State Network*" para fazer previsões de produção em longo período, indicando que o modelo orientado a dados seria capaz de realizar otimização em tempo real. Outrossim, Soares, Secchi e Souza (2022) executaram um controlador preditivo não-linear baseado em modelo orientado a dados (rede neural artificial *feed-forward*) e mostraram que a estimativa dos estados internos pela rede neural foi suficientemente precisa para permitir um controle adequado do escoamento multifásico.

Além das aplicações em pesquisa, de acordo com Bikhmukhametov e Jäschke (2020), os modelos orientados a dados têm sido aplicados na indústria, como no caso da Baker Hughes, que desenvolveu o *software NeuraFlow* baseado em redes neurais artificiais e utilizado para estimar as vazões em sistemas com bombeio centrífugo submerso (BCS).

O problema de alocação de gás do GL foi apresentada por Kanu, Mach e Brown (1981), Eles descobriram que taxas elevadas de injeção de gás em poços equipados com GL são dispendiosas e, para mitigar o problema, desenvolveram uma curva econômica relacionada

à produção de óleo. Com base nas informações da curva de desempenho econômico, Ferrer e Maggiolo (1991) propuseram a utilização de um modelo computacional para lidar com o problema de alocação. Os autores representaram a curva do GL através de uma equação de orifício e pressão estática, empregando o algoritmo de gradiente descendente para determinar a melhor vazão de injeção de gás.

Posteriormente, Martinez et al. (1994) apresentaram um problema de otimização empregando algoritmos genéticos, utilizando o mesmo modelo da curva proposta por Ferrer e Maggiolo (1991), ao algoritmo genético.

Em seguida, várias pesquisas foram realizadas levando em consideração a curva de desempenho estática GL. Por exemplo, Nishikiori et al. (1995) aplicaram a técnica de otimização não-linear quase-Newton. Já Alarcon, Torres e Gomez (2002) também utilizaram uma técnica de otimização não-linear, neste caso o algoritmo de pontos inteiros, além de proporem um novo ajuste matemático para a curva de desempenho, usando um polinômio.

Em um estudo anterior, Camponogara e Nakashima (2003) desenvolveram um algoritmo de programação dinâmica para resolver o problema de otimização (alocação de gás) para um poço específico. Posteriormente, Nakashima e Camponogara (2006) aplicaram a técnica de programação dinâmica para resolver um problema de otimização em um campo produtor *onshore*. Em seguida, Camponogara e Nakashima (2006) estenderam a aplicação para incorporar restrições discretas, ou seja, definiram quais poços deveriam produzir, além de admitirem múltiplos modelos de escoamento para se protegerem contra incertezas nos processos de identificação.

Em ambos os estudos, o desempenho do escoamento multifásico de GL foi modelado por polinômios.

No que tange a uso de polinômios para representar o sistema GL, Cudas e Camponogara (2012) propuseram uma nova abordagem considerando restrições de roteamento dos poços e capacidade dos separadores para campos com vários separadores. Para isso, utilizaram uma formulação linear inteira mista obtida por linearização por partes da curva não linear do GL, empregando variáveis binárias para expressar as decisões e uma formulação integrada combinando as decisões em uma única variável.

Posteriormente, Hülse e Camponogara (2014) apresentaram uma formulação linear inteira mista robusta, também linearizada por partes, na qual consideram a incerteza na curva de desempenho medida e simulada.

Em relação aos trabalhos relacionados à RTO dinâmica com modelos fenomenológicos, podemos citar o trabalho de Cudas, Jahanshahi e Foss (2016). Nesse estudo, foi proposto

um problema de otimização em tempo real com o objetivo de fornecer configurações ideais para controles regulatórios. Além disso, foi aplicado o filtro de Kalman estendido para estimar os estados do sistema.

Por outro lado, Krishnamoorthy, Foss e Skogestad (2016) avaliaram a incerteza do modelo fenomenológico na RTO diária aplicada a uma rede com dois poços *onshore*. Em seguida, Krishnamoorthy, Foss e Skogestad (2017) examinaram novamente a incerteza do modelo na RTO, desta vez utilizando o filtro de Kalman estendido e comparando o tempo de cálculo. Isso ressaltou uma melhoria, porém ao custo do tempo computacional.

Tendo em vista que a RTO dinâmica requer um certo tempo computacional e não é necessário aguardar o estacionário do processo para iniciar um novo ciclo de otimização, entretanto, a RTO estacionária apresenta um baixo tempo computacional e necessita de um tempo para alcançar o estado estacionário antes de iniciar um novo ciclo. Caso contrário, pode gerar decisões subótimas. Com o objetivo de alcançar um equilíbrio, Krishnamoorthy, Foss e Skogestad (2018) propuseram uma abordagem híbrida na qual a adaptação do modelo é feita utilizando o modelo dinâmico e a RTO em estado estacionário.

Um outro ponto que cabe ressaltar é que a maioria dos problemas de otimização do GL consideram apenas a injeção de gás como variável de decisão. Então, Santarossa (2021) comparou as metodologias existentes, tais como os problemas de otimização com duas variáveis de decisões (injeção de gás e a abertura do *choke* de produção), evidenciando que em certos momentos é necessária a redução da abertura no *choke* de produção. Além disso, comparou a RTO dinâmica e estacionária, indicando que a RTO dinâmica apresentou melhores resultados de produção, embora sua utilização em um sistema real exigiria tempo computacional.

Por fim, Matias et al. (2022) aplicou a RTO em uma planta experimental do GL, na qual os parâmetros do modelo em estado estacionário são atualizados dinamicamente usando medições transientes, ou seja, sem a necessidade de esperar por um estado estacionário antes de acionar o ciclo de otimização

O campo da Otimização em Tempo Real (RTO) aplicado ao GL tem passado por avanços significativos. Diferentes abordagens, como modelos fenomenológicos, redes neurais artificiais e algoritmos de otimização, foram exploradas para melhorar a produção de petróleo. A RTO dinâmica tem se mostrado promissora, embora exija maior tempo computacional. A utilização de modelos orientados a dados e abordagens híbridas têm sido importantes para lidar com incertezas e o tempo computacional, tornando-se ferramentas valiosas para a otimização e controle eficiente na produção de petróleo.

## 1.4 OBJETIVOS DO TRABALHO

O objetivo principal do presente estudo é implementar uma estratégia de otimização diária em tempo real com um modelo orientado a dados para uma rede de poços de petróleo assistidos com *Gas Lift*. Essa metodologia híbrida consiste na substituição do modelo fenomenológico, que representa o modelo do processo, por uma rede neural artificial. Entretanto, o modelo fenomenológico ainda tem sua utilidade para soluções offlines, gerando os dados necessários para treinar a rede neural proposta.

Essa abordagem permite que a estratégia de otimização alcance um menor tempo computacional para resolver o problema, tornando-a mais ágil na tomada de decisões em tempo real. Apesar do modelo fenomenológico ser útil para soluções offlines, o modelo orientado a dados reduz a dependência de modelos complexos, simplificando o processo de otimização e facilitando sua implementação prática.

A seguir são apresentados alguns objetivos complementares deste trabalho:

- (i) Desenvolver um sensor virtual para estimar as variáveis de difícil medição no sistema de *Gas Lift*, principalmente para prever as vazões de óleo e gás de cada poço com base nas variáveis medidas disponíveis. Para isso, propõe-se o projeto de um estimador não linear baseado em horizonte móvel (MHE - *moving horizon estimation*), que utiliza o modelo fenomenológico.
- (ii) Propor uma arquitetura de rede neural artificial para representar a elevação artificial por GL com dados gerados pelo sensor virtual.
- (iii) Comparar a metodologia proposta utilizando o modelo orientado a dados com a formulação padrão que utiliza o modelo fenomenológico, com o propósito de avaliar o tempo computacional e a precisão de ambas as abordagens.

## 1.5 PUBLICAÇÃO

Ezequias, S. Matos; Odilon, S. Abreu; Taniel, S. Franklin; Leonardo, S.Souza; Márcio, F. Martins; Otimização Econômica em Tempo Real Orientada a Dados Para Poços de Petróleo com Injeção de Gás. Congresso Brasileiro de Automática CBA 2022. Anais. Fortaleza - CE: UFC, 2022;

## 1.6 ESTRUTURA DO TRABALHO

Os demais capítulos deste trabalho estão organizados da forma como segue.

- **Capítulo 2:** Neste capítulo, a metodologia do trabalho será abordada. Primeiramente, demonstra-se como uma rede de poços assistidos por GL pode ser representada como um sistema de equações algébricas diferenciais. Em seguida, é apresentada a formulação do sensor virtual proposto, denominado MHE, juntamente com uma breve explicação sobre redes neurais dinâmicas e a arquitetura de rede aplicada neste projeto. Por fim, discute-se a formulação do problema de otimização em tempo real, com foco em objetivos econômicos.
- **Capítulo 3:** Neste capítulo, são apresentados os resultados e análises de simulação de três estudos de caso distintos. No primeiro estudo, avaliou-se o tempo computacional necessário para encontrar a solução ótima do problema de otimização, utilizando o modelo fenomenológico. Esse estudo empregou duas técnicas de integração: a primeira envolveu a aplicação de diferenças finitas com o algoritmo ODE15s, enquanto a segunda se baseou na diferenciação automática utilizando a estrutura CasADI.

No segundo estudo, examinou-se o tempo computacional gasto para encontrar a solução ótima do problema de otimização, utilizando um modelo fenomenológico e um modelo orientado a dados, ou seja, uma rede neural artificial. Neste caso, a análise concentrou-se em um único poço.

No terceiro estudo, também foi analisado o tempo computacional necessário para encontrar a solução ótima do problema de otimização utilizando um modelo fenomenológico e um modelo orientado a dados, ou seja, uma rede neural artificial. Neste caso, a análise concentrou-se em uma rede com três poços produtores

- **Capítulo 4:** Nas considerações finais, são apresentados comentários sobre os resultados obtidos, destacando suas contribuições e apontando possíveis direções para futuras extensões do trabalho.





*Este capítulo tem como objetivo apresentar o desenvolvimento de um problema de otimização dinâmico em tempo real com objetivos econômicos, bem como os modelos fenomenológico e orientado a dados que são utilizados para representar a planta dentro do otimizador. Além disso, é apresentada a proposta de um medidor virtual utilizado para estimar variáveis de difícil medição.*

## METODOLOGIA

### 2.1 MODELO FENOMENOLÓGICO DE UMA REDE DE POÇOS COM GAS LIFT

A produção uma rede de poço de petróleo com  $P = \{1, \dots, p_w\}$  poços assistido por *Gas Lift* pode ser descrita usando um conjunto de equações diferenciais, conforme Jahanshahi, Skogestad e Hansen (2012) e Krishnamoorthy, Fjalestad e Skogestad (2019). A Figura 2.1 apresenta um esquema simplificado de uma rede de poços equipados com GL.

A dinâmica desse processo pode ser obtida por meio dos balanços de massa do anular e da coluna de produção em cada no poço, como também do *riser*. Então, os balanços de massa pode ser descritos pelas seguintes equações diferenciais.


$$\dot{m}_{ga_i} = w_{ing_i} - w_{iv_i} , \quad (2.1)$$

$$\dot{m}_{gt_i} = w_{iv_i} + w_{rg_i} - w_{pg_i} , \quad (2.2)$$

$$\dot{m}_{ot_i} = w_{ro_i} - w_{po_i} , \quad \forall_i \in P . \quad (2.3)$$

Em que:

$m_{ga_i}$  é a massa do gás no anular,  $m_{gt_i}$  é a massa do gás na coluna produção (*tubing*),  $m_{ot_i}$  é a massa do óleo na coluna produção (*tubing*),  $w_{ing_i}$  é a vazão mássica de gás injetada



**Figura 2.1** Representação esquemática simplificado para uma rede de poço de GL.

no anular,  $w_{iv_i}$  é a vazão mássica de gás através da válvula operadora entre o anular e coluna de produção,  $w_{rg_i}$  e  $w_{ro_i}$  são as vazões mássicas de gás e óleo do reservatório,  $w_{pg_i}$  e  $w_{po_i}$  são as vazões mássicas de gás e óleo produzidas na válvula *choke* de produção localizada na cabeça de cada poço. No caso do *riser*, os balanços de massa são compostos:

$$\dot{m}_{gr} = \sum_{i=1}^{p_w} w_{pg_i} - w_{tg} , \quad (2.4)$$

$$\dot{m}_{or} = \sum_{i=1}^{p_w} w_{po_i} - w_{to} . \quad (2.5)$$

sendo que:

$m_{gr}$  representa a massa de gás no *riser*,  $m_{or}$  representa a massa de óleo no *riser*,  $w_{tg}$  e  $w_{to}$  são as vazões mássicas de gás e óleo total produzidas pelo *riser*, respectivamente. Visto que o modelo é composto por um conjunto de equações algébrico-diferenciais, as

vazões mássicas dependem de pressões a montante e a jusante, parâmetros das válvulas, propriedades dos fluidos, entre outros, e podem ser descritas pelas seguintes equações:

$$w_{iv_i} = C_{iv_i} \sqrt{\rho_{a_i} \max(0, p_{a_i} - p_{wi_i})} , \quad (2.6)$$

$$w_{pci_i} = C_{pci_i} Z_{pci_i} \sqrt{\rho_{w_i} \max(0, p_{wh_i} - p_m)} , \quad (2.7)$$

$$w_{pg_i} = \frac{m_{gt_i}}{m_{gt_i} + m_{ot_i}} w_{pci_i} , \quad (2.8)$$

$$w_{po_i} = \frac{m_{ot_i}}{m_{gt_i} + m_{ot_i}} w_{pci_i} , \quad (2.9)$$

$$w_{ro_i} = PI_i (p_{r_i} - p_{bh_i}) , \quad (2.10)$$

$$w_{rg_i} = GOR_i \cdot w_{ro_i} , \quad \forall_i \in P . \quad (2.11)$$

Sendo que,  $C_{iv_i}$  e  $C_{pci_i}$  são os coeficientes de fluxo da válvula operadora e da *choke* de produção localizada na cabeça de poço, respectivamente.  $\rho_{a_i}$  é a densidade do gás no anular,  $\rho_{w_i}$  é a densidade média do óleo no poço,  $p_{a_i}$  é a pressão na montante da válvula operadora no anular,  $p_{wi_i}$  é a pressão na jusante da válvula operadora, ou seja, a pressão no *tubing* correspondente à profundidade de instalação,  $p_{wh_i}$  é a pressão de topo do poço,  $p_m$  é a pressão de *manifold*,  $p_{bh_i}$  é a pressão de fundo do poço, ou seja, pressão de canhoneados,  $p_{r_i}$  é a pressão de reservatório,  $PI_i$  é o índice de produtividade de reservatório,  $GOR_i$  é a razão gás-óleo produzida pelo reservatório, por fim,  $Z_{pci_i}$  é a abertura da *choke* de produção.

As pressões na parte superior do anular, na parte superior da coluna produção e na parte superior de *riser* são calculadas pela leis dos gases ideais, além disso a pressão do reservatório deve ser suficientemente elevada para que o petróleo suba acima do ponto de injeção de gás na coluna de produção. Logo as pressões e densidades são dadas conforme as equações:

$$\rho_{a_i} = \frac{M_w p_{a_i}}{T_{a_i} R} , \quad (2.12)$$

$$\rho_{w_i} = \frac{m_{gt_i} + m_{ot_i} - \rho L_{bh_i} A_{bh_i}}{L_{w_i} A_{w_i}} , \quad (2.13)$$

$$p_{a_i} = \left( \frac{T_{a_i} R}{V_{a_i} M_w} + \frac{g H_{a_i}}{L_{a_i} A_{a_i}} \right) m_{gai} , \quad (2.14)$$

$$p_{wh_i} = \frac{T_{w_i} R}{V_{a_i}} \left( \frac{m_{gt_i}}{L_{w_i} A_{w_i} + L_{bh_i} A_{bh_i} - \frac{m_{ot_i}}{\rho_{o_i}}} \right), \quad (2.15)$$

$$p_{w_i} = p_{wh_i} + \frac{g}{L_{w_i} A_{w_i}} (m_{ot_i} + m_{gt_i} - \rho_o L_{bh_i} A_{bh_i}) H_{w_i} + \Delta p_{fric_i}, \quad (2.16)$$

$$p_{bh_i} = p_{w_i} + g H_{bh_i} + \Delta p_{fric_i}, \quad \forall_i \in P. \quad (2.17)$$

Em que,  $M_w$  é o peso molecular do gás,  $T_{a_i}$  é a temperatura do anular,  $T_{w_i}$  é a temperatura do *tubing*,  $R$  é a constante universal dos gases e  $L_{a_i}$ ,  $A_{a_i}$  e  $H_{a_i}$  são as dimensões do anular, tais como, o comprimento, a área e a altura, respectivamente. Ademais,  $L_{w_i}$ ,  $A_{w_i}$  e  $H_{w_i}$  são as dimensões do poço, especificamente o comprimento, a área e a altura entre o topo e a válvula operadora. As dimensões entre a válvula operadora e o canhoneado (fundo do poço) são  $L_{bh_i}$ ,  $A_{bh_i}$  e  $H_{bh_i}$  que representam o comprimento, a área e a altura, por fim,  $V_{a_i}$  é o volume do anular,  $\rho_o$  é a densidade do óleo do reservatório,  $g$  é a gravidade e  $\Delta p_{fric_i}$  é a pressão gerada devido ao atrito de escoamento entre a tubulação e óleo. Então, dando continuidade com as equações algébricas para o *riser*, as vazões mássicas de topo podem ser descritas de acordo com as equações seguintes,

$$w_{rh} = C_{rh} Z_c \sqrt{\rho_r \max(0, p_{rh} - p_s)}, \quad (2.18)$$

$$w_{tg} = \frac{m_{gr}}{m_{gr} + m_{or}} w_{rh}, \quad (2.19)$$

$$w_{to} = \frac{m_{or}}{m_{gr} + m_{or}} w_{rh}, \quad (2.20)$$

Sendo que:

$$\rho_r = \frac{m_{gr} + m_{or}}{L_r + A_r}, \quad (2.21)$$

$$p_{rh} = \frac{T_r R}{M_w} \left( \frac{m_{gr}}{L_r A_r} \right), \quad (2.22)$$

$$p_m = p_{rh} + \rho_r g H_r + \Delta p_{fric}. \quad (2.23)$$

sendo que,  $w_{rh}$  é a vazão mássica multifásica,  $w_{tg}$  e  $w_{to}$  são as vazões mássicas individuais de gás e óleo do *riser*, respectivamente.  $C_{rh}$  é o coeficiente de fluxo da válvula de topo do *riser*,  $Z_c$  é a abertura da válvula no *riser*,  $\rho_r$  é a densidade média do fluido ao longo do *riser*,  $p_{rh}$  é a pressão de topo do *riser* e  $p_m$  é a pressão de *manifold*,  $p_s$  é a pressão de separador e  $T_r$  é a temperatura. Ademais, são as dimensões do *riser*, tais como,  $H_r$ ,  $L_r$  e  $A_r$ , ou seja, altura, comprimento e área, respectivamente. Por fim, para o

cálculo de pressão de fricção é usado a equação de Darcy-Weisbach e considerado apenas a fase líquida do fluido e pode ser representada pela Equação (2.24).

$$\Delta_{fric_i} = \frac{\alpha_{l_i} \lambda_{w_i} \rho_{w_i} U_{w_i}^2 L_{w_i}}{2D_{w_i}} . \quad (2.24)$$

Porém, para realizar o cálculo do fator de atrito entre o fluido e a tubulação, utilizou-se uma aproximação explícita da equação implícita de Colebrook-White. Essa aproximação é adotada com o objetivo de simplificar o cálculo do fator de atrito, tornando-o mais rápido e eficiente computacionalmente. A equação original de Colebrook-White é uma equação implícita, o que significa que o fator de atrito é determinado como uma solução de uma equação não linear, requerendo iterações para encontrar o valor correto.

Por outro lado, a aproximação explícita é uma forma simplificada da equação que permite calcular diretamente o fator de atrito sem a necessidade de iterações. Essa abordagem é vantajosa em cenários onde o tempo de processamento é relevante, como em problemas de otimização ou simulações em tempo real. Essa aproximação é descrita em detalhes em Haaland (1983) e pode ser vista na Equação (2.25).

$$\frac{1}{\sqrt{\lambda_{w_i}}} = 1.8 \log_{10} \left[ \left( \frac{\varepsilon/D_{w_i}}{3.7} \right)^{1.11} + \frac{6.9}{Re_{w_i}} \right] , \quad (2.25)$$

Sendo que:

$$\alpha_{l_i} = \frac{m_{ot_i} + \rho_o L_{bh_i} A_{bh_i}}{V_{wt_i} \rho_{o_i}} , \quad (2.26)$$

$$U_{o_i} = \frac{4w_{po_i}}{\rho_{w_i} \pi D_{w_i}^2} , \quad (2.27)$$

$$U_{g_i} = \frac{4w_{pg_i}}{\rho_{gw_i} \pi D_{w_i}^2} , \quad (2.28)$$

$$U_{w_i} = U_{o_i} + U_{g_i} , \quad (2.29)$$

$$Re_{e_i} = \frac{\rho_{w_i} U_{w_i} D_{w_i}}{\mu_{w_i}} , \quad (2.30)$$

$$\rho_{g_i} = \frac{m_{gt_i}}{V_{wt_i} - \left( \frac{m_{ot_i}}{\rho_{o_i}} \right)} , \quad \forall_i \in P . \quad (2.31)$$

Em que,  $\varepsilon$  é a rugosidade do tubo,  $Re_{w_i}$  é a constante de Reynolds,  $D_{w_i}$  é o diâmetro do tubo de escoamento,  $U_{w_i}$  é a velocidade de escoamento da mistura,  $U_{g_i}$  é a velocidade de escoamento do gás,  $U_{o_i}$  é a velocidade escoamento do óleo,  $L_{w_i}$  é o comprimento do

tubo,  $V_{wt_i}$  é o volume total,  $\alpha_{l_i}$  é a fração volumétrica de óleo,  $\rho_{g_i}$  é a densidade do gás e  $\mu_{w_i}$  é viscosidade do fluido.

Então, como visto nas Equações (2.1) - (2.31), O GL poder ser modelado com um sistema de primeira ordem *differential algebraic equation* (DAE) de forma:

$$\dot{\mathbf{x}} = f(\mathbf{x}, \mathbf{z}, \mathbf{u}) , \quad (2.32)$$

$$h(\mathbf{x}, \mathbf{z}, \mathbf{u}) = 0 . \quad (2.33)$$

Em que:

$$\mathbf{x} = [m_{ga_i} \ m_{gt_i} \ m_{ot_i} \ m_{gr} \ m_{or}]^T , \quad (2.34)$$

$$\mathbf{z} = [w_{iv_i} \ w_{pci} \ w_{pg_i} \ w_{po_i} \ w_{ro} \ w_{rg} \ \rho_{a_i} \ \rho_{w_i} \ p_{a_i} \ p_{wh_i} \ p_{wi_i} \ p_{bh_i} \ w_{rh} \ w_{to} \ w_{tg} \ \rho_r \ p_{rh} \ p_m]^T , \quad (2.35)$$

$$\mathbf{u} = [w_{ing_i} \ Z_{pc_i} \ Z_c]^T , \quad \forall_i \in P . \quad (2.36)$$

sendo que,  $f(\mathbf{x}, \mathbf{z}, \mathbf{u})$  é o conjunto de equações diferenciais e  $g(\mathbf{x}, \mathbf{z}, \mathbf{u})$  é o conjunto de equações algébricas,  $\mathbf{x}$  são os estados diferenciais,  $\mathbf{z}$  são os estados algébricos e  $\mathbf{u}$  são as variáveis de decisões, a Tabela 2.1 apresenta os parâmetros utilizados no modelo.

Vale ressaltar que o modelo apresentado considera o *Gas Lift* contínuo (GL) com escoamento bifásico (gás e óleo) e não possui capacidade para representar a ocorrência de golfadas severas.

A incorporação do fenômeno da golfada severa pode aumentar a complexidade do modelo matemático, tornando-o mais difícil de ser implementado e computacionalmente mais exigente. Isso pode levar a um aumento no tempo de cálculo, o que pode ser problemático em aplicações que requerem respostas em tempo real. Portanto, é importante ponderar os benefícios e desafios da inclusão do fenômeno de golfada severa no modelo do *Gas Lift* e avaliar se os ganhos em termos de precisão e eficiência superam os potenciais impactos negativos na complexidade, disponibilidade de dados e validação do modelo. Essa abordagem merece uma atenção especial em trabalhos futuros.

**Tabela 2.1** Parâmetros do modelo utilizado na simulação.

Parâmetro	Unidade	Poço I	Poço II	Poço III	<i>Riser</i>
$L_w$	[m]	1500	1500	1500	-
$H_w$	[m]	1000	1000	1000	-
$D_w$	[m]	0.121	0.121	0.121	-
$L_{bh}$	[m]	500	500	500	-
$D_{bh}$	[m]	0.121	0.121	0.121	-
$L_a$	[m]	1500	1500	1500	-
$H_a$	[m]	1000	1000	1000	-
$D_a$	[m]	0.189	0.189	0.189	-
$L_r$	[m]	-	-	-	500
$H_r$	[m]	-	-	-	500
$D_r$	[m]	-	-	-	1.121
$\rho_o$	[kg/m <sup>3</sup> ]	800	820	790	-
$GOR$	[kg/kg]	0.1	0.12	0.09	-
$p_r$	[bar]	150	155	160	-
$PI$	[kg/s/bar]	7	7	7	-
$C_v$	[m <sup>2</sup> ]	0.1E-3	0.1E-3	0.1E-3	-
$C_{pc}$	[m <sup>2</sup> ]	2E-3	2E-3	2E-3	-
$C_{rh}$	[m <sup>2</sup> ]	-	-	-	10E-3
$T_a$	[c <sup>o</sup> ]	28	28	28	-
$T_w$	[c <sup>o</sup> ]	32	32	32	-
$T_r$	[c <sup>o</sup> ]	-	-	-	30
$Mw$	[g]	30	30	20	20


## 2.2 MÉTODOS NUMÉRICOS APLICADOS

Os métodos numéricos computacionais despontam como ferramentas indispensáveis na resolução de problemas de engenharia, tamanha é sua relevância na capacidade de abordar desafios complexos antes considerados intratáveis. A automatização proporcionada pelos computadores garante soluções precisas e eficientes, mesmo para problemas com alto grau de complexidade, liberando tempo e recursos humanos para atividades mais estratégicas e criativas, como a formulação do problema e a interpretação da solução (CHAPRA; CANALE, 2011).

Nesse contexto, os métodos numéricos computacionais assumem um papel fundamental na engenharia moderna, abrindo um leque de possibilidades para a resolução de problemas complexos e o desenvolvimento de soluções inovadoras. Através da combinação de poder computacional e expertise humana, os métodos numéricos impulsionam o progresso tecnológico em diversas áreas, desde a construção civil até a medicina e a indústria

como um todo.

O cálculo é a matemática da variação. De acordo com o dicionário, diferenciação significa marcar por diferenças ou, em outras palavras, discernir a diferença. Matematicamente, a derivada representa a taxa de variação de uma variável dependente em relação a uma variável independente. Como mostrado na Figura 2.2.



**Figura 2.2** Representação gráfica de uma derivada.

Fonte: (CHAPRA; CANALE, 2011)

Ao passo que  $\Delta x$  se aproxima de zero, como ao nos movermos da Figura 2.2 de a para c, a diferença tende à derivada. Essa aproximação nos permite estabelecer uma ponte entre a derivação, que foca na taxa de mudança instantânea de uma função em um ponto específico, e a integração, que se concentra no processo de acumulação ao longo de um intervalo.

A integração se configura como o processo inverso da derivação, análogo à junção das partes de um todo. Se a derivação nos fornece a taxa de mudança, a integração nos permite calcular a mudança total. A derivação e a integração, embora pareçam conceitos distintos, são ferramentas complementares que se entrelaçam para fornecer uma compreensão mais profunda do comportamento de funções e sistemas.

A integração é um processo matemático fundamental para encontrar soluções para equações diferenciais (EDOs). EDOs são ferramentas matemáticas que descrevem como uma função desconhecida e suas derivadas mudam em relação a uma ou mais variáveis. Quando combinadas com as leis de conservação de energia, massa e momento, as EDOs permitem modelar o comportamento de diversos sistemas físicos. A integração subsequente dessas equações resulta em funções matemáticas que descrevem o estado espacial e temporal do sistema em termos da variação de energia, massa ou velocidade. Por



exemplo, a altura de um objeto em queda livre pode ser modelada por uma EDO. A integração dessa EDO fornece a função que descreve a altura do objeto em qualquer instante de tempo (CHAPRA; CANALE, 2011).

Para solucionar EDOs complexas, os métodos de diferenças numéricas fornecem ferramentas para calcular aproximações numéricas de derivadas e integrais. Estes métodos são flexíveis, fáceis de implementar em computadores e permitem modelar, analisar e simular o comportamento de sistemas em diversos campos, como engenharia e ciência.

Neste trabalho, o modelo fenomenológico é representado por equações diferenciais ordinárias e as soluções destas foram obtidas utilizando dois tipos de métodos numéricos: diferenças finitas e diferenças automáticas

**Diferenças Finitas:** A estratégia do método de diferenças finitas (DF) consiste em construir equações algébricas que aproximem a solução em cada ponto da malha. Para isso, as derivadas são aproximadas por expressões algébricas que relacionam o valor da solução em pontos adjacentes da malha. A escolha da forma de aproximação depende da precisão desejada, da natureza do problema e das condições de contorno. Todas as formas de aproximação utilizadas no método de diferenças finitas derivam da aproximação em série de Taylor em torno de cada ponto da malha.

A derivada  $f'(x)$  de uma função  $f(x)$  no ponto  $x = a$  é definida como:

$$f'(a) = \lim_{x \rightarrow a} \frac{f(x) - f(a)}{x - a} . \quad (2.37)$$

A derivada de uma função em  $x = a$  representa a inclinação da curva da função naquele ponto específico. Para aproximar numericamente essa inclinação, podemos utilizar o método das diferenças finitas. Nesse método, utiliza valores da função em um entorno de  $x = a$  para estimar a inclinação. Existem várias fórmulas de diferenças finitas utilizadas em diferentes situações, e apresentaremos três delas que calculam a derivada usando apenas dois pontos, conforme Kong, Siau e Bayen (2021).

A diferença para frente (*forward difference*) é uma técnica para aproximar a inclinação (derivada) de uma função em um ponto específico  $x_j$  usando a reta que conecta apenas dois pontos: o próprio ponto  $x_j$  e o seu vizinho à direita  $x_{j+1}$ :

$$f'(j) = \frac{f(x_{j+1}) - f(x_j)}{x_{j+1} - x_j} . \quad (2.38)$$

A diferença para trás (*backward difference*) também estima a inclinação (derivada) de uma função em um ponto específico  $x_j$ , mas utilizando uma abordagem ligeiramente diferente. Ela calcula a inclinação da reta que conecta dois pontos: o próprio ponto  $x_j$  e


o seu vizinho à esquerda  $x_{j-1}$ .

$$f'(j) = \frac{f(x_j) - f(x_{j-1})}{x_j - x_{j-1}}. \quad (2.39)$$

diferença central (*central difference*) busca o Equilíbrio na Inclinação. Diferentemente das abordagens para frente e para trás, a diferença central estima a inclinação (derivada) de uma função em um ponto específico  $x_j$  buscando um equilíbrio. Ela utiliza a reta que conecta dois pontos equidistantes do ponto alvo  $x_j$ : seu vizinho à direita  $x_{j+1}$  e seu vizinho à esquerda  $x_{j-1}$ .

$$f'(j) = \frac{f(x_{j+1}) - f(x_{j-1}))}{x_{j+1} - x_{j-1}}. \quad (2.40)$$

A Figura 2.3 ilustra as três diferentes fórmulas necessárias para estimar a inclinação.



**Figura 2.3** Aproximação da derivada por diferenças finitas.

Fonte: (KONG; SIAUW; BAYEN, 2021)

Diferenças automática: A diferenciação automática (DA) é uma ferramenta poderosa para calcular derivadas de funções complexas de forma eficiente. Ela se baseia na regra da cadeia do cálculo, quebrando a função em operações simples como adições e multiplicações. As derivadas dessas operações são fáceis de calcular, e a regra da cadeia é aplicada sucessivamente para obter as derivadas da função completa em relação às suas variáveis de entrada. O desenvolvimento manual de código para calcular derivadas analíticas de funções complexas é uma tarefa árdua e propensa a erros. Ferramentas de manipulação simbólica podem diferenciar equações individuais, mas o código real geralmente possui um fluxo de controle complexo, com instruções condicionais, loops, chamadas de sub-rotinas e estruturas de dados mutáveis. Se o programa original

for sujeito a mudanças frequentes, automatizar a transformação em um programa que calcula derivadas se torna ainda mais desejável. Essa foi a principal motivação para o desenvolvimento da Diferenciação Automática (GEBREMEDHIN; WALTHER, 2020; BARTHOLOMEW-BIGGS et al., 2000).

As duas abordagens básicas da Diferenciação Automática (DA) são o modo direto e o modo reverso. Cada modo permite calcular derivadas de funções compostas por operações elementares, como soma, multiplicação e funções trigonométricas.

Conforme Gebremedhin e Walther (2020), a diferenciação algorítmica baseia-se na aplicação da regra da cadeia, permitindo calcular derivadas de funções compostas por operações elementares. Essa técnica propaga as derivadas junto com a avaliação da função durante a execução de um código, simplificando o processo. Matematicamente, essa propagação pode ser interpretada como o cálculo de informações tangentes. Considere um vetor argumento  $x$  que representa o valor de uma trajetória dependente do tempo  $x(t)$  em  $t = 0$ . Essa trajetória define uma tangente  $\dot{x} = \partial/\partial t|_{t=0}$ .

No modo direto da DA, calculamos a tangente  $\dot{y}$  resultante da trajetória dependente do tempo  $F(x(t))$ . Essa tangente é bem definida se a função  $F$  for suficientemente suave, o que significa:

$$\dot{y} = \frac{\partial}{\partial t} F(x(t))|_{t=0} = F'(x(t)) \frac{\partial x(t)}{\partial t}|_{t=0} = F'(x) \dot{x} \equiv \dot{F}(x, \dot{x}). \quad (2.41)$$

Interpretação da equação:

Primeiro termo:  $\dot{y} = \frac{\partial}{\partial t} F(x(t))|_{t=0}$  representa a derivada total de  $y$  em relação ao tempo. Indica a taxa de variação de  $y$  no tempo específico  $t_0$ .

Segundo termo:  $F'(x(t)) \frac{\partial x(t)}{\partial t}|_{t=0}$  expressa a regra da cadeia aplicada à função composta  $y = F(x(t))$ . Multiplica a derivada parcial de  $F$  (inclinação da tangente de  $F$ ) pelo valor da taxa de variação de  $x$  (inclinação da tangente de  $x$ ) no tempo  $t_0$ .

Terceiro termo:  $F'(x) \dot{x}$  simplifica o segundo termo, já que  $x(t_0) = x$  no valor instantâneo  $t_0$ .

Quarto termo:  $\dot{F}(x, \dot{x})$  representa a forma mais compacta da equação, escrevendo a taxa de variação de  $y$  como a própria taxa de variação de  $F$  avaliada com  $x$  e sua taxa de variação.

No modo reverso, as derivadas são calculadas retroativamente. Começamos com o valor final da função e propagamos as informações de sensibilidade para as variáveis de entrada. As informações de sensibilidade representam como uma pequena mudança na entrada afetará o valor final da função (GEBREMEDHIN; WALTHER, 2020).

A diferenciação numérica utiliza uma abordagem empírica, estimando a derivada através da avaliação da função em pontos próximos e calculando a inclinação da secante, a diferenciação automática, por outro lado, utiliza uma abordagem analítica, decompondo a derivada complexa em operações mais simples usando a regra da cadeia. Em resumo, a diferenciação numérica é uma técnica simples e robusta, mas pode ser imprecisa e custosa. A diferenciação automática é mais precisa e eficiente, mas exige conhecimento da estrutura interna da função e pode ser menos eficiente para funções com muitas operações intermediárias. A escolha da melhor técnica depende das características da função, da precisão desejada e dos recursos computacionais disponíveis.

Quando se trata de métodos numéricos, deve-se levar em consideração que a instabilidade numérica é um desafio crucial que surge ao utilizar tais métodos para solucionar EDOs. Ela se refere ao crescimento descontrolado de erros durante a computação, comprometendo a precisão e confiabilidade da solução. Imagine um barco navegando em um mar turbulento: as ondas (erros) podem aumentar gradativamente, levando o barco (solução) a um destino incerto (CHAPRA; CANALE, 2011).

No combate à instabilidade numérica em EDOs, dois métodos se destacam: diferenças finitas (DF) e diferenças automáticas (DA). Cada um possui suas armas e fraquezas, tornando a escolha do vencedor dependente das características da EDO em questão e dos recursos disponíveis.

Diferenças finitas permitem a discretização de EDOs de diversos tipos e com diferentes condições de contorno. Além disso, podem ser mais eficientes que diferenças automáticas (DA) para EDOs com estrutura simples. Por outro lado, a implementação da discretização pode levar a erros que amplificam a instabilidade numérica. Por isso, as diferenças finitas tendem a ser mais suscetíveis à instabilidade numérica em comparação com DA (CHAPRA; CANALE, 2011; GEBREMEDHIN; WALTHER, 2020).

Diferenças automáticas gera código automaticamente, reduzindo erros humanos e aumentando a precisão e menos propensa à instabilidade numérica devido à derivação precisa das equações diferenciais. Porém, A DA deriva as equações diferenciais automaticamente, utilizando regras predefinidas. Isso limita sua capacidade de lidar com condições de contorno complexas que exigem manipulações matemáticas específicas (GEBREMEDHIN; WALTHER, 2020).

Enfim, a DA oferece uma vantagem que a torna menos propensa à instabilidade numérica: a derivação simbólica das equações diferenciais, que evita erros de arredondamento e truncamento introduzidos na discretização manual.

## 2.3 ESTIMADOR DE HORIZONTE MÓVEL (MHE)

Conforme mencionado anteriormente, as medições de vazões em tempo real e individuais dos poços de petróleo nem sempre estão disponíveis, principalmente quando o assunto é produção de petróleo *offshore*. Essas medições podem até ser adquiridas por meio de medidores físicos ou testes de medições, mas essas opções implicam em um certo custo de investimento e manutenção dos medidores físicos. O teste de medições é obrigatório para ANP, e durante esse procedimento, o poço é alinhado para o separador de teste, garantindo uma produção estável e sem perdas.

No entanto, essa opção implica em um certo custo de investimento e manutenção dos equipamentos utilizados no teste. Ambos os métodos de medições citados resultam em altos custos. No entanto, as vazões são informações necessárias para executar o processo de otimização diária.

Neste contexto, os sensores virtuais surgem com uma alternativa para o monitoramento de áreas críticas, a fim de substituir os instrumentos que apresentam um alto investimento e, conseqüente, diminuir os custos de manutenção e calibração. Embora, impliquem no aumento da complexidade matemática e de um certo poder computacional, seu uso vêm sendo cada vez mais importante para o monitoramento de processo devido a sua robustez em estimar sinais não medidos.

Os sensores virtuais são técnicas que utilizam modelos matemáticos para estimação de variáveis de estado não observáveis baseado em variáveis observáveis, ou seja, permitir identificar o estado oculto de uma sistema dinâmico com base em variáveis medidas fisicamente.

Existem diferentes tipos de estimadores de estado, tais como o filtro de Kalman estendido discreto, o filtro de Kalman estendido com restrições e o filtro de Kalman sem rastro (*Unscented Kalman Filter* - UKF). Neste estudo, considerando as restrições existentes no processo de produção, especialmente no *Gas Lift*, o foco é no estimador de horizonte móvel. Essa técnica de estimativa de estado é baseada em otimização dinâmica, onde o estado atual do sistema é estimado com base em uma sequência finita de medições passadas.

Nesse contexto, o processo é descrito como um modelo discreto não linear conforme as Equações (2.42) e (2.43).

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \Theta_{k-1} , \quad (2.42)$$

$$\mathbf{y}_k = h(\mathbf{x}_k, \mathbf{u}_k) + d_k . \quad (2.43)$$

Em que,  $f(\cdot)$  é uma função não linear que descreve o comportamento dinâmico do sistema e  $h(\cdot)$  é a função de mapeamento de  $\mathbf{x}$ , ou seja, a função que relaciona os estados com as saídas.  $\mathbf{x}_k$  é o vetor de estado,  $\mathbf{u}_k$  é o vetor de entrada,  $\mathbf{y}_k$  é o vetor de saída, por fim,  $\Theta$  contém as parcelas relativas aos erros de modelagem e  $d_k$  são os ruídos de medições, ambos são ruídos brancos com média zero, independentes entre si e com distribuição de probabilidade normal.

O principal objetivo do MHE neste trabalho é fornecer soluções off-line, ou seja, gerar os dados necessários para treinar a RNA proposta, principalmente as vazões de óleo e gás de cada poço em função das variáveis medidas disponíveis. Para isso, serão consideradas como medidas a pressão do anular, a pressão de topo do poço e a pressão de topo no *riser*.

Dado o modelo, o MHE pode ser formulado a partir de uma função de custo quadrática que penaliza o erro entre a predição do modelo e as medições do sistema. Por se tratar de um problema de otimização dinâmico restrito e não linear, é descrito pelas seguintes equações, conforme Mehrez, Mann e Gosine (2014).

$$\min_{\mathbf{x}_0 \dots \mathbf{x}_N} J_N(\mathbf{x}, \mathbf{u}) = \sum_{k=q-N}^q \|\tilde{\mathbf{y}}_k - \mathbf{y}_k\|_{\nu_k}^2 + \sum_{k=q-N}^{q-1} \|\tilde{\mathbf{u}}_k - \mathbf{u}_k\|_{\omega_k}^2, \quad (2.44)$$

$$\mathbf{u}_0 \dots \mathbf{u}_{N-1}$$

s.a :

$$\mathbf{x} = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}), \quad \forall q-N \leq k \leq q-1, \quad (2.45)$$

$$\mathbf{y}_k = h(\mathbf{x}_k, \mathbf{u}_k), \quad \forall q-N \leq k \leq q-1, \quad (2.46)$$

$$\mathbf{x}_k^{inf} \leq \mathbf{x}_k \leq \mathbf{x}_k^{sup}, \quad \forall q-N \leq k \leq q, \quad (2.47)$$

$$\mathbf{u}_k^{inf} \leq \mathbf{u}_k \leq \mathbf{u}_k^{sup}, \quad \forall q-N \leq k \leq q. \quad (2.48)$$

Em que:  $k$  indica o instante atual,  $\tilde{\mathbf{y}}_k$  é a medição do GL,  $\mathbf{y}_k$  é a saída estimada,  $\tilde{\mathbf{u}}_k$  é a entrada medida,  $\mathbf{u}_k$  é a entrada desejada,  $N$  é o horizonte de predição,  $\nu_k > 0$  e  $\omega_k > 0$  são as matrizes de ponderação diagonal.

Neste trabalho, o estimador de estados tem como objetivo filtrar as variáveis medidas e estimar as vazões individuais de óleo, gás em cada poço e de topo do *riser*, sem violar as restrições da planta. Além disso, as diferenças entre as entradas também são consideradas no problema de otimização, a fim de contabilizar os desvios efetivos aplicados ao sistema, por exemplo, a incerteza na vazão de injeção de gás no anular e/ou a imprecisão do atuador.

## 2.4 SISTEMA BASEADO EM DADOS

Essa modelagem baseia-se na análise de dados de séries temporais, por meio da qual são encontradas as ligações entre as variáveis de estado do sistema (variáveis de entrada, internas e de saída). Essas relações são identificadas através de equações matemáticas que não são derivadas de processos físicos, tais como a geometria do poço, os equipamentos de superfície e subsuperfície, a espessura das linhas de escoamento, etc.

Os recentes desenvolvimentos na inteligência computacional, em particular na área da aprendizagem de máquinas, expandiram grandemente as capacidades da modelagem empírica. Assim, o campo que engloba essas novas abordagens é denominado modelagem baseada em dados e vem tornando-se muito popular nos últimos anos, não apenas para aplicações em petróleo e gás, mas também para muitas outras áreas, conforme explicam os autores Bikhmukhametov e Jäschke (2020) e Solomatine, See e Abrahart (2008).

Dentre as principais técnicas de modelagem orientada a dados, estão incluídos os sistemas baseados em regras difusas, os algoritmos genéticos e as redes neurais artificiais, sendo esta última a abordagem adotada neste trabalho.

Um neurônio é uma unidade básica de processamento de informação que se baseia no funcionamento do cérebro humano, imitando o modo como os neurônios biológicos se comunicam (trocas de sinais). Segundo Goodfellow, Bengio e Courville (2016), as redes neurais artificiais (RNAs) são compostas por modelos matemáticos de neurônios artificiais conectados uns aos outros. Cada um recebe os sinais de entradas externas ou de outros neurônios, pondera esse conjunto através de pesos (multiplicação e somatório) e passa por uma função de ativação ou transferência, tal como uma sigmoide ou logística, conforme ilustrado na Figura 2.4.


Em termos matemáticos, um neurônio  $n$  pode ser descrito pelas seguintes equações, Goodfellow, Bengio e Courville (2016):

$$z_n = \sum_{j=1}^m \mathbf{W}_{n_j} \mathbf{i}_{n_j} , \quad (2.49)$$

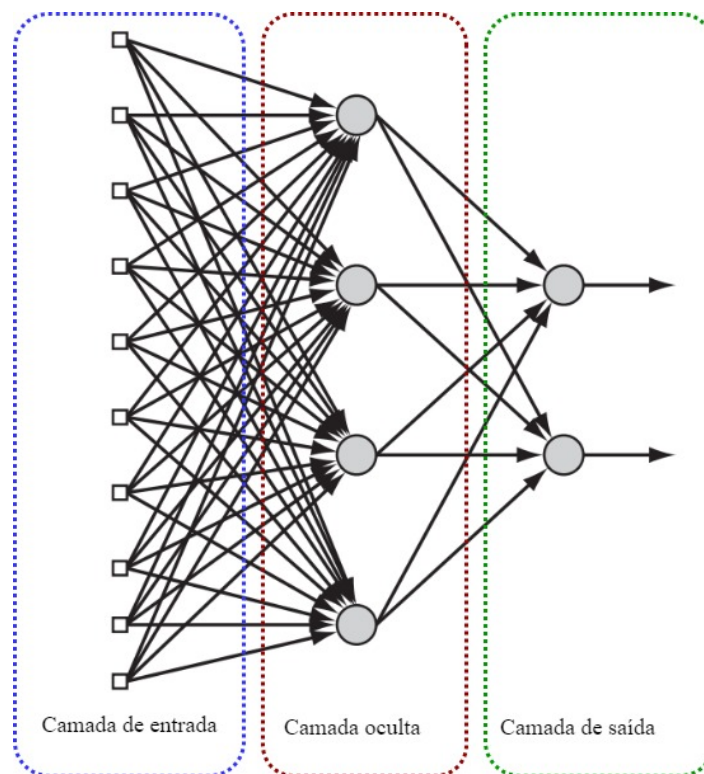
$$y_n = \varphi(z_n + b_n) . \quad (2.50)$$

sendo que,  $\mathbf{i}_n$  é o vetor de entrada,  $\mathbf{W}_n$  é o vetor de peso sináptico,  $b_n$  é o bias,  $\varphi$  é a função de ativação e  $y_n$  é o sinal de saída do neurônio.

Como dito anteriormente, uma rede neural é formada por um conjunto de neurônios, contendo uma camada de entrada, uma de saída e um ou mais camadas ocultas. A Figura 2.5 simboliza uma rede neural do tipo *feedforward*.



**Figura 2.4** Representação de um neurônio não linear.



**Figura 2.5** Arquitetura simplificada de uma rede *feedforward*

Fonte: Goodfellow, Bengio e Courville (2016).

A camada oculta é o componente essencial que permite à rede neural aprender as relações entre os dados. Ao adicionar uma ou mais camadas ocultas, a rede é habilitada a



extrair estatísticas de ordem superior da camada de entrada, adquirindo uma perspectiva mais rigorosa devido ao conjunto extra de ligações sinápticas. Esta estrutura de neurônios é conhecida por apresentar uma propriedade interessante: a de ser um aproximador universal, conforme destacam Bikmukhametov e Jäschke (2020), Goodfellow, Bengio e Courville (2016) e Soares, Secchi e Souza (2022).

”Um aproximador universal” refere-se à capacidade das redes neurais de aproximar qualquer função contínua com precisão arbitrária, desde que tenham camadas ocultas suficientes e parâmetros adequadamente ajustados. Isso significa que, teoricamente, uma rede neural profunda com camadas ocultas pode representar qualquer função matemática contínua, tornando-a uma ferramenta poderosa para modelar relações complexas entre os dados (GOODFELLOW; BENGIO; COURVILLE, 2016; BIKMUKHAMETOV; JÄSCHKE, 2020).

As redes neurais podem ser classificadas em estáticas e dinâmicas: i) Redes estáticas são aquelas que não possuem elementos de realimentação (*feedback*), não contêm atrasos nas entradas (*delays*), e suas saídas dependem apenas de suas entradas e conexões ao longo de sua arquitetura. ii) Redes dinâmicas são aquelas que possuem pelo menos um laço de realimentação ou atraso, e, dependendo da arquitetura, podem ter ambos. Por esse motivo, as saídas dependem das entradas, conexões e estados.

Tendo em vista o aspecto de comportamento dinâmico do processo do GL, compreende-se que é necessária uma arquitetura de uma rede dinâmica para representar o sistema GL. Conforme Bianchi et al. (2017), existem diferentes redes dinâmicas que são capazes de fazer previsões de séries temporais. Segundo os autores, a rede neural recorrente de Elman (ERNN, *Elman Recurrent Neural Network*) foi pioneira e é considerada uma versão base para outras redes, tais como *nonlinear auto-regressive with exogenous inputs* (NARX) e *Echo State Network* (ESN), incluindo redes mais complexas, por exemplo, a arquitetura *Short-Term Memory* (LSTM) e a *Gated Recurrent Unit* (GRU).

A arquitetura ERNN é constituída por uma camada de entrada e uma camada de saída sendo caracterizadas por conexões *feedforward* e uma camada oculta que abrange a recorrência, ou seja, *feedback*. Então, em cada passo de tempo  $k$  as entradas  $\mathbf{e}_k \in \mathbb{R}^{N_i}$  da série de entrada são somadas com o vetor de bias de entrada  $\mathbf{b}_i \in \mathbb{R}^{N_h}$  ( $N_h$  é o número de nó da camada oculta) e multiplicado pela matriz de pesos de entrada  $\mathbf{W}_i^{h_n} \in \mathbb{R}^{N_h \times N_i}$ . De maneira semelhante, a mesma operação acontece os estados internos  $\mathbf{h}_{nk-1} \in \mathbb{R}^{N_h}$ , bias internas  $\mathbf{b}_{h_n} \in \mathbb{R}^{N_h}$  e pesos os internos  $\mathbf{W}_{h_n}^{h_n} \in \mathbb{R}^{N_h \times N_h}$ , logo as entradas e os estados passados são combinados e processados pela transformação não linear da camada oculta e posteriormente, pela transformação linear da camada de saída. Atualização do estado

interno e a saída da rede no tempo são representados pelas equações abaixo (BIANCHI et al., 2017).

$$\mathbf{h}_{nk} = fn \left( \mathbf{W}_i^{h_n} (\mathbf{e}_k + \mathbf{b}_i) + \mathbf{W}_{h_n}^{h_n} (\mathbf{h}_{nk-1} + \mathbf{b}_{h_n}) \right), \quad (2.51)$$

$$\mathbf{y}_{nk} = gn \left( \mathbf{W}_{h_n}^o (\mathbf{h}_{nk} + \mathbf{b}_o) \right). \quad (2.52)$$

Em que,  $fn(\cdot)$  é a função de ativação geralmente implementada por uma sigmoide ou uma tangente hiperbólica,  $\mathbf{h}_{nk}$  é o estado oculto responsável pela memória da rede,  $\mathbf{y}_{nk} \in \mathbb{R}^{N_o}$  é a saída,  $gn(\cdot)$  é a função de ativação de saída usualmente linear, por fim,  $\mathbf{W}_{h_n}^o \in \mathbb{R}^{N_h \times N_o}$  é a matriz de peso de saída e  $\mathbf{b}_o \in \mathbb{R}^{N_o}$  é o vetor de bias de saída.

Como mencionado anteriormente, as redes ERNN inspiraram outros modelos, incluindo a arquitetura *nonlinear auto-regressive with eXogenous inputs* (NARX) empregada nesta pesquisa. Essa escolha foi feita com base na constatação de que a rede é capaz de fazer previsões precisas de um passo à frente, ou seja, estimar o valor futuro de uma variável em um único ponto no tempo após receber as informações disponíveis até o momento presente do GL. A NARX é uma rede dinâmica com camadas internas *feedforward*, onde a recorrência é dada pelo *feedback* das saídas previstas e não a partir dos estados internos, como na ERNN (BIANCHI et al., 2017); (XIE; TANG; LIAO, 2009). Segundo os autores, a rede NARX pode ser implementada como um perceptron multicamadas (MLP), onde o sinal de saída  $\mathbf{y}_{nk} \in \mathbb{R}^{N_{yn}}$  é regredido pelos  $d_{yn}$  valores anteriores do sinal de saída, e o sinal de entrada  $\mathbf{e}_k \in \mathbb{R}^{N_e}$  é regredido pelos  $d_e$  valores anteriores do sinal de entrada. Dessa forma, a saída no tempo  $k$  pode ser representada pela Equação (2.53).

$$\mathbf{y}_{nk} = \phi \left( \mathbf{e}_{k-d_e}, \dots, \mathbf{e}_{k-1}, \mathbf{e}_k; \mathbf{y}_{nk-d_{yn}}, \dots, \mathbf{y}_{nk-1}, \mathbf{y}_{nk}; \Phi \right), \quad (2.53)$$

onde,  $\phi$  é a função de mapeamento não-linear executada pelo MLP e  $\Phi$  são os parâmetros de treinamento. Logo a entrada total da rede  $\mathbf{i}_k$  têm componentes de  $d_e N_e + d_{yn} N_{yn}$  que corresponde a um conjunto de duas linha de *Tapped-Delay Lines* (TDLs), sendo descrita pela Equação (2.54), .

$$\mathbf{i}_k = \begin{bmatrix} (\mathbf{e}_{k-d_e}, \dots, \mathbf{e}_{k-1})^\top \\ (\mathbf{y}_{nk-d_{yn}}, \dots, \mathbf{y}_{nk-1})^\top \end{bmatrix}^\top, \quad (2.54)$$

Por fim, a arquitetura da rede consiste de uma camada de entrada,  $N_l \geq 1$  camada oculta e uma camada de saída, na qual estão representadas nas seguintes equações:

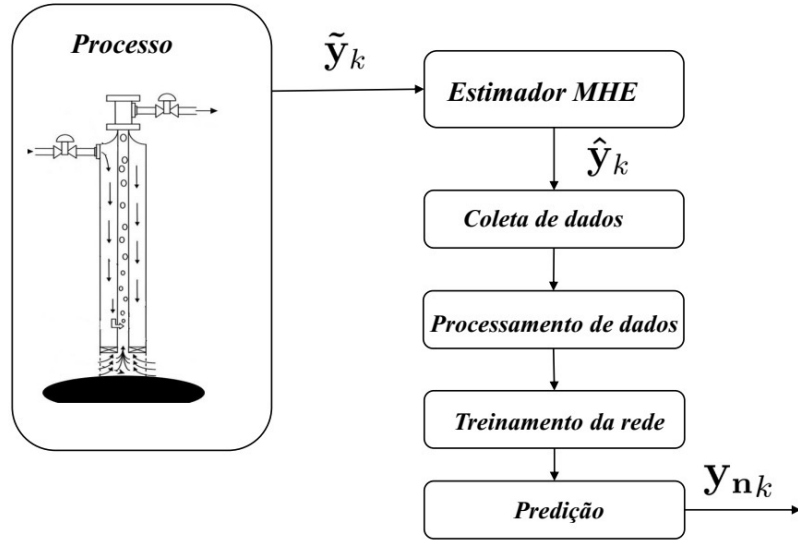
$$\mathbf{h}_{n1k} = fn \left( \mathbf{W}_i^{h_{n1}} (\mathbf{i}_k + \mathbf{b}_{h_{n1}}) \right), \quad (2.55)$$

$$\mathbf{h}_{nlk} = fn \left( \mathbf{W}_{h_{n_{l-1}}}^{h_{n_l}} (\mathbf{h}_{n_{l-1}(k-1)} + \mathbf{b}_{h_{n_l}}) \right), \quad (2.56)$$

$$\mathbf{y}_{nk} = gn \left( \mathbf{W}_{h_{n_{N_l}}}^o (\mathbf{h}_{n_{N_l}(k-1)} + \mathbf{b}_o) \right), \quad (2.57)$$

em que,  $\mathbf{h}_{nlk} \in \mathbb{R}^{N_{h_{n_l}}}$  é a saída da  $l^{th}$  camada oculta no tempo  $k$ ,  $fn(\cdot)$  é a função de transferência não linear,  $gn(\cdot)$  é a função de transferência linear,  $\mathbf{W}_i^{h_{n1}} \in \mathbb{R}^{d_e N_e + d_{yn} N_{yn} \times N_{h_{n1}}}$  e  $\mathbf{b}_{h_{n1}} \in \mathbb{R}^{N_{h_{n1}}}$  são os parâmetros ( pesos e bias) da camada de entrada,  $\mathbf{W}_{h_{n_{l-1}}}^{h_{n_l}} \in \mathbb{R}^{N_{h_{n_{l-1}}} \times N_{h_{n_l}}}$  e  $\mathbf{b}_{h_{n_l}} \in \mathbb{R}^{N_{h_{n_l}}}$  são os parâmetros da  $l^{th}$  camada de oculta e por fim,  $\mathbf{W}_{h_{n_{N_l}}}^o \in \mathbb{R}^{N_{N_l} \times N_{yn}}$  e  $\mathbf{b}_o \in \mathbb{R}^{N_{yn}}$  são os parâmetros da camada de saída.

Em síntese, a proposta de desenvolvimento do modelo orientada a dados aplicada neste trabalho está representada na Figura 2.6. Nessa representação,  $\tilde{\mathbf{y}}_k$  é o vetor de saída da planta, ou seja, as variáveis medidas (especificamente pressões). Já  $\hat{\mathbf{y}}_k$  é a saída estimada do MHE, que inclui os valores medidos filtrados e as novas variáveis estimadas, como as vazões mássicas.



**Figura 2.6** Visão geral da proposta aplicada ao processo de treinamento do modelo orientado a dados.

Uma vez que um conjunto de dados suficiente é coletado, esses dados são preparados e utilizados para treinar a rede neural artificial. Após o treinamento, o modelo poderá ser

usado para fazer previsões com um passo à frente  $\mathbf{y}_{n_k}$ , ou seja, estimar os valores futuros das variáveis após receber as informações disponíveis até o momento presente

A atividade de identificação e modelagem de sistemas é de fundamental importância em sistemas de otimização em tempo real, estimadores de estados e controle preditivo. Diversos algoritmos, tais como controle preditivo e otimização em tempo real, dedicam grande esforço para encontrar abordagens adequadas para representar os sistemas que se deseja controlar ou otimizar. No entanto, as etapas tradicionais desse processo têm se mostrado dispendiosas, demoradas e pouco efetivas em problemas industriais de maior complexidade (ORENSTEIN, 2013).

A aplicação de redes neurais pode trazer uma abordagem mais promissora para a identificação e modelagem de sistemas, pois essas redes têm demonstrado excelente capacidade de aproximação de funções complexas e são conhecidas por lidar bem com dados não lineares e multidimensionais. Sua flexibilidade e eficácia podem oferecer soluções mais rápidas e precisas para os desafios de controle e otimização em contextos industriais de grande escala.

Conforme Orenstein (2013), O princípio básico por trás da identificação de sistemas consiste em perturbar o processo de interesse a fim de se obter uma representação do mesmo. Para isto, é aplicado um sinal conhecido a um conjunto de variáveis que podem ser manipuladas, chamadas de entradas. Uma vez aplicada a excitação definida ao sistema, são medidas as respostas do sistema no decorrer do tempo. Com base nas entradas e saídas, a rede neural busca aprender e estabelecer relações matemáticas entre elas, criando um modelo que correlaciona eficientemente as entradas fornecidas com as respectivas saídas desejadas.

O sucesso do processo de treinamento da RNA depende em grande parte dos dados coletados do sistema que se deseja modelar. Entretanto, as entradas projetadas podem não excitar o sistema em regiões importantes, resultando em dados pouco informativos e modelos que não representam suas verdadeiras características. Isso leva ao desperdício de esforço, tempo e recursos para obter tais dados, tornando necessários novos testes para complementá-los. Além disso, as perturbações aplicadas no sistema podem variar dependendo da finalidade do modelo e das restrições operacionais, o que requer um projeto ótimo de sinal para teste (WAGNER, 2015; ORENSTEIN, 2013). Embora este trabalho não esteja focado no projeto ótimo de sinal, é fundamental considerar alguns aspectos para obter resultados significativos no treinamento da RNA.

Segundo Wagner (2015) e Orenstein (2013), apesar da identificação de modelos caixa preta ser bastante utilizada na indústria, ainda não há consenso sobre o método de

perturbação adequado para cada característica de processo, seja para sistemas bem ou mal condicionados. No entanto, existem alguns métodos disponíveis na literatura que podem auxiliar nessa questão, por exemplo, perturbação em degrau, Sinal Binário Pseudo Aleatório (PRBS) e o Ruído Binário Generalizado (GBN). Para maiores informações sobre o métodos disponíveis de sinais, é recomendado consultar os autores mencionados.

O Sinal Binário Pseudo Aleatório (PRBS) é amplamente utilizado na identificação de sistemas. Esse sinal consiste em uma sequência binária aleatória com uma distribuição equilibrada de 0s e 1s, que é ideal para excitar o sistema de forma eficiente e abranger diferentes frequências de excitação. Essa característica é especialmente útil na identificação de sistemas não lineares e com múltiplos graus de liberdade, presentes no GL, onde as relações entre as variáveis podem ser complexas e variáveis ao longo do tempo. Além disso, o PRBS permite obter informações úteis sobre o comportamento dinâmico do sistema, identificando suas características e propriedades fundamentais. Assim, o uso do PRBS na identificação do sistema de GL torna-se uma escolha valiosa para obter modelos precisos e representativos, que são essenciais para o desenvolvimento de estratégias de otimização eficazes nesse cenário complexo de produção de petróleo.

## 2.5 PROBLEMA DE OTIMIZAÇÃO ECONÔMICA

Para realizar otimização dinâmica em tempo real carece de um modelo dinâmico do processo que é usado para resolver o problema de otimização numérico, conforme mencionado no capítulo I. Logo, o modelo do sistema poder ser representado pelas Equações (2.42) e (2.43).

O problema de otimização dinâmico em tempo real (produção diária) é baseado em um modelo não linear da planta (modelo fenomenológico e orientado a dados). Esses modelos são empregados para determinar os valores ótimos das variáveis de decisão, ou seja, as vazões mássicas de gás injetadas no topo do anular e a abertura das *chokes* de produção.

A formulação do problema de otimização é realizada da seguinte maneira:

$$\max_{\mathbf{u}} J(\mathbf{x}, \mathbf{u}) = \beta \mathbf{w}_{to} - \alpha \sum_{j=1}^n \mathbf{w}_{ing} \quad (2.58)$$

s.a :

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}), \quad \mathbf{x}_{k_0} = \hat{\mathbf{x}} \quad (2.59)$$

$$\mathbf{y}_k = h(\mathbf{x}_k, \mathbf{u}_k), \quad (2.60)$$

$$\sum_{i=1}^{p_w} w_{ing} \leq c_p \quad (2.61)$$

$$p_{rh} \geq p_{rt} \quad (2.62)$$

$$\mathbf{x}^{inf} \leq \mathbf{x}_k \leq \mathbf{x}^{sup} \quad (2.63)$$

$$\mathbf{z}^{inf} \leq \mathbf{z}_k \leq \mathbf{z}^{sup} \quad (2.64)$$

$$\mathbf{u}^{inf} \leq \mathbf{u}_k \leq \mathbf{u}^{sup} . \quad (2.65)$$

No qual,  $\hat{\mathbf{x}}$  são as estimativas atuais dos estados,  $\beta$  é preço por metro cúbico do óleo,  $\alpha$  é custo por metro cúbico de gás injetado,  $\mathbf{w}_{to}$  é a vazão mássica óleo produzida no topo do *riser* e  $w_{ing}$  é vazão mássica de gás injetado no topo do anular,  $c_p$  é a capacidade máxima de gás disponível para injeção,  $p_{rh}$  é a pressão no topo do *riser* e  $p_{rt}$  é a pressão requisitada (desejada) no topo do *riser*.

Na prática beta  $\geq$  alfa, o que seria interessante é verificar o ponto em que a injeção de gás prejudica a produção e com a restrição de vazão máxima de GL. será verificada no resultados.

A otimização em tempo real de processos busca ajustar continuamente as variáveis de controle para otimizar o desempenho do processo em resposta a mudanças dinâmicas. As duas principais técnicas para otimização em tempo real são diferenças finitas (DF) e diferenças automáticas (DA).

Nas diferenças finitas, as equações diferenciais que descrevem o processo são discretizadas em pontos específicos do domínio do problema. Esses pontos discretos formam uma malha espacial e/ou temporal, onde as equações discretizadas são resolvidas numericamente. Para a otimização em tempo real, as diferenças finitas podem ser aplicadas em modelos que descrevem o comportamento dinâmico do sistema. No entanto, a implementação da diferenciação numérica para calcular os gradientes necessários na otimização

pode ser computacionalmente intensiva e imprecisa, especialmente para sistemas complexos com muitas variáveis.

A diferenciação numérica é sensível a pequenos erros numéricos, especialmente quando os passos de discretização são muito pequenos. Isso pode resultar em instabilidade numérica e erros de arredondamento que afetam a precisão dos gradientes calculados, especialmente em sistemas complexos onde os erros podem se propagar rapidamente.

A diferenciação automática é uma abordagem mais direta e precisa para calcular gradientes de funções, incluindo aquelas que descrevem processos dinâmicos. Ao invés de discretizar e resolver numericamente as equações diferenciais, a diferenciação automática calcula os gradientes diretamente através de um processo de "propagação" das derivadas ao longo das operações realizadas na função. Isso significa que a diferenciação automática pode ser mais eficiente e precisa do que as diferenças finitas, especialmente para problemas de otimização em tempo real.

Em resumo, enquanto as diferenças finitas envolvem a discretização das equações diferenciais e a resolução numérica, a diferenciação automática calcula diretamente os gradientes das funções envolvidas no processo de otimização. Para problemas de otimização em tempo real, a diferenciação automática tende a ser mais eficiente e precisa, especialmente em sistemas com muitas variáveis.

No entanto, os modelos de redes neurais podem, de fato, mitigar muitos problemas de instabilidade numérica associados a métodos numéricos. Os modelos de redes neurais geralmente lidam bem com instabilidade numérica, uma vez que são treinados para aprender padrões e relações nos dados, em vez de depender de discretizações numéricas das equações. Portanto, a utilização de redes neurais pode ajudar a evitar problemas de instabilidade numérica que podem surgir com métodos numéricos tradicionais.

## 2.6 MATERIAIS UTILIZADOS

A planta GL é representada pelo modelo fenomenológico do processo que foi integrado com solver IDAS na linguagem *MatLab* usando a estrutura *CasADI*. Para o problema de otimização com o modelo orientado a dados foi utilizado o solucionador *fmincon* e a rede neural artificial foi treinada com o algoritmo NARX na linguagem *Matlab*. O computador utilizado foi um core i7 8ª geração com memória (RAM) de 16 GB

O problema de otimização dinâmico com objetivos econômico usando o modelo fenomenológico foi resolvido usando solver IPOPT na linguagem *MatLab* em conjunto com a estrutura de diferenciação automática *CasADI*. Essa mesma estrutura foi usada no estimador de estado MHE.

## 2.7 COMENTÁRIOS

No presente capítulo, descrevemos a metodologia aplicada neste trabalho. Inicialmente, apresentamos um modelo fenomenológico do sistema em questão, com o intuito de solucionar o problema de otimização. Em seguida, propusemos um modelo orientado a dados baseado na rede dinâmica NARX, que consiste em camadas *feedforward* internas e a recorrência é dada pela saída prevista. Para o treinamento deste modelo, é necessário fornecer dados, e para isso, propusemos um sensor virtual baseado em um estimador de estado de horizonte móvel, que requer um modelo fenomenológico do sistema. Utilizamos o modelo fenomenológico proposto anteriormente para este fim. Finalmente, abordamos o problema de otimização dinâmica com objetivos econômicos, que é o principal objetivo deste trabalho. Nesse problema, o modelo fenomenológico é substituído pelo modelo orientado a dados proposto anteriormente.



*Neste capítulo, serão apresentados os principais resultados da simulação relacionados à aplicação de otimização dinâmica em tempo real com objetivos econômicos diários com um passo à frente. Os resultados foram divididos em três estudos de caso, a saber: i) O primeiro está resumido em demonstrar o tempo computacional gasto para encontrar a solução ótima do problema de otimização utilizando modelos fenomenológicos. ii) No segundo, foi realizada uma simulação em loop aberto com a aplicação do sensor virtual e o modelo orientado a dados, seguido de uma comparação. Além disso, foi abordada a aplicação de otimização dinâmica em apenas um poço, utilizando o modelo orientado a dados e o fenomenológico. Neste sistema, buscou-se investigar o desempenho do otimizador em relação ao conjunto de restrições econômicas e operacionais. Por fim, foi feita uma avaliação do tempo computacional. iii) Em seguida, são apresentados os principais resultados da otimização dinâmica em tempo real para uma rede de poços, ou seja, três poços produtores conectados a um riser, representando um sistema de produção offshore. Neste cenário, também foram consideradas as perturbações econômicas e operacionais.*

## **RESULTADOS**

### **3.1 CASO I: RTO DE POÇO COM GL USANDO METODOLOGIA PADRÃO**

Este estudo de caso visa avaliar o tempo computacional gasto para encontrar a solução ótima do problema de otimização utilizando o modelo fenomenológico. Duas técnicas de integração foram utilizadas: a primeira consiste na aplicação de diferenças finitas com o algoritmo ODE15s, e a segunda no uso de diferenciação automática com a estrutura CasADI.

A estrutura de produção considerada é composta por um poço. As variáveis de decisão são a vazão de injeção de gás no topo do anular e a abertura da válvula *choke* de produção. As perturbações dos parâmetros e restrições (econômicos e/ou operacionais) variam ao longo do tempo, especificamente a cada 24 horas.

O modelo representado na forma discreta, conforme as Equações (3.1) e (3.2). As equações mostram como os estados do sistema  $\mathbf{x}_k$  e as saídas do sistema  $\mathbf{y}_k$  são calculados em um intervalo de tempo discreto  $\mathbf{k}$ .

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \Theta_{k-1} , \quad (3.1)$$

$$\mathbf{y}_k = h(\mathbf{x}_k, \mathbf{u}_k) + d_k . \quad (3.2)$$

Em que,  $f(\cdot)$  é uma função não linear que descreve o comportamento dinâmico do sistema e  $h(\cdot)$  é a função de mapeamento de  $\mathbf{x}$ , ou seja, a função que relaciona os estados com as saídas.  $\mathbf{u}_k$  é o vetor de entrada,  $\Theta$  contém as parcelas relativas aos erros de modelagem e  $d_k$  são os ruídos de medições, ambos são ruídos brancos com média zero, independentes entre si e com distribuição de probabilidade normal.

O modelo fenomenológico é integrado por diferenças finitas durante um período de 24 horas com uma taxa de amostragem de 10 segundos. Isso significa que o modelo é atualizado a cada 10 segundos. A cada atualização, o modelo usa os valores dos estados anteriores e das entradas para calcular os novos estados do sistema. A taxa de amostragem de 10 segundos é suficiente para capturar a dinâmica do sistema de produção de petróleo.

No caso de diferenças automática, o modelo também é integrado durante um período de 24 horas. Porém, a taxa de amostragem é definida automaticamente pelo integrador. o mesmo aplicado na solução do problema de otimização.

Isso significa que o modelo é atualizado com a frequência necessária para capturar a dinâmica do sistema com precisão. O integrador usa um algoritmo para estimar a taxa de amostragem ideal.

Neste caso, a integração por diferenças automáticas é uma boa opção, pois o sistema de produção de petróleo é um sistema dinâmico complexo (multifásico). A integração por diferenças automáticas pode capturar a dinâmica do sistema com precisão, garantindo que o processo de otimização seja eficaz.

As perturbações dos parâmetros e restrições são variações no preço do óleo e no custo de cada metro cúbico de gás injetado no anular. Além disso, a pressão requisitada no topo do poço de acordo com o separador também varia. Essas variações são fundamentais para avaliar a solução ótima do otimizador em face de grandes variações financeiras do mercado atual. A Tabela 3.1 apresenta essas variações.

Onde,  $\beta$  é preço do óleo,  $\alpha$  é o custo do gás injetado,  $p_{rt}$  é a pressão requisitada na superfície e  $c_p$  é capacidade máxima de gás disponível.

**Tabela 3.1** Caso I - Perturbações nos parâmetros econômicos e operacionais

Tempo ( $d$ )	$\beta$ (\$)	$\alpha$ (\$)	$p_{rt}$ (bar)	$c_p$ (kg/s)
0	100	200	40	3
1	100	200	40	3
2	150	200	40	3
3	150	150	40	3
4	120	150	40	3
5	120	150	55	3

### 3.1.1 Otimização de um poço equipado com GL


Este estudo de caso foi realizado no contexto da indústria de petróleo e gás. O objetivo do estudo foi comparar o tempo computacional gasto para encontrar a solução ótima do problema de otimização utilizando duas técnicas de integração diferentes: diferenças finitas e diferenciação automática.

A Figura 3.1 apresenta a solução do problema de otimização da produção diária aplicada no processo. As variáveis de decisões são  $w_{ing}$  e  $Z_c$ , sendo respectivamente, a vazão de gás injetada no anular e abertura da válvula da *choke* de produção. Além disso, são consideradas algumas perturbação, que serão mostradas na Tabela 3.1.

De acordo com a Figura 3.1, as soluções encontradas em ambas as aplicações dos modelos, ou seja, solução utilizando diferenças finitas (ODE) e solução utilizando diferenciação automática (MF), denotam respostas análogas. Em todos os casos de otimização foram aplicados o algoritmo de programação não linear de pontos interiores e desempenho das soluções como o modelos orientando a dados serão exploradas no caso II.

Como dito anteriormente, este estudo de caso está focado simplesmente em demonstrar o tempo computacional gasto para encontrar a solução ótima do problema de otimização utilizando o modelo fenomenológico com integradores diferentes. Conforme explanam os resultados na Figura 3.2, a solução que emprega a diferenciação automática na integração do modelo aponta um tempo computacional mais eficiente.

Apesar da notável eficiência computacional da abordagem MF, sua imunidade às questões de instabilidade numérica não é automática. A exigência de integração do modelo cria uma oportunidade para a implementação de uma metodologia híbrida. Nesse sentido, a utilização de um modelo orientado a dados surge como uma alternativa viável. Uma metodologia híbrida pode ser utilizada, combinando a solução MF com um modelo orientado a dados. Além disso, a expansão do modelo pode acarretar em um maior custo computacional, conforme será avaliado nos casos seguintes.



**Figura 3.1** Caso I - Resposta do processo a partir da aplicação das soluções ótimas gerado pelo problema de otimização utilizando o modelo fenomenológico integrado pela diferenciação automática (MF) e o fenomenológico integrado pela diferenciação finita (ODE) .

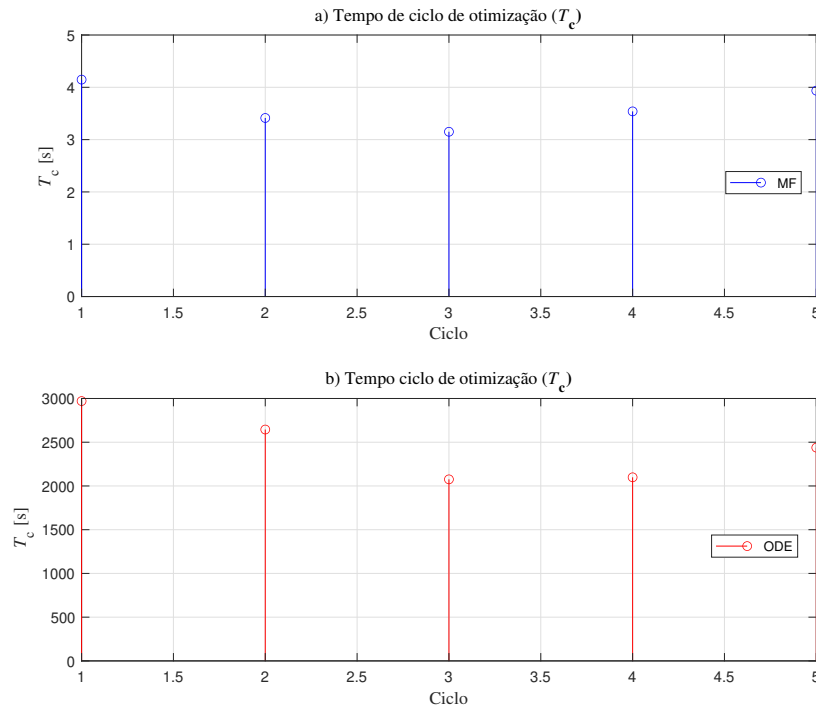
Em resumo, a técnica de diferenciação automática é significativamente mais eficiente em termos de tempo computacional do que a técnica de diferenças finitas para encontrar a solução ótima do problema de otimização utilizando o modelo fenomenológico. No entanto, a solução MF não está isenta do problema de instabilidade numérica, que pode ser mitigado pela utilização de uma metodologia híbrida.

## 3.2 CASO II: RTO DE POÇO COM GL USANDO METODOLOGIA HÍBRIDA

### 3.2.1 Simulação em malha aberta para um poço

Para este estudo de caso as variáveis medidas são as pressões no topo de poço, no topo de anular e a pressão fundo do poço, também conhecida como PDG. Todas as outras variáveis do processo são estimadas, inclusive os estados, porém os estados não foram utilizados no treinamento da rede neural artificial.

As entradas, que correspondem à vazão de injeção de gás no topo do anular e à




**Figura 3.2** caso I - Comparação entre os tempos computacionais

abertura da válvula *choke* de produção, desempenharam o papel de estimular o processo e gerar os dados de treinamento. No entanto, as variações nos estímulos foram engendradas através da combinação das sequências Halton juntamente com os sinais pseudo-aleatórios conhecidos como PRBS, como ilustrado de forma esquemática na Figura 3.3. O conjunto de dados totalizou 55 mil amostras, das quais 70% foram alocadas para o treinamento, reservando os restantes 30% para as etapas de teste e validação no próprio ciclo de treinamento. Não obstante, para efeitos de comparação dos modelos dos resultados finais (conforme a seção de resultados), novas entradas foram geradas através de um mecanismo aleatório alternativo, disponível no ambiente do *MatLab* (diferente do PRBS).

As sequências Halton, conhecidas por sua distribuição uniforme e baixa discrepância, são ferramentas poderosas para amostragem eficiente em espaços multidimensionais. Ao contrário das abordagens de amostragem aleatória tradicionais, as sequências Halton são estruturadas de forma determinística, resultando em uma cobertura mais uniforme do espaço de busca. Isso é especialmente benéfico para identificação de sistema, onde uma amostragem abrangente é essencial para capturar uma visão completa das características do sistema em análise. A uniformidade dessas sequências contribui para evitar bias e

subamostragem, garantindo uma representação mais precisa das regiões de interesse.



**Figura 3.3** Entradas para a identificação do sistema.

Os sinais PRBS (*Pseudo-Random Binary Sequence*) são frequentemente usados para excitar sistemas e adquirir dados experimentais. Esses sinais alternam entre dois estados binários de maneira aparentemente aleatória, o que os torna ideais para estimular uma ampla gama de frequências de interesse em sistemas dinâmicos. Quando esses sinais são aplicados a um sistema, eles provocam respostas que revelam informações sobre as características de dinâmica, estabilidade e comportamento transiente do sistema. Isso se torna crucial na identificação, pois a resposta do sistema a diferentes entradas PRBS permite a extração de parâmetros e modelos que descrevem a relação entre as entradas e saídas.

A combinação do uso de sequências Halton e sinais PRBS fornece uma abordagem holística para identificação de sistema. Essas sequências Halton fornecem uma amostragem sistemática e bem distribuída no espaço de parâmetros, enquanto os sinais PRBS

fornecem uma maneira eficaz de excitar e explorar a resposta dinâmica do sistema. Essa abordagem conjunta permite a obtenção de dados de alta qualidade que são cruciais para treinar modelos, ajustar parâmetros e entender as características intrínsecas do sistema. No processo de treinamento da rede neural artificial, esse mesmo sinal também foi empregado de forma semelhante.

A arquitetura da rede é composta por uma camada oculta com quatro neurônios e uma camada de saída com cinco neurônios. O algoritmo de aprendizagem utilizado foi o *quasi-Newton backpropagation* (BFGS), tendo como função objetivo o erro médio absoluto (MAE - *Mean absolute error*). Os parâmetros da rede foram ajustados de acordo com os testes simulados e conforme o trabalho de Soares, Secchi e Souza (2022). Esses resultados mostram que a rede neural é capaz de representar o sistema de produção de petróleo.

Neste estudo caso, o modelo discretizado é integrado por diferenças automáticas durante um período de 24 horas. A taxa de amostragem é definida automaticamente pelo integrador. O mesmo aplicado na solução do problema de otimização.

Além disso, foi considerada uma estrutura de produção composta por um poço. Assim como na maioria dos processos, existem parâmetros e restrições (econômicos e/ou operacionais) que variam ao longo do tempo e devem ser considerados no problema de otimização. Na produção de petróleo não é diferente. Portanto, com o propósito de enaltecer a importância da tomada de decisões na camada de otimização, foram considerados alguns parâmetros e restrições, tais como o preço do óleo, o custo de compressão do gás, a capacidade de gás disponível na planta e a pressão na topo do poço.


As restrições e parâmetros do sistema são considerados fatores perturbadores que podem variar ao longo do dia. Por esse motivo, o problema de otimização precisa ser resolvido diariamente para obter as novas condições ideais. É importante destacar que o modelo dinâmico é integrado em tempo real, sendo um período total de integração 24 horas.

As variáveis consideradas medidas e utilizadas no MHE são as pressões do anular, pressão de fundo do poço (PDG) e pressão de topo (cabeça do poço). No terceiro estudo de caso, apenas as pressões de topo (anular, cabeça e *riser*) são consideradas como medidas. Isso é feito para investigar o impacto da falta de dados de medição na otimização do sistema.

Inicialmente, foi realizada uma simulação em loop aberto para avaliar o comportamento do modelo orientado a dados em relação ao modelo fenomenológico. As variáveis de pressão foram consideradas como medidas (pontilhada), depois filtradas pelo MHE ([linha azul](#)), e, finalmente, estimadas pelo modelo orientado a dados RNA ([linha vermelha](#)).

A Figura 3.4 e a Figura 3.5 mostram os resultados da simulação em loop aberto.

As vazões de óleo e gás são estimadas pelo MHE com base nas pressões. Essas vazões são então utilizadas para treinar uma rede neural, que é capaz de estimar as vazões. Conforme visualizado na Figura 3.5.




**Figura 3.4** caso II -Predições das pressões de poço de um passo à frente - comparação entre os valores medido GL, sensor virtual MHE e o modelo orientado a dados RNA.

Conforme ilustrado nas Figuras 3.4 e 3.5, o modelo orientado a dados é capaz de acompanhar o comportamento do modelo fenomenológico de forma satisfatória, com erros de previsão relativamente baixos. No entanto, os erros de previsão da rede neural são maiores na previsão de vazão de gás, sugerindo que o modelo pode ser ainda mais preciso se ajustado para esse parâmetro. Apesar disso, o modelo é adequado para aplicações de otimização, pois é capaz de estimar as vazões de óleo e gás produzidas com precisão suficiente. Os resultados do estimador de estado são adequados para esta aplicação, tanto para filtrar as variáveis de medição quanto para estimar as vazões de óleo e gás produzidas.

As redes neurais são uma ferramenta poderosa que pode ser usada para estimar vazões de óleo em poços de petróleo. No entanto, é importante considerar os erros de previsão,





**Figura 3.5** caso II -Predições das vazões de produção poço de um passo à frente - comparação entre os valores medido GL, sensor virtual MHE e o modelo orientado a dados RNA.

que podem ser corrigidos ajustando o modelo ou usando dados de medição adicionais.

### 3.2.2 Otimização de um poço equipado com GL

Para avaliar a solução ótima do otimizador em face a grandes variações financeiras do mercado atual, foram adicionados distúrbios medidos à solução do problema de otimização da produção diária, como variações no preço do óleo e no custo de cada metro cúbico de gás injetado no anular. Além disso, a pressão requisitada no topo do poço sofre alterações ao longo dos dias frente as demandas do separador. A Tabela 3.2 apresenta essas variações.

A estrutura de produção considerada é composta por um poço. As variáveis de decisão são a vazão de injeção de gás no topo do anular e a abertura da válvula *choke* de produção.

Na tabela,  $\beta$  representa o preço do óleo,  $\alpha$  representa o custo do gás injetado,  $p_{rt}$  representa a pressão requisitada na superfície e  $c_p$  representa a capacidade máxima de gás disponível.

**Tabela 3.2** Caso II - Perturbações nos parâmetros econômicos e operacionais

Tempo ( $d$ )	$\beta$ (\$)	$\alpha$ (\$)	$p_{rt}$ (bar)	$c_p$ (kg/s)
0	100	200	40	3
1	100	200	40	3
2	150	200	40	3
3	150	150	40	3
4	120	150	40	3
5	120	150	55	3

A Tabela 3.3 apresenta as decisões ótimas para o problema de otimização.  $w_{ing_1}$  é a vazão ótima de gás injetada no anular,  $Z_c$  é a abertura ótima da válvula da *choke* de produção. MF e RNA representam os modelos usados para a solução do problema de otimização, fenomenológico e orientado a dados, respectivamente.


A Figura 3.6 mostra o desempenho ótimo do processo a partir das soluções.  $w_{po}$  e  $w_{pg}$  são as vazões ótimas de óleo e gás produzidas, e  $F_{ob}$  é a função objetivo, ou seja, o lucro ótimo obtido.

Vale ressaltar que o problema de otimização só é resolvido a partir do primeiro dia. No entanto, as perturbações são as mesmas para o dia zero e o primeiro dia.

**Tabela 3.3** caso II - Soluções ótimas encontradas com o problema de otimização utilizando o modelo orientado a dados e o fenomenológico.

Tempo ( $d$ )	$w_{ing_1}$ (kg/s)	$Z_c$ (%)
	MF - RNA	MF - RNA
0	3,00 - 3,00	99,0 - 99,0
1	0,63 - 0,50	100 - 100
2	1,11 - 0,96	100 - 100
3	1,48 - 1,53	100 - 100
4	0,96 - 0,73	100 - 100
5	3,00 - 3,00	74,6 - 74,1

Ao analisar o desempenho do processo na Figura 3.6 e Tabela 3.3, observa-se que, a partir do dia 0 até o dia 1, o processo está operando com uma taxa de injeção de 3 kg/s de gás, ou seja, na capacidade máxima. Porém, a partir do dia 1, quando o otimizador é acionado, há uma redução brusca na quantidade de gás injetado, assim como também há uma redução nas vazões de óleo e gás produzidas. No entanto, obteve-se um leve acréscimo no lucro. Portanto, nem sempre é vantajoso operar na capacidade máxima de injeção, pois esta ação pode aumentar o custo de injeção e não ter uma melhoria




**Figura 3.6** Caso II - Resposta do processo a partir da aplicação das soluções ótimas gerado pelo problema de otimização utilizando o modelo orientado a dados e fenomenológico.

significativa no lucro.

Nos dias seguintes, 2 e 3, a quantidade de gás injetado cresceu. Este crescimento se deu em função das alternâncias nas variáveis econômicas, como o aumento do preço do óleo no segundo dia e a queda no custo do gás de injeção no terceiro dia. Diante disso, o otimizador agiu para elevar a quantidade de gás injetado, aumentando assim a vazão de óleo produzida e, conseqüentemente, um incremento considerável no lucro. O inverso também acontece quando o preço do óleo reduz.

O aumento de pressão no topo do poço acarreta no fechamento da válvula *choke*. Esse estrangulamento é ainda maior quando a capacidade de gás disponível é reduzida, como pode ser constatado no quinto dia do processo de otimização. Também é possível observar que as restrições são respeitadas e as soluções ótimas nem sempre estão atreladas à disponibilidade máxima de gás. Ou seja, é necessário entender que uma alta taxa de injeção de gás pode não ser a melhor estratégia em determinados momentos.

Um dos objetivos deste trabalho é avaliar o tempo computacional da rotina de oti-



**Figura 3.7** caso II - Comparação entre os tempos computacionais

mização com ambos os modelos. Apesar de o modelo fenomenológico fazer uso da estrutura de diferenciação automática implementada no CasADI V.3.5.5.2 na linguagem MATLAB, sua performance é inferior à do modelo orientado a dados, conforme demonstram os resultados na Figura 3.7. Isso abre a possibilidade para implementações em problemas de larga escala, como a otimização da produção diária do campo de petróleo (vários poços integrados pelo reservatório e *manifold*).


A otimização diária de um poço de petróleo pode ser uma ferramenta valiosa para melhorar a eficiência, reduzir os custos e aumentar a produtividade. Nesse contexto, o uso de modelos matemáticos é fundamental para entender melhor a dinâmica do processo e tomar decisões. A otimização com modelos orientados a dados mostrou-se uma solução eficiente para otimização em tempo real. Os resultados foram muito parecidos com o modelo fenomenológico, mas com um tempo computacional significativamente menor. Essa informação ajuda a mostrar que o modelo orientado a dados é uma opção viável para otimização em tempo real, pois pode fornecer resultados precisos sem exigir muito

tempo de processamento.

### 3.3 CASO III: RTO DE UMA REDE DE POÇOS COM GL METODOLOGIA HÍBRIDA

#### 3.3.1 Simulação em malha aberta

Neste caso, foi considerado uma estrutura de produção composta por três poços conectados a um *riser*. O modelo discretizado é integrado por diferenças automáticas durante um período de 24 horas. A taxa de amostragem é definida automaticamente pelo integrador. A mesma aplicada na solução do problema de otimização.




**Figura 3.8** Entradas para a identificação do sistema.

Neste estudo de caso, foram coletadas 47 mil amostras. Desse total, 70 % foram destinadas ao treinamento e 30 % foram reservadas para teste e validação durante o treinamento. A arquitetura da rede neural consiste em uma camada oculta com quatro neurônios e uma camada de saída com oito neurônios. O algoritmo de aprendizado utilizado foi o *quasi-Newton backpropagation* (BFGS), com a função objetivo de minimizar


o erro médio absoluto (MAE). O processo de *Gas Lift* (GL) foi simulado com um modelo fenomenológico, utilizando quatro entradas: três vazões de injeção de gás no topo do anular e uma abertura da válvula choke de produção. As entradas geradas para estimular o processo foram combinadas com sequências Halton e sinais PRBS. Esse conjunto de dados está representado nas Figuras 3.8 e 3.9.

No entanto, as entradas de abertura das válvulas na cabeça dos poços não foram utilizadas devido a erros numéricos na integração do GL.



**Figura 3.9** Entradas para a identificação do sistema.

Para avaliar a capacidade preditiva do MHE e da Rede Neural Artificial (RNA) no terceiro estudo de caso, que envolve múltiplos poços, também foi realizada uma simulação em malha aberta com entradas aleatórias. Na Figura 3.10, são apresentadas as pressões de cabeça dos poços. Essas pressões são consideradas medidas reais na planta (representadas pela linha pontilhada), passam pelo filtro do sensor virtual (destacadas pela **linha azul**) e são estimadas por meio do modelo orientado a dados (visualizadas pela **linha vermelha**). As referências para as variáveis filtradas e estimadas são indicadas pela sigla GL (marcadas pela **linha verde - GL**). Em resumo, as três próximas figuras ilustram os resultados da simulação em malha aberta.




**Figura 3.10** Caso III - Predições das pressões de cabeça de poço de um passo à frente - comparação entre a referência GL, valores medido, sensor virtual e o modelo orientado a dados.

A Figura 3.11 ilustra as vazões de óleo estimadas pelo sensor virtual (representadas pela [linha azul](#)), as vazões estimadas pelo modelo orientado a dados (destacadas pela [linha vermelha](#)) e a referência (indicada pela [linha verde](#)).

Além disso, na Figura 3.12, são apresentadas as variáveis no topo do *riser*. Isso inclui as vazões estimadas de gás e óleo, obtidas por meio do modelo orientado a dados (destacadas pela [linha vermelha](#)), assim como as vazões calculadas utilizando o sensor virtual ([linha azul](#)). Adicionalmente, a pressão medida no topo do *riser* é representada na Figura 3.12 pela linha pontilhada preta (sensor). Essa pressão é submetida a um processo de filtragem através do sensor virtual. Em resumo, as 3.10, 3.11 e 3.12 exibem os resultados de uma simulação em malha aberta, cujo objetivo é avaliar o desempenho dos modelos propostos.

De acordo com as Figuras 3.10, 3.11 e 3.12, compreende que o sensor virtual é capaz de rastrear de maneira satisfatória o comportamento da planta. Ele não apenas filtra as variáveis medidas, mas também estima as variáveis de difícil mensuração, como as vazões individuais de óleo e gás. Além disso, o modelo orientado a dados segue a trajetória



**Figura 3.11** Caso III - Predições das vazões de cabeça de poço de um passo à frente - comparação entre a referência GL, sensor virtual e o modelo orientado a dados.


do sensor virtual na previsão e, em algumas situações, o supera, como é observado na Figura 3.11, especialmente nos intervalos diários 90 e 105. Nestes intervalos, o sensor virtual registrou picos, enquanto o modelo orientado a dados se manteve suavizado. Essa discrepância era esperada, dado que a rede foi treinada com os dados filtrados.

Em resumo, há pequenos desvios nas previsões do modelo orientado a dados em relação ao sensor virtual, assim como desvios do próprio sensor virtual em relação à referência. No entanto, os resultados indicam concordância, ou seja, o modelo orientado a dados demonstra ser uma escolha viável para a resolução do problema de otimização.

### 3.3.2 Otimização de uma rede de poços equipado com GL

A solução do problema de otimização leva em consideração uma rede composta por três poços e um *riser*. As variáveis de decisão incluem as vazões de injeção de gás no topo





**Figura 3.12** Caso III -Predições de vazões e pressão de topo do *riser* de um passo à frente - comparação entre a referência GL, valores medido, sensor virtual e o modelo orientado a dados.

do anular de cada poço e a abertura da válvula de produção do *riser*. Assim como nos primeiros e segundo estudos de caso, existem parâmetros e restrições (econômicos e/ou operacionais) que variam ao longo do tempo. Os parâmetros econômicos e operacionais estão apresentados na Tabela 3.4, onde  $\beta$  representa o preço por metro cúbico do óleo,  $\alpha$  é o custo por metro cúbico de gás injetado,  $p_{rt}$  é a pressão requisitada na superfície, que pode corresponder à pressão desejada na entrada do separador, e  $c_p$  é a capacidade máxima disponível para a injeção.

Neste caso, o modelo discretizado é integrado usando diferenças automáticas ao longo de um período de 24 horas. A taxa de amostragem é definida automaticamente pelo integrador. A rede neural artificial foi treinada sob essas mesmas condições.

A Tabela 3.5 apresenta as decisões ótimas para problema de otimização, onde  $w_{ing_1}$ ,  $w_{ing_2}$  e  $w_{ing_3}$  são as vazões ótimas de gás injetada em cada poço,  $Z_c$  é a abertura ótima da válvula de topo do *riser*. MF e RNA representam os modelos utilizados no problema

**Tabela 3.4** Caso III - Perturbações nos parâmetros econômicos e operacionais

Tempo ( <i>d</i> )	$\beta$ (\$)	$\alpha$ (\$)	$p_{rt}$ (bar)	$c_p$ (kg/s)
0	100	200	24	7
1	100	200	24	7
2	150	200	24	7
3	150	220	24	7
4	120	220	24	7
5	120	220	24	4
6	120	220	24	4
7	120	220	24	6
8	120	220	24	6
9	120	220	30	6
10	120	220	30	6


de otimização, fenomenológico e orientado a dados, respectivamente.

**Tabela 3.5** Caso III - Soluções ótimas encontradas com o problema de otimização utilizando o modelo orientado a dados e o fenomenológico.

Tempo ( <i>d</i> )	$w_{ing_1}$ (kg/s)	$w_{ing_2}$ (kg/s)	$w_{ing_3}$ (kg/s)	$Z_c$ (%)
	MF - RNA	MF - RNA	MF - RNA	MF - RNA
0	1,00 - 1,00	1,00 - 1,00	1,00 - 1,00	90,0 - 90,0
1	2,04 - 2,05	1,43 - 1,40	1,29 - 1,28	100 - 100
2	2,53 - 2,52	1,89 - 1,89	1,76 - 1,77	100 - 100
3	2,42 - 2,52	1,78 - 1,79	1,65 - 1,66	100 - 100
4	2,15 - 2,15	1,53 - 1,55	1,39 - 1,39	100 - 100
5	1,76 - 1,78	1,18 - 1,21	1,04 - 1,00	100 - 100
6	1,76 - 1,78	1,18 - 1,21	1,04 - 1,00	100 - 100
7	2,15 - 2,15	1,53 - 1,55	1,39 - 1,39	100 - 100
8	2,15 - 2,15	1,53 - 1,55	1,39 - 1,39	100 - 100
9	2,41 - 2,33	1,85 - 1,88	1,72 - 1,77	76,9 - 77,0
10	2,41 - 2,33	1,85 - 1,88	1,72 - 1,77	76,9 - 77,0

A Figura 3.13 demonstra o desempenho ótimo do processo a partir das soluções, sendo  $w_{to}$  e  $w_{tg}$  são as vazões ótimas de óleo e gás produzida no topo do *riser* e  $F_{ob}$  é o lucro ótimo obtido. Vale salientar que o problema de otimização é resolvido a partir do primeiro dia, porém os parâmetros são os mesmos para os intervalos diários zero e um.

Ao analisar a Figura 3.13 e a Tabela 3.5, nota-se que no dia zero o processo está operando com uma vazão de injeção de 1 kg/s de gás para cada poço. No entanto, a partir do primeiro dia, quando o otimizador é ativado, ocorrem alterações nas vazões de




**Figura 3.13** Caso III - Resposta do processo a partir da aplicação das soluções ótimas gerado pelo problema de otimização utilizando o modelo orientado a dados e fenomenológico.

gás injetado. Além disso, observa-se um aumento nas vazões de óleo e gás produzidas, bem como um leve acréscimo no lucro, levando a planta ao ponto ótimo.

As diferenças entre as soluções ótimas utilizando o modelo orientado a dados e o modelo fenomenológico são pequenas, porém perceptíveis, conforme a Tabela 3.5. Geralmente, essas diferenças são observadas na segunda casa decimal quando as soluções são apresentadas com duas casas decimais. Portanto, as soluções do problema de otimização com o modelo orientado a dados demonstram a capacidade de se equiparar às soluções do modelo de referência.

A quantidade de gás injetada aumentou novamente no segundo dia, devido às variações nas variáveis econômicas, ou seja, à valorização do óleo. Isso resultou em um aumento considerável na vazão de óleo produzido e, conseqüentemente, em um incremento significativo no lucro. O oposto ocorre quando o preço do óleo diminui ou o custo de injeção aumenta.

Os efeitos das restrições são ilustrados na Figura 3.14, onde  $P_{rh}$  representa a pressão no topo do *riser*. Essas pressões, obtidas a partir das soluções ótimas, são consistentes com os modelos utilizados (RNA e MF). Além disso,  $P_{rt}$  é a pressão requisitada na superfície, ou seja, solicitada no topo do *riser*. Na Figura 3.14, também podemos observar que  $c_p$  é a capacidade máxima de injeção de gás disponível, e  $Q_{tg} = \sum_{j=1}^n w_{ing}$  é o somatório total das vazões de gás injetadas no anular, ou seja, a soma das soluções ótimas de injeção geradas no intervalo diário.



**Figura 3.14** Caso III - Resposta do processo em relação a restrições do problema de otimização problema de otimização utilizando o modelo orientado a dados e fenomenológico.


As restrições foram respeitadas em todas as soluções ótimas, conforme ilustrado nos resultados da Figura 3.14. Além disso, é notável que em algumas ocasiões não foi necessário utilizar a capacidade máxima de injeção de gás para alcançar o lucro máximo. Por fim, é possível observar que o aumento da pressão no topo do *riser* resulta no fecha-

mento da válvula no topo do *riser*, o que é ainda mais significativo quando a capacidade de gás disponível é reduzida.

Portanto, as soluções ótimas nem sempre estão vinculadas à disponibilidade máxima de injeção de gás. Em outras palavras, é importante compreender que altas vazões de injeção de gás podem não ser a melhor estratégia em determinados momentos

Em uma segunda análise, especificamente durante o período entre os dias 4 e 8, observa-se que as soluções ótimas conseguiram manter o lucro máximo estável, apesar da redução na capacidade máxima de gás disponível, como mostra a Figura 3.13.

Para representar uma situação na qual ocorreu uma queda abrupta na capacidade  $c_p$  de injeção de gás. Inicialmente, havia uma vazão disponível de 7 kg/s de gás. No entanto, devido a um imprevisto no fornecimento de gás (situação hipotética), essa vazão foi drasticamente reduzida para 4 kg/s. Apesar da queda abrupta no fornecimento de gás no quinto dia, o sistema otimizado conseguiu manter a válvula da superfície do *riser* completamente aberta, respeitando todas as restrições operacionais. Conforme apontado na 3.14



**Figura 3.15** Caso III - Comparação entre os tempos computacionais

A Figura 3.15 apresenta o tempo computacional necessário para resolver o problema

de otimização utilizando os diferentes modelos propostos. Esse tempo é verificado a cada ciclo de otimização. A **linha azul** representa o tempo computacional gasto pelo modelo fenomenológico, sendo que, neste caso, a integração é realizada com diferenciação automática. A **linha vermelha** representa o modelo orientado a dados.


O objetivo principal deste trabalho é avaliar o tempo computacional gasto nas rotinas de otimização para encontrar a solução ótima em ambos os modelos. No entanto, mesmo sendo integrado através da diferenciação automática, o modelo fenomenológico apresenta um desempenho inferior ao do modelo orientado a dados, como evidenciado pelos resultados apresentados na Figura 3.15.

**Tabela 3.6** Caso III - Perturbações nos parâmetros econômicos e operacionais (maior peso pra o óleo)

Tempo ( $d$ )	$\alpha$ (\$)	$\beta$ (\$)	$p_{rt}$ (bar)	$c_p$ (kg/s)
0	50	250	24	7
1	50	250	24	7
2	50	250	24	7
3	50	250	24	7
4	50	220	24	7
5	50	220	24	4
6	50	220	24	4
7	50	270	24	6
8	50	270	24	6
9	50	270	30	6
10	50	270	30	6

Outro aspecto a ser considerado é que o modelo fenomenológico, quando integrado com a técnica de diferenciação automática, mantém um tempo computacional razoável. No entanto, esse tempo pode aumentar exponencialmente à medida que representa processos em larga escala. Além disso, ele pode ser suscetível a problemas de instabilidade numérica. Por outro lado, a rede neural não requer a técnica de integração para representar a planta e, portanto, não enfrenta esses problemas de instabilidade numérica.

Com o peso do óleo sendo mais significativo em relação ao custo do gás, Tabela 3.6, nem todas as restrições foram respeitadas em todas as soluções ótimas. Notavelmente, em determinados momentos, quando o preço do óleo aumentou no sétimo dia, a restrição  $P_{rt}$  foi violada, conforme a Figura 3.16. Além disso, a RNA violou a restrição nos dias quinto e sexto, como demonstrado nos resultados da Figura 3.16. Observa-se que, com um peso maior atribuído ao óleo, é necessário utilizar a capacidade máxima de injeção de gás para alcançar o lucro máximo. Isso faz sentido, uma vez que a otimização econômica



**Figura 3.16** Caso III - Resposta do processo em relação a restrições do problema RTO utilizando o modelo orientado a dados e fenomenológico: com maior peso para o óleo

busca identificar os pontos de maior lucratividade dentro de uma região restrita.

Em resumo, as redes neurais representam uma possível alternativa para substituir ou trabalhar em conjunto com os modelos fenomenológicos em algumas aplicações específicas.

As análises realizadas ao longo deste trabalho destacam a importância de avaliar cuidadosamente a escolha entre modelos fenomenológicos e redes neurais em aplicações de otimização. Embora o modelo fenomenológico, quando integrado com a diferenciação automática, possa manter um desempenho razoável em termos de tempo computacional, ele enfrenta desafios significativos, como o aumento exponencial do tempo em processos em larga escala e a possibilidade de instabilidade numérica. Por outro lado, as redes neurais apresentam-se como uma alternativa promissora, pois não dependem da técnica de integração e evitam problemas de instabilidade numérica. Portanto, a escolha entre

essas abordagens deve ser orientada pela natureza específica da aplicação e pelas demandas computacionais, visando sempre a obtenção de soluções eficazes e estáveis para os problemas de otimização em questão

### 3.4 COMENTÁRIOS

Neste capítulo, foi realizada uma análise da aplicação da otimização dinâmica em tempo real com objetivos econômicos diários, usando um passo à frente, em um sistema de GL em Três estudos de caso. No primeiro estudo de caso, o objetivo foi avaliar o tempo computacional necessário para encontrar a solução ótima do problema de otimização usando o modelo fenomenológico. Duas técnicas de integração foram empregadas: a primeira consistiu na aplicação de diferenças finitas com o algoritmo ODE15s, enquanto a segunda envolveu a diferenciação automática com a estrutura CasADI. No segundo estudo de caso (um único poço), abordou-se a capacidade do modelo orientado a dados em acompanhar o comportamento da planta, representada pelo modelo fenomenológico, considerando ruídos de medição e posterior filtragem pelo MHE, além de estimar novas variáveis de difícil medição. O otimizador proposto para o modelo de referência (fenomenológico) e o modelo orientado a dados apresentaram resultados semelhantes, com ênfase no tempo computacional e na observação de que ambos respeitaram as restrições do sistema. No terceiro estudo de caso (rede de poços), os resultados foram semelhantes ao segundo caso, mas com um melhor desempenho do modelo orientado a dados, que está associado o tempo computacional.



*Neste capítulo são apontadas as principais conclusões e contribuições deste trabalho e alguns comentários acerca dos resultados obtidos. Por fim, são feitas algumas sugestões de aspectos que poderiam melhorar e dar continuidade ao trabalho desenvolvido.*

## **CONCLUSÕES**

Neste trabalho, estudou-se uma formulação de um problema de otimização dinâmica em tempo real com objetivos econômicos, substituindo o modelo fenomenológico de referência por um modelo orientado a dados - uma rede neural com arquitetura NARX. O problema proposto foi aplicado a um sistema típico de produção de petróleo, e a eficácia da abordagem foi ilustrada por meio de simulações de cenários com instabilidade nos parâmetros econômicos e falta de dados medidos.]

Os resultados simulados indicaram uma melhoria no tempo computacional necessário para resolver o problema de otimização quando comparado com o modelo fenomenológico padrão. Além disso, as simulações demonstraram que a rede NARX foi efetiva em suas previsões de um passo à frente, assim como o sensor virtual.

### **4.1 CONTRIBUIÇÕES**

- Desenvolvimento de um sensor virtual capaz de estimar variáveis não medidas com base em medições distintas e respeitando o limites operacionais do sistema, além de avaliar a competência do MHE em frente a um sistema com poucas variáveis medidas.
- Realização de estudo via simulação para aplicação de formulação de um problema de otimização dinâmica em tempo real com objetivos econômicos, substituindo

o modelo fenomenológico por um modelo orientado a dados. Tendo em vista os aspectos de competências das redes neurais e tempo computacional.

- Desenvolvimento de programas na linguagem *Matlab* para cálculo do otimizador dinâmico em tempo real com objetivos econômicos em sistemas de produção de petróleo assistido por GL.

## 4.2 COMENTÁRIOS FINAIS

Os resultados computacionais das simulações ilustraram um desempenho satisfatório do otimizador, com ênfase na eficiência em termos de tempo de computação. É notável que o uso do modelo orientado a dados tornou o problema de otimização mais eficiente em termos de tempo, uma das principais limitações na aplicação da otimização dinâmica em tempo real

Os resultados obtidos indicaram que a aplicação do modelo orientado a dados reduziu o tempo de computação do otimizador em 79% em comparação com a utilização do modelo de referência (fenomenológico) no primeiro estudo de caso. Vale destacar que, na aplicação do otimizador com o uso do modelo de referência, a integração do sistema DAE foi realizada por diferenciação automática e não por diferenciação numérica, o que resulta em um tempo de computação inviável para a maioria das aplicações de DRTO

No segundo estudo de caso, foi realizada uma expansão no escopo do problema de otimização, que passou a incluir três poços e um *riser* no processo. Os resultados indicaram que o tempo médio de solução do otimizador com o modelo de referência aumentou de 2,9 segundos para 20 segundos, enquanto o otimizador com o modelo orientado a dados aumentou de 0,6 segundo para 0,8 segundo. De forma geral, a utilização do modelo orientado a dados resultou em uma redução de tempo computacional de 96%.

Esses resultados indicam que a metodologia proposta apresenta uma alternativa tangível para um dos gargalos da aplicação do DRTO, ou seja, o tempo de computação. Além disso, é importante ressaltar que os resultados obtidos com o otimizador com modelo orientado a dados são similares aos gerados pelo otimizador com o modelo de referência.

## 4.3 TRABALHOS FUTUROS

- Na produção *offshore* ocorre um fenômeno denominado com *severe slugging*, ou seja, a formação de bolha de gás no *pipeline-riser* devido ao escoamento multifásico que fomenta instabilidade na produção, neste cenário, existem alguns trabalhos que propuseram controle baseado em modelo com o objetivo de estabilizar a produção.

Então, mesmo aplicando controle não há garantia de que não opere na região de *severe slugging* ou garantia produção ótima, dado que esse fenômeno é dinâmico e não tem-se identificação desse em tempo real. neste contexto, seria interessante identificar esse fenômeno através de técnicas de reconhecimento de padrão, por exemplo, com o uso de redes neurais, além disso, monitorá-lo ao longo da produção.

- Outra abordagem interessante, além de identificar o *severe slugging*, seria propor uma otimização em tempo real ou um controle baseado em modelo que adote essa identificação como restrição operacional, de modo a eliminar essa região da solução ótima ou possibilite que o sistema não opere nessa região.
- Além disso, realizar a integração do otimizador proposto em ambiente de escala real ou de escala experimental, de maneira que o otimizador gere condições ótima (*se-point*) para controle implementado em um controlador lógico programável (CLP).
- A manipulação da válvula *choke* permite controlar a taxa de injeção de gás no anular. Isso é crítico para otimizar a eficiência do GLC, pois permite ajustar a quantidade de gás injetada de acordo com as condições operacionais, como a vazão de produção, a pressão do reservatório. Nesse sentido, a consideração da modificação do modelo fenomenológico do GLC, de modo a incorporar a capacidade de manipulação direta da válvula *choke* de injeção de gás no anular, em substituição à dependência da vazão mássica de gás como entrada, assume um papel central. Essa abordagem não apenas representa um passo significativo na busca pela otimização dos processos de elevação artificial, mas também é essencial para verificar o desempenho e a eficácia das melhorias propostas no modelo, bem como garantir sua aplicabilidade prática e viabilidade em sistemas reais de elevação artificial.
- A Para investigações posteriores, seria altamente recomendável realizar estudos adicionais que explorem o uso de sinais binários alternativos, como o GBN (ruído binário generalizado), como entrada para o modelo. Isso pode envolver a comparação do desempenho da RNA com diferentes tipos de sinais binários e a análise de como esses sinais afetam as previsões do sistema. Além disso, a pesquisa poderia se concentrar em entender como essas diferenças nos sinais de entrada afetam a identificabilidade do sistema e a precisão das previsões.



## REFERÊNCIAS BIBLIOGRÁFICAS

- AAMO, O. 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, apr 2005. ISSN 09591524.
- AL-QUTAMI, T. A. et al. Development of Soft Sensor to Estimate Multiphase Flow Rates Using Networks and Early Stopping . *International Journal on Smart Sensing and Intelligent Systems*, v. 10, n. 1, p. 1–24, jan 2017. ISSN 1178-5608.
- ALARCON, G. A.; TORRES, C. F.; GOMEZ, L. E. Global Optimization of Gas Allocation to a Group of Wells in Artificial Lift Using Nonlinear Constrained Programming. *Journal of Energy Resources Technology*, v. 124, n. 4, p. 262–268, dec 2002. ISSN 0195-0738.
- ALMEIDA, E. *Otimização dinâmica em tempo real : arquitetura de software, diagnóstico e análise de inviabilidades*. Tese (Doutorado) — Universidade Federal do Rio Grande do Sul, 2011.
- ANDERSSON, J. A. E. et al. CasADi: a software framework for nonlinear optimization and optimal control. *Mathematical Programming Computation*, v. 11, n. 1, p. 1–36, mar 2019. ISSN 1867-2949.
- BARTHOLOMEW-BIGGS, M. C. et al. Automatic differentiation of algorithms. *Journal of Computational and Applied Mathematics*, v. 124, p. 171–190, 2000.
- BIANCHI, F. M. et al. *Recurrent Neural Networks for Short-Term Load Forecasting*. Cham: Springer International Publishing, 2017. (SpringerBriefs in Computer Science). ISBN 978-3-319-70337-4.
- BIEGLER, L. Technology advances for dynamic real-time optimization. Elsevier, v. 27, p. 1–6, 2009. ISSN 1570-7946.
- BIKMUKHAMEDOV, T.; JÄSCHKE, J. First Principles and Machine Learning Virtual Flow Metering: A Literature Review. *Journal of Petroleum Science and Engineering*, v. 184, p. 106487, jan 2020. ISSN 09204105.
- CAMPONOGARA, E.; NAKASHIMA, P. H. Solving a gas-lift optimization problem by dynamic programming. *European Journal of Operational Research*, v. 174, n. 2, p. 1220–1246, oct 2006. ISSN 03772217.

CAMPONOGARA, E.; NAKASHIMA, P. H. R. Applying dynamic programming to a gas-lift optimization problem. *In Proceedings of the 2nd Brazilian Conference on Research and Development in Petroleum and Gas Brazil: Rio de Janeiro.*, 2003.

CAMPONOGARA, E.; PLUCENIO, A. Automação de elevação artificial com injeção de gás. *pdpetro*, p. 1–10, 2007.

CAMPOS, M. et al. Challenges and problems with advanced control and optimization technologies. *IFAC Proceedings Volumes*, v. 42, n. 11, p. 1–8, 2009. ISSN 14746670.

CAMPOS, M. C.; GOMES, M. C.; PEREZ, J. M. *Controle Avançado e Otimização na Indústria do Petróleo*. [S.l.: s.n.], 2013. 510 páginas p. ISBN 978-8571933095.

CHAPRA, S. C.; CANALE, R. P. *Métodos Numéricos Para Engenharia*. 5<sup>a</sup> ed. ed. [S.l.]: McGraw Hill, 2011. ISBN 9788586804878.

CODAS, A.; CAMPONOGARA, E. Mixed-integer linear optimization for optimal lift-gas allocation with well-separator routing. *European Journal of Operational Research*, v. 217, n. 1, p. 222–231, feb 2012. ISSN 03772217.

CODAS, A.; JAHANSHAHI, E.; FOSS, B. A two-layer structure for stabilization and optimization of an oil gathering network Well acknowledge the support of the Center for Integrated Operations at NTNU (Norway). *IFAC-PapersOnLine*, v. 49, n. 7, p. 931–936, 2016. ISSN 24058963.

Di Meglio, F.; KAASA, G.-O.; PETIT, N. A first principle model for multiphase slugging flow in vertical risers. *IEEE*, 2009.

Dias, A. et al. Extracting Valuable Information from Big Data for Machine Learning Control: An Application for a Gas Lift Process. *Processes*, v. 7, n. 5, p. 252, apr 2019. ISSN 2227-9717.

DIEHL, F. C. *Controle Ativo de Golfadas em Poços de Petróleo Offshore*. 127 p. Tese (Doutorado) — Universidade Federal do Rio Grande do Sul, 2022.

DIEHL, F. C. et al. Oil production increase in unstable gas lift systems through nonlinear model predictive control. *Journal of Process Control*, v. 69, p. 58–69, sep 2018. ISSN 09591524.

DIEHL, F. C. et al. Fast Offshore Wells Model (FOWM): A practical dynamic model for multiphase oil production systems in deepwater and ultra-deepwater scenarios. *Computers & Chemical Engineering*, v. 99, p. 304–313, apr 2017. ISSN 00981354.

DURAIISKI, R. *Otimização Dinâmica em Tempo Real Utilizando Modelos Não-Lineares Simplificados*. Tese (Doutorado) — UFRGS, 2009.

EIKREM, G. O. et al. stabilization of Gas Lifted Wells . *IFAC Proceedings Volumes*, v. 35, n. 1, p. 139–144, 2002. ISSN 14746670.

- EIKREM, G. O.; IMSLAND, L.; FOSS, B. Stabilization of Gas Lifted Wells Based on State Estimation. *IFAC Proceedings Volumes*, Elsevier, v. 37, n. 1, p. 323–328, jan 2004. ISSN 14746670.
- FERRER, A.; MAGGIOLO, R. Use of a Computerized Model in the Optimization of Continuous Gas-Lift Operations. Society of Petroleum Engineers, n. 10, apr 1991.
- FRANKLIN, T. S. et al. A Physics-Informed Neural Networks (PINN) oriented approach to flow metering in oil wells: an ESP lifted oil well system as a case study. *Digital Chemical Engineering*, v. 5, p. 100056, dec 2022. ISSN 27725081.
- GEBREMEDHIN, A. H.; WALTHER, A. An introduction to algorithmic differentiation. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, v. 10, n. 1, p. 1–21, 2020. ISSN 19424795.
- GÓES, M. R. R. et al. Virtual flow metering of oil wells for a pre-salt field. *Journal of Petroleum Science and Engineering*, v. 203, p. 108586, aug 2021. ISSN 09204105.
- GOODFELLOW, I. J.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.
- HAALAND, S. E. Simple and Explicit Formulas for the Friction Factor in Turbulent Pipe Flow. *Journal of Fluids Engineering*, v. 105, n. 1, p. 89–90, mar 1983. ISSN 0098-2202.
- HERNÁNDEZ, A. *Fundamentals of Gas Lift Engineering*. [S.l.]: Elsevier, 2016. 295–313 p. ISBN 9780128041338.
- HÜLSE, E.; CAMPONOGARA, E. A mathematical programming formulation for robust production optimization of gas-lifted oil fields. CRC Press, n. July, p. 891–896, sep 2014.
- HülSE, E. O.; CAMPONOGARA, E. A mathematical programming formulation for robust production optimization of gas-lifted oil fields. *Engineering Optimization IV - Proceedings of the 4th International Conference on Engineering Optimization, ENGOPT 2014*, 09 2014.
- IMS LAND, L. *Topics in Nonlinear Control - Output Feedback Stabilization and Control of Positive Systems*. Tese (Doutorado) — Norwegian University of Science and Technology, 2002.
- JAHANSHAH, E. *Control Solutions for Multiphase Flow: Linear and nonlinear approaches to anti-slug control* jahanshahi, E. Tese (Doutorado) — Norwegian University of Science and Technology Norwegian University of Science and Technology Faculty of Engineering Science and Technolog, 2013.
- JAHANSHAH, E.; SKOGESTAD, S.; HANSEN, H. Control structure design for stabilizing unstable gas-lift oil wells. *IFAC Proceedings Volumes*, IFAC, v. 45, n. 15, p. 93–100, 2012. ISSN 14746670.

KANU, E. P.; MACH, J.; BROWN, K. E. Economic Approach to Oil Production and Gas Allocation in Continuous Gas Lift (includes associated papers 10858 and 10865 ). *Journal of Petroleum Technology*, v. 33, n. 10, p. 1887–1892, oct 1981. ISSN 0149-2136.

KONG, Q.; SIAUW, T.; BAYEN, A. M. *Python Programming and Numerical Methods A Guide for Engineers and Scientists*. [S.l.: s.n.], 2021. i–iii p. ISBN 9780128195499.

KRISHNAMOORTHY, D.; FJALESTAD, K.; SKOGESTAD, S. Optimal operation of oil and gas production using simple feedback control structures. *Control Engineering Practice*, v. 91, p. 104107, oct 2019. ISSN 09670661.

KRISHNAMOORTHY, D.; FOSS, B.; SKOGESTAD, S. Real-Time Optimization under Uncertainty Applied to a Gas Lifted Well Network. *Processes*, v. 4, n. 4, p. 52, dec 2016. ISSN 2227-9717.

KRISHNAMOORTHY, D.; FOSS, B.; SKOGESTAD, S. Gas Lift Optimization under Uncertainty. p. 1753–1758, 2017.

KRISHNAMOORTHY, D.; FOSS, B.; SKOGESTAD, S. Steady-state real-time optimization using transient measurements. *Computers & Chemical Engineering*, v. 115, p. 34–45, jul 2018. ISSN 00981354.

LOH, K.; OMRANI, P. S.; LINDEN, R. van der. Deep Learning and Data Assimilation for Real-Time Production Prediction in Natural Gas Wells. feb 2018.

MARTINEZ, E. et al. Application of Genetic Algorithm on the Distribution of Gas-Lift Injection. Society of Petroleum Engineers, apr 1994.

MATIAS, J. et al. Steady-state real-time optimization using transient measurements on an experimental rig. *Journal of Process Control*, v. 115, p. 181–196, jul 2022. ISSN 09591524.

MEHREZ, M. W.; MANN, G. K. I.; GOSINE, R. G. Nonlinear moving horizon state estimation for multi-robot relative localization. IEEE, p. 1–5, may 2014.

NAKASHIMA, P.; CAMPONOGARA, E. Optimization of lift-gas allocation using dynamic programming. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, v. 36, n. 2, p. 407–414, mar 2006. ISSN 1083-4427.

NISHIKIORI, N. et al. An Improved Method for Gas Lift Allocation Optimization. *Journal of Energy Resources Technology*, v. 117, n. 2, p. 87–92, jun 1995. ISSN 0195-0738.

ORENSTEIN, L. P. *Procedimento Para Identificação De Sistemas Dinâmicos Em Ambiente Industrial*. 121 p. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2013.

QIU, J.; TORAL, H. Three-Phase Flow-Rate Measurement by Pressure Transducers. Society of Petroleum Engineers, Pi, p. 543–549, apr 1993.



SANTAROSSA, B. *Comparação de Técnicas Baseadas em Modelos para Otimização da Produção de Petróleo em Sistemas Multipoço*. Tese (Doutorado) — Universidade Federal do Rio Grande do Sul, 2021.

Soares, F.; SECCHI, A.; Souza, M. Development of a Nonlinear Model Predictive Control for Stabilization of a Gas-Lift Oil Well. *Industrial & Engineering Chemistry Research*, p. acs.iecr.1c04728, mar 2022. ISSN 0888-5885.

SOLOMATINE, D.; SEE, L.; ABRAHART, R. Data-driven modelling: Concepts, approaches and experiences. Springer Berlin Heidelberg, Berlin, Heidelberg, p. 17–30, 2008.

TAKACS, G. *Gas lift manual*. 2005. ISBN 0-87814-805-1.

TASMI, T. et al. Applications of line-pack model of gas flow in intermittent gas lift injection line. *Journal of Petroleum Science and Engineering*, v. 157, p. 930–940, aug 2017. ISSN 09204105.

WAGNER, R. R. *Metodologia para identificação de sistemas mal condicionados com restrições maximizando a amplitude das perturbações*. 97 p. Tese (Doutorado) — Universidade Federal do Rio Grande do Sul, 2015.

XIE, H.; TANG, H.; LIAO, Y.-H. Time series prediction based on narx neural networks: An advanced approach. v. 3, p. 1275–1279, 2009.

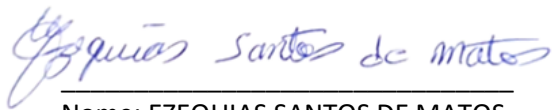
YADUA, A. U. et al. Performance of a gas-lifted oil production well at steady state. *Journal of Petroleum Exploration and Production Technology*, v. 11, n. 6, p. 2805–2821, jun 2021. ISSN 2190-0558.

YAHIA, S. H. *Real Time Optimization and Nonlinear Model Predictive Control of a Gas Lifted Oil Network*. Tese (Doutorado) — Norwegian University of Science and Technology, 2018.

Salvador, 16/04/2024

## DECLARAÇÃO

Declaro para os devidos fins que o texto final apresentado para a conclusão do meu curso de Mestrado em Mecatrônica da Universidade Federal da Bahia é de minha autoria. Declaro também que quaisquer informações utilizadas neste texto, mas que sejam provenientes de outros trabalhos, têm fonte claramente expressa e, quando for o caso, o seu uso foi devidamente autorizado pelo(s) respectivo(s) autor(es).



Nome: EZEQUIAS SANTOS DE MATOS

CPF: 048.153.175-00