



**ABORDAGEM BASEADA EM APRENDIZADO DE
MÁQUINA PARA MODELAGEM E CONTROLE
PREDITIVO DE POÇOS DE PETRÓLEO COM
GAS LIFT CONTÍNUO**

Thiago Dopazo Rey Simões

Monografia em Engenharia Química

Orientadores:

Prof. Maurício Bezerra de Souza Jr., D.Sc.

Felipo Doval Rojas Soares, M.Sc.

Março de 2022

Abordagem Baseada em Aprendizado de Máquina para Modelagem e Controle Preditivo de Poços de Petróleo com Gas Lift Contínuo

Thiago Dopazo Rey Simões

Monografia em engenharia química submetida ao Corpo Docente da Escola de Química como parte dos requisitos necessários à obtenção do grau de Engenheiro Químico.

Aprovado por:

José Carlos Costa da Silva Pinto, D.Sc

Bruno Didier Olivier Capron, D.Sc.

Orientado por:

Maurício Bezerra de Souza Jr., D.Sc.

Felipo Doval Rojas Soares, M.Sc.

Rio de Janeiro, RJ – Brasil

Março de 2022

Simões, Thiago Dopazo Rey

Abordagem Baseada em Aprendizado de Máquina para Modelagem e Controle Preditivo de Poços de Petróleo com Gas Lift Contínuo / Thiago Dopazo Rey Simões. Rio de Janeiro/EQ, 2022

x, 71 p.; il.

(Monografia) – Universidade Federal do Rio de Janeiro, Escola de Química, 2022.

Orientadores: Mauricio Bezerra de Souza Jr e Felipe Doval Rojas Soares

1. Gas Lift Contínuo. 2. Redes Neurais. 3. Controle de Processos. 4. Monografia. (Graduação – UFRJ/EQ). 5. Maurício Bezerra de Souza Jr. e Felipe Doval Rojas Soares I. Abordagem Baseada em Aprendizado de Máquina para Modelagem e Controle Preditivo de Poços de Petróleo com Gas Lift Contínuo

À dona Lola, por seu amor incondicional e carinho sempre presente

"It is far better to grasp the universe as it really is than to persist
in delusion, however satisfying and reassuring."

- Carl Sagan

AGRADECIMENTOS

Aos que me auxiliaram no caminho até aqui, este trabalho representa o fim dos meus estudos de Engenharia Química dentro da graduação, mas simultaneamente marca o início de um novo ciclo.

Inicialmente agradeço aos professores e funcionários da UFRJ que me auxiliaram na construção dos conceitos que nortearão minha carreira. Em especial, aos meus orientadores Maurício Bezerra de Souza e Felipe Rojas Soares pelo apoio, atenção e disponibilidade ao longo do último ano.

Não poderia deixar de agradecer meus professores Arlindo e Jamel do Colégio Internacional Everest. Lá atrás vocês me incentivaram a buscar a Engenharia Química e se hoje me sinto realizado com a carreira que escolhi, certamente existe o dedo de vocês nisso.

Do ponto de vista pessoal, agradeço a minha família, especialmente à minha mãe Dolores e meu pai Manuel por me apoiar a cada passo. Vocês me ensinaram o valor do estudo, sempre acreditando em mim e me dando coragem para seguir em frente. Vocês são meu alicerce, minha base e minha força. Amo vocês.

A minha grande companheira Gabriela, por seu meu porto seguro e aquela com quem consigo passar noites conversando sobre nada em específico, por estar comigo a cada curva e acreditar em mim mesmo quando eu não consigo.

As amizades que fiz ao longo dos anos de graduação. Jon, Amanda, Bia, Fer, Fabio, Mat, Leozin, Laf e Clark. A caminhada foi longa, mas ao lado de vocês as alegrias foram infinitas.

As amizades de antes, mas que me ajudaram a construir quem sou hoje. Matheus, Tiago, Manu, Lulu, Benjamin, Woods, Dessa, Bel, Gio, Knupp, Ju e Paraná. Estamos juntos sempre!

Por fim, ao Grupo Escoteiro Caio Vianna Martins, em especial, ao Chefe Willian, Camila e Chefe Neuza, por colaborar na construção do meu caráter, me ensinando o que a formação acadêmica jamais seria capaz de ensinar. O Grupo sempre será aquele local especial de infinitas memórias. Só quem teve a oportunidade de pertencer entenderá o sentimento.

Resumo do Projeto de Graduação apresentado à Escola de Química/ UFRJ como parte dos requisitos necessários para a obtenção do grau de Engenheiro Químico.

ABORDAGEM BASEADA EM APRENDIZADO DE MÁQUINA PARA
MODELAGEM E CONTROLE PREDITIVO DE POÇOS DE PETRÓLEO COM GAS
LIFT CONTÍNUO

Thiago Dopazo Rey Simões

Março, 2022

Orientadores: Prof. Mauricio Bezerra de Souza Jr., D.Sc.

Felipo Doval Rojas Soares, M.Sc.

Comportamentos complexos e não lineares são comuns dentro da indústria química, sendo assim, a obtenção de modelos fidedignos pode muitas vezes ser impossibilitada ao se empregarem abordagens tradicionais de modelagem. Em função da ampla disponibilidade de dados cada vez mais presente nas operações industriais, estratégias utilizando redes neuronais são justificadas uma vez que além de sua não linearidade inerente, são consideradas funções aproximadoras universais e possuem boa capacidade de predição. Sob a ótica de modelagem e controle de processos, poços de petróleo com elevação artificial por injeção de gás configuram-se como um problema interessante pois apresentam características que dificultam sua identificação, são estas: inversão do sinal de ganho estático, comportamento de fase não mínima, resposta transitória lenta e instabilidades da malha. O presente trabalho empregou redes neuronais com atrasos temporais na identificação do comportamento do poço. Objetivou-se predizer a vazão de final de óleo a partir de diferentes conjuntos de dados como entrada. Posteriormente, as redes foram avaliadas e selecionadas de modo que os melhores resultados fossem utilizados em estudos preliminares como modelo interno de controladores preditivos. O comportamento do poço foi satisfatoriamente replicado pelas redes treinadas e os testes aos quais os controladores foram submetidos apresentaram boa capacidade de adequação a curva de referência (*setpoint*) e capacidade de estabilização da vazão de produção em zonas de golfadas.

Abstract of the Graduation Project presented to Escola de Química/ UFRJ as part of the necessary requirements to obtain the degree of Chemical Engineer.

MACHINE LEARNING BASED APPROACH FOR MODELING AND PREDICTIVE
CONTROL OF OIL WELLS WITH CONTINUOUS LIFT GAS

Thiago Dopazo Rey Simões

March, 2022

Advisors: Prof. Mauricio Bezerra de Souza Jr., D.Sc.

Felipo Doval Rojas Soares, M.Sc.

Complex and nonlinear behaviors are common within the chemical industry and obtaining reliable models can often be unachievable through traditional modeling approaches. Due to the wide increasingly available data at present industrial operations, machine learning strategies are justified. Particularly, neural networks, in addition to their inherent nonlinearities, they are considered universal approximation functions and have good predictive capacity. From the modeling and process control point of view, oil wells with artificial elevation by gas injection are an interesting problem because they present characteristics that make their identification arduous such as: inversion of the static gain signal, non-minimum phase behavior, slow transient response, and loop instabilities. The present work used neural networks with temporal delays to identify the behavior of the well. The objective was to predict the final oil flow utilizing different data sets as input. Subsequently, the networks were evaluated and selected so the best results could be used in preliminary studies as internal models of nonlinear model predictive controllers. The trained networks satisfactorily replicated the behavior of the well, and the tests to which the controllers were submitted showed good ability to adapt to the reference curve (setpoint) and to stabilize the production flow in slug zones.

ÍNDICE

Capítulo 1: INTRODUÇÃO.....	1
1.1. Motivação e Objetivos	1
1.2. Organização do Trabalho	2
Capítulo 2: REVISÃO BIBLIOGRÁFICA.....	4
2.1. Aprendizado de Máquina: Redes Neurais.....	4
2.1.1. Breve Histórico	4
2.1.2. O Neurônio como um modelo	6
2.1.3. Arquitetura de Redes neuronais	9
2.1.4. Treinamento de Redes	11
2.1.5. Hiperparâmetros Adicionais	14
2.2. Poço de Elevação Artificial	16
2.2.1. Princípios de Funcionamento.....	17
2.2.2. Princípios de Operação e Comportamento Dinâmico de Poços	18
2.2.3. Modelagem Matemática	21
2.3. Controle Preditivo Baseado em Modelo (MPC).....	26
2.3.1. Fundamentos Teóricos.....	26
2.3.2. Redes Neurais Artificiais em Controle	29
2.3.3. MPC no contexto de poços de Gas Lift	32
Capítulo 3: METODOLOGIA	35
3.1. Simulação do Modelo.....	35
3.1.1. Parâmetros das Simulações.....	35
3.1.2. Modelos de Identificação Escolhidos	37
3.1.3. Criação dos Conjuntos de Treinamento.....	38
3.2. Treinamento das RNA.....	39

3.2.1. Ajuste de Hiperparâmetros	40
3.2.2. Avaliação das Redes	40
3.2.3. Estratégia para Obtenção das Redes	41
3.3. Protótipos de Controladores	42
3.3.1. Estrutura dos Controladores.....	42
3.3.2. Avaliação dos Controladores	44
Capítulo 4: RESULTADOS E DISCUSSÃO.....	46
4.1. Avaliação das Redes Treinadas	46
4.1.1. Conjunto de Treino Completo	46
4.1.2. Conjunto de Treino Instável	47
4.1.3. Conjunto de Treino Estável	49
4.1.4. Ponderações Gerais	50
4.2. Avaliação dos Controladores	55
4.2.1. Primeiro Teste: Melhores Redes.....	55
4.2.2. Segundo Teste: Melhores Redes.....	58
4.2.3. Segundo Teste: Modelos sem Pressão de Injeção (UF).....	61
Capítulo 5: CONCLUSÕES E TRABALHOS FUTUROS	65
5.1 Conclusão.....	65
5.2 Sugestão de Trabalhos Futuros	66
Capítulo 6: REFERÊNCIAS BIBLIOGRÁFICAS.....	67

Capítulo 1: INTRODUÇÃO

1.1. Motivação e Objetivos

Em um contexto de crescente complexidade dos processos químicos, somado a pressões econômicas e logísticas, plantas industriais são condicionadas a operar de forma segura sob vários cenários operacionais, adaptando-se a diferentes requisitos. O controle clássico através de controladores proporcionais, integrais e/ou derivativos ainda configura a técnica mais empregada industrialmente, contudo, neste contexto de elevada complexidade, margens apertadas e rígida regulamentação, observa-se uma demanda por estratégias com múltiplos níveis hierárquicos. Nessas estratégias, acima da camada de controle regulatório, tem-se uma camada de controle preditivo baseada em modelo, acoplada a uma camada superior de otimização em tempo real. Assim, busca-se manter o processo operando em condição ótima, mesmo na presença de perturbações.

A dependência de modelos fidedignos leva à criação de modelos de processo mais complexos e não lineares. No entanto, a necessidade de resolução *online* de problemas de otimização na presença de restrições, dificulta a implementação de versões não lineares de controle preditivo baseadas em modelos fenomenológicos. Por outro lado, a ampla digitalização dos processos produz um elevado volume de informações, abrindo espaço para metodologias de controle que possam se aproveitar desta vasta quantidade de dados produzidos.

Neste contexto, abordagens que empregam o aprendizado de máquina como estratégia apresentam vantagem visto que são capazes de reconhecer padrões escondidos nos dados, padrões estes que seres humanos sozinhos não estão aptos a encontrar, e são capazes de transformá-los em conhecimento sobre os fenômenos presentes na operação, estabelecendo previsões sobre o comportamento do processo e permitindo uma melhor tomada de decisão.

A indústria offshore de óleo e gás por certo se beneficiará da digitalização e de sua integração com técnicas de controle avançado. No Brasil, a produção de petróleo está localizada quase que em sua totalidade no mar e aproximadamente 70% desta produção é feita empregando a técnica de injeção de gás (DIAS et al., 2019).

Poços de *gas lift* apresentam custos relativamente baixos de instalação e operação, porém estão sujeitos a diversas instabilidades em campo, como oscilações e golfadas. Do ponto de vista operacional, a ocorrência de golfadas configura-se como um dos principais problemas enfrentados, podendo ser caracterizada como um comportamento altamente danoso em que são atingidos picos elevados no fluxo de óleo prejudicando a segurança, integridade mecânica e economia da operação. Desta forma, o projeto de controladores capazes de prever e estabilizar o comportamento do poço é um desafio, principalmente devido às plataformas tradicionalmente utilizarem somente controladores PID para cada uma de suas malhas, desconsiderando a relação entre as variáveis individuais de processo.

Apesar da relevância do tema, pouco ainda é encontrado na literatura relacionando técnicas avançadas de controle com poços de injeção, menos ainda empregando técnicas que sejam capazes de se aproveitar da digitalização dos processos e disponibilidade de dados.

Neste contexto, a escolha de poços de *gas lift* como objeto de estudo é interessante do ponto de vista do controle de processos justamente devido às características que o tornam um bom candidato para uma abordagem livre de modelos fenomenológicos, são essas: a inversão do sinal de ganho estático, comportamento de fase não mínima, resposta transitória lenta e instabilidades da malha.

O presente trabalho visa contribuir neste quesito, através da utilização de redes neurais, objetiva-se obter um modelo que seja capaz de replicar a dinâmica complexa do processo de *gas lift*. Complementarmente, após obtido o melhor modelo baseado em aprendizado de máquinas, este será usado como modelo interno em uma avaliação preliminar da estratégia de controle preditivo.

1.2. Organização do Trabalho

Inicialmente, o Capítulo 2 apresenta uma revisão bibliográfica referente aos fundamentos relevantes para o presente trabalho, isto é: Redes Neurais Artificiais, Poços de Elevação Artificial e Controle Preditivo Baseado em Modelo.

Em seguida, o Capítulo 3 descreve a metodologia empregada no presente trabalho, desde a etapa de identificação do poço, suas estratégias e métricas quanto o projeto dos controladores e os testes propostos para os mesmos

O Capítulo 4 expõe os resultados dos métodos descritos anteriormente, mostrando as melhores redes da etapa de treinamento e seus desempenhos como modelo interno de controladores.

Por fim, o Capítulo 5 apresenta as conclusões alcançadas, assim como sugestões para trabalhos futuros.

Capítulo 2: REVISÃO BIBLIOGRÁFICA

2.1. Aprendizado de Máquina: Redes Neurais

Algoritmos compreendidos dentro da área do aprendizado de máquina podem variar consideravelmente quanto aos seus conceitos, formulações e estratégias. Entretanto, possuem como característica pétreia a sua inerente iteratividade, assim, “aprendem” por meio da identificação de padrões, muitas vezes ocultos ao ser humano. A partir deste reconhecimento de padrões, modelos são construídos de modo a descrever os comportamentos exibidos pelos dados, podendo ser incorporados a diversas aplicações, desde controladores industriais a sites de busca.

A seguir, um breve histórico da evolução do aprendizado de máquina será exposto seguido da apresentação dos conceitos que constituem a estratégia de redes neurais, pilar fundamental deste trabalho.

2.1.1. Breve Histórico

A convergência de diversos fatores como plataformas baratas e poderosas de computação, progresso significativo em engenharia molecular, automação de operações globalmente integradas, rígidas restrições ambientais e demandas de negócios mais apertadas conduziram a engenharia química a um período importante de transição. Todos estes fatores estão diretamente associados a uma produção massiva de dados, combustível para o emprego de técnicas de Inteligência Artificial (IA), em particular, para o aprendizado de máquina. (VENKATASUBRAMANIAN, 2019)

Apesar de ser um assunto que vem ganhando significativa notoriedade nos últimos tempos, a aplicação de técnicas de IA à engenharia química não é necessariamente algo novo. Em meados das décadas de 80 e 90, os chamados sistemas especialistas viram sua popularidade crescer de forma parecida com o que é visto hoje com a inteligência artificial. Este tipo de abordagem é constituído por programas de computador que imitam a resolução humana de problemas com experiência em um determinado domínio através da adoção de heurísticas (ROTH et al., 1983). Apesar de sua popularidade neste período, algumas desvantagens como o esforço, custo e tempo necessários para desenvolver estes sistemas impediram sua ampla adoção.

Paralelamente ao declínio desta abordagem, o emprego de redes neuronais viu sua expansão. Este movimento representou uma mudança crucial do paradigma de design “*top-down*” de sistemas especialistas para um paradigma “*bottom-up*” de redes neuronais que adquirem conhecimento automaticamente de grandes quantidades de dados. Esta modalidade, acoplada aos significativos avanços técnicos que permearam a década de 90 e os anos 2000, estimulou uma enorme quantidade de trabalho em uma vasta variedade de domínios, incluindo engenharia química (HUANG, 1996). Nesta, pesquisadores fizeram progressos substanciais no tratamento de problemas desafiadores na modelagem, diagnóstico de falhas, controle e design de produto. (CASTRO; NEW, 2016; GANI, 2004; HERNÁNDEZ; ARKUN, 1992; VENKATASUBRAMANIAN; CHAN, 1989).

Apesar do sucesso das redes neuronais em muitas aplicações práticas, a necessidade de utilização de mais camadas para seu treinamento impedia sua maior empregabilidade até que futuros avanços permitissem a criação das chamadas redes neuronais profundas. Estas redes possuem várias camadas ocultas cuja arquitetura tem o potencial de extrair recursos hierarquicamente para o reconhecimento de padrões complexos (HINTON; OSINDERO; TEH, 2006), suplementarmente, estratégias de treinamento de redes por procedimentos convolucionais também foram fundamentais para o avanço da IA na última década, por fim, a combinação do aprendizado de máquinas com métodos matemáticos oriundos da estatística originou diversas técnicas de processamento de dados, podendo-se citar: florestas aleatórias, clusterização, LASSO (“*least absolute shrinkage and selection operator*”) e máquina de vetores de suporte (VENKATASUBRAMANIAN; CHAN, 1989).

Complementarmente aos avanços técnicos e teóricos, o imenso ganho computacional com redução do tamanho de hardware, desenvolvimento de diversas linguagens de programação de alto nível, evolução nas tecnologias de comunicação wireless e a ampla disponibilidade de dados são, cada um destes fatores por si só, divisores de águas e responsáveis conjuntamente pelo interesse renovado na inteligência artificial.

No contexto da engenharia química, apesar de diversos segmentos serem capazes de se beneficiar deste interesse renovado, projeto de materiais, operação de processos e diagnóstico de falhas se destacam como os principais. São áreas que já tiveram provas de conceito e barreiras psicológicas já foram vencidas no passado (PIRDASHTI et al., 2013). Por exemplo,

as empresas General Electric e British Petroleum (BP) já possuem softwares de aprendizado de máquina para monitoramento do desempenho de poços de petróleo em tempo real, permitindo que a BP maximize sua produção, reduzindo o tempo sem que ocorra nenhum comprometimento de segurança ou ambiental (KELLNER, 2015). Outro exemplo interessante consiste na empresa Uptake, que usou o ML para analisar dezenas de modos de falha em turbinas eólicas e previu com sucesso a maioria das falhas com antecedência para programar sua manutenção preventiva (WINICK, 2018).

2.1.2. O Neurônio como um modelo

Após séculos de pesquisa, o cérebro e o sistema ao qual ele faz parte seguem possuindo mistérios ainda não elucidados pela ciência, entretanto, há muito se conhece a unidade estrutural responsável pela condução de um impulso nervoso: o neurônio. Esta célula possui como característica a capacidade de estabelecer conexões entre si, recebendo estímulos, processando-os e repassando-os para células seguintes. Um conjunto de neurônios interconectados é denominado uma rede neuronal ou, quando inserido no contexto da ciência de dados, rede neuronal artificial (RNA).

Redes neuronais artificiais se inspiram no sistema nervoso e podem ser definidas como uma estrutura de processamento distribuída e altamente paralelizada, compostas por subunidades simples (neurônios) e que possui capacidade inerente para armazenamento de padrões e posterior disponibilização. (HAYKIN, 2007)

De forma análoga a um sistema biológico, os neurônios das RNAs (também conhecidos como perceptrons) são constituídos por três partes principais: as sinapses, uma junção somadora e uma função de ativação. A Figura 1 apresenta o esquema de um neurônio artificial n contendo m entradas (x_j) e dividido nas três partes que o compõem.

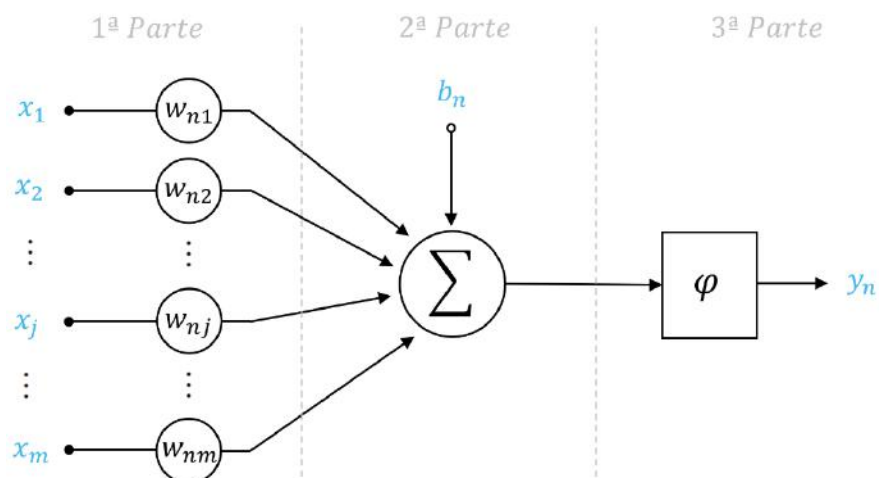


Figura 1: Modelo de um neurônio

A primeira parte caracteriza-se por um conjunto de sinapses, ou ligações, cada uma associada a um peso próprio (w_{nj}). Nesta etapa os sinais de entrada (x_j) são ponderados por seus pesos sinápticos para serem alimentados à segunda parte do neurônio. Ao contrário do peso de uma sinapse biológica, o peso aqui em questão pode estar em uma faixa que inclui tanto valores negativos quanto positivos. (HAYKIN, 2007)

A segunda parte do neurônio ou junção somadora é responsável por somar as entradas que foram ponderadas por seus pesos na primeira parte e acrescê-las a um *bias* (b_n). O *bias* b_n tem o efeito de aumentar ou diminuir a entrada da função de ativação, dependendo se este parâmetro é positivo ou negativo (HAYKIN, 2007). Uma outra forma de compreender este *bias* é comparando-o com a constante b de uma função linear ($y = ax + b$), sem ela, este tipo de função sempre cruzaria a origem e sua inclusão possibilita o deslocamento da reta para cima ou para baixo no eixo y . A representação matemática da segunda parte do neurônio é apresentada nas equações 1 e 2:

$$u_k = \sum_{j=1}^m w_{kj}x_j \quad (1)$$

$$v_k = u_k + b_k \quad (2)$$

Por fim, o resultado do processamento (v_k) torna-se o argumento de uma função de ativação (φ) responsável por limitar a amplitude da saída de um neurônio. Normalmente, a faixa de amplitude da saída de um neurônio é escrita como um intervalo de unidade fechada $[0,1]$ ou alternativamente $[-1,1]$ a depender da função de ativação empregada. (HAYKIN,

2007)

Esta etapa pode ser representada por:

$$y_k = \varphi(u_k + b_k) \quad (3)$$

Existem diversos exemplos de funções de ativação reportadas na literatura e que em geral podem ser classificadas em três grupos: degraus, lineares e não lineares. Dentre estas três classificações, normalmente este último configura-se como o tipo de função mais empregado uma vez que são capazes de introduzir não linearidades ao sistema e possibilitar a representação de um grupo maior de modelos, ainda que funções lineares do tipo ReLU tenham ganhado um grande espaço e relevância dentro da área. (FENG; LU, 2019)

Dentre as funções de ativação não lineares, as mais utilizadas são as funções logística (sigmoide) e tangente hiperbólica. Normalmente a função tangente hiperbólica apresenta desempenho superior uma vez que seu treinamento é facilitado pois ela aproxima-se mais do comportamento da função identidade, uma função linear. (MCCLELLAND et al, 1986)

As principais expoentes do grupo de funções lineares são as funções: identidade, ReLU (Rectifier Linear Unit) e *leaky* ReLU (rigorosamente essas duas últimas são lineares por partes). Por muito tempo este grupo foi preterido frente às estratégias não lineares, parcialmente pois algumas funções de ativação não eram capazes de capturar não linearidades do modelo ou devido a possibilidade de apresentarem natureza descontínua, possuindo um ou mais pontos não diferenciáveis em sua formulação. Atualmente e em função dos trabalhos de Hahnloser et al (2000) e Jarrett et al (2009), funções que apresentam característica linear retificante ganharam maior utilidade uma vez que possuem uma boa capacidade de generalização e apresentam relativo fácil treinamento.

As funções degrau possuem menos representantes e podem ser compreendidas como um subgrupo das funções lineares. São principalmente compostas pela função sinal e o degrau unitário, dentro da teoria do controle muito conhecido também como a função de Heaviside. (RAMACHANDRAN et al, 2017)

A Tabela 1 exemplifica as funções citadas, seu gráfico e suas as equações características

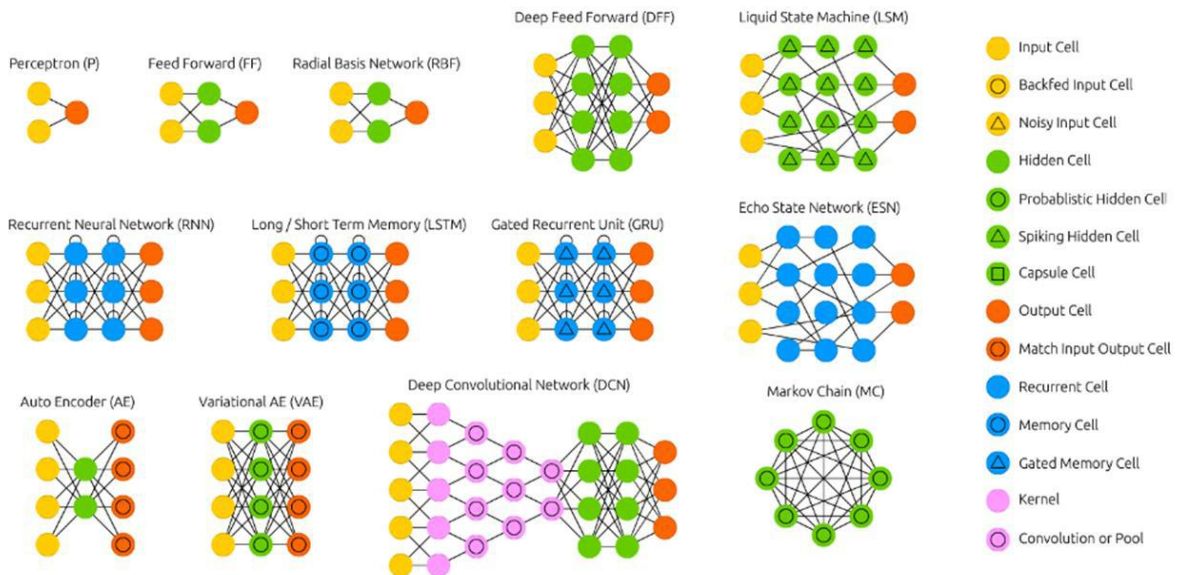
Tabela 1: Funções de ativação com suas respectivas equações e gráficos

<i>Tangente Hiperbólica</i>	<i>Logística</i>	<i>ReLU</i>	<i>Leaky ReLU</i>	<i>Identidade</i>	<i>Sinal</i>	<i>Degrau Unitário</i>
$\tanh(x)$	$\frac{1}{1 + e^{-x}}$	$\begin{cases} 0 & \text{se } x < 0 \\ x & \text{se } x \geq 0 \end{cases}$	$\begin{cases} ax & \text{se } x < 0 \\ x & \text{se } x \geq 0 \end{cases}$	$f(x) = x$	$\begin{cases} -1 & \text{se } x < 0 \\ 1 & \text{se } x \geq 0 \end{cases}$	$\begin{cases} 0 & \text{se } x < 0 \\ 1 & \text{se } x \geq 0 \end{cases}$

2.1.3. Arquitetura de Redes neuronais

Apesar de ter sido descrito apenas o modelo de um neurônio na seção anterior, existem outras variações e a forma como estes neurônios são estruturados em uma RNA gera um grande leque de tipos de rede e, ainda mais relevante que as diferenças estruturais, existe uma também ampla variedade de algoritmos empregados para o treinamento de RNAs. A Figura 2 ilustra algumas das configurações de redes neuronais, cabendo a ressalva que a imagem apenas arranha a superfície das vastas possibilidades existentes.

Figura 2: Mostruário de redes neuronais artificiais



Fonte: Adaptado de Van Veen, 2016

Nesta seção serão descritas as duas classes fundamentais de arquiteturas de rede, das quais todas as estruturas derivam-se.

Redes Feedforward

Esta classe de rede caracteriza-se pela propagação somente para frente dos sinais ao longo de suas camadas. A estrutura de uma rede *feedforward* inclui necessariamente uma camada de entrada, que disponibiliza os inputs para a camada seguinte, e uma camada de saída que retorna os resultados computacionais da RNA. Caso não existam camadas intermediárias entre estas duas camadas descritas, trata-se, portanto, de uma Rede *Feedforward* de Camada Única, e caso existam então a RNA configura-se como uma Rede *Feedforward* de Múltiplas Camadas (ou MLP como se é referido em inglês).

A adição de camadas escondidas é justificada pois ao adicionar uma ou mais camadas ocultas, a rede é habilitada a extrair estatísticas de ordem superior de sua entrada, aumentando o leque de funções, comportamento e modelos que podem ser aproximados. (GOODFELLOW et al, 2016).

A Figura 3 ilustra os dois tipos de rede previamente expostas, cada círculo deve ser compreendido como um neurônio, idêntico ao mostrado na Figura 1. Na esquerda é exibida uma rede com camada única contendo quatro entradas (x_j) e quatro saídas (y_j). Na direita uma rede MLP é exibida contendo quatro entradas (x_j), três saídas (y_j) e duas camadas escondidas, cada uma contendo quatro neurônios.




Figura 3: Redes Feedforward com única ou múltiplas camadas

Uma forma alternativa de informar a quantidade de camadas e número de neurônios (e que será empregada neste trabalho) consiste em escrever dentro de parênteses o número de neurônios por camadas. Por exemplo, a rede MLP contida na Figura 3 pode ser representada segundo: (4, 4, 4, 3).

Redes MLP são comumente aplicadas a problemas de aprendizagem supervisionada, isto é, treinam com um conjunto de entrada / saída (também denominado padrão) e buscam ajustar o valor dos pesos e bias do modelo buscando minimizar o erro frente a saída esperada. Esta etapa de treinamento será melhor detalhada na seção 2.1.4.

Redes Recorrentes

Esta segunda classe de rede se distingue da primeira pela presença de um ou mais *loops* de *feedback*. Dentro de um sistema dinâmico, um *feedback* existe se a saída de um elemento no sistema influencia a entrada aplicada a esse elemento direta ou indiretamente. Assim, dá-se origem a um ou mais *loops* fechados para a transmissão de sinais ao redor do sistema. (HAYKIN, 2007)

No contexto de redes recorrentes, esse *feedback* se dá quando a saída de um neurônio é realimentada como entrada a ele ou a outro neurônio permitindo a rede memorizar, temporalmente, informações.

A Figura 4 exemplifica este tipo de rede, nela pode-se observar um *feedback* de um neurônio para si próprio (em azul) e de um neurônio para outros (em preto).




Figura 4: Rede Recorrente Genérica

2.1.4. Treinamento de Redes

De forma geral o treinamento de uma rede neuronal pode ser compreendido como o processo pelo qual a rede adquire a capacidade de replicar padrões e modelar fenômenos complexos. Neste processo, seus pesos e *bias* são gradativamente sintonizados buscando o ajuste mais fidedigno ao modelo intrínseco ao conjunto de dados fornecido.

Este processo é inerentemente iterativo e muito depende do tipo e das características da rede, também denominados hiperparâmetros. Fatores como a quantidade de camadas,

número de neurônios, sua disposição, funções de ativação, presença ou não de recorrência são fundamentais para a escolha da estratégia a ser empregada. Hiperparâmetros ainda não apresentados serão expostos na seção 2.1.5.

Naturalmente existe uma ampla variedade de possibilidades de treinamento, podendo ser agrupadas em três grandes tipos de abordagens: supervisionada, não supervisionada e treinamento por reforço.

Abordagens supervisionadas são caracterizadas pela presença de um conjunto de valores de entrada e de saídas esperadas e, a cada etapa, a rede processa as suas variáveis de entradas obtendo de um conjunto de saída. A seguir este resultado é comparado com a saída esperada fornecida e um erro pode ser calculado. Este processo pode ser comparado ao aprendizado de um aluno em sala de aula, que, ao resolver um exercício, examina a solução fornecida ao final do livro e compara com a que ele havia originalmente obtido, em seguida e em caso de equívocos, busca ajustar suas contas de modo a eliminar seu erro. Por fim a resolução sucessiva de diversos exercícios garante ao aluno um entendimento daquelas equações que ele buscou utilizar. (GOODFELLOW et al, 2016).

As seguintes duas abordagens caracterizam-se pela ausência de um conjunto de saída rotulado. Na estratégia não supervisionada, a rede busca identificar padrões estatísticos nas entradas fornecidas, criando subgrupos que visam classificar os diferentes padrões presentes no conjunto de treinamento. É uma estratégia frequentemente usado para identificar padrões e tendências em conjuntos de dados brutos ou agrupar dados semelhantes em grupos. (GOODFELLOW et al, 2016).

Aprendizado por reforço é um tipo de técnica de aprendizado de máquina que permite que um agente aprenda em um ambiente interativo por tentativa e erro usando feedback de suas próprias ações e experiências. Embora tanto o aprendizado supervisionado quanto o aprendizado por reforço usem mapeamento entre entrada e saída, o aprendizado por reforço usa recompensas e punições como sinais de comportamento positivo e negativo. (GOODFELLOW et al, 2016).

Como exposto previamente, diferentes configurações de RNAs demandam estratégias de treinamento diferentes. Em vista ao tipo de rede empregado no presente trabalho, torna-

se pertinente o detalhamento do conjunto de estratégias que podem ser aplicadas no treinamento de redes do tipo MLP. Na etapa seguinte busca-se explicar o funcionamento do algoritmo de *backpropagation* assim como aperfeiçoamentos desenvolvidas.

Backpropagation

O algoritmo de *backpropagation* (BP) foi originalmente introduzido na década de 1970, contudo sua grande relevância somente foi apreciada após 1986 quando Rumelhart, Hinton e Willians publicaram seu (hoje) famoso artigo “*Learning representations by back-propagating errors*”. Nele os autores mostraram como a retropropagação funcionava muito mais rápido do que as abordagens anteriores de aprendizagem, e assim, tornaram possível sua utilização para resolução de problemas antes tidos como impossíveis.

O princípio de funcionamento da estratégia pode ser dividido em duas etapas: Na primeira as entradas são propagadas para a frente, efetuando-se todo o processamento matemático até a obtenção das saídas e subsequente computo dos erros, em seguida os erros são propagados para trás e os pesos são atualizados. A segunda etapa equivale a minimização de uma função correspondente ao erro entre as saídas calculadas (y_i) e as saídas alvo (\hat{y}_i), no caso clássico do algoritmo de BP, ela corresponde à função de mínimos erros quadráticos exposta a seguir. (DE SOUZA JR, 1993)

$$E = \frac{1}{2N} \sum_{i=1}^N \left(\hat{y}_i - y_i(\bar{w}, \bar{x}, \bar{b}) \right)^2 \quad (4)$$

Onde N corresponde ao número total de saídas e y_i é uma função dos vetores de entradas (\bar{x}), pesos (\bar{w}) e bias (\bar{b}) da rede.

Em um ponto de mínimo:

$$\nabla E(\bar{w}) = \bar{0} \quad (5)$$

No artigo original de Rumelhart et al (1986), a estratégia de minimização e atualização de parâmetros consistiu no emprego do método do gradiente descendente (GD ou *steepest descent* em inglês) no qual a direção de busca é o negativo do gradiente. As derivadas são calculadas segundo a regra da cadeia e o erro é propagado ao longo das camadas de neurônios no sentido contrário da informação. Na k -ésima iteração o vetor de pesos e bias é expresso por:

$$\Delta \bar{w}_{k+1} = \bar{w}_k - \eta \nabla E(\bar{w}_k) \quad (6)$$

$$\Delta \bar{b}_{k+1} = \bar{b}_k - \eta \nabla E(\bar{b}_k) \quad (7)$$

Onde η corresponde a uma taxa de aprendizagem, podendo ser fixa ou variar a cada iteração. Na implementação do método, os parâmetros podem ser atualizados a cada padrão ou após a apresentação do conjunto de padrões (lote ou época).

O método de *backpropagation* foi extensivamente investigado na literatura, sendo aprimorado ao longo dos anos. Alguns dos principais aprimoramentos relacionam-se às abordagens para determinação das direções de busca e taxas de aprendizado.

Para determinação da direção de busca, algumas abordagens empregam a métodos de Newton, incorporando informações de segunda ordem sobre a função objetivo através da utilização da Hessiana. Alternativamente, métodos quasi-Newton como o BFGS (Broyden–Fletcher–Goldfarb–Shanno) também podem ser utilizados, evitando-se assim o cálculo analítico da Hessiana. (DE SOUZA JR, 1993)

2.1.5. Hiperparâmetros Adicionais

A seguir, parâmetros ainda não apresentados das RNAs serão expostos, dentre eles são relevantes citar: número de camadas, de neurônios por camadas, tamanho de lote e termo de regularização.

Número de Camadas

Admitindo um número suficiente de neurônios, a utilização de apenas uma camada escondida pode ser o suficiente para modelar diversos tipos de funções. Conforme a complexidade da função cresce, o número de neurônios necessários também cresce e seu treinamento pode se tornar computacionalmente custoso.

Redes com mais camadas são capazes de realizar um treinamento mais eficiente enquanto utilizam uma quantidade de neurônios por camada muito inferior. Géron (2017) sugere iniciar o estudo com duas camadas e aumentar gradualmente, evitando assim o sobre ajuste do conjunto de treinamento.

Número de Neurônios por Camada

A determinação da quantidade ideal de neurônios é normalmente feita de forma empírica e não há um consenso na literatura sobre a melhor forma ou método para estruturar uma rede, normalmente encontram-se apenas recomendações de abordagens ou estratégias. O número de neurônios não deve ser demasiadamente pequeno uma vez que se diminui a chance de convergência, porém também não deve ser excessivamente grande de modo que se favoreça a memorização dos dados de treinamento (*overfitting*). (HAYKIN, 2007)

Uma prática comum consiste em dimensionar o número de neurônios de acordo com a quantidade de *input* e *outputs* das redes, em outras palavras, de acordo com o número de neurônios nas camadas de entrada e saída. Nessa estratégia o número de neurônios é escolhido formando um “funil” entre as duas extremidades da rede. (GÉRON, 2017)

Alternativamente, outra prática consiste em utilizar o mesmo número, ou quantidades ligeiramente maiores, de neurônios da camada de entrada em todas as camadas, entretanto esta estratégia costuma ter um custo computacional mais elevado.(GÉRON, 2017)

Tamanho de Lote

Quando inserido em uma estrutura segundo a abordagem de aprendizado por reforço em lote, ou seja, a cada iteração da rede, um conjunto de dados (lote ou *batch*, em inglês) é utilizado para treiná-la. O número de amostras por lote possui influência direta no esforço computacional e no desempenho da rede.

Geralmente deseja-se usar um tamanho de lote maior para treinar determinado modelo, pois permite acelerações computacionais advindas do paralelismo das GPUs. No entanto, um tamanho de lote muito grande levará a uma generalização ruim. Para funções convexas, há um cabo de guerra inerente entre os benefícios de tamanhos menores e maiores. (SMITH, 2018)

Por um lado, usar um lote igual a todo o conjunto de dados garante a convergência para o ótimo global da função objetivo. No entanto, isso ocorre à custa de uma convergência mais lenta para esse ótimo. Por outro lado, o uso de tamanhos de lote menores demonstra ter uma convergência mais rápida para soluções satisfatórias. Isso é explicado intuitivamente pelo

fato de que tamanhos de lote menores permitem que o modelo “comece a aprender antes de ter que ver todos os dados”. (SMITH, 2018)

Termo de Regularização

O termo de regularização, também conhecido como alfa ou termo de penalidade, possui a função de combater o *overfitting* restringindo o tamanho dos pesos ao atualizar a função de custo. A equação 8 ilustra a adição do termo de regularização L2 à função custo associada ao problema de otimização de interesse.

$$\text{Função Custo} = \text{Perda} + \alpha * \sum \|\bar{w}\|^2 \quad (8)$$

Aumentar o alfa pode corrigir a alta variância (um sinal de *overfitting*) incentivando pesos menores. Da mesma forma, a diminuição do alfa pode corrigir o alto viés (um sinal de *underfitting*) incentivando pesos maiores. (HAYKIN, 2007)

2.2. Poço de Elevação Artificial

De forma simplificada, a exploração de uma reserva de petróleo passa por três macro etapas diferentes. A primeira consiste na perfuração do poço, estabelecendo o elo entre a reserva e o leito marítimo. A etapa seguinte é denominada completação, esta fase é composta por diversas operações destinadas a equipar o poço com todos os equipamentos e acessórios necessários para torná-lo apto para produção. (THOMAS, 2001)

A etapa final denomina-se extração e compreende a retirada de fluidos do poço que, quando surgente, possui pressão de reservatório suficientemente elevada para que haja fluxo de fluidos (óleo, água e gás) do reservatório até as facilidades de produção. (THOMAS, 2001)

No início de sua vida útil, o petróleo costuma escoar espontaneamente até a superfície, porém devido à inevitável redução da pressão do poço, ele deixa de ser capaz de sustentar um fluxo de óleo, tornando-se necessário o uso de equipamentos e estratégias que sejam capazes de estender sua vida útil. Estas estratégias são denominadas como elevação artificial e de forma geral compreendem dois grandes grupos: Elevação por bombas ou elevação por meio de gás (*Gas Lift – GL*). (ARCHER; WALL, 2012)

Em função das motivações previamente expostas no Capítulo 1, o presente trabalho focará na segunda alternativa e seus princípios de funcionamento e modelos existentes serão

mais amplamente investigados a seguir.

2.2.1. Princípios de Funcionamento

A estratégia de elevação artificial por meio de gás é comumente descrita como uma estratégia versátil em termos de vazões e profundidades, além de ser considerada uma abordagem robusta, de fácil manutenção e baixo custo. (THOMAS, 2001)

As Figura 5 e Figura 6 ilustram de forma simplificada respectivamente uma unidade offshore e a estrutura de uma coluna de produção adaptada à estratégia de *gas lift*.




Figura 5: Representação de uma unidade offshore de exploração




Figura 6: Representação simplificada de uma coluna offshore de *gas lift*

Os princípios físicos e de funcionamento que regem a estratégia de *gas lift* são simples em sua essência, o gás é injetado pelo topo da seção anular (*annulus*) e conduzido ao fundo da tubulação onde é misturado ao gasóleo através de um orifício denominado como orifício de injeção. A adição de gás ao fluido reduz a densidade média nas proximidades do orifício de injeção. A adição de gás ao fluido reduz a densidade média nas proximidades do orifício, reduzindo consequentemente a pressão hidrostática do meio, facilitando o escoamento e viabilizando a produção do poço. (ARCHER; WALL, 2012)

Dependendo de fatores como o índice de produtividade do poço, condições do reservatório e volume produzido, a injeção de gás pode ser feita de maneira contínua ou

intermitente. Operações contínuas são caracterizadas por um fluxo contínuo de gás-óleo e regime estacionário. Operações intermitentes são por natureza não estacionárias e o comportamento do fluxo é caracterizado como oscilatório, isto é, ora fluindo, ora sem fluir do fundo do poço até a superfície.

Apesar de ser majoritariamente empregada em poços não surgentes, a estratégia em questão também pode ser utilizada para cenários nos quais poços são ainda capazes de promover o fluxo de forma natural. Neste caso, a injeção de gás aumentará a produção, contudo cabe a empresa detentora dos direitos de exploração avaliar a viabilidade econômica da estratégia.

A adoção do *Gas Lift* é recomendada sob diversos cenários, contudo destacam-se seu emprego em poços com trajetória inclinada, uma vez que a instalação de bombas no fundo do oceano é dificultada, e poços que produzem juntamente com o óleo outros sólidos como areia e sedimentos pois esta abordagem emprega menos partes móveis se comparada às estratégias utilizando bombas.

2.2.2. Princípios de Operação e Comportamento Dinâmico de Poços

A condução da operação de elevação artificial é realizada baseando-se nas decisões tomadas nas salas de operações, principalmente sobre os dois graus de liberdade do sistema: a abertura da *choke* de injeção e da *choke* de produção. A manipulação destas válvulas objetiva a adequação ao patamar de produção desejado (*set-point*), podendo operar em zonas estáveis ou de grandes instabilidades. (JAHANSHAHI et al, 2012)

A depender de fatores como temperatura, pressão, vazão de injeção, velocidade de escoamento e disposição física das tubulações, o escoamento multifásico pode tomar diversas formas, alguns dos quais podendo trazer problemas à produção, como é o caso das golfadas. A Figura 7 ilustra os diferentes padrões de golfadas para escoamentos verticais e horizontais.

A problemática das golfadas caracteriza-se por um fluxo intermitente com comportamento tipicamente cíclico cujos principais problemas associados são: altas pressões na linha de produção, excesso de líquido nos separadores gás-líquido, fadiga mecânica dos equipamentos, diminuição da produção do poço. (ASHIKAWA, 2017)




Figura 7: Tipos de Escoamento Multifásico

Fonte: Adaptado de Jahanshani, 2013

Dentre os mecanismos causadores de golfadas, podem-se citar:

- Golfadas Hidrodinâmicas (*Hydrodynamic Slugging*): Ocorrem em dutos horizontais e caracterizam-se por apresentarem elevada frequência, porém amplitudes menores na variação de pressões e vazões.
- Golfadas induzidas pelo terreno (*Terrain-Induced Slugging*): irregularidades no leito marinho podem induzir o acúmulo de líquido em posições de menor elevação, causando bloqueio no fluxo de gás.
- Golfadas por manobras (*Operation-based Slugging*): Determinadas manobras podem causar instabilidades na operação de poços, a passagem do PIG para limpeza interna de dutos é um exemplo disso.

Para sistemas de elevação vertical como o estudado neste trabalho, destacam-se ainda um quarto tipo de golfada: Golfadas causadas pelo efeito *casing-heading*.

A origem deste fenômeno reside na abertura das válvulas de injeção e produção, portanto, devido à sua relevância ao trabalho será mais aprofundado que as outras.

Golfadas por *Casing-Heading*

Idealmente, pontos de operação ótimo estão localizados em regiões nas quais há baixa injeção de gás, e com elevadas produções de gasóleo. Contudo, é nestas regiões que o fenômeno de *casing-heading* tende a ocorrer.

Para uma determinada abertura da choke de produção, o poço pode operar segundo três padrões de comportamento. A Figura 8 ilustra o comportamento da vazão de produção em três regimes mediante a aplicação de um degrau na válvula de injeção e simulada utilizando o modelo de Rojas Soares et al. (2019).




Figura 8: Perfis de comportamento de vazão

Observa-se que, para uma mesma abertura da válvula de produção ($u_1 = 60\%$), o comportamento da vazão de gásóleo pode variar de estável a instável à medida que a válvula de injeção (u_2) é fechada, isto é, a vazão de ar injetado é reduzida. O comportamento exibido no gráfico intermediário corresponde ao limite de abertura da válvula de injeção no qual ainda há estabilidade, também denominado ponto de bifurcação de Hopf. Matematicamente este ponto caracteriza-se como um ponto crítico onde a estabilidade de um sistema deixa de existir, dando origem a uma solução periódica de oscilação sustentada. (DIEHL et al., 2021; RODRIGUES et al., 2018)

O fenômeno de *casing-heading* é justamente o responsável pela natureza oscilatória demonstrada no terceiro gráfico da figura e seu entendimento é facilitado se for dividido em etapas. Estas são descritas a seguir e o comportamento dinâmico pode ser verificado na Figura 9. (JAHANSHAHI et al., 2009)

1. Em um primeiro momento a pressão ar de injeção é inferior à pressão no ponto de injeção, como consequência a pressão no *annulus* cresce até que se atinja

um valor igual à pressão no ponto de injeção. Neste momento o fluxo de ar para o tubo interior é viabilizado.

2. À medida que o ar injetado se mistura com o óleo, a coluna de líquido tem sua densidade reduzida e começa a se deslocar. Uma vez que a taxa de injeção de gás não atende a necessidade do poço, a pressão no *annulus* cai e a produção atinge o máximo.
3. Com a queda de pressão no annulus, a injeção de gás é reduzida e consequentemente a vazão de produção também. Com menos gás sendo injetado, a coluna de óleo fica mais pesada e a pressão no tubo interior excede a pressão a montante. Neste momento a vazão de ar é novamente interrompida.

Quando este fenômeno de pressão insuficiente ocorre no riser ao invés do annulus, o tipo de golfada é denominado de golfada de *riser* ou golfada severa (*Riser Slugging*). (ASHIKAWA, 2017)

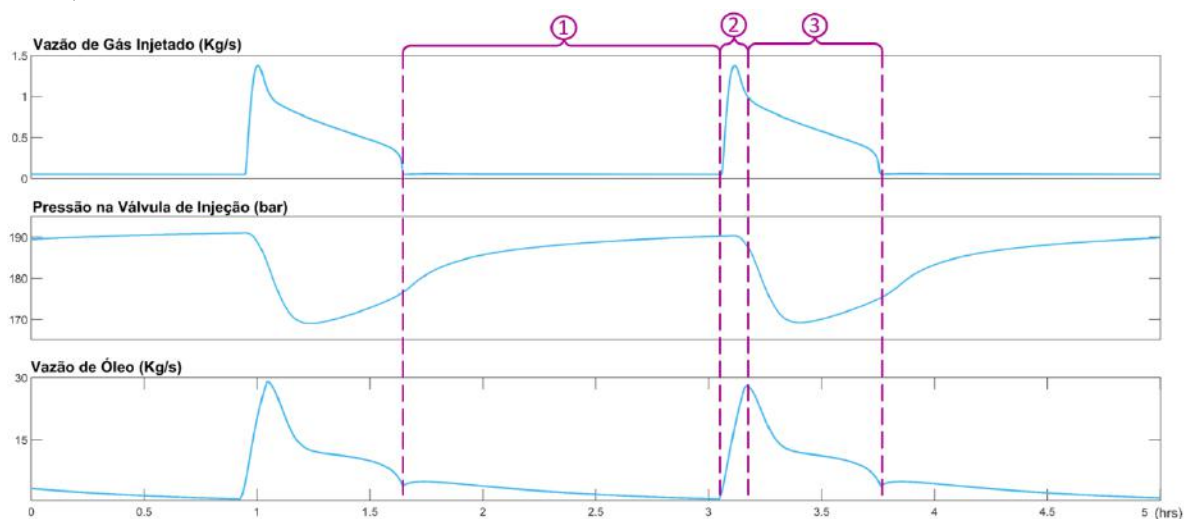


Figura 9: Comportamento Dinâmico no regime Casing-Heading

Fonte: Adaptado de Jahanshani et al., 2009

2.2.3. Modelagem Matemática

O ambiente de elevada complexidade no interior dos poços torna a tarefa de obtenção de modelos matemáticos rigorosos um significativo desafio para o setor. Na literatura específica do segmento existem alguns exemplos de modelos, contudo estes ainda apresentam diversas aproximações frente o comportamento real.

A seguir três modelos disponíveis na literatura são apresentados de forma simplificada, e caso deseje-se um aprofundamento maior, recomenda-se que os artigos originais sejam consultados uma vez que os detalhes e pormenores foram aqui omitidos. O primeiro modelo descrito (Eikram *et al.*) configura-se como a base dos demais, portanto um maior aprofundamento matemático será feito neste. Para os demais modelos, suas principais diferenças e melhorias serão discutidas.

Modelo de Eikrem et al. (2008)

Baseando-se em estudos utilizando equipamentos em escala piloto da *Delft University of Technology* (DUT), os autores buscaram desenvolver um modelo que representasse de forma simplificada o fenômeno de *casing heading* de um poço de *gas lift*. Desta forma, algumas simplificações foram feitas como:

- Comportamento de gás ideal;
- Perfil de composição homogêneo e propriedades constantes;
- Perda de pressão devido ao atrito com o tubo é negligenciável, assim como compressibilidade e variações de temperatura.

Na proposta dos autores, o processo é modelado a partir de três estados: massa do gás no annulus (x_1), massa de gás no tubo interior (x_2) e massa de óleo produzido (x_3). As equações que descrevem estes três estados estão dispostas a seguir.

$$\dot{x}_1 = w_{G,in} - w_{G,inj} \quad (9)$$

$$\dot{x}_2 = w_{G,inj} + w_{G,res} - w_{G,out} \quad (10)$$

$$\dot{x}_3 = w_{L,res} - w_{L,out} \quad (11)$$

Por sua vez, as vazões w apresentadas acima podem ser explicitadas segundo:

$$w_{gc} = \text{vazão de gás injetado} = \text{Constante} \quad (12)$$

$$w_{iv} = \text{vazão de gás no annulus} = C_{iv} \sqrt{\rho_{a,i} \cdot \max(0, P_{a,i} - P_{wi})} \cdot \quad (13)$$

$$w_{pc} = \frac{\text{vazão da mistura vindo do tubo interior}}{\text{do tubo interior}} = C_{pc} \sqrt{\rho_m \cdot \max(0, P_{wh} - P_0)} \cdot f_{pc}(u) \quad (14)$$

$$w_{pg} = \frac{\text{vazão de gás que passa pela válvula de produção}}{\text{pela válvula de produção}} = \frac{x_2}{x_2 + x_3} \cdot w_{pc} \quad (15)$$

$$w_{po} = \frac{\text{vazão de óleo que passa pela válvula de produção}}{\text{pela válvula de produção}} = \frac{x_3}{x_2 + x_3} \cdot w_{pc} \quad (16)$$

$$w_{ro} = \frac{\text{vazão de óleo do reservatório para o tubo interior}}{\text{para o tubo interior}} = C_r \sqrt{\rho_0 \cdot (P_{res} - P_{wb})} \quad (17)$$

$$w_{rg} = \frac{\text{vazão de gás do reservatório para o tubo interior}}{\text{para o tubo interior}} = GOR \cdot w_{ro} \quad (18)$$

Em que C_{iv} , C_{pc} , C_r correspondem a constantes associadas às válvulas do processo.

As variáveis $P_{a,i}$, P_{wi} , P_{wh} , P_{wb} são respectivamente as pressões no annulus, na coluna, na cabeça do poço, no fundo do poço.

P_0 corresponde à pressão no *manifold* e P_{res} é a pressão do reservatório, ambas são consideradas constantes.

GOR é o acrônimo em inglês para “*gas to oil ratio*” e é a razão gás/óleo da mistura que sai do reservatório.

Por fim, os símbolos $\rho_{a,i}$, ρ_m e ρ_0 correspondem respectivamente às densidades do gás no annulus no ponto de injeção, da mistura na cabeça do poço, e do óleo no reservatório.

As densidades e pressões utilizadas nos cálculos de vazões são por sua vez calculadas segundo a equação de estado do gás ideal e são apresentadas nas equações:

$$P_{a,i} = \left(\frac{R \cdot T_a}{V_a \cdot M} + \frac{g \cdot L_a}{V_a} \right) \cdot x_1 \quad (19)$$

$$P_{wh} = \frac{R \cdot T_w}{M} \cdot \frac{x_2}{L_w \cdot A_w - v_0 \cdot x_3} \quad (20)$$

$$P_{wi} = P_{wh} + \frac{g}{A_w} \cdot (x_2 + x_3) \quad (21)$$

$$P_{wb} = P_{wi} + g \cdot L_r \cdot \rho_0 \quad (22)$$

$$\rho_0 = \frac{1}{v_0} \quad (23)$$

$$\rho_{a,i} = \frac{M}{R \cdot T_a} \cdot P_{a,i} \quad (24)$$

$$\rho_m = \frac{x_2 + x_3}{L_t \cdot A_w} \quad (25)$$

Em que v_0 é o volume específico do óleo, M é a massa molar do gás, R é a constante universal dos gases e g corresponde à gravidade.

A, L, T e V são respectivamente: área, comprimento, temperatura e volume. Os subscritos que estas variáveis podem apresentar referem-se à posição delas no equipamento, o subscrito a refere-se ao *annulus*, r ao ponto abaixo do ponto de injeção de gás e w ao ponto acima do ponto de injeção de gás no tubo interior.

Modelo de Jahanshahi et al. (2012)

Apesar de configurar-se como uma estratégia sólida para a representação do comportamento dinâmico do poço, o modelo de (Eikrem et al., 2008) possui premissas que o distancia de um modelo rigoroso. Jahanshahi e seus colaboradores buscaram responder a isto com modificações como incorporação de efeitos da perda de pressão por atrito no poço e uma abordagem diferente para o cálculo das frações de óleo e gás e da densidade no topo da tubulação.

O cálculo da perda de pressão no tubo foi viabilizado pelo uso de uma aproximação implícita proposta por Haaland (1983) da equação de Colebrook-White (Eq. 26) para determinação do fator de atrito.

$$\frac{1}{\sqrt{\lambda_t}} = -1.8 \cdot \log_{10} \left[\left(\frac{\epsilon}{3.7 \cdot D_t} \right)^{1.11} + \frac{6.9}{Re_t} \right] \quad (26)$$

Em que λ_t é o fator de fricção, Re_t é o número de Reynolds do fluxo no tubo interior, D_t é o diâmetro do tubo e ϵ é a aspereza do tubo.

A abordagem para o cálculo de frações e densidade se baseou nos trabalhos de Jahanshahi e Skogestad (2011) em que se sugere que as frações podem ser bem aproximadas pela divisão das vazões médias de líquido pela soma das vazões médias de gás e líquido.

O modelo proposto pelos autores obteve sucesso em expandir a base criada por Eikram et al. obtendo respostas mais próximas de simulações obtidas em softwares comerciais (*OLGA Dynamic Multiphase Flow Simulator*), contudo algumas das premissas do modelo original ainda foram mantidas.

Modelo de Rojas Soares et al. (2019)

Em um ambiente submarino cujas pressões são elevadas e temperaturas baixas, a hipótese e adoção de comportamento ideal para fase gasosa não é a mais adequada. Rojas Soares et al. (2019) utilizaram a Equação de Estado de Peng-Robinson para descrever o comportamento do gás de forma mais realista. Complementarmente, foi adicionado ruído à razão gás/óleo da mistura (GOR) e o cálculo da perda de pressão por fricção passa a utilizar a produção média nos 5 segundos anteriores. As características principais dos modelos são resumidas na Tabela 2:

Tabela 2: Comparação entre modelos

Eikram et al. (2008)	Jahanshani et al. (2012)	Rojas Soares et al. (2019)
Perfil de frações de fase homogêneo	Perfil de frações de fase linear ao longo do tubo	Perfil de frações de fase linear ao longo do tubo
Perda de pressão por fricção não considerada	Perda de pressão por fricção é considerada utilizando produção constante do reservatório	Perda de pressão por fricção é considerada utilizando produção média do reservatório pelos últimos 5 segundos
GOR constante	GOR constante	GOR Ruidoso
Equação de Estado do Gás Ideal	Equação de Estado do Gás Ideal	Equação de Estado de Peng-Robinson
Vazão de gás injetado como variável manipulada	Válvula de injeção e produção como variáveis manipuladas	Válvula de injeção e produção como variáveis manipuladas

Fonte: Adaptado de Dias et al., 2019

2.3. Controle Preditivo Baseado em Modelo (MPC)

O termo MPC por princípio não se refere a um controle ou abordagem específica, mas sim a um conjunto de métodos de controle com propriedades comuns objetivando manter um processo em uma condição desejada ou promover a mudança entre dois estados estacionários. Naturalmente, o pilar fundamental deste conjunto de abordagens está na utilização de um modelo representativo do processo para prever o comportamento da saída em um determinado horizonte, assim, o controlador passa a considerar as interações entre as variáveis de entrada e saída, bem como as dinâmicas que existam entre elas.(RIBEIRO, 2019; SCHNITMAN, 1998)

Apesar de não serem a abordagem de maior adoção em ambientes industriais, estratégias de controle preditivo por modelo estão vendo sua popularidade e aplicabilidade crescerem significativamente. A motivação por trás deste fato reside em sua versatilidade, uma vez que MPCs demonstraram êxito ao longo dos anos ao lidar com diferentes problemas de controle, desde sistemas SISO (uma única entrada e saída) a sistemas com MIMO (múltiplas entradas e saídas). Complementarmente, esta abordagem possibilita o acoplamento com técnicas de otimização da planta como um todo, bem como suas restrições operacionais.(RIBEIRO, 2019)

A seguir, os principais fundamentos dos MPC serão expostos e, em vista à natureza deste trabalho, será dado um maior enfoque para a utilização de redes neurais artificiais como modelo. Em seguida, serão discutidos alguns trabalhos recentes relacionados ao controle de poços de *gas lift*.

2.3.1. Fundamentos Teóricos

Fundamentalmente um controlador é um algoritmo capaz de gerar valores para as variáveis manipuladas (MV) de um processo de modo a atender uma determinada especificação (*set-point*) da variável controlada (CV). Enquanto abordagens tradicionais não consideram de forma explícita o efeito futuro das ações de controle, MPCs são capazes de ponderar as suas ações levando em consideração o comportamento futuro do processo, evitando assim a condução a estados que apresentem dificuldades.(QIN; BADGWELL, 2003)

Os modelos escolhidos são a parte fundamental de qualquer MPC, da qual o sucesso do controlador é extremamente dependente. Nesse sentido, Rawlings (2000) escreveu que “O feedback pode superar alguns efeitos indesejados de modelos, mas começar com um modelo de processo ruim é semelhante a dirigir um carro à noite sem faróis”.

Sendo assim, a única restrição à utilização de determinado modelo é a necessária capacidade de evidenciar adequadamente a relação entre as entradas e saídas do processo. Consequentemente eles podem possuir as mais variadas formulações matemáticas como: lineares, não lineares, fenomenológicos, empíricos, baseados em funções de transferência, espaço de estados, redes neuronais etc. Quando os modelos internos utilizados são de natureza linear, emprega-se a terminologia MPC, contudo, quando o conjunto de equações que compõe o modelo for de natureza não linear, adota-se a terminologia NMPC (*Nonlinear Model Predictive Control*).

Os objetivos gerais de um controlador MPC foram resumidos por Qin e Badgwell (2003) como sendo:

1. Prevenir violações de restrições de entrada e saída.
2. Levar algumas variáveis de saída para seus set-points ótimos, enquanto mantém outras saídas dentro de intervalos especificados.
3. Prevenir movimentos excessivos de variáveis de entrada.
4. Controlar o maior número possível de variáveis quando um sensor ou atuador está indisponível.

O horizonte em que um controlador avaliará a resposta de um processo é denominado horizonte de predição e configura-se como um de seus mais importantes parâmetros de sintonia. Seu ajuste deve ser tal que permita o controlador “enxergar” o comportamento relevante do processo, porém não pode ser tão curto que sua utilização seja inviabilizada devido ao alto custo computacional. Complementarmente, o horizonte de controle configura-se como o espaço de tempo em que o controlador possuirá graus de liberdade para atuar no sistema. (SEBORG et al., 2016)

Assim, a tarefa do MPC é escolher a melhor sequência de ações dentro do horizonte de controle que conduza e mantenha o processo na trajetória almejada. A escolha destas ações é realizada baseando-se na minimização de uma função custo, esta deve idealmente ser de natureza simples e englobar aspectos futuros do processo. (SEBORG et al., 2016)

Um exemplo simples de função custo é apresentado pela Eq. 27 em que HC é o horizonte de controle, HP é o horizonte de predição, \hat{y} é a trajetória calculada pelo modelo e r a trajetória de referência (*set-point*), Δu corresponde às variações aplicadas às variáveis manipuladas e α é um fator de penalização.

$$S = \sum_{k=1}^{HC} (r_{k+1} - \hat{y}_{k+1})^2 + \alpha \cdot \sum_{k=0}^{HP-1} \Delta u_{k+1}^2 \quad (27)$$

A metodologia empregada em controladores NMPC é apresentada visualmente na Figura 10 e pode ser resumida nas três etapas descritas a seguir. (MOREIRA, 2013)

1. Utilizando o modelo do processo, as saídas futuras (y_{k+t} em que $t = 1 \dots N$) para um determinado horizonte de predição (HP) são determinadas a cada instante k utilizando os valores conhecidos até o momento.
2. O conjunto de ações de controle futuros (u_{k+t} em que $t = 1 \dots N$) são calculados de modo a manter o processo o mais próximo da trajetória de referência (*set-point*) a partir da minimização da função custo.
3. O primeiro sinal de controle dentro do horizonte de controle é enviado ao processo enquanto os demais sinais são descartados. No exemplo da figura o horizonte de controle é igual a 1, portanto somente a primeira ação (u_{k+1}) é enviada ao processo. Em seguida, repete-se o passo 1 deslocando o horizonte. A esta estratégia é dado nome de “estratégia de recuo”, em que cada instante de amostragem o horizonte é levado para o futuro, aumentando a precisão do controlador.




Figura 10: Visualização gráfica da metodologia de um controlador MPC

2.3.2. Redes Neurais Artificiais em Controle

A maioria dos processos industriais, de reatores químicos a poços de elevação artificiais, apresentam comportamento não linear. Sendo assim, muitos processos são por natureza muito complexos, necessitando demasiado tempo e esforço para desenvolver e validar modelos dinâmicos teóricos detalhados. Ainda assim, quando o esforço e tempo são empregados, muitas vezes os modelos desenvolvidos ainda podem possuir diversas restrições devido às premissas adotadas. (HIMMELBLAU, 2008; SEBORG et al., 2016)

Alternativamente, um modelo empírico não linear pode ser obtido a partir de dados experimentais, nessa linha as redes neurais artificiais são uma classe importante de modelos não lineares empíricos e tem sido usada extensivamente nos últimos anos para modelar não somente fenômenos físicos e químicos como do mercado de ações, estratégias de xadrez, reconhecimento de fala e diagnósticos médicos. (SEBORG et al., 2016)

As redes neurais são atrativas sempre que é necessário modelar processos complexos ou pouco compreendidos com grandes conjuntos de dados de entrada-saída, bem como substituir modelos muito complicados de resolver em tempo real. A seguir, serão discutidas duas facetas importantes do controle de processos sob a ótica das RNAs: A identificação de sistemas e a estrutura de um controlador NMPC.

Identificação de Sistemas usando RNAs

Ao se empregar a Teoria de Controle, é fundamental estabelecer uma ponte entre o mundo real e a teoria matemática que rege o projeto de controladores. Essa ponte é criada a partir do processo de modelagem ou identificação de processos, e o resultado idealmente será um modelo que descreva adequadamente o mundo real. (DE OLIVEIRA, 1999)

No contexto de redes neuronais, a habilidade de reproduzir comportamentos dinâmicos complexos é uma consequência da utilização de Redes Neuronais com Atrasos Temporais (*Time Delay Neural Network – TDNN*). Esta classe de RNA configura-se como uma extensão de redes MLP que permitem lidar com padrões temporais e comportamentos dinâmicos de processos, essencialmente são redes cujas entradas são compostas por valores passados da própria entrada e saídas da rede. (KAISER, 1994; DE OLIVEIRA, 1999)

A título de exemplificação, admite-se um modelo expresso pela equação:

$$y_{k+1} = F_{RNA} [y_k, y_{k-1}, \dots, y_{k-N}, u_k, u_{k-1}, \dots, u_{k-M}] \quad (28)$$

Nele, F_{RNA} corresponde à uma função do tipo rede neuronal cujas entradas são os N valores passados da saída ($y_k, y_{k-1}, \dots, y_{k-N}$) e dos M valores de entrada do sistema ($u_k, u_{k-1}, \dots, u_{k-M}$).

Para sistemas dinâmicos existem duas configurações fundamentais para a disposição de RNAs, são estes os modelos direto e inverso. Schnitman (1998) descreve os princípios destes dois tipos de modelo como:

Modelos Diretos são caracterizados pela disposição em paralelo com o sistema a ser identificado e o erro entre as saídas reais e estimadas é utilizado para o treinamento, classicamente representadas pelo algoritmo de backpropagation.

Modelos Inversos são estruturas que admitem a saída da planta real como sendo a entrada de uma RNA. Assim, a variáveis de saída são utilizadas para a estimação dos parâmetros das redes neurais e treinadas para descrever adequadamente o vetor de dados de entrada do processo.

As Figuras 11 e 12 exemplificam respectivamente as metodologias direta e indireta para identificação de processos utilizando redes neuronais artificiais.

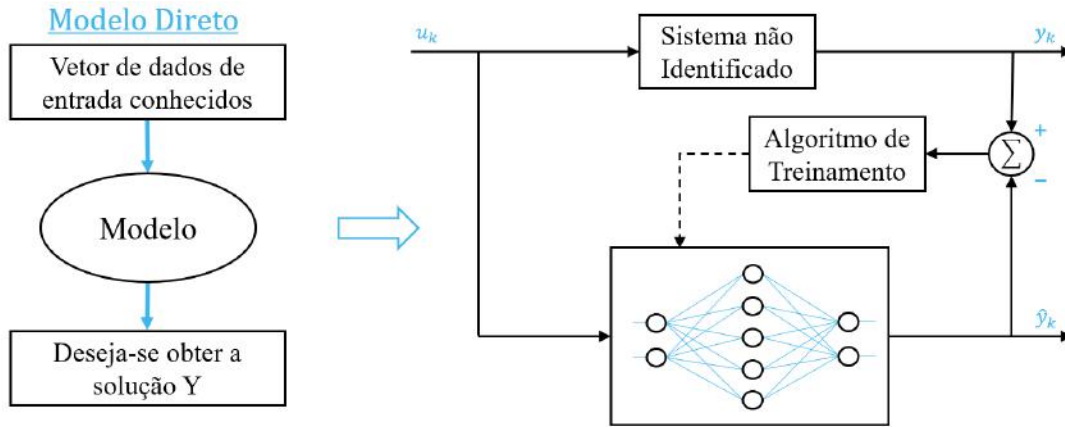


Figura 11: Esquema ilustrativo e diagrama de blocos do Modelo Direto de identificação

Fonte: Adaptado de Schnitman, 1998

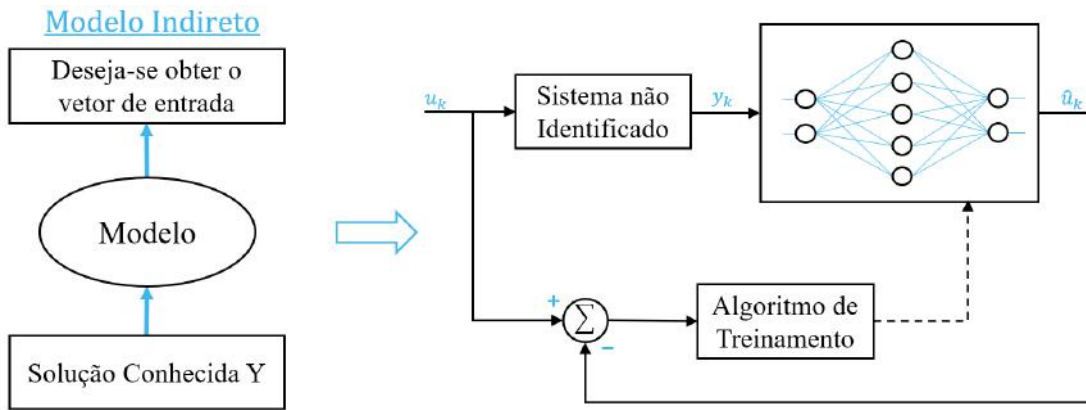


Figura 12: Esquema ilustrativo e diagrama de blocos do Modelo Direto de identificação

Fonte: Adaptado de Schnitman, 1998

Estruturas de controladores usando RNAs

Uma vez que a etapa de identificação de determinado processo seja concluída, a RNA treinada estará apta a ser implementada a um controlador. A Figura 13 apresenta a estrutura básica de um controlador NMPC, nela, um modelo utilizando RNAs é empregado para prever as saídas futuras de uma planta, baseando-se em valores atuais, valores passados e nas ações ótimas de controle. (MOREIRA, 2013)

As ações de controle ótimas são calculadas a partir da minimização da função custo no espaço limitado pelas restrições do processo e objetivam a adequação à trajetória de

referência estipulada ao processo.

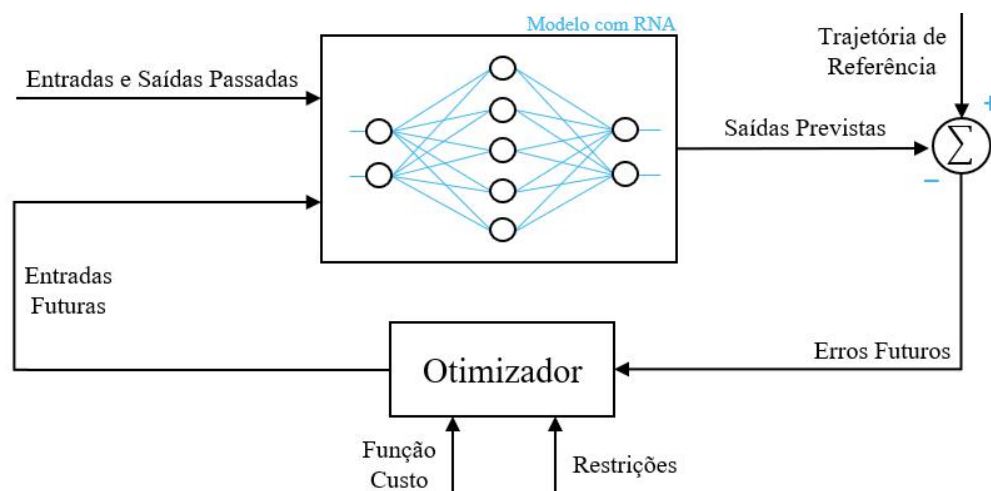


Figura 13: Esquema simplificado de controlador NMPC com Redes Neuronais Artificiais

2.3.3. MPC no contexto de poços de Gas Lift

Estado Atual da Literatura

Apesar do crescimento de popularidade, pouco ainda é encontrado na literatura relacionando técnicas avançadas de controle a poços de gas lift. Contudo, existe um crescente interesse na criação de poços inteligentes, isto é, poços equipados com avançados sensores que, por sua vez, possibilitam o monitoramento e maior controle da produção em tempo real.

A partir experiência do autor, três categorias macro podem ser traçadas envolvendo o controle de poços de *gas lift*, sendo elas: a criação de NMPCs para o poço, estratégias de otimização em tempo real e a criação de estimadores de processo. Mesmo possuindo uma produção acadêmica pouco expressiva, a convergência de fatores observada na última década como a capacidade de microprocessadores, disponibilidade de dados, legislação e impostos mais rigorosos levou a uma crescente produção acadêmica na área, mais especificamente nos últimos cinco anos.

O processo de digitalização de plataformas possui impacto direto na produção acadêmica na área, essa correlação é explicada pois muitas propostas presentes na literatura se aproveitam justamente da digitalização para avançar a ciência envolvida no processo. Além disso, outras tendências atuais como *digital twins*, computação em nuvem e internet das coisas começam se manifestar dentro da indústria de óleo e gás.

Exemplos de Trabalhos

A seguir, alguns trabalhos presentes na literatura e relevantes ao meio em que este estudo está inserido serão apresentados.

Pluencio et al. (2009) propuseram um NMPC baseado em um modelo empírico de Hammerstein para controlar um grupo de poços recebendo gás de um *manifold* comum de *gas lift*. O controlador objetivou maximizar uma função econômica minimizando as oscilações das pressões no *manifold* e no fundo dos poços. Os resultados obtidos pelos autores indicaram que a qualidade do modelo de predição ainda precisa ser melhor avaliada.

Salahshoor et al. (2013) aplicaram uma metodologia de modelagem dinâmica recursiva a partir de redes neurais de base radial baseada para descrever a instabilidade causada pela interação dinâmica entre a injeção de gás com o fluido multifásico do reservatório. A estratégia NMPC apresentou bom desempenho com duas variáveis manipuladas, choke de injeção e produção, e pressão de cabeça de poço como variável controlada para mitigar impactos na produção de petróleo causados por regimes de golfadas.

Ribeiro et al. (2016) propuseram um controlador integrado à uma camada de otimização objetivando maximizar a produção. O controlador utiliza um modelo não linear baseado na estrutura de Hammerstein para representar o processo, com válvula de produção, vazão de injeção e o nível de interface do tambor separador como variáveis manipuladas, e a vazão de produção de óleo, conteúdo de óleo (TOG) e conteúdo de água e sedimentos (BSW) como variáveis de controle. Como resultado, a estratégia NMPC integrada à camada de otimização foi capaz de estabilizar a produção de petróleo offshore em condições de golfadas, mantendo as especificações dentro dos limites, e levou o processo à condição operacional ótima determinada pela camada de otimização.

Jordanou et al. (2018) propuseram um controlador que considera uma rede de estado e eco (ESN) para explicar o modelo do poço e uma outra rede foi usada para calcular a ação de controle. A abertura da válvula de produção foi a variável manipulada e pressão do orifício inferior do poço foi a variável controlada. Os resultados do estudo concluíram que ESNs possuem um bom desempenho para obtenção do ponto de ajuste e rejeição de perturbação.

Antonelo et al. (2018) projetaram um sensor inferencial baseado em redes neuronais para estimar a pressão do poço com base em simulações de modelos fenomenológicos e informações reais de campo. Os resultados mostram que a rede foi capaz de explicar satisfatoriamente o comportamento do poço para casos de golfadas e casos estacionários.

Miyoshi et al. (2018) desenvolveram um NMPC usando modelos baseados na estrutura de Hammerstein para representar um processo e empregaram uma abordagem contendo estimadores de horizonte móveis (MHE). Foi proposta uma estrutura SISO em que a manipulação da injeção de gás-lift deveria controlar a produção de óleo. O controlador proposto apresentou bons resultados, mesmo na região de inversão de ganho.

Dias et al. (2019) investigaram o uso de uma rede ESN para compor um esquema de controle preditivo para a operação. A principal contribuição deste trabalho constituiu-se na avaliação do desempenho da rede em condições normalmente enfrentadas em um sistema real de produção: medições ruidosas, distúrbios não mensuráveis, comportamento lento e incompatibilidade de modelos.

Capítulo 3: METODOLOGIA

Objetivando estudar o comportamento em um poço e de modo a reproduzir uma situação real, o presente trabalho assumiu que uma unidade offshore pode ser corretamente representada pelo modelo fenomenológico de Rojas Soares et al. (2019) previamente exposto.

Munido de um modelo, conjuntos de dados representativos do comportamento dinâmico foram gerados e utilizados como insumo para o treinamento e seleção de diferentes redes neurais.

As redes que obtiveram os melhores desempenhos foram utilizadas como modelo interno em uma avaliação preliminar da estratégia de controle preditivo e comparados usando métricas baseadas nos erros de previsão de dados de validação e parcimônia de parâmetros.

A seguir as etapas do trabalho serão mais detalhadamente descritas de modo a melhor fundamentar a metodologia empregada.

3.1. Simulação do Modelo

A fim de reproduzir o comportamento de um poço real, o modelo desenvolvido e previamente implementado em MATLAB (R2021a) por Rojas Soares et al. (2019) foi simulado sob diversas condições operacionais, gerando assim os dados transientes que foram empregados no treinamento das redes neurais. O integrador utilizado foi o *ode15s* e foi adicionado até 5% de ruído aos valores de pressão, vazão e temperatura objetivando simular as incertezas das medições presentes em dados reais de campo.

3.1.1. Parâmetros das Simulações

Os parâmetros de modelo empregados estão resumidos na Tabela 3:

Tabela 3: Parâmetros das simulações

Variável	Valor	Unidade
Constante Universal dos Gases	8314	$J/(kmol \cdot K)$
Gravidade	9.81	m/s^2
Viscosidade	$3.64 \cdot 10^{-3}$	$Pa \cdot s$
Densidade do Líquido	760	kg/m^3
Massa Molar do Gás	16.7	gr

Temperatura no <i>Annulus</i>	348	<i>K</i>
Volume do <i>Annulus</i>	64.34	<i>m</i> ³
Comprimento do <i>Annulus</i>	2048	<i>m</i> ³
Volume do Tubo Interior	25.03	<i>m</i> ³
Área das Seção Transversal abaixo da Injeção	0.314	<i>m</i> ²
Comprimento abaixo da Injeção	75	<i>m</i>
Temperatura no Tubo Interior	369.4	<i>K</i>
Pressão de Fornecimento de Gás	140	<i>bar</i>
Pressão do Reservatório	160	<i>bar</i>
Diâmetro do Tubo	0.134	<i>m</i>
GOR	0	–
Índice de Produtividade	$2.47 \cdot 10^{-6}$	<i>kg/(s \cdot Pa)</i>
Constante do <i>Choke</i> de Injeção	$9.98 \cdot 10^{-5}$	–
Constante da Válvula de Injeção	$1.40 \cdot 10^{-4}$	–
Constante do <i>Choke</i> de Produção	$2.90 \cdot 10^{-3}$	–

Sistemas reais são comumente contínuos no tempo, porém torna-se necessário discretizá-los de modo a viabilizar a identificação de modelos e a construção de controladores. O intervalo entre duas amostras é denominado tempo de amostragem (Δt) e a escolha deste parâmetro deve ser grande o suficiente para não evidenciar ruído, porém pequena suficiente para descrever o processo adequadamente. (SEBORG et al., 2016)

Apesar de existirem inúmeras formas apresentadas na literatura de como definir o tempo de amostragem, a escolha deste parâmetro é descrita por Seborg (2016) como sendo mais uma arte que uma ciência. Neste trabalho, a estratégia proposta por Åstrom e Wittenmark (2013) em que o tempo de amostragem foi definido a partir do tempo de assentamento (t_s), isto é, o tempo necessário para o processo adentrar e permanecer dentro de uma faixa de 5% da resposta final. Os autores recomendam a faixa:

$$\frac{t_s}{15} \leq \Delta t \leq \frac{t_s}{6}$$

A Figura 34 ilustra graficamente um exemplo de degrau aplicado no sistema, apresentando a resposta contínua e a resposta discreta do sistema inicialmente com u_1 em 30% e u_2 em 40% e submetido a um degrau nas válvulas para o ponto u_1 em 50% e u_2 em 70%. A faixa de tolerância foi cruzada em aproximadamente 960 s, e o valor de Δt foi calculado utilizando o limite inferior da faixa proposta Åstrom e Wittenmark (2013), isto é :

$$\Delta t = \frac{960}{15} s \quad (29)$$

$$\Delta t = 64 \approx 1 \text{ minuto} \quad (30)$$




Figura 14: Resposta Normalizada do modelo de Rojas Soares et al. (2019) a uma perturbação degrau.

3.1.2. Modelos de Identificação Escolhidos

Três versões de modelos com crescentes complexidades foram implementadas. O primeiro e mais simples modelo (Eq. 31) utiliza valores atrasados da vazão de produção ($F_k^{\acute{o}leo}$) e as posições das válvulas no presente momento ($u_k^{(1)}$ e $u_k^{(2)}$) para estimar a vazão de saída no próximo instante.

$$\text{Modelo 1 (F):} \quad F_{k+1}^{\acute{o}leo} = F_{RNA} \begin{pmatrix} u_k^{(1)} \\ u_k^{(2)} \\ F_k^{\acute{o}leo}, F_{k-1}^{\acute{o}leo}, \dots, F_{k-N}^{\acute{o}leo} \end{pmatrix} \quad (31)$$

O segundo modelo (Eq. 32) passa a considerar valores atrasados também das aberturas das válvulas.

$$\text{Modelo 2 (UF):} \quad F_{k+1}^{\acute{o}leo} = F_{RNA} \begin{pmatrix} u_k^{(1)}, u_{k-1}^{(1)}, \dots, u_{k-N}^{(1)} \\ u_k^{(2)}, u_{k-1}^{(2)}, \dots, u_{k-N}^{(2)} \\ F_k^{\acute{o}leo}, F_{k-1}^{\acute{o}leo}, \dots, F_{k-N}^{\acute{o}leo} \end{pmatrix} \quad (32)$$

Por fim, o terceiro modelo (Eq. 33) passa a considerar valores atrasados para a pressão de injeção de gás como um quarto parâmetro acompanhado. Esta escolha torna-se relevante uma vez que a pressão na válvula de injeção possui efeito direto no comportamento da vazão de produção quando o sistema se encontra em zonas de *casing-heading*. Uma vez que o controlador projetado utiliza previsões em horizontes maiores que $k + 1$, torna-se necessário que esta rede também seja capaz de prever o valor saída de $P^{g,inj}$, viabilizando assim uma

simulação dinâmica do processo.

$$\text{Modelo 3 (UFP)} : \left(F_{k+1}^{\acute{o}leo} , P_{k+1}^{g,inj} \right) = F_{RNA} \begin{pmatrix} u_k^{(1)} , u_{k-1}^{(1)} , \dots , u_{k-N}^{(1)} \\ u_k^{(2)} , u_{k-1}^{(2)} , \dots , u_{k-N}^{(2)} \\ F_k^{\acute{o}leo} , F_{k-1}^{\acute{o}leo} , \dots , F_{k-N}^{\acute{o}leo} \\ P_k^{g,inj} , P_{k-1}^{g,inj} , \dots , P_{k-N}^{g,inj} \end{pmatrix} \quad (33)$$

O número de valores atrasados (N) foi estipulado em 10 valores correspondendo a 10 minutos de operação em campo.

3.1.3. Criação dos Conjuntos de Treinamento

Em função das características oriundas do modelo de Rojas Soares et al. (2019) foram consideradas como variáveis manipuladas a abertura da válvula *choke* de gás e a abertura da válvula *choke* de produção, e, como variável de controle, foi considerada a produção de óleo.

A abertura da válvula de injeção pode levar o poço a regiões de instabilidades, neste trabalho buscou-se avaliar a capacidade das redes de replicarem o comportamento em todos os valores possíveis de abertura de válvulas, mas também se optou por investigar a capacidade das redes neuronais modelarem satisfatoriamente o comportamento tanto somente das zonas estáveis quanto das zonas instáveis.

A Figura 15 apresenta o comportamento do poço para os possíveis valores de abertura das válvulas. Em verde observa-se a zona de produção estável e em vermelho a zona de instabilidade ocasionada pela baixa injeção de gás e consequentes golfadas.

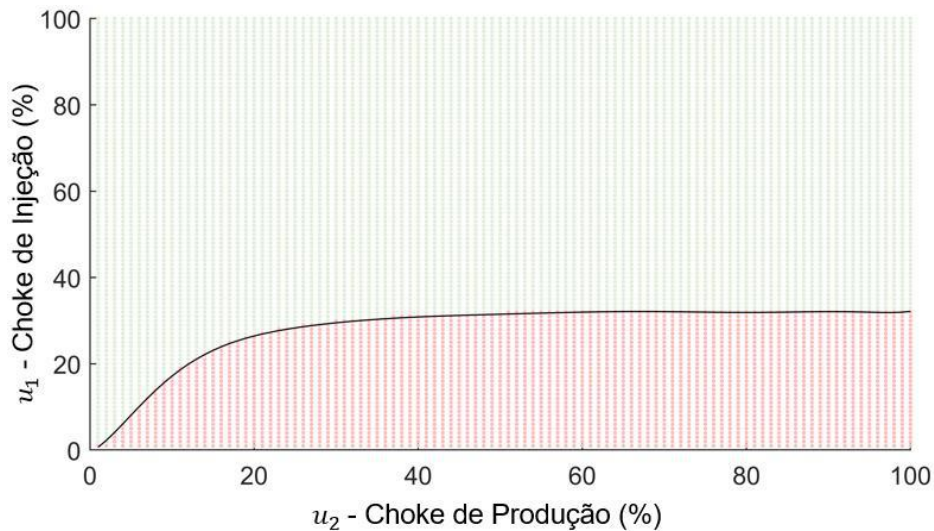


Figura 15: Mapa de Estabilidade para o modelo nas condições apresentadas

Os conjuntos de treino foram estruturados na forma de uma simulação contínua com aplicação periódica de degraus.

Para a criação do conjunto de treino que contemplou ambas as zonas previamente expostas, foram utilizados 580 mil pares entrada/saída correspondendo a aproximadamente 400 dias de operação.

No caso dos conjuntos parciais, isto é, os conjuntos estáveis e instáveis, foram considerados 290 mil pares entrada/saída, aproximadamente 200 dias de operação cada.

Cada par de u_1 e u_2 dentro da zona estável foi simulado durante 2 horas até a aplicação de um novo degrau. Pares dentro da zona instável foram simulados durante 6 horas uma vez que nesse regime a dinâmica cíclica das golfadas não seria capturada em apenas 2 horas.

Para o conjunto completo, os distúrbios aplicados nas válvulas migraram de uma zona para a outra e totalizaram aproximadamente 3200 mil degraus. Os conjuntos instável e estável contaram respectivamente com 800 e 2400 degraus, sendo a diferença entre os dois valores explicada pelo intervalo escolhido para aplicação dos distúrbios exposto no parágrafo anterior. A Figura 16 mostra a distribuição dos degraus nos conjuntos de treino:




Figura 16: Distribuição dos pares u_1, u_2 para os três conjuntos de treino

3.2. Treinamento das RNA

O design e o treinamento do modelo foram realizados usando a biblioteca Sci-Kit Learn. As RNAs foram treinadas usando o otimizador Adam em função do quadrado do coeficiente de correlação (R^2). O treinamento era interrompido caso uma redução menor que de 10^{-3} não fosse observada ao longo de 10 épocas na função custo. A seguir serão expostas as metodologias utilizadas na busca pelos melhores hiperparâmetros, assim como as validações empregadas sobre as RNAs.

3.2.1. Ajuste de Hiperparâmetros

Visando obter as melhores redes, foram empregados algoritmos de *Grid Search* para treinamento das redes, nessa categoria de algoritmos todas as combinações possíveis de hiperparâmetros são testadas exaustivamente.

Número de Camadas: As redes neste trabalho foram treinadas utilizando duas, três e quatro camadas escondidas, averiguando assim um cenário base e um cenário com mais camadas.

Número de Neurônios por Camada: A título de comparação, foram empregadas ambas as estratégias descritas na seção 2.1.5, isto é, dimensionando o número de neurônios baseado nas entradas e saídas (funil) e utilizando quantidades iguais de neurônios por camadas. A Tabela 4 contém a estrutura das redes empregadas para cada um dos modelos utilizados no trabalho.

Tabela 4: Estrutura das Redes Neurais

Molelo	Duas Camadas	Três Camadas	Quatro Camadas
Modelo 1	(10 6) (8 4) (12 12) (16 16)	(10 6 2) (10 7 5) (12 12 12) (16 16 16)	(10 8 6 4) (10 7 5 3) (12 12 12 12) (16 16 16 16)
Modelo 2	(26 8) (22 12) (32 32) (40 40)	(32 26 8) (30 22 12) (32 32 32) (40 40 40)	(32 22 12 6) (30 24 10 8) (32 32 32 32) (40 40 40 40)
Modelo 3	(22 8) (30 12) (42 42) (52 52)	(42 26 10) (40 18 6) (42 42 42) (50 50 50)	(42 28 16 6) (40 30 20 10) (42 42 42 42) (50 50 50 50)

Função de Ativação: Neste trabalho foram avaliadas as principais expoentes dos grupos descritos na seção 2.1.2., sendo elas a função tangente hiperbólica (*tanh*) e unidade linear retificada (*ReLU*).

Tamanho de Lote: O número de amostras por lote possui influência direta no esforço computacional e no desempenho da rede. Aqui foram utilizados os tamanhos: 100, 200, 400, 600, 800 e 1000.

Termo de Regularização: O valor da taxa de penalidade foi variado de 10^{-3} , 10^{-4} , 10^{-5} , 10^{-6} .

3.2.2. Avaliação das Redes

De modo a avaliar o desempenho das redes treinadas, os conjuntos de treino foram separados na proporção 70/20/10, isto é, 70% foi destinado para treinamento, 20% para

validação e 10% testagem do modelo identificado e. O procedimento de teste contou com duas métricas de avaliação: o quadrado do coeficiente de correlação (R^2) e o erro quadrático médio (MSE) definidas pelas equações 34 e 35.

$$R^2 = 1 - \frac{\text{Soma do Quadrado dos Resíduos}}{\text{Soma Total dos Quadrados}} = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (34)$$

$$MSE = \frac{\text{Erro Quadrático}}{\text{Médio}} = \frac{1}{n} \sum (y_i - \hat{y}_i)^2 \quad (35)$$

Para utilização da rede neuronal como modelo interno em uma estratégia de controle preditivo também é fundamental avaliar sua capacidade preditiva em horizontes de tempo futuro, cujos valores medidos não estão disponíveis. Nesse caso, as saídas da rede no instante $k + 1$ são retidas e utilizadas como entrada novamente para o computo das saídas no instante $k + 2$. Sendo assim, o presente trabalho empregou as métricas apresentadas para avaliar o desempenho das redes em horizontes de previsão variando de $HP = 1$ até $HP = 30$ (1, 3, 5, 10, 20, 30).

3.2.3. Estratégia para Seleção das Redes

Na busca pela obtenção de modelos que descrevam adequadamente o comportamento, é fundamental possuir princípios orientadores de modo que o melhor modelo seja escolhido.

O presente trabalho utilizou o princípio da parcimônia, ou navalha de Ockham, em que se busca utilizar o modelo mais simples possível que fosse consistente com os dados observáveis para representar o comportamento do poço, isto é, que esteja dentro de um critério de satisfação.

O critério de satisfação adotado para as redes consistiu na avaliação das métricas do maior horizonte de predição ($HP = 30$), desta forma, uma rede foi considerada satisfatória se seu coeficiente de correlação for superior a 0.9 e seu erro quadrático médio inferior a 2.

A metodologia de seleção empregada partiu do modelo mais simples (modelo F), passando para modelos mais complexos à medida que o critério de satisfação não fosse atingido. O processo de seleção é resumido pelo diagrama exposto na Figura 17.

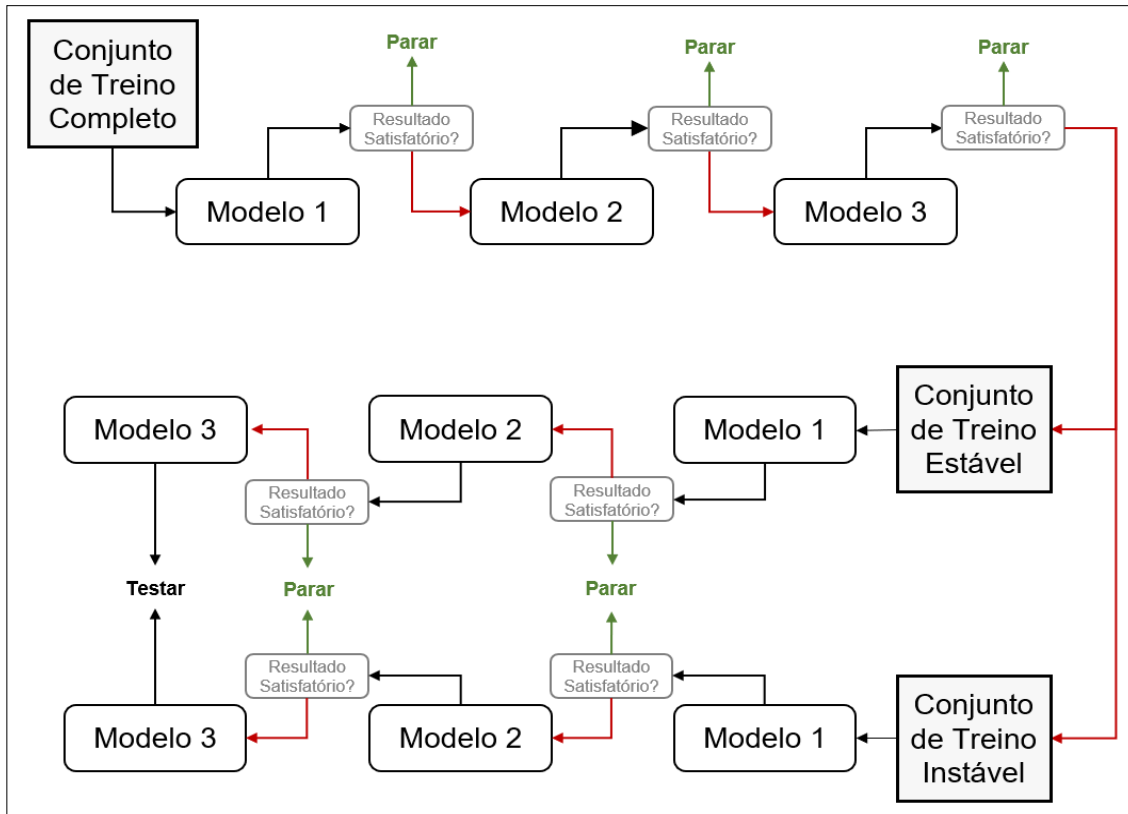


Figura 17: Estrutura da Metodologia de Busca

3.3. Protótipos de Controladores

A fim de avaliar a capacidade preditiva dos modelos identificados, estes foram utilizados como modelo interno em controladores do tipo NMPC que em seguida foram testados sob diferentes condições. O controlador não considerou distúrbios, contudo uma incerteza de 5% foi adicionada as medições provenientes do modelo de Rojas Soares et al. (2019).

3.3.1. Estrutura dos Controladores

Os controladores desenvolvidos foram projetados segundo a estrutura direta previamente exposta na seção 2.3.2. No entanto, a abordagem que conta com duas redes, uma para zona estável e uma para zona instável, teve que ter a estrutura modificada de modo que o controlador fosse capaz de identificar qual rede utilizar em qual momento.

Uma função foi aproximada de modo a delimitar o ponto no qual o sistema deixava de apresentar estabilidade e passava a demonstrar comportamento instável e é apresentada na Figura 18. A melhor aproximação foi obtida a partir de uma aproximação de Fourier, apresentada na equação 36. O valor da frequência fundamental (w) da aproximação é

0.003216, e suas constantes são apresentadas na Tabela 5.

$$\begin{aligned}
 f_{fourier} = & a_0 + a_1 \cos(w \cdot x) + b_1 \text{sen}(w \cdot x) + a_2 \cos(w \cdot x) + b_2 \text{sen}(w \cdot x) \\
 & + a_3 \cos(w \cdot x) + b_3 \text{sen}(w \cdot x) + a_4 \cos(w \cdot x) + b_4 \text{sen}(w \cdot x) \quad (36) \\
 & + a_5 \cos(w \cdot x) + b_5 \text{sen}(w \cdot x)
 \end{aligned}$$

Tabela 5: Constantes da aproximação de Fourier

	0	1	2	3	4	5
$a_n (\cdot 10^{12})$	1.84	-3.03	1.66	-0.578	0.115	-0.00983
$b_n (\cdot 10^{12})$	-	-0.518	0.5847	-0.322	0.0926	-0.00111

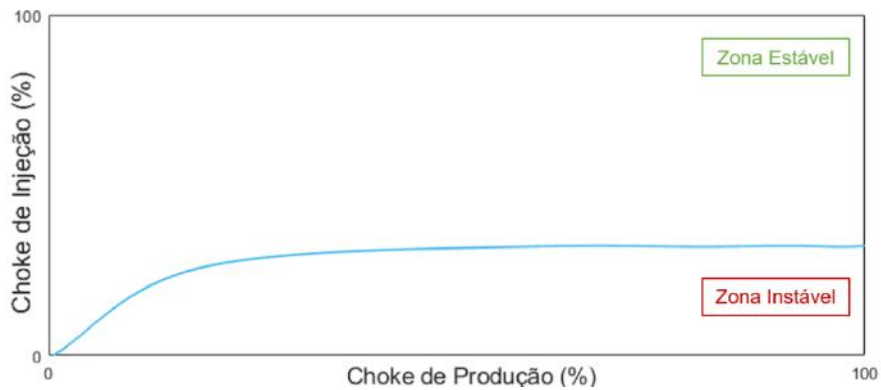


Figura 18: Função que delimita comportamento estável e instável

A cada nova avaliação do controlador, a posição das válvulas é avaliada, se o processo se encontrar em uma zona estável o modelo interno utilizado é o modelo estável e vice-versa. A Figura 19 ilustra a estrutura desse novo controlador direto.

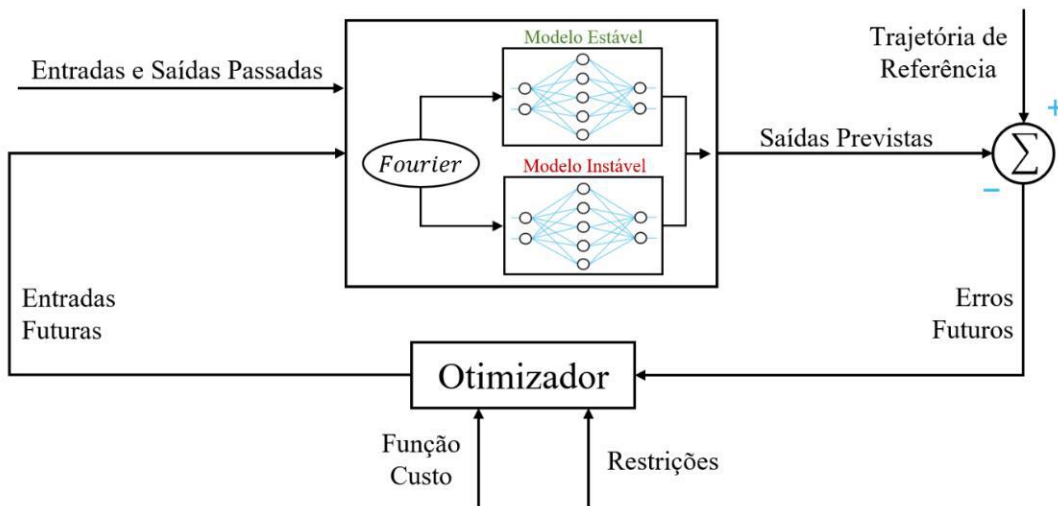


Figura 19: Controlador direto com dois modelos internos

Além da estrutura, é importante definir também os demais parâmetros dos controladores. Foram avaliados múltiplos horizontes de predição baseando-se nos testes prévios das redes, o horizonte de controle estipulado foi igual a um, a variação máxima das posições das válvulas a cada passo foi igual a 2% e a função objetivo do controlador foi estipulada segundo a equação 27 com fator de penalização igual à 1.1.

3.3.2. Avaliação dos Controladores

O desempenho dos controladores foi avaliado em duas categorias de testes:

O primeiro buscou avaliar a capacidade do NMPC de adequar o processo a uma sequência de alterações na trajetória de referência, os *setpoints* foram alterados a cada três horas dentro da janela de capacidade de produção do poço.

O segundo buscou testar a capacidade do controlador na região instável, avaliando se a manutenção de *setpoint* foi possível e se as golfadas foram evitadas mesmo limitando a abertura do *choke* de produção somente à região instável.

As trajetórias de referência e o comportamento e malha aberta de ambos os testes são apresentadas nas Figuras 20 e 21.




Figura 20: Setpoints para Teste 1




Figura 21: Trajetória de Malha Aberta e *Setpoint* para Teste 2

Os estados iniciais dos testes são apresentados na Tabela 5.

Tabela 5: Estados iniciais dos testes aplicados aos controladores

Teste	u_1	u_2	Massa de Gás no Annulus	Massa de Gás no Tubo	Massa de Óleo no Tubo	Velocidade da Mistura
1	0.8	0.40	27 400	160.0	5 900	25
2	0.8	0.25	47 330	0.1186	20 650	0.4283

O desempenho dos controladores foi analisado quantitativamente por meio do cômputo da integral do erro ao quadrado (*ISE – Integral of the Square of the Error*) descrito pela equação 37. Por conta de sua natureza quadrática, este índice possui como característica atuar em grandes proporções para erros grandes e em pequenas proporções para erros menores.

$$ISE = \int_0^t erro^2(t) dt \quad (37)$$

Capítulo 4: RESULTADOS E DISCUSSÃO

Neste capítulo serão abordados os resultados obtidos utilizando os três modelos descritos no Capítulo 3 considerando as diferentes combinações de parâmetros.

Inicialmente, os resultados dos diferentes modelos serão apresentados em função das métricas utilizadas, em seguida, a influência dos hiperparâmetros será avaliada por meio de uma análise de sensibilidade. Por fim, os resultados dos controladores serão avaliados segundo os testes previamente expostos.

4.1. Avaliação das Redes Treinadas

4.1.1. Conjunto de Treino Completo

A primeira abordagem estudada utilizou o comportamento do poço como um todo, isto é, em todas as possibilidades de posicionamento das válvulas. Partindo do princípio de parcimônia, inicialmente buscou-se identificar o modelo utilizando a abordagem mais simples (Modelo 1 – U), seguindo para os modelos seguintes mais complexos em caso de resultados insatisfatórios.

O conjunto de validação utilizado contou com pares $u_1 - u_2$ da zona estável e da zona instável. As melhores redes foram escolhidas pela média das métricas em ambas as validações e são apresentadas na Tabela 6. Seus resultados são apresentados na Tabela 7 e visualmente na Figura 22. As demais redes treinadas são apresentadas no Anexo I.

Tabela 6: Melhores redes por modelo – Conjunto de treino completo

Redes	Estrutura	Ativação	Lote	Penalidade
Modelo 1 (<i>F</i>)	(16 16 16 16)	<i>relu</i>	1000	10^{-4}
Modelo 2 (<i>UF</i>)	(32 26 8)	<i>relu</i>	100	10^{-4}
Modelo 3 (<i>UFP</i>)	(50 50 50 50)	<i>relu</i>	800	10^{-3}

Tabela 7: Melhores resultados por modelo – Conjunto de treino completo

Redes	HP = 1		HP = 3		HP = 5		HP = 10		HP = 20		HP = 30	
	R²	MSE	R²	MSE	R²	MSE	R²	MSE	R²	MSE	R²	MSE
Modelo 1 (<i>F</i>)	0.96	1.9	0.73	2.2	0.69	4.0	0.65	4.7	0.58	5.1	0.51	5.37
Modelo 2 (<i>UF</i>)	0.97	1.2	0.75	1.4	0.71	2.2	0.66	3.3	0.62	4.0	0.56	4.4
Modelo 3 (<i>UFP</i>)	0.98	0.88	0.9	0.96	0.84	1.3	0.77	2.2	0.69	3.3	0.59	4.2

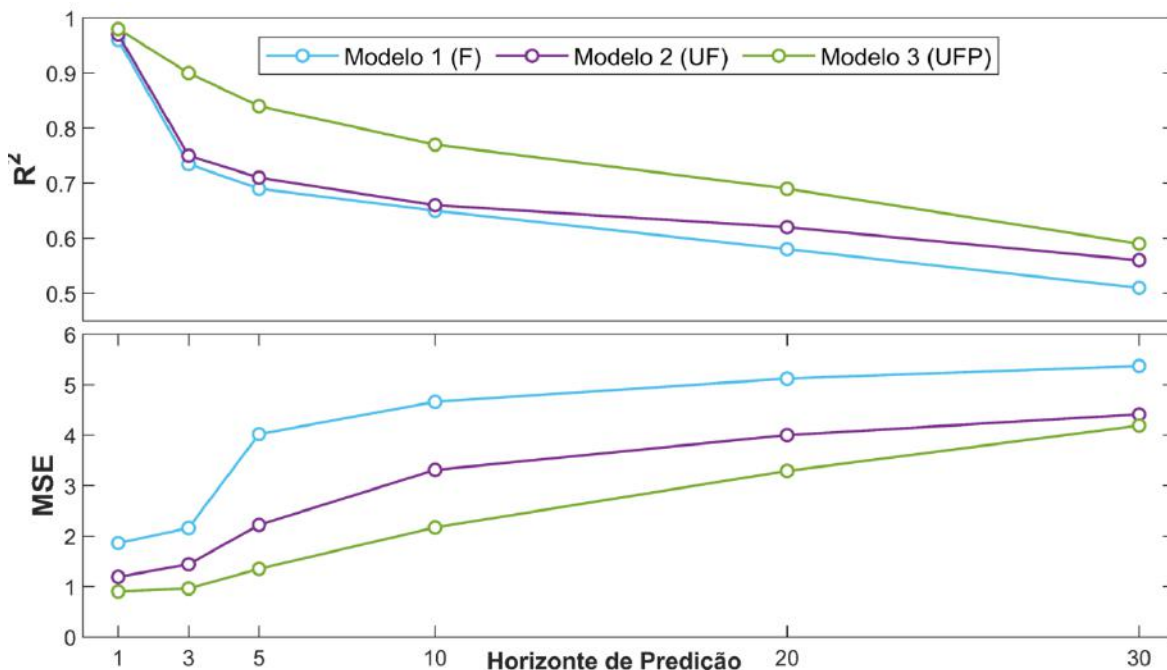


Figura 22: Resultados da validação para conjunto de treinamento completo

Os resultados apresentados pela Tabela 6 mostraram uma prevalência nos melhores resultados por redes com mais de duas camadas escondidas. Para o conjunto de treino em questão, redes menores possivelmente encontraram dificuldade para representar o comportamento complexo do modelo em ambas as zonas de estabilidade, isto é, de generalizar o processo como um todo.

A partir das métricas, ficou clara a melhora na capacidade de predição do modelo 3 (UFP) em relação aos demais, contudo, pode-se observar uma rápida deterioração de sua capacidade preditiva em horizontes de predição superiores a 1 tempo de amostragem.

Os resultados obtidos para esta abordagem não foram considerados satisfatórios, sendo assim, a segunda alternativa de controlador não foi descartada e seus modelos serão apresentados a seguir.

4.1.2. Conjunto de Treino Instável

Em vista à dificuldade de generalização para todas as aberturas de válvula das redes neuronais treinadas, a segunda abordagem proposta neste trabalho utilizando dois modelos internos no controlador torna-se uma alternativa interessante. O conjunto de validação utilizado contou com pares $u_1 - u_2$ somente da zona instável e as melhores redes são

apresentadas na Tabela 8. O resultado das métricas são apresentados na Tabela 9 e visualmente na Figura 23. As demais redes treinadas são apresentadas no Anexo II.

Tabela 8: Melhores redes por modelo – Conjunto de treino instável

Redes	Estrutura	Ativação	Lote	Penalidade
Modelo 1 (F)	(16 16 16 16)	<i>tanh</i>	1000	10^{-6}
Modelo 2 (UF)	(30 22 12)	<i>relu</i>	100	10^{-3}
Modelo 3 (UFP)	(42 42)	<i>relu</i>	100	10^{-4}

Tabela 9: Melhores resultados por modelo – Conjunto de treino instável

Redes	HP = 1		HP = 3		HP = 5		HP = 10		HP = 20		HP = 30	
	R ²	MSE	R ²	MSE	R ²	MSE	R ²	MSE	R ²	MSE	R ²	MSE
Modelo 1 (F)	0.95	2.2	0.84	2.4	0.75	3.4	0.69	4.3	0.68	4.6	0.66	4.9
Modelo 2 (UF)	0.95	1.2	0.86	1.4	0.83	1.8	0.82	3.1	0.81	3.6	0.76	4.4
Modelo 3 (UFP)	0.98	0.6	0.94	0.7	0.91	1.0	0.90	1.8	0.88	2.7	0.86	3.5

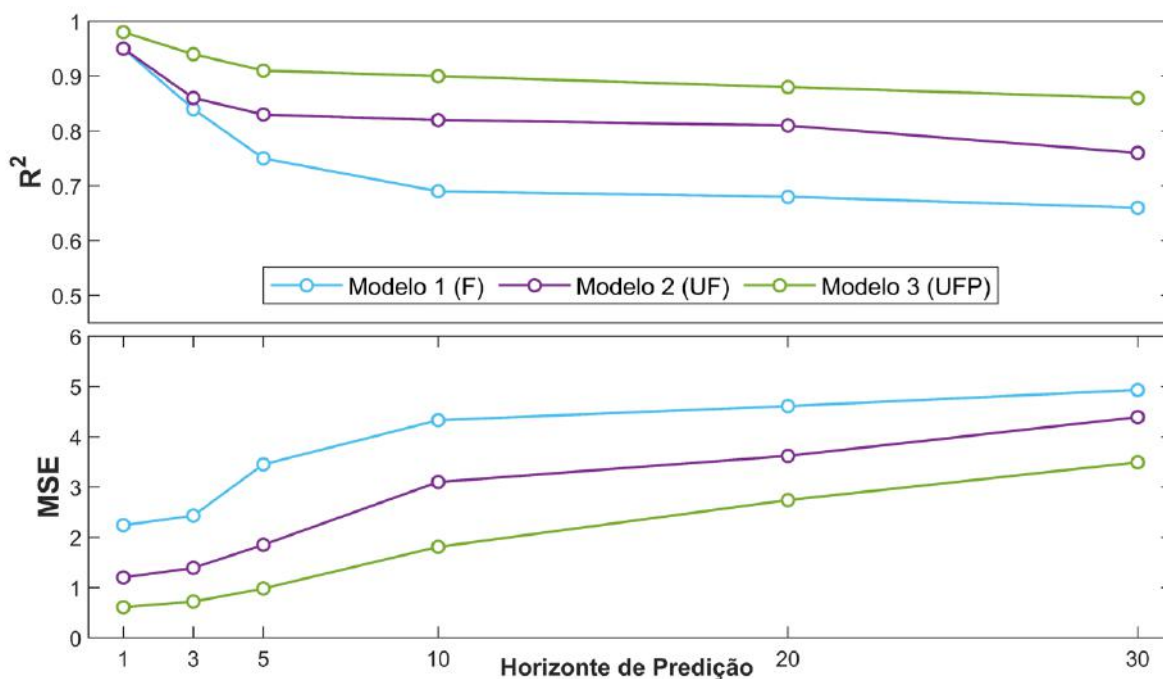


Figura 23: Resultados da validação para conjunto de treinamento instável

Em linhas gerais, o resultado das métricas para as redes treinadas somente na região instável se alinhou com os observados para o conjunto de treino previamente exposto, ou seja, os modelos de maior complexidade apresentaram melhor capacidade na reprodução do comportamento dinâmico do sistema.

Apesar de ter apresentado resultados melhores, os valores de R^2 e MSE nos maiores horizontes de predição não atingiram patamares superiores a 0.9 e 2, respectivamente. Contudo, cabe ressaltar que diferentemente da primeira abordagem discutida, os valores de R^2 não apresentaram a mesma deterioração para valores de HP maiores, tendo encontrado resultados próximos para horizontes de predição superiores a 10 tempos de amostragem.

4.1.3. Conjunto de Treino Estável

Por fim, são exibidos abaixo os resultados para as redes treinadas com simulações na região estável. O conjunto de validação utilizado também contou somente com pares $u_1 - u_2$ da zona estável. As melhores redes são apresentadas na Tabela 10, o resultado das métricas são apresentados na Tabela 11 e visualmente na Figura 24. As demais redes treinadas são apresentadas no Anexo III.

Tabela 10: Melhores redes por modelo – Conjunto de treino estável

Redes	Estrutura	Ativação	Lote	Penalidade
Modelo 1 (F)	(10 7 5)	\tanh	200	10^{-6}
Modelo 2 (UF)	(40 40 40)	\tanh	200	10^{-4}
Modelo 3 (UFP)	(42 42 42)	\tanh	100	10^{-4}

Tabela 11: Melhores resultados por modelo – Conjunto de treino estável

Redes	$HP = 1$		$HP = 3$		$HP = 5$		$HP = 10$		$HP = 20$		$HP = 30$	
	R^2	MSE	R^2	MSE	R^2	MSE	R^2	MSE	R^2	MSE	R^2	MSE
Modelo 1 (F)	0.98	0.6	0.96	0.7	0.93	0.8	0.90	1.0	0.86	1.0	0.85	1.1
Modelo 2 (UF)	0.99	0.5	0.97	0.6	0.96	0.7	0.94	0.8	0.93	0.8	0.92	0.8
Modelo 3 (UFP)	1.00	0.3	0.99	0.3	0.99	0.4	0.98	0.6	0.97	0.7	0.95	0.7

A natureza oscilatória e sensível a ruídos da zona instável aparenta ser a principal fonte de dificuldade para as redes neuronais uma vez que, comparadas aos outros conjuntos de treinamento, o resultado das métricas foram melhores em todos os casos. Complementarmente, a função de ativação mais proeminente nas melhores redes deste conjunto de treino foi a tangente hiperbólica enquanto nos outros casos a função $Relu$ mostrou-se mais eficiente. A relação entre os hiperparâmetros e os resultados observados será melhor debatida na seção 4.1.4.




Figura 24: Resultados da validação para conjunto de treinamento estável

Apesar dos resultados superiores do Modelo 3 (UFP) frente o Modelo 2 (UF), o critério de satisfação definido na metodologia deste trabalho aliado com o princípio de parcimônia seleciona a RNA do Modelo 2 como a rede a ser implementada como modelo interno do controlador.

4.1.4. Ponderações Gerais

Sensibilidade aos Hiperparâmetros

Até então, a relação entre as melhores RNAs treinadas e seus hiperparâmetros foi pouco discutida neste trabalho propositalmente. Este caminho foi escolhido pois conclusões baseadas unicamente no resultado da melhor rede não são passíveis de generalização para todas as melhores redes.

A fim de viabilizar uma discussão mais aprofundada, médias das métricas para cada hiperparâmetro das redes de cada modelo e conjunto de treino foram realizadas. De forma geral, os resultados obtidos apresentaram comportamento semelhante para os três conjuntos de treino estudados. Sendo assim e de modo a evitar repetição de informações, somente os resultados para o Modelo 3 (UFP) do conjunto instável são apresentados nas figuras a seguir, contudo, suas conclusões podem ser extrapoladas para os outros conjuntos.

O único comportamento que diferiu dos demais foi a melhor função de ativação para o conjunto estável. Por esse motivo, a Figura 25 também apresenta o gráfico do comportamento nos diferentes horizontes de predição para a rede estável selecionada (primeira linha, segunda coluna).

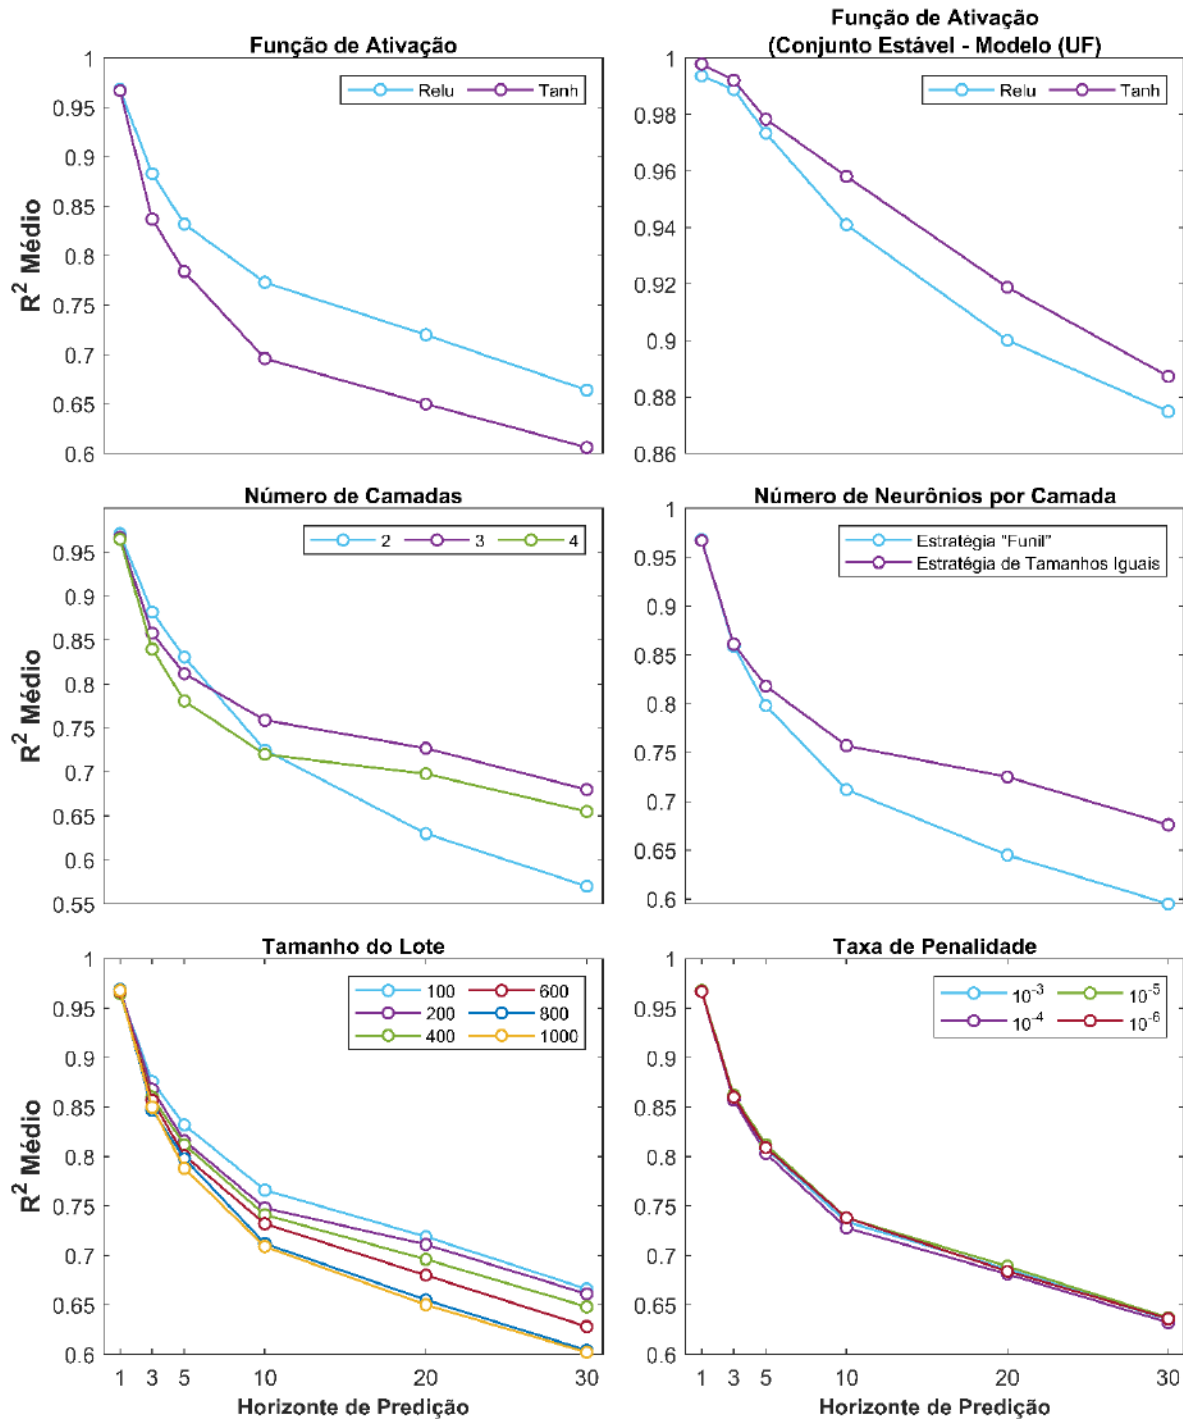


Figura 25: Médias de R^2 por horizonte de predição e hiperparâmetros

Como previamente mencionado, a melhor função de ativação para o conjunto estável foi a tangente hiperbólica enquanto, para o conjunto instável, a função *Relu* apresentou melhores resultados. O desempenho dos demais hiperparâmetros apresentaram comportamentos qualitativamente semelhantes. A partir dos resultados, pode-se levantar a hipótese de uma rede que combine as duas funções de ativação como a melhor alternativa para representar o processo como um todo e se evitar uma estratégia de controlador com dois modelos internos.

O número de camadas das RNAs apresentou resultados não uniformes para todos os horizontes de predição. Em horizontes até 5 tempos de amostragem, redes menores com duas camadas escondidas apresentaram resultados superiores enquanto horizontes maiores tiveram melhores resultados com redes com 3 e 4 camadas, indicando que o comportamento dinâmico do poço é melhor aproximado por estas redes.

Dentre as duas estratégias empregadas para determinar o número de neurônios por camada, a abordagem utilizando a quantidade de neurônios da camada de entrada como forma de determinar o número de neurônios apresentou clara superioridade nos resultados das redes. Possivelmente o comportamento do poço é complexo de modo que, de forma geral, quanto mais neurônios na RNA, melhores os resultados das redes, não dando sinais de sobreajuste.

O tamanho do lote de treinamento apresentou diferenças modestas entre os valores estudados, no entanto, lotes menores apresentaram consistentemente melhor capacidade de generalização e conseqüentemente melhores resultados em termos de métricas de avaliação.

Por fim, observou-se que a taxa de penalidade não possuiu forte influência sobre o desempenho médio das redes.

Resultados Dinâmicos dos Modelos

Para todos os conjuntos de treino avaliados, a utilização dos modelos mais robustos levou a melhores resultados na etapa de validação. A seguir são debatidas as possíveis influências das entradas nos resultados observados

O primeiro e mais simples modelo (F) avalia somente as vazões passadas e posição atual das válvulas, sendo assim, não incorpora informações referentes a mudanças nas posições das válvulas na construção de uma aproximação para comportamento dinâmico do processo.

Por outro lado, o segundo modelo (UF) consegue assimilar esta informação e demonstrou consistentemente que valores atrasados referentes às posições das válvulas são importantes na construção do modelo

Por fim, o terceiro modelo avaliado (UFP) leva em consideração a pressão na válvula de injeção como variável de entrada. O valor desta pressão é relevante para a modelagem do processo na zona de *casing-heading* pois, como explicado na seção 2.2.2, a relação entre a pressão ar de injeção e a pressão no ponto de injeção é o principal fator para o regime do poço passar para um regime instável. Em contrapartida, este fator não é fundamental para a previsão de vazões na zona estável, fato que justifica a melhora modesta entre as redes UF e UFP para esta zona.

A título de visualização, simulações dinâmicas dos modelos foram realizadas e comparadas às curvas obtidas pelo modelo de Rojas Soares et al. (2019). A Figura 26 apresenta os resultados das simulações desenvolvidas.

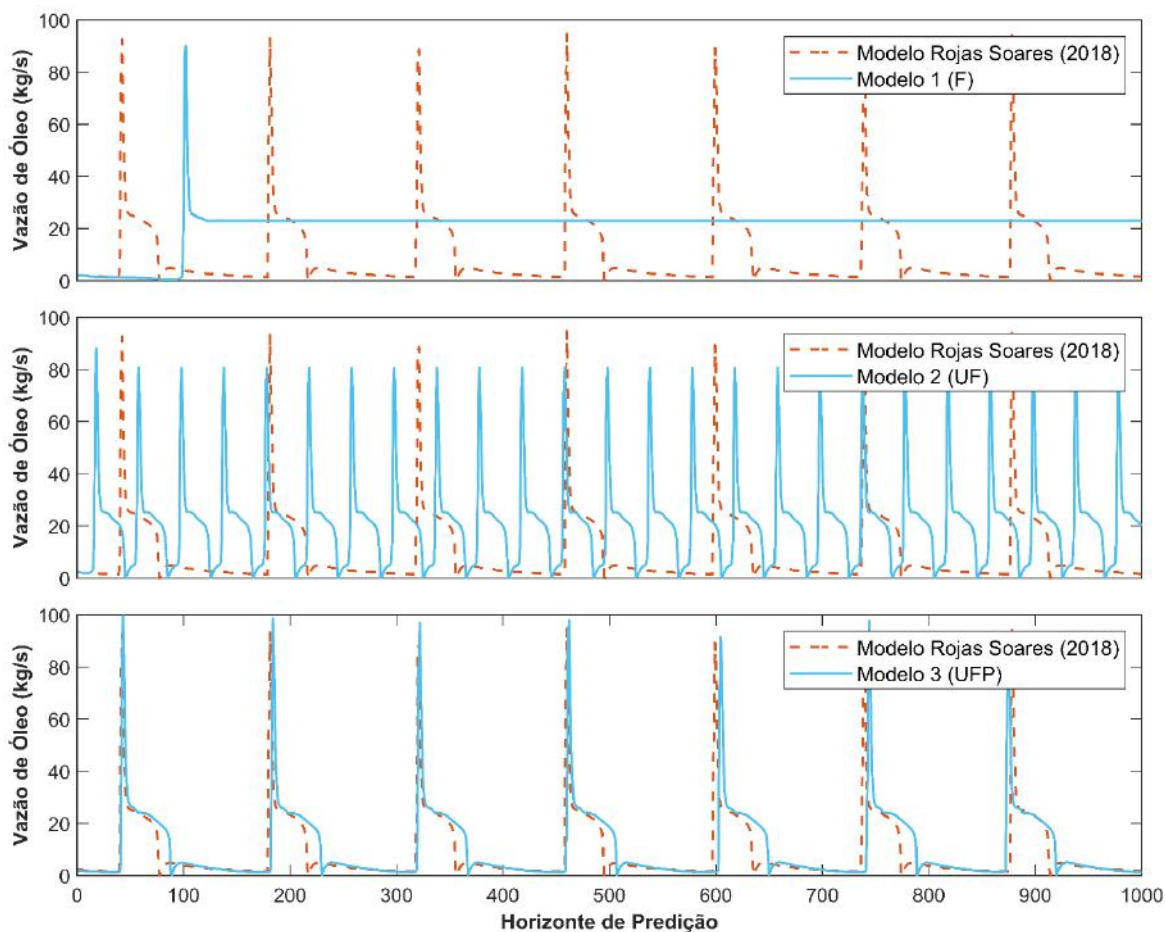


Figura 26: Simulações dinâmicas dos três melhores modelos instáveis

As simulações foram geradas com as redes do conjunto instável apresentadas na Tabela 8 para o par $u_1, u_2 = [0.83 \ 0.27]$.

A partir da avaliação da Figura 26, fica clara a melhora da capacidade de predição das redes ao se empregar os diferentes modelos apresentados neste trabalho. Observa-se que apesar do modelo mais simples ser capaz de prever a ocorrência de uma golfada, ele não é capaz de replicar o comportamento cíclico do regime, estabilizando em uma vazão destoante do modelo de referência.

Ao empregar o segundo modelo, a dinâmica cíclica de oscilação sustentada é replicada adequadamente, contudo, a frequência de oscilação é muito superior ao comportamento esperado. Possivelmente devido à ausência de mais informações, a RNA associa a ocorrência de uma golfada a um valor de vazão de óleo, quando na prática ela é inteiramente dependente das pressões no fundo do poço. Ao introduzir a pressão de injeção na modelagem do processo (Modelo 3 – UFP), a frequência das golfadas passa a ser replicada de forma satisfatória com perfis de curva semelhantes ao comportamento previsto pelo modelo de Rojas Soares et al. (2019).

A avaliação representada na Figura 26 foi repetida para as melhores redes do conjunto estável. Em linhas gerais, os dados de campo operam em valores estáveis e golfadas ocorrem somente quando erros na operação ocorreram. Sendo assim, avaliar a capacidade das RNAs treinadas com conjuntos estáveis de replicar o comportamento de poços torna-se muito importante. A Figura 27 apresenta os resultados das simulações dinâmicas do processo utilizando as melhores redes treinadas com o modelo estável.

Observou-se um comportamento similar ao comportamento expresso na Figura 26, isto é, uma melhora na capacidade preditiva ao se utilizar modelos mais complexos. De forma geral, o resultado implícito à Figura 27 indica que redes MLP são capazes de extrapolar o comportamento dinâmico de um poço na zona instável, mesmo sendo treinadas com um conjunto composto unicamente de degraus na zona estável.

Apesar de ser um resultado esperado, cabe o comentário de que a frequência de golfadas, duração e amplitude possuíram menor acurácia que a Figura 26, principalmente no caso do modelo 3 (UFP).




Figura 27: Simulações dinâmicas dos três melhores modelos estáveis

4.2. Avaliação dos Controladores

As RNAs treinadas e descritas na seção anterior foram utilizadas como modelo interno dos dois controladores propostos. A Tabela 12 indica as redes empregadas em cada controlador assim como e os seus modelos correspondentes.

Tabela 12: Redes utilizadas nos controladores avaliados

NMPC	Zona Compreendida	Modelo	Estrutura	Ativação	Lote	Penalidade
Um Modelo	Ambas	UFP	(50 50 50 50)	<i>relu</i>	800	10^{-3}
Dois Modelos	Estável	UF	(40 40 40)	<i>tanh</i>	200	10^{-4}
	Instável	UFP	(42 42)	<i>relu</i>	100	10^{-4}

4.2.1. Primeiro Teste: Melhores Redes

Os resultados dos controladores são apresentados na Tabela 13 e nas Figuras 28 e 29. As figuras ilustram o comportamento da vazão de óleo comparada com o *setpoint* de referência,

o gráfico quadrado à direita ilustra o trajeto cartesiano percorrido pelas válvulas ao longo das 24 horas simuladas no determinado horizonte de predição.

Tabela 13: Resultado do primeiro teste para os controladores avaliados

NMPC	Métrica	HP = 3	HP = 5	HP = 10	HP = 20	HP = 30
Um Modelo	Erro (ISE)	3.71	4.02	4.47	6.70	35.56
Dois Modelos	Erro (ISE)	3.53	3.59	3.65	3.71	3.77

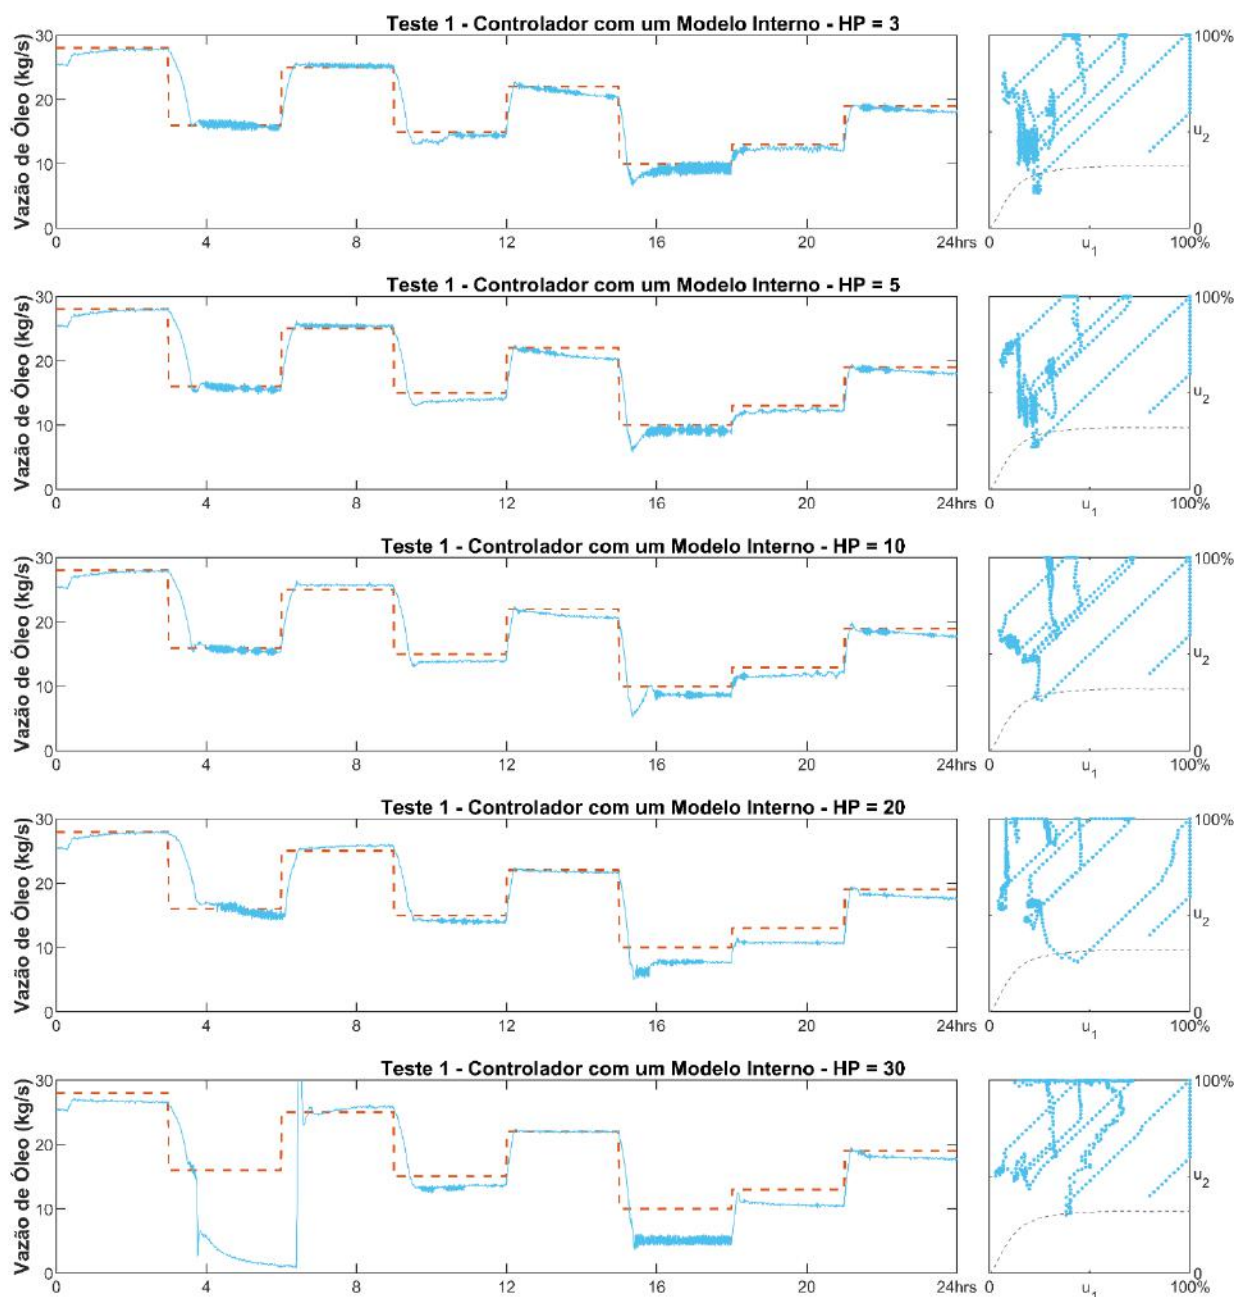


Figura 28: Teste 1 para controle com um modelo interno em diferentes horizontes de predição

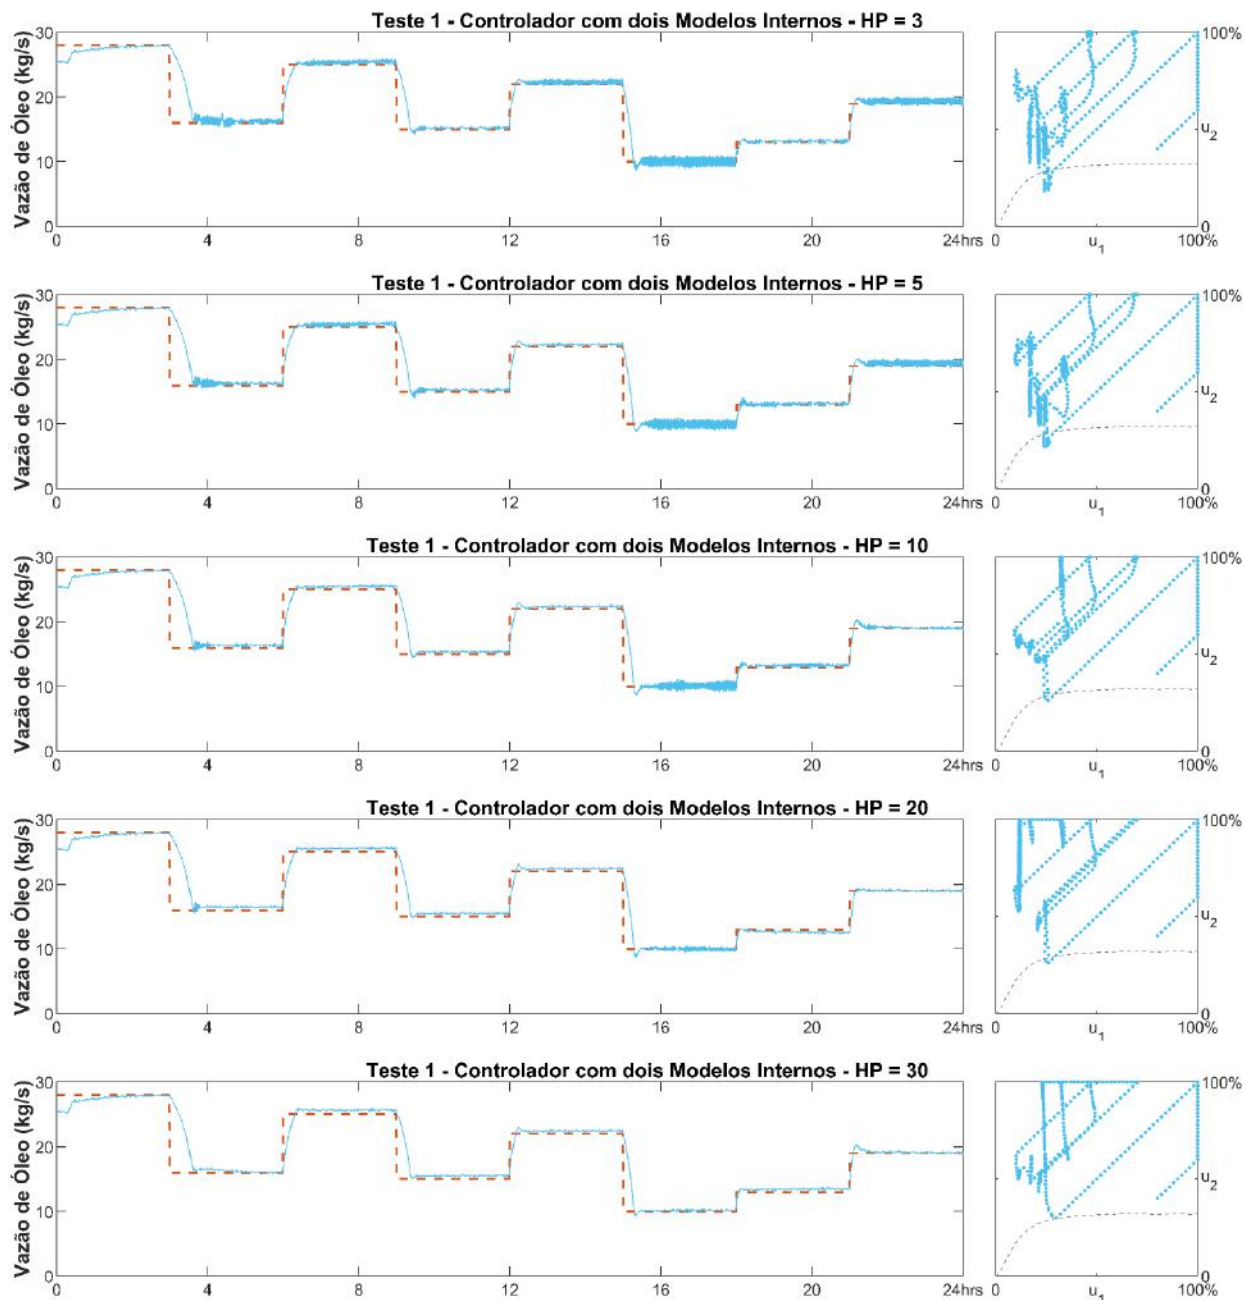


Figura 29: Teste 1 para controle com dois modelos internos em diferentes horizontes de predição

O controlador com modelo único foi capaz de promover a mudança de *setpoints* com sucesso, no entanto, mesmo no controlador com o menor erro ($HP = 3$) pode-se observar a presença de *offset* na vazão do poço frente a curva de referência estabelecida. Este offset cresceu à medida que o horizonte de predição aumentava, indicando que a deterioração observada nas métricas da RNA traduzem-se diretamente nos resultados dos NMPC avaliados, nesse sentido, no maior horizonte de predição avaliado, a rede levou o processo

para a zona instável e não conseguiu conter a golfada, ainda que posteriormente tenha sido capaz de remover o processo desta zona e mantê-lo estável.

O NMPC que utilizou dois modelos apresentou resultado superior ao controlador com modelo único, nesse sentido, os resultados exibidos na Figura 29 indicam a redução significativa do *offset* observado no primeiro caso.

Diferentemente do controlador com modelo único, o erro associado ao NMPC pode ser atribuído principalmente ao tempo necessário para transitar entre *setpoints*, fator principalmente dependente da abertura máxima de válvula permitida a cada passo de controle (2%). Se aumentada, o intervalo de tempo necessário para conduzir o processo de uma vazão para outra é reduzido, contudo, seu aumento também pode introduzir instabilidades ao controlador. O ajuste deste parâmetro normalmente é feito em conjunto com a definição do melhor horizonte de controle e predição, etapas não contempladas neste trabalho.

A medida que o horizonte de predição foi aumentado no controlador com dois modelos, o comportamento variável da vazão de óleo observada no antepenúltimo e no último *setpoint* foi eliminado. Este comportamento pode ser atribuído a falta de “visão” do processo até um patamar estável por parte do controlador, que pode ser aprimorada ao se operar horizontes de predição maiores.

Cabe ressaltar que sem uma camada de otimização superior aos controladores, ou ao menos limitando-se a abertura da válvula de injeção de gás, ambos os controladores pouco operaram na zona instável, evitando-a sempre que possível.

4.2.2. Segundo Teste: Melhores Redes

Uma vez que os custos associados à injeção de ar são menores na zona instável, é economicamente vantajoso operar o poço dentro desta zona. O segundo teste buscou avaliar justamente esta capacidade dos controladores, isto é, avaliar se eles foram eficientes em impedir a ocorrência de golfadas enquanto simultaneamente buscavam adequar o processo a mudanças na trajetória de referência. Este teste configura-se como uma avaliação mais rigorosa aos controladores pois manipulações equivocadas na vazão rapidamente podem induzir a ocorrência de uma golfada. Os resultados dos controladores são apresentados na Tabela 14 e nas Figuras 30 e 31.

Tabela 14: Resultado do primeiro teste para os controladores avaliados

NMPC	Métrica	HP = 3	HP = 5	HP = 10	HP = 20	HP = 30
Um Modelo	Erro (ISE)	40.81	8.07	11.27	22.50	17.83
Dois Modelos	Erro (ISE)	52.14	10.26	10.53	10.93	12.60

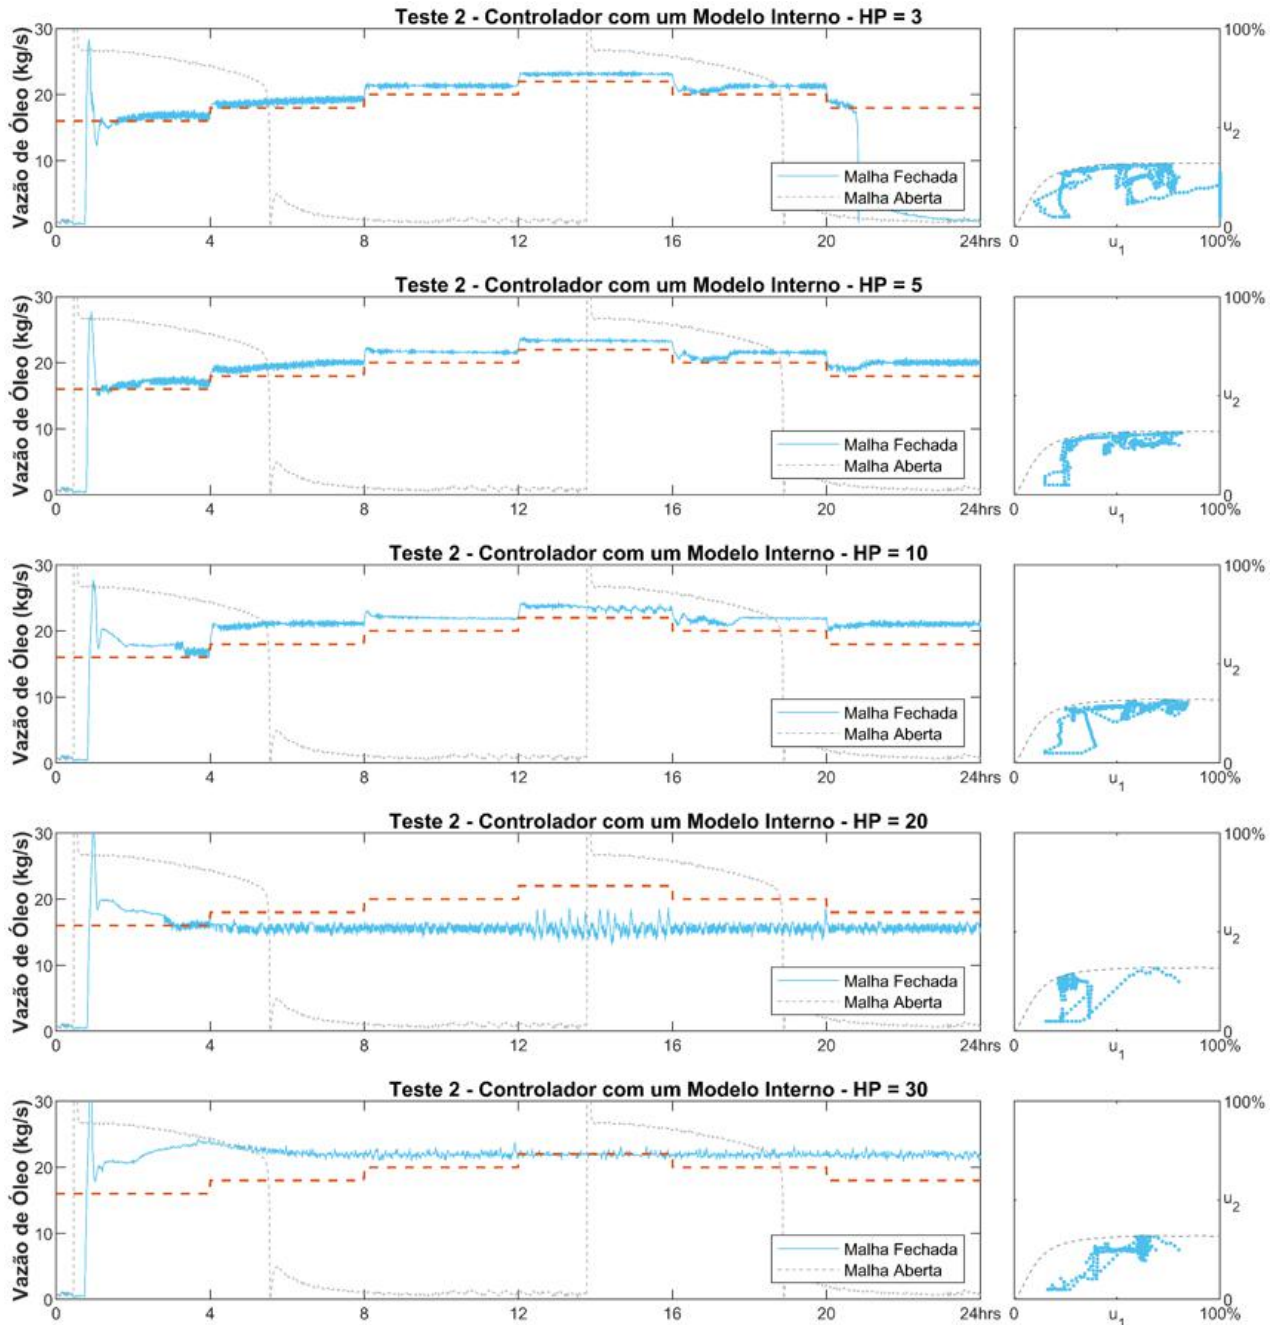


Figura 30: Teste 2 para controle com um modelo interno em diferentes horizontes de previsão

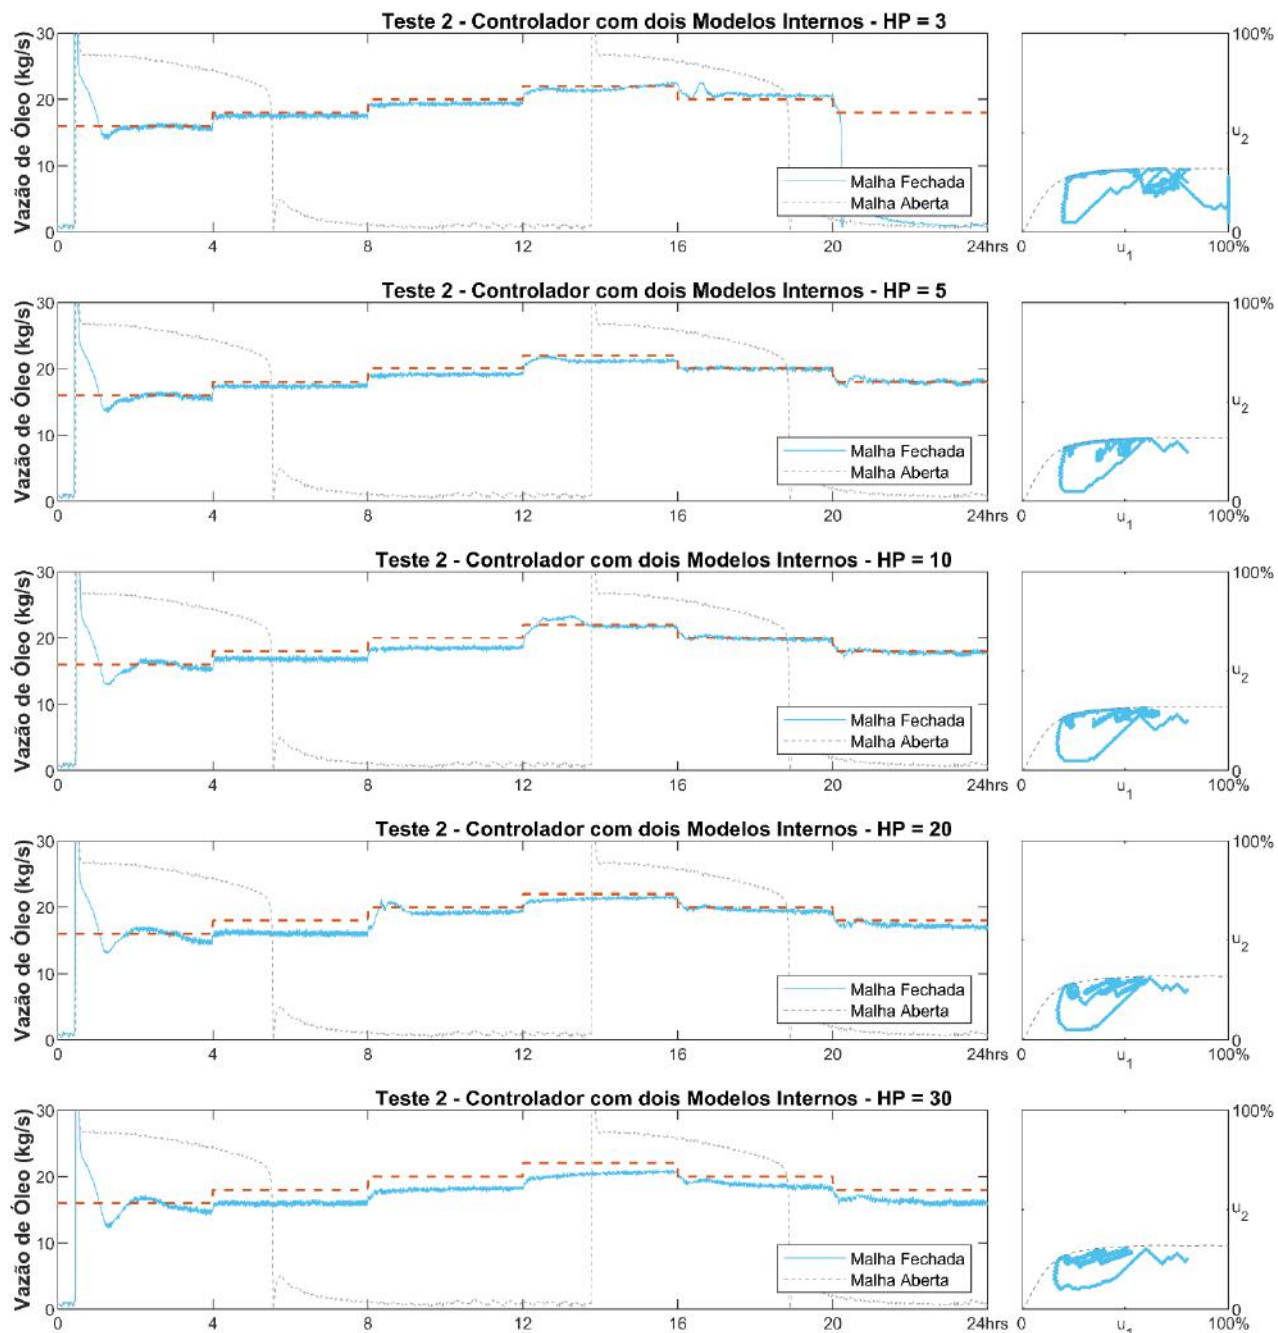


Figura 31: Teste 2 para controle com dois modelos internos em diferentes horizontes de predição

O regime de golfadas possui dinâmica lenta se comparada a região estável, sendo assim, horizontes de predição pequenos podem ser insuficientes para descrever o processo e nortear a tomada de decisão por parte dos controladores. O resultado observado para ambos os controladores implementados no menor HP avaliado reforça esta ideia, uma vez que os NMPC enfrentaram dificuldade na adequação da vazão ao último *setpoint* avaliado.

Como mostrado na Tabela 13, o controlador com modelo interno único obteve resultados inferiores, apresentando *offsets* mais significativos e, para HP maiores, se mostrou incapaz de manipular a vazão de modo a atingir os *setpoints* estabelecidos, ainda que tenha sido capaz de estabilizar o poço na zona instável.

Apesar do desempenho inferior, é importante observar que o segundo NMPC teve mais dificuldade para impedir que as vazões imediatamente após as golfadas atingissem valores muito elevados. A dinâmica nas primeiras duas horas de ambos os controladores no horizonte igual a 5 é mostrada na Figura 32 com o eixo das vazões em uma escala que possibilita a comparação da intensidade da golfada.




Figura 32: Intensidade da golfada para ambos os controladores com HP = 5

A partir da figura, fica clara a superioridade na contenção do pico de vazão do NMPC com um modelo, ainda que para tal as ações de controle provocaram a golfada aproximadamente 30 minutos após o outro controlador.

Os maiores erros observados no teste 2 frente ao teste 1 (nos casos em que o controle foi capaz de estabilizar o processo) podem ser justificados pelos minutos iniciais do processo, em que as vazões se aproximam de zero e, para o cálculo do erro ISE, há uma significativa penalização para pontos que distam significativamente do *setpoint*.

4.2.3. Segundo Teste: Modelos sem Pressão de Injeção (UF)

Para poços mais antigos, normalmente a pressão de injeção pode não ser uma variável monitorada, geralmente devido a defeitos nos medidores cujo reparo é impossibilitado sem interromper a operação. Nesses casos o valor da pressão é inferido a partir da pressão de gás *topside*.

Objetivando averiguar a capacidade dos controladores no cenário descrito acima, as melhores redes treinadas segundo o modelo UF foram implementadas como modelo interno. A Tabela 15 indica as redes empregadas em cada controlador assim como e os seus modelos correspondentes.

Tabela 15: Redes utilizadas nos controladores avaliados (Teste 2: Modelos UF)

NMPC	Zona Compreendida	Modelo	Estrutura	Ativação	Lote	Penalidade
Um Modelo	Ambas	UF	(32 26 8)	<i>relu</i>	100	10^{-4}
Dois Modelos	Estável	UF	(40 40 40)	<i>tanh</i>	200	10^{-4}
	Instável	UF	(30 22 12)	<i>relu</i>	100	10^{-3}

Os resultados dos controladores são apresentados na Tabela 16 e nas Figuras 33 e 34.

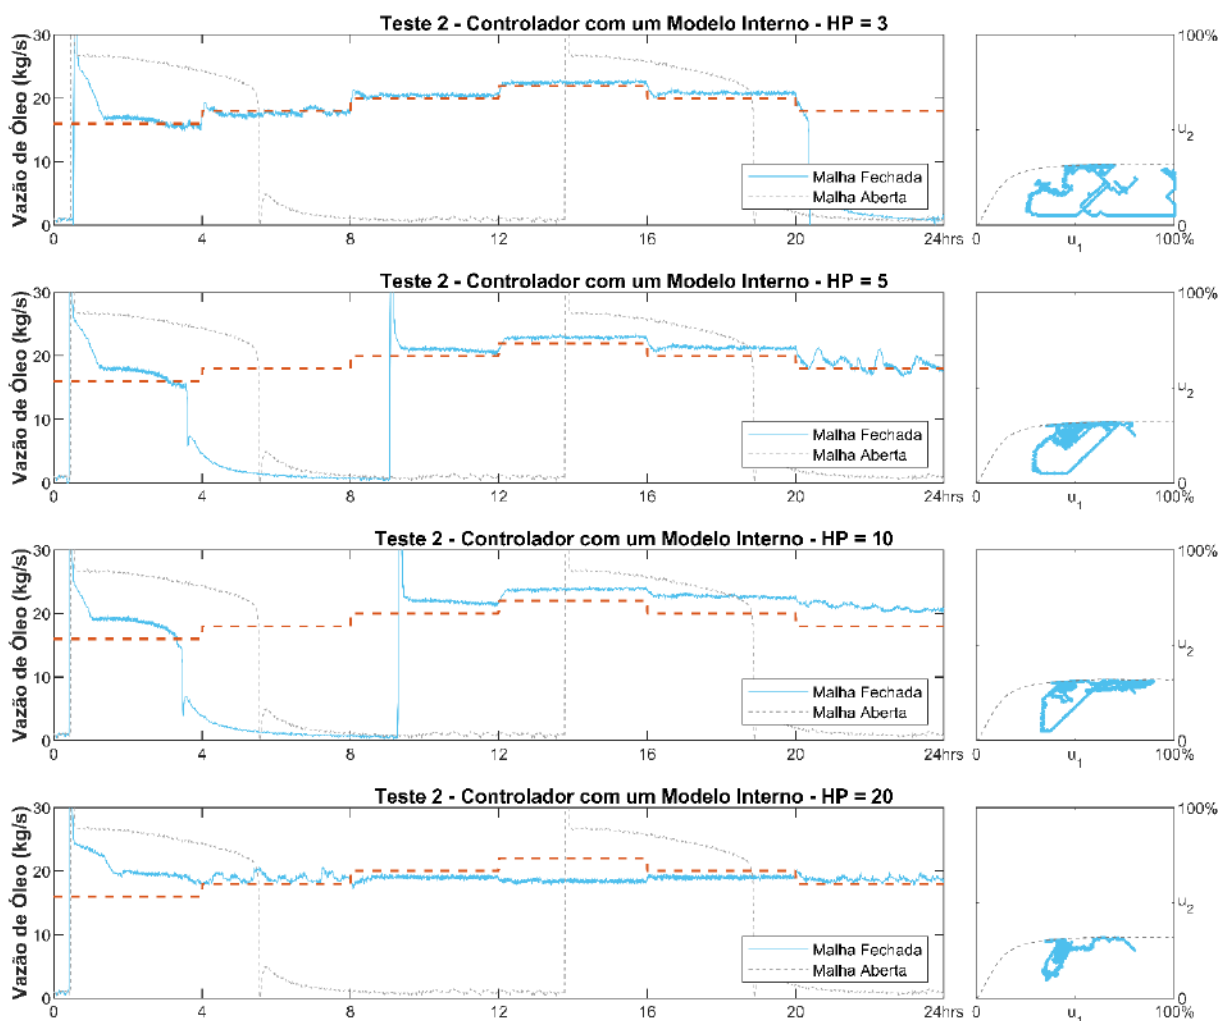


Figura 33a: Teste 2 (Modelos UF) para controle com um modelo interno (HP = 3, 5, 10, 20)




Figura 32b: Teste 2 (Modelos UF) para controle com um modelo interno (HP = 30)








Figura 34: Teste 2 (Modelos UF) para controle com dois modelos internos

Tabela 16: Resultado do primeiro teste para os controladores avaliados

NMPC	Métrica	HP = 3	HP = 5	HP = 10	HP = 20	HP = 30
Um Modelo	Erro (ISE)	53.1	84.7	90.1	15.64	29.1
Dois Modelos	Erro (ISE)	121.6	123.4	123.4	126.5	120.0

O comportamento exibido nas figuras demonstrou que os controladores não foram capazes de estabilizar o processo como um todo, enfrentando dificuldades principalmente na parte final da curva de referência ou, no caso do controlador com modelo único, também no segundo *setpoint* (entre 4 e 8 horas).

A redução no *setpoint* de vazão implica necessariamente na redução da injeção de gás ou no fechamento da válvula de produção, ambas as abordagens ocasionam uma redução na pressão de injeção e podendo levar a maiores instabilidades e conseqüentemente a golfadas. Sendo assim, a variação decrescente no *setpoint* possivelmente apresenta maiores dificuldades ao controlador e é auxiliada pela presença das medições de pressão de injeção do poço do modelo UFP.

Capítulo 5: CONCLUSÕES E TRABALHOS FUTUROS

5.1 Conclusão

O presente trabalho objetivou estudar a identificação de um poço de elevação artificial e subsequente controle da operação, um processo complexo e com diversas características não lineares e interessantes ao controle de processos.

As redes treinadas obtiveram métricas satisfatórias, contudo, cabe ressaltar que os resultados da região instável do poço não atingiram patamares elevados como os da região estável. Nesse sentido, a inclusão da pressão de injeção como variável de entrada no modelo se mostrou importante para a qualidade e acurácia das simulações dinâmicas, ainda que enquanto em zonas estáveis, tais medições de pressões pouco influenciaram no resultado.

As redes foram treinadas segundo duas estratégias: uma rede única capaz de replicar ambos os comportamentos estável e instável do poço e redes específicas para cada zona. A estratégia empregada ao utilizar conjuntos de treinamento específicos para cada zona mostrou-se superior a estratégia contendo modelo único.

As melhores redes foram avaliadas e selecionadas para inclusão como modelo interno de controladores NMPC e submetidas a duas classes de teste. O primeiro objetivou avaliar a capacidade dos controladores de se adequar a diferentes vazões dentro de das possíveis faixas de operação do poço. A segunda classe de teste, mais rigorosa, avaliou a capacidade dos controladores estabilizarem a operação na zona instável e adequá-la a diferentes vazões de referência.

Em ambos os casos a estratégia contendo dois modelos se mostrou superior, provando-se como uma abordagem interessante e indicando que ao utilizar-se dados reais de campo, uma etapa de pré-tratamento, classificando-os segundo a zona de operação, pode possuir forte impacto no resultado do controlador.

5.2 Sugestão de Trabalhos Futuros

De modo a responder perguntas e aprofundar as reflexões acerca do presente trabalho, são propostas as seguintes possibilidades de trabalhos futuros:

- Avaliação de outras classes e estruturas de redes neuronais na identificação do comportamento do poço.
- Análise da influência do tamanho dos conjuntos de treino no desempenho das redes.
- Utilização de dados reais de campo para o treinamento, incorporando distúrbios à modelagem do processo.

Capítulo 6: REFERÊNCIAS BIBLIOGRÁFICAS

- ANTONELO, E. A.; CAMPONOGARA, E.; FOSS, B. Echo State Networks for data-driven downhole pressure estimation in gas-lift oil wells. **Neural Networks**, v. 85, p. 106–117, 2017.
- ARCHER, J. S.; WALL, C. G. **Petroleum engineering: principles and practice**. [s.l.] Springer Science & Business Media, 2012.
- ASHIKAWA, F. H. **Mitigação de golfadas em sistemas offshore utilizando modelo dinâmico simplificado**. [s.l.: s.n.].
- ÅSTRÖM, K. J.; WITTENMARK, B. **Computer-controlled systems: theory and design**. [s.l.] Courier Corporation, 2013.
- CASTRO, D.; NEW, J. The promise of artificial intelligence. **Center for Data Innovation**, v. 115, n. 10, p. 32–35, 2016.
- DE SOUZA JR, M. **Redes Neurais Multicamadas Aplicadas a Modelagem e Controle De Processos Químicos**. [s.l.: s.n.].
- DIAS, A. et al. Extracting Valuable Information from Big Data for Machine Learning Control: An Application for a Gas Lift Process. **Processes**, v. 7, p. 252, 30 abr. 2019.
- DIEHL, F. C. et al. Anti-slug control design: Combining first principle modeling with a data-driven approach to obtain an easy-to-fit model-based control. **Journal of Petroleum Science and Engineering**, v. 207, p. 109096, 2021.
- EIKREM, G.; AAMO, O.; FOSS, B. On Instability in Gas Lift Wells and Schemes for Stabilization by Automatic Control. **SPE Production & Operations - SPE PROD OPER**, v. 23, p. 268–279, 1 maio 2008.
- FENG, J.; LU, S. Performance Analysis of Various Activation Functions in Artificial Neural Networks. **Journal of Physics: Conference Series**, v. 1237, n. 2, p. 022030, 2019.
- GANI, R. Chemical product design: challenges and opportunities. **Computers & Chemical Engineering**, v. 28, n. 12, p. 2441–2457, 15 nov. 2004.

- GÉRON, A. Hands-on machine learning with scikit-learn and tensorflow: Concepts. **Tools, and Techniques to build intelligent systems**, 2017.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. [s.l.] MIT press, 2016.
- HAALAND, S. E. Simple and explicit formulas for the friction factor in turbulent pipe flow. 1983.
- HAHNLOSER, R. H. R. et al. Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit. **Nature**, v. 405, n. 6789, p. 947–951, 2000.
- HAYKIN, S. **Redes neurais: princípios e prática**. [s.l.] Bookman Editora, 2007.
- HERNÁNDEZ, E.; ARKUN, Y. Study of the control-relevant properties of backpropagation neural network models of nonlinear dynamical systems. **Computers & Chemical Engineering**, v. 16, n. 4, p. 227–240, 1 abr. 1992.
- HIMMELBLAU, D. M. Accounts of experiences in the application of artificial neural networks in chemical engineering. **Industrial & Engineering Chemistry Research**, v. 47, n. 16, p. 5782–5796, 2008.
- HINTON, G.; OSINDERO, S.; TEH, Y.-W. A Fast Learning Algorithm for Deep Belief Nets. **Neural computation**, v. 18, p. 1527–1554, 1 ago. 2006.
- HUANG, Y.-W. **Neural Networks for Chemical Engineers Edited by AB Bulsari (Lappeenranta University of Technology, Finland). Elsevier: Amsterdam. 1995. ix+ 680 pp. \$285.25. ISBN 0-444-820970-3.**ACS Publications, , 1996.
- JAHANSHAHI, E. **Control Solutions for Multiphase Flow: Linear and nonlinear approaches to anti-slug control**. [s.l.: s.n.].
- JAHANSHAHI, E.; SALAHSHOOR, K.; SAHRAIE, Y. Fuzzy estimation and stabilization in gas lift wells based on a new stability map. **Advances in Sustainable Petroleum Engineering Science**, v. 1, p. 201–219, 1 jan. 2009.
- JAHANSHAHI, E.; SKOGESTAD, S.; HANSEN, H. **Control structure design for stabilizing unstable gas-lift oil wells**. [s.l.: s.n.].

- JARRETT, K. et al. **What is the best multi-stage architecture for object recognition?** 2009 IEEE 12th international conference on computer vision. **Anais...IEEE**, 2009.
- JORDANOU, J. P. et al. Nonlinear Model Predictive Control of an Oil Well with Echo State Networks. **IFAC-PapersOnLine**, v. 51, n. 8, p. 13–18, 2018.
- KAISER, M. Time-delay neural networks for control. **IFAC Proceedings Volumes**, v. 27, n. 14, p. 967–972, 1 set. 1994.
- KELLNER, T. **Deep Machine Learning: GE and BP Will Connect Thousands of Subsea Oil Wells to the Industrial Internet.** Julho 2015. Disponível em: <<https://www.ge.com/news/reports/deep-machine-learning-ge-and-bp-will-connect-2>> Acesso em 01 nov. 2021.
- MCCLELLAND, J. L.; RUMELHART, D. E.; GROUP, P. D. P. R. **Parallel distributed processing.** [s.l.] MIT press Cambridge, MA, 1986. v. 2
- MIYOSHI, S. C. et al. Nonlinear model predictive control application for gas-lift based oil production. In: FRIEDL, A. et al. (Eds.). **Computer Aided Chemical Engineering.** [s.l.] Elsevier, 2018. v. 43p. 1177–1182.
- MOREIRA, I. M. **Controle Preditivo Baseado em Modelo com Estimaco de Distrbios para Plantas Monovariveis.** Rio de Janeiro: [s.n.].
- OLIVEIRA, R. C. L. DE. Rede neural com dinmica interna aplicada a problemas de identificao e controle no-linear. 1999.
- PIRDASHTI, M. et al. Artificial neural networks: Applications in chemical engineering. **Reviews in chemical engineering**, v. 24, p. 205–239, 2 ago. 2013.
- PLUCENIO, A. et al. Gas-lift optimization and control with nonlinear mpc. **IFAC Proceedings Volumes**, v. 42, n. 11, p. 904–909, 2009.
- QIN, S. J.; BADGWELL, T. A. A survey of industrial model predictive control technology. **Control engineering practice**, v. 11, n. 7, p. 733–764, 2003.
- RAMACHANDRAN, P.; ZOPH, B.; LE, Q. V. Searching for Activation Functions. **arXiv preprint arXiv:1710.05941**, 2017.

- RAWLINGS, J. B. Tutorial overview of model predictive control. **IEEE control systems magazine**, v. 20, n. 3, p. 38–52, 2000.
- RIBEIRO, C. H. P. et al. Model Predictive Control with quality requirements on petroleum production platforms. **Journal of Petroleum Science and Engineering**, v. 137, p. 10–21, 2016.
- RIBEIRO, L. D. **Uma Nova Metodologia NMPC Integrada com uma Camada de Otimização Para Maximizar a Produção de Óleo Offshore com Especificações de Qualidade**. Rio de Janeiro: [s.n.].
- RODRIGUES, R. F.; TRIERWEILER, J. O.; FARENZENA, M. New methodology for parameter estimation of offshore slug models with Hopf bifurcation. **Comput. Chem. Eng.**, v. 117, p. 247–255, 2018.
- ROJAS SOARES, F. D.; DE SOUZA JR, M. B.; SECCHI, A. R. Development of a Model Predictive Control for Stabilization of a Gas Lift Oil Well. 2019.
- ROTH, F. H. et al. **Building Expert Systems**. [s.l.] Addison-Wesley Publishing Company, 1983.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533–536, 1986.
- SALAHSHOOR, K.; ZAKERI, S.; HAGHIGHAT SEFAT, M. Stabilization of gas-lift oil wells by a nonlinear model predictive control scheme based on adaptive neural network models. **Engineering Applications of Artificial Intelligence**, v. 26, n. 8, p. 1902–1910, 1 set. 2013.
- SCHNITMAN, L. **Controladores Preditivos Baseados em Redes Neurais Artificiais**. Salvador: [s.n.].
- SEBORG, D. E. et al. **Process dynamics and control**. [s.l.] John Wiley & Sons, 2016.
- SMITH, L. N. A disciplined approach to neural network hyper-parameters: Part 1--learning rate, batch size, momentum, and weight decay. **arXiv preprint arXiv:1803.09820**, 2018.

- THOMAS, J. E. **Fundamentos de engenharia de petróleo**. [s.l.] Interciência, 2001.
- VAN VEEN, Fjodor. The Neural Network Zoo. **The Asimov Institute**, 2016. Disponível em: <https://www.asimovinstitute.org/neural-network-zoo/>. Acesso em: 05 nov. 2021
- VENKATASUBRAMANIAN, V. The promise of artificial intelligence in chemical engineering: Is it here, finally? **AIChE Journal**, v. 65, n. 2, p. 466–478, 1 fev. 2019.
- VENKATASUBRAMANIAN, V.; CHAN, K. A neural network methodology for process fault diagnosis. **AIChE Journal**, v. 35, n. 12, p. 1993–2002, 1989.
- WINICK, E. **Uptake is Putting the World’s Data to Work**. Setembro 2018. Disponível em: <https://www.technologyreview.com/2018/09/12/140306/uptake-is-putting-the-worlds-data-to-work/> Acesso em 01 nov. 2021.