

# OTIMIZAÇÃO ECONÔMICA EM TEMPO REAL ORIENTADA A DADOS PARA POÇOS DE PETRÓLEO COM INJEÇÃO DE GÁS

Ezequias. S. Matos\*, Odilon S.L. Abreu\*, Taniel S. Franklin\*, Leonardo S. Souza\*, Márcio A. F. Martins\*

\* Programa de Pós-Graduação em Mecatrônica, Universidade Federal da Bahia, Rua Aristides Novis, Federação, 40210-630, Salvador, BA,

Brasil (e-mail: ezequiasmatoseng@gmail.com) (e-mail: odilon.abreu@ufba.br) (e-mail: tanielfranklin@gmail.com) (e-mail: leosilvasouza2001@gmail.com) (e-mail: marciomartins@ufba.br)

**Abstract:** This work addresses the daily economic optimization problem in gas-lift oil wells. The proposal uses an artificial neural network (ANN) to find the optimal solution with a lower computational cost than one produced with a phenomenological model. However, a first-principle nonlinear model of a gas-assisted oil well production system was developed to generate the experimental data. From the practical point of view, a moving horizon estimator was designed as an adequate solution for estimating hard-to-measure variables such as produced oil and gas flow rates. Thus, it was possible to train the ANN with Nonlinear Auto-regressive with Exogenous Input-type architecture. The results showed a good ANN performance in terms of prediction capability suitable to daily optimization horizon (one-step ahead) and a better computational time in the optimization problem solution compared with the standard phenomenological model. The solution approach opens possibilities for large-scale problem implementations, such as the daily optimization of the oil field production (multiple wells integrated by reservoir and manifold).

**Resumo:** Este trabalho aborda um problema de otimização econômica diária em tempo real, cuja proposta consiste em usar uma rede neural artificial (RNA) para substituir o modelo fenomenológico que representa um sistema de produção de poços de petróleo assistido por gás. Devido à indisponibilidade dos dados para fazer o treinamento da RNA, então o uso de um estimador de horizonte móvel (MHE) apresentou-se como uma solução adequada para estimar algumas variáveis de difícil medição, tais quais as vazões de óleo e gás produzidas. Desta maneira, foi possível viabilizar o treinamento da RNA com arquitetura do tipo Nonlinear Auto-regressive with Exogenous Input. Os resultados apontam um bom desempenho da rede neural em fazer previsão compatível com a janela de otimização diária (um passo à frente), assim como apresenta um melhor tempo computacional na solução do problema de otimização quando comparado com o modelo fenomenológico padrão. A abordagem da presente solução abre possibilidades para implementações em problemas de larga escala, tal qual a otimização da produção diária do campo de petróleo (vários poços integrados pelo reservatório e manifold).

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

**Palavras-chaves:** Otimização em Tempo Real; Gas Lift; Inteligência Artificial; Estimação não Linear.

## 1. INTRODUÇÃO

O sistema de elevação artificial operado por injeção de gás (GL - Gas Lift) para produção de petróleo (*onshore* e *offshore*), consiste em pressurizar a coluna de produção através das válvulas (choke/operadora) a fim de reduzir a densidade do óleo na extração de petróleo. Tal sistema, apresenta diversas variáveis que necessitam de monitoramento e avaliação para auxiliar na tomada de decisão. A manipulação dessas variáveis é extremamente complexa e, por conta disso, a otimização em tempo real (RTO, *Real-time Optimization*) mostra-se uma ferramenta essencial para garantir a maior rentabilidade de produção.

Segundo Krishnamoorthy et al. (2019) a otimização diária da produção de petróleo desempenha um papel essencial para maximizar o lucro operacional e reduzir o consumo de energia. Porém, ainda não é amplamente utilizada na sua forma

sistemática e integral na prática de produção de petróleo em virtude de algumas limitações tecnológicas e corporativas.

Os principais desafios tecnológicos encontrados até o presente momento na literatura foram: *i*) falta de modelos fenomenológicos representativos que sejam capazes de representar o sistema dentro de um problema de otimização em tempo real (desenvolvimento de modelos offline); *ii*) incertezas dos parâmetros e distúrbios no modelo (atualização do modelo online); *iii*) robustez numérica, incluindo os problemas computacionais; *iv*) problema de inconsistência entre a camada de otimização e controle, dentre outros (Krishnamoorthy et al. 2019).

A literatura demonstra que os modelos fenomenológicos têm sido explorados em proposições de RTO com mais frequência. Entretanto, ao considerar o surgimento de novas e desafiadoras condições de campo e reservatório, por exemplo, o reservatório não convencional, os modelos existentes que

descrevem o comportamento de pressão, vazão de reservatório e de produção, podem não conseguir representar de forma precisa o sistema de elevação artificial. Além disso, o desenvolvimento de um novo modelo fenomenológico requer uma equipe dedicada e consome tempo (Krishnamoorthy et al. 2019).

De modo a contornar os problemas enfrentados com os modelos fenomenológicos, Bikmukhametov and Jäschke (2020) apontam os modelos orientados a dados como alternativa nos últimos anos. Segundo os autores, a abordagem orientada a dados depende da coleta de dados de campo e de ajustes entre os dados medidos e os valores estimados pelo modelo sem a necessidade da descrição exata dos parâmetros físicos do sistema. Logo, se o modelo orientado a dados for treinado corretamente e as condições de operação estiverem dentro do intervalo de treinamento, esse poderá fazer previsões rapidamente e com um baixo custo computacional quando comparado com os fenomenológicos. Além disso, não dispõe de problemas de instabilidade numérica, uma vez que os modelos orientados a dados não precisam de um integrador numérico.

As redes neurais artificiais também já são exploradas há algum tempo, principalmente quando o assunto é escoamento multifásico. Qiu e Toral (1993) tentaram estimar a pressão em escoamento multifásico utilizando modelo RNA, usaram dados de transdutores de pressão de laboratório e fluxo trifásico horizontal em tubo de 3 e 4 polegadas como entrada para a rede e taxas previstas de gás-líquido como saída. Deste então, as redes neurais artificiais vêm ganhando espaço quando o assunto é medidor virtual de fluxo. AL-Qutami et al. (2017) propuseram um sensor virtual de fluxo multifásico para prever a vazão na linha de produções de um poço de petróleo utilizando rede neural artificial *feed-forward*. Posteriormente Loh, Omrani e van der Linden (2018) utilizaram uma rede neural artificial dinâmica (LSTM, *Long Short Term Memory*) para fazer previsão de vazão multifásica em poço de petróleo, fazendo uso de dados de teste de poço sintético e de dados de campo.

No trabalho de Dias et al. (2019), os autores utilizaram uma arquitetura de RNA recorrente chamada de "*Echo State Network*" para fazer previsões de produção do GL em longo período, indicando que o modelo seria capaz de realizar otimização em tempo real. Outrossim, Soares et al. (2022) executaram um controlador preditivo não-linear baseado em modelo orientado a dados (rede neural artificial *feed-forward*) e mostraram que estimativa dos estados internos pela rede neural foi suficientemente precisa para permitir um controle adequado do GL. Além das aplicações em pesquisa, de acordo com Bikmukhametov e Jäschke (2020), os modelos orientados a dados têm sido aplicados na indústria, como no caso da Baker Hughes que desenvolveu o software NeuraFlow baseado em redes neurais artificiais e usado para estimar as vazões em sistemas com bombeio centrifugo submerso (BCS).

Em relação aos trabalhos relacionados a RTO com modelos fenomenológicos, pode-se citar Codas et al. (2016), no qual

propuseram um problema de otimização em tempo real com objetivo de fornecer configurações ideais para controles regulatórios. Já Krishnamoorthy et al. (2016) avaliaram as incertezas do modelo fenomenológico na RTO. Um pouco depois, Matias et al. (2022) propuseram um problema RTO com a adaptação persistente dos parâmetros do modelo, em que os parâmetros do modelo em estado estacionário são atualizados dinamicamente usando medições transientes, ou seja, sem a necessidade de esperar por um estado estacionário antes de acionar o ciclo de otimização.

A otimização em tempo real exige uma alta velocidade computacional, o que é um problema para os modelos fenomenológicos de larga escala ou até mesmo, um mais rigoroso. Como por exemplo, integrar várias unidades de processo com o objetivo de expandir o escopo do problema de otimização, ou seja, envolver mais de uma unidade de processo (Campos et al. 2009).

Por outro lado, para o aprendizado de um modelo orientado a dados são necessários dados que representem o sistema e em alguns casos, como na produção de petróleo *offshore*, as vazões individuais de cada poço em tempo real geralmente não estão disponíveis, devido à dificuldade de implementação de dispositivos de medição (Gões et al. 2021).

Partindo dessa premissa, este trabalho visa formular um problema de otimização econômica em tempo real (produção diária), substituindo o modelo fenomenológico que representa o sistema GL, por uma rede neural artificial (RNA). Desta forma, o modelo fenomenológico continua com espaço de uso, mas visando soluções offlines, para gerar os dados necessários para treinar a RNA proposta e, sobretudo, para prever as vazões de óleo e gás de cada poço em função das variáveis medidas disponíveis. A fim de estimar as variáveis não medidas, propõe-se o projeto de um estimador não linear baseado em horizonte móvel (MHE, *moving horizon estimation*).

O restante do texto está organizado da seguinte forma. Na Seção 2 detalha-se a metodologia aplicada no artigo. Na Seção 3 discute-se os resultados obtidos, seguida pela Seção 4, que encerra o texto com as considerações finais.

## 2. METODOLOGIA PROPOSTA

### 2.1 Modelo do Processo

A produção de um poço de petróleo assistido por gás pode ser descrita usando equações diferenciais, conforme Jahanshahi et al. (2012); Krishnamoorthy et al. (2019). A dinâmica é obtida por meio dos balanços de massa na coluna de produção e no anular e são descritos pelas seguintes equações diferenciais.

$$\frac{dm_{ga}}{dt} = w_{ing} - w_{iv} \quad (1)$$

$$\frac{dm_{gt}}{dt} = w_{iv} - w_{pg} + w_{rg} \quad (2)$$

$$\frac{dm_{ot}}{dt} = w_{ro} - w_{po} \quad (3)$$

Sendo que,  $m_{ga}$  é a massa do gás no anular,  $m_{gt}$  é a massa do gás na coluna produção (*tubing*),  $m_{ot}$  é a massa do óleo no *tubing*,  $w_{ing}$  é a vazão mássica de gás injetada no anular,  $w_{iv}$  é a vazão mássica de gás através da válvula operadora entre o anular e coluna de produção,  $w_{rg}$  e  $w_{ro}$  são as vazões mássicas de gás e óleo do reservatório,  $w_{pg}$  e  $w_{po}$  são as vazões mássicas de gás e óleo na válvula *choque* na cabeça do poço. Na Figura 1 é possível visualizar o esquema de um poço equipado com GL. O modelo completo está disponível no apêndice A.

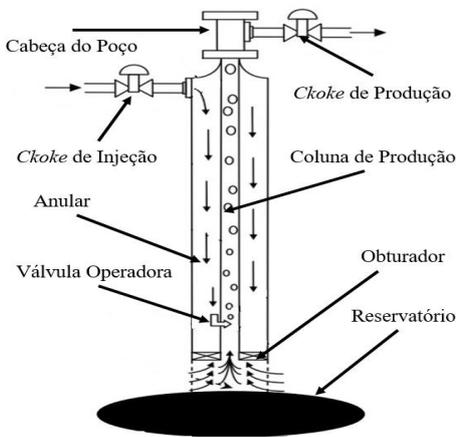


Figura 1: Representação esquemática de um poço de GL

Fonte: Adaptada de Jahanshahi et al. (2012)

## 2.2 Estimador de horizonte móvel (MHE)

A estimativa de horizonte móvel é uma técnica de estimativa de estado baseada em otimização, onde o estado atual do sistema é estimado com base em uma sequência finita de medições passadas. Neste contexto, o sistema de equações não lineares que representa o modelo é dado conforme as equações 4 e 5.

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \mathbf{w}_{k-1} \quad (4)$$

$$\mathbf{y}_{pk} = h(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{v}_k \quad (5)$$

Em que,  $f(\cdot)$  é o modelo do processo e  $h(\cdot)$  é a função que relaciona os estados com as saídas.  $\mathbf{x}_k = [m_{ga}; m_{gt}; m_{ot}]^T$  é o vetor de estado,  $\mathbf{u}_k = [w_{ing}; Z_{open}]^T$  é o vetor de entrada,  $\mathbf{y}_{pk} = [p_{wh}; p_{ai}; p_{bh}; W_{to}; W_{tg}]^T$  é o vetor de saída,  $\mathbf{w}$  e  $\mathbf{v}$  são os ruídos do processo.  $w_{ing}$  é a injeção de gás no anular,  $Z_{open}$  é abertura da válvula *choke* de produção,  $p_{wh}$ ,  $p_{ai}$  e  $p_{bh}$  são as pressões na cabeça do poço, anular e fundo

respectivamente, por fim,  $W_{to}$  e  $W_{tg}$  são as vazões de óleo e gás produzidas.

O MHE é formulado usando uma função de custo quadrática que penaliza o erro entre a predição do modelo e as medições do sistema, como também, é um problema de otimização dinâmico restrito e não linear e pode ser descrito da seguinte maneira, conforme Mehrez et al. (2014)

$$\min_{\substack{\mathbf{x}_0 \dots \mathbf{x}_N \\ \mathbf{u}_0 \dots \mathbf{u}_{N-1}}} J_N(\mathbf{x}, \mathbf{u}) = \sum_{k=q-N}^q \|\mathbf{y}_{pk} - \hat{\mathbf{y}}_{pk}\|_{\mathbf{v}_k}^2 + \sum_{k=q-N}^{q-1} \|\mathbf{u}_k - \hat{\mathbf{u}}_k\|_{\mathbf{w}_k}^2 \quad (6)$$

$$\text{s. a.: } \hat{\mathbf{x}}_{k+1} = f(\hat{\mathbf{x}}_k, \mathbf{u}_k), \quad \forall q-N \leq k \leq q-1 \quad (7)$$

$$\hat{\mathbf{y}}_{pk} = h(\hat{\mathbf{x}}_k, \mathbf{u}_k), \quad \forall q-N \leq k \leq q-1 \quad (8)$$

$$\mathbf{x}_k^{inf} \leq \hat{\mathbf{x}}_k \leq \mathbf{x}_k^{sup}, \quad \forall q-N \leq k \leq q \quad (9)$$

$$\mathbf{u}_k^{inf} \leq \mathbf{u}_k \leq \mathbf{u}_k^{sup}, \quad \forall q-N \leq k \leq q \quad (10)$$

em que,  $k$  indica o instante atual,  $\mathbf{y}_{pk}$  é a medição do GL,  $\hat{\mathbf{y}}_{pk}$  é a saída estimada e  $\mathbf{u}_k$  é a entradas medida,  $\hat{\mathbf{u}}_k$  é a entrada estimada,  $N$  é o horizonte de predição,  $\mathbf{v}_k > 0$  e  $\mathbf{w}_k > 0$  são as matrizes de ponderação diagonal. Neste trabalho, o estimador de estados tem como objetivo filtrar as variáveis medidas e estimar as vazões individuais de óleo, gás no topo do poço, sem violar as restrições da planta. Além disso, as diferenças nas entradas estão inclusas no problema de otimização, a fim de contabilizar os desvios efetivos aplicados ao sistema, por exemplo, incerteza na vazão de entrada de gás no anular e/ou imprecisão do atuador.

## 2.3 Rede neural artificial

A RNA é um modelo não linear que tem a interessante propriedade de ser um aproximador universal, desde que haja dados suficientes para treinamento e uma rede de complexidade (número de neurônios e camadas) apropriada. Um neurônio não linear é a unidade básica de processamento de informação e em termos matemáticos, um neurônio pode ser descrito pelas seguintes equações, Courville (2016):

$$ur_k = \sum_{j=1}^m W_{kj} c_j \quad (11)$$

$$vr_k = ur_k + b_k \quad (12)$$

$$\hat{y}_{nk} = P(vr_k) \quad (13)$$

Onde:  $c_1, c_2, \dots, c_m$  são os sinais de entrada,  $W_{k1}, W_{k2}, \dots, W_{km}$  são os pesos sinápticos do neurônio,  $b_k$  é o *bias*,  $P(\cdot)$  é a função de ativação (não linear) e  $\hat{y}_{nk}$  é o sinal de saída no neurônio.

Neste trabalho, foi utilizada a arquitetura *Nonlinear Autoregressive with Exogenous Input* (NARX) para modelar o sistema de GL, uma vez constatada que essa arquitetura consegue fazer a predição um passo à frente de forma conveniente. NARX é uma rede dinâmica com camadas

internas *feedforward*, onde a recorrência é dada pelo feedback sobre sinais passados das saídas preditas e não a partir de estados internos.

As etapas da modelagem do orientada a dados aplicada neste trabalho são mostradas na Figura 2.  $y_p(k)$  são as saídas da planta (especificamente pressões) que são utilizados pelo MHE,  $\hat{y}_p(k)$  é o resultado do MHE, como por exemplo, os valores medidos filtrados e novos valores estimados (vazões de produção). Uma vez, com um conjunto de dados suficiente (coletado), então esses dados são preparados e utilizado para treinar a rede, por fim o modelo pode ser usado para fazer a predição, então  $\hat{y}_n(k)$  é a saída do modelo orientado a dado, ou melhor, pressões e vazões.

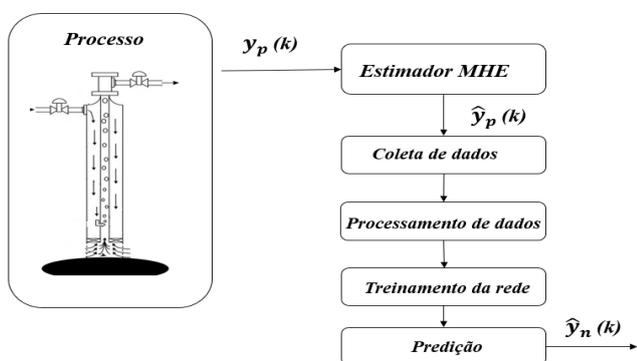


Figura 2: Visão geral do modelo orientado a dados.

#### 2.4 Problema de otimização econômica

O problema de otimização em tempo real (produção diária) é baseado em um modelo não linear da planta (modelo fenomenológico e orientado a dados) que são usados para encontrar os valores ótimos das variáveis de decisões, ou seja, vazão de gás injetada no topo do anular e abertura da válvula *choke* (variáveis de decisões). O problema de otimização é formulado da seguinte maneira:

$$\max_u J = \beta W_{to} - \alpha \sum_{j=1}^n W_{ing} \quad (14)$$

s. a.:

$$f(x, z, u) = 0 \quad (15)$$

$$g(x, z, u) = 0 \quad (16)$$

$$W_{ing} \leq c_p \quad (17)$$

$$P_{wh} \geq p_{rt} \quad (18)$$

$$x_{inf} \leq x \leq x_{sup} \quad (19)$$

$$z_{inf} \leq z \leq z_{sup} \quad (20)$$

$$u_{inf} \leq u \leq u_{sup} \quad (21)$$

As variáveis diferenciais são representadas como  $x$ , algébricas como  $z$ , e as entradas do sistema como  $u$ .  $\beta$  é preço

óleo,  $\alpha$  é custo de injeção de gás,  $W_{to}$  é a vazão óleo produzida no topo do poço e  $W_{ing}$  é a vazão de injeção de gás no topo do anular.  $c_p$  é a capacidade máxima de gás disponível para injeção,  $P_{wh}$  é a pressão na cabeça do poço e  $p_{rt}$  é a pressão requisitada (desejada) na cabeça do poço. Além disso, das Equações 14 a 21, estão a função objetivo econômica, as restrições de desigualdades e igualdades e os limites, respectivamente.

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

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

As variáveis medidas são as pressões no topo de poço, no topo de anular e a pressão fundo do poço, também conhecida como PDG. Todas as outras variáveis do processo são estimadas, inclusive os estados, porém no treinamento da rede só foram utilizadas as vazões de gás e óleo produzidas topo do poço.

As entradas (vazão de injeção de gás no topo do anular e abertura da válvula *choke* de produção) utilizadas para excitar o processo e gerar os dados de treinamento foram construídas pelo algoritmo pseudo-aleatórios denominado como PRBS. Foram coletadas 45 mil amostras, sendo 70% para o treinamento e 30% para teste e validação na própria etapa de treinamentos, contudo para os resultados de comparação de modelos (sessão de resultados) foram geradas novas entradas a partir de outro gerador aleatório disponível no *MATLAB* (diferente do PRBS). A arquitetura da rede é formada por uma camada oculta com quatro neurônio e cinco neurônio na camada de saída. o algoritmo de aprendizagem utilizado foi *quasi-Newton backpropagation* (BFGS), tendo como função objetivo o erro médio absoluto (*Mean absolute error* -MAE). O parâmetros da rede foram ajustados de acordo os teste simulados e conforme o trabalho de Soares et al. (2022)

### 3. RESULTADOS

Inicialmente, foi realizado uma simulação em *loop* aberto para avaliar o comportamento do modelo orientado a dados. As variáveis de pressão são consideradas como medidas, então são filtradas pelo MHE, enquanto, as vazões de óleo e gás são estimadas pelo MHE, no caso do modelo orientados a dados, todas são preditas. A Figura 3 e a Figura 4 mostram os resultados da simulação em *loop* aberto.

Como pode ser visto pelas Figura 3 e Figura 4, o modelo orientado a dados é capaz de acompanhar o comportamento da planta de maneira satisfatória. Entretanto, existem *offsets* nas previsões realizada pela rede, percebe-se que estes são ainda

maiores na previsão de vazão de gás, contudo, o modelo indica ser conveniente para aplicação de problema de otimização. Os resultados do estimador de estado são adequados para esta aplicação, tanto para filtrar as variáveis de medições, quanto para estimar as vazões de óleo e gás produzidas.

Na solução do problema de otimização da produção diária, foram adicionados distúrbios medidos, ou seja, variações no preço do óleo e no custo de cada metro cúbico de gás injetado no anular, além disso, a pressão requisitada no topo do poço sofre alterações ao longo dos dias. Estas variações são fundamentais para avaliar a solução ótima do otimizador em frente a grandes variações financeiras do mercado atual. A Tabela 1 apresenta estas variações, então,  $\beta$  é preço do óleo,  $\alpha$  é custo do gás injetado,  $p_{rt}$  é a pressão requisitada na superfície e  $c_p$  é capacidade máxima de gás disponível.

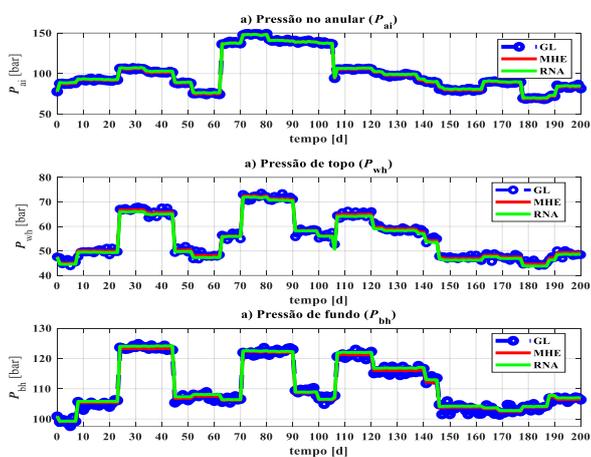


Figura 3: Parte 1 – Predição um passo à frente do modelo RNA em comparação com a planta GL e o estimador de estado (filtradas).

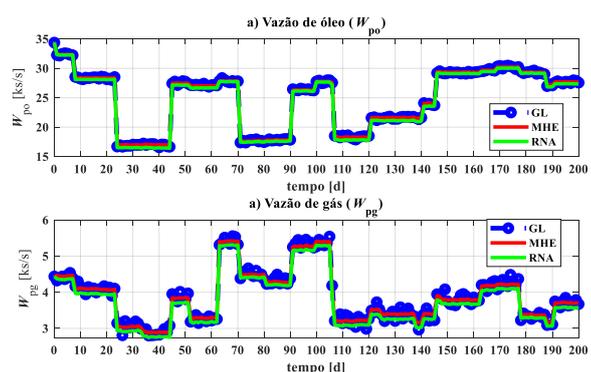


Figura 4: Parte 2 -Predição um passo à frente do modelo RNA em comparação com a planta GL e o estimador de estado.

Tabela 1: Variações de parâmetros econômicos e operacional.

Nº de dias	$\beta$ (\$)	$\alpha$ (%)	$p_{rt}$ (bar)	$c_p$ (kg/s)
0	100	200	40	3
1	100	200	40	3
2	150	200	40	3
3	150	150	40	3
4	120	150	40	3
5	120	150	55	3

A Tabela 2 apresenta as decisões ótimas para problema de otimização, onde  $W_{ing}$  é a vazão ótima de gás injetada por dia,  $Z_{open}$  é a abertura ótima da válvula da *choke* de produção, MF e RNA representam os modelos usados para solução do problema de otimização, fenomenológico e orientado a dados, respectivamente. A Figura 5 mostra o desempenho ótimo do processo a partir das soluções, sendo  $W_{po}$  e  $W_{tg}$  as vazões ótimas de óleo e gás produzidas e  $FOB$  é o  $\max J$ , ou seja, lucro ótimo obtido. Vale ressaltar que o problema de otimização só é resolvido a partir do primeiro dia, porém as perturbações são as mesmas para o dia zero e o primeiro dia.

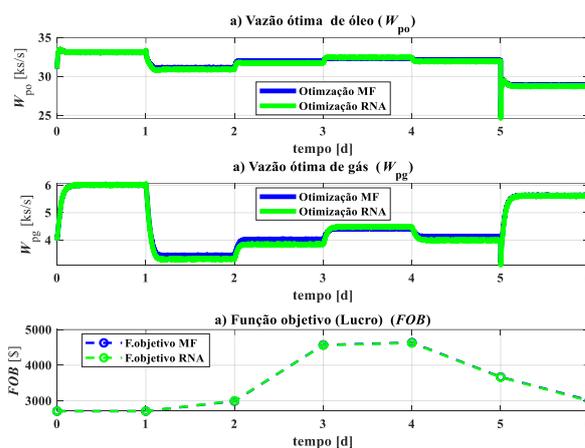


Figura 5: Resposta do processo com as mudanças nas soluções ótimas gerado pelo problema de otimização usando o modelo orientado a dados (RNA) e fenomenológico (MF).

Tabela 2: Soluções ótimas encontradas com o problema de otimização usando o modelo orientado a dados (RNA) e fenomenológico (MF).

Nº de dias	$W_{ing}$ - Injeção de gás (kg/s)		$Z_{open}$ - Abertura da <i>choke</i> (%)	
	MF	RNA	MF	RNA
0	3	3	99,0	99,0
1	0,631	0,503	100	100
2	1,117	0,963	100	100
3	1,487	1,533	100	100
4	0,967	0,723	100	100
5	3,00	3,00	74,6	74,1

Ao analisar o desempenho do processo na Figura 5 e a Tabela 2, observa-se que do dia zero até o dia primeiro o processo está operando com uma taxa de injeção de 3 kg/s de gás, ou seja, capacidade máxima. Porém, a partir do primeiro dia, quando o otimizador é chamado, há uma redução brusca na quantidade de gás injetado, assim como também, há uma redução nas vazões de óleo e gás produzida, por outro lado, obteve-se um leve acréscimo no lucro. Portanto, nem sempre é vantajoso operar na capacidade máxima de injeção, uma vez que esta ação pode aumentar o custo de injeção e não ter uma melhoria significativa no lucro.

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

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

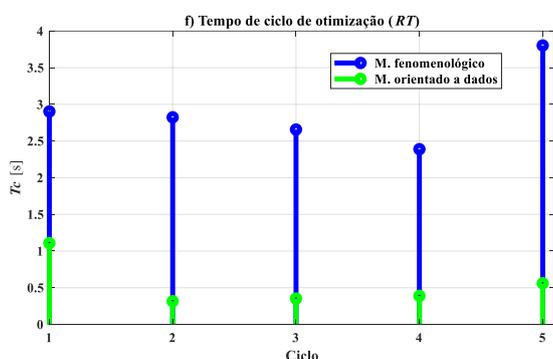


Figura 6: Comparação de tempo de rotina.

Um dos objetivos deste trabalho é avaliar o tempo computacional da rotina na otimização com ambos os modelos. Mesmo o modelo fenomenológico fazendo uso da estrutura de diferenciação automática implementado no *CasADI V.3.5.5.2* na linguagem *MatLab*, sua performance é inferior à do modelo orientado a dados, conforme demonstra os resultados na Figura 6, isso abre possibilidade para implementações em problemas de larga escala, tal qual a otimização da produção diária do campo de petróleo (vários poços integrados pelo reservatório e manifold).

#### 4. CONCLUSÕES

Neste trabalho foi apresentado uma formulação para otimização em tempo real diária, substituindo o modelo fenomenológico por uma rede neural com arquitetura *NARX*. A potencialidade da proposta está ilustrada por meio de simulações de cenários em que há instabilidade nos parâmetros econômicos e a falta de dados medidos. Contudo, os resultados simulados apontam uma melhoria no tempo computacional da solução do problema de otimização quando comparado com o modelo fenomenológico padrão. Além do mais, as simulações demonstraram que a rede *NARX* foi efetiva em suas predições com um passo à frente.

#### AGRADECIMENTOS

Agradecemos o apoio financeiro do PRH 35.1- ANP e da Capes.

#### REFERÊNCIAS

- AL-Qutami, T.A. *et al.* (2017) ‘development of soft sensor to estimate multiphase flow rates using neural networks and early stopping’, *International Journal on Smart Sensing and Intelligent Systems*, 10(1), pp. 1–24. Available at: <https://doi.org/10.21307/ijssis-2017-209>.
- Bikmukhametov, T. and Jäschke, J. (2020) ‘First Principles and Machine Learning Virtual Flow Metering: A Literature Review’, *Journal of Petroleum Science and Engineering*, 184, p. 106487. Available at: <https://doi.org/10.1016/j.petrol.2019.106487>.
- Carolina Spindola Rangel Dias, A. *et al.* (2019) ‘Extracting Valuable Information from Big Data for Machine Learning Control: An Application for a Gas Lift Process’, *Processes*, 7(5), p. 252. Available at: <https://doi.org/10.3390/pr7050252>.
- Codas, A., Jahanshahi, E. and Foss, B. (2016) ‘A two-layer structure for stabilization and optimization of an oil gathering network\*\*We acknowledge the support of the Center for Integrated Operations at NTNU (Norway).’, *IFAC-PapersOnLine*, 49(7), pp. 931–936. Available at: <https://doi.org/10.1016/j.ifacol.2016.07.317>.
- Courville, I.G. and Y.B. and A. (2016) ‘Deep learning by Ian Goodfellow, Yoshua Bengio, Aaron Courville’, *Nature*, 29(7553), pp. 1–73.
- Góes, M.R.R.T. *et al.* (2021) ‘Virtual flow metering of oil wells for a pre-salt field’, *Journal of Petroleum Science and Engineering*, 203, p. 108586. Available at: <https://doi.org/10.1016/j.petrol.2021.108586>.
- Jahanshahi, E., Skogestad, S. and Hansen, H. (2012) ‘Control structure design for stabilizing unstable gas-lift oil wells’, *IFAC Proceedings Volumes*, 45(15), pp. 93–100. Available at: <https://doi.org/10.3182/20120710-4-SG->

2026.00110.

Krishnamoorthy, D., Fjalestad, K. and Skogestad, S. (2019) ‘Optimal operation of oil and gas production using simple feedback control structures’, *Control Engineering Practice*, 91(June), p. 104107. Available at: <https://doi.org/10.1016/j.conengprac.2019.104107>.

Krishnamoorthy, D., Foss, B. and Skogestad, S. (2016) ‘Real-Time Optimization under Uncertainty Applied to a Gas Lifted Well Network’, *Processes*, 4(4), p. 52. Available at: <https://doi.org/10.3390/pr4040052>.

Loh, K., Omrani, P.S. and van der Linden, R. (2018) ‘Deep Learning and Data Assimilation for Real-Time Production Prediction in Natural Gas Wells’. Available at: <https://doi.org/arXiv:1802.05141>.

Matias, J. *et al.* (2022) ‘Steady-state real-time optimization using transient measurements on an experimental rig’, *Journal of Process Control*, 115, pp. 181–196. Available at: <https://doi.org/10.1016/j.jprocont.2022.04.015>.

Mehrez, M.W., Mann, G.K.I. and Gosine, R.G. (2014) ‘Nonlinear moving horizon state estimation for multi-robot relative localization’, in *2014 IEEE 27th Canadian Conference on Electrical and Computer Engineering (CCECE)*. IEEE, pp. 1–5. Available at: <https://doi.org/10.1109/CCECE.2014.6901134>.

Qiu, J. and Toral, H. (1993) ‘Three-Phase Flow-Rate Measurement by Pressure Transducers’, in *SPE Annual Technical Conference and Exhibition*. Society of Petroleum Engineers, pp. 543–549. Available at: <https://doi.org/10.2118/26567-MS>.

Rojas Soares, F.D., Secchi, A.R. and Bezerra de Souza, M. (2022) ‘Development of a Nonlinear Model Predictive Control for Stabilization of a Gas-Lift Oil Well’, *Industrial & Engineering Chemistry Research*, p. acs.iecr.1c04728. Available at: <https://doi.org/10.1021/acs.iecr.1c04728>.

## Apêndice A. PRIMEIRO APÊNDICE

A produção de um poço de petróleo assistido por gás pode ser descrita usando equações diferenciais, conforme Jahanshahi et al. (2012); Krishnamoorthy et al. (2019). A dinâmica é obtida por meio dos balanços de massa na coluna de produção e no anular e são descritos pelas seguintes equações diferenciais.

$$\dot{m}_{ga} = w_{ing} - w_{iv} \quad (\text{A.1a})$$

$$\dot{m}_{gt} = w_{iv} - w_{pg} + w_{rg} \quad (\text{A.1b})$$

$$\dot{m}_{ot} = w_{ro} - w_{po} \quad (\text{A.1c})$$

sendo,  $\dot{m}_{ga}$  é massa do gás no anular,  $\dot{m}_{gt}$  é massa do gás na coluna produção (*tubing*),  $\dot{m}_{ot}$  é massa do óleo no *tubing*,  $w_{gt}$  é vazão de gás injetada no anular,  $w_{iv}$  é o vazão de gás através da válvula operadora entre o anular e *tubing*,  $w_{rg}$  e  $w_{ro}$  são as vazões mássicas de gás e óleo do reservatório, respectivamente e,  $w_{pg}$  e  $w_{po}$  são as vazões mássicas de produção de gás e óleo na *choke*.

$$w_{iv} = C_{iv} \sqrt{\rho_a \max(0, P_a - P_{wi})} \quad (\text{A.2a})$$

$$w_{pc} = C_{pc} Z_p \sqrt{\rho_m \max(0, P_{\omega h} - P_m)} \quad (\text{A.2b})$$

$$w_{pg} = \frac{m_{gt}}{m_{gt} + m_{ot}} w_{pc} \quad (\text{A.2c})$$

$$w_{po} = \frac{m_{ot}}{m_{gt} + m_{ot}} w_{pc} \quad (\text{A.2d})$$

$$w_{ro} = PI(P_r - P_{bh}) \quad (\text{A.2e})$$

$$w_{rg} = GOR \cdot w_{ro} \quad (\text{A.2f})$$

Em que,  $C_{iv}$  e  $C_{pc}$  são os coeficientes de fluxo da operadora e da *choke* de produção no poço, respectivamente,  $\rho_a$  é a densidade do gás no anular,  $\rho_m$  é densidade média no poço,  $P_a$  é a pressão na montante da válvula operadora no anular,  $P_{wi}$  é a pressão na jusante da válvula operadora no *tubing*,  $P_{\omega h}$  é a pressão do topo do poço,  $P_m$  é a pressão do *manifold*,  $P_{bh}$  é a pressão no fundo do poço ou nos canhoneados,  $P_r$  é a pressão do reservatório,  $PI$  é o índice de produtividade do reservatório,  $GOR$  é a razão gás-óleo do reservatório e  $Z_p$  é a abertura da *choke* de produção no poço.  $P_r$ ,  $GOR$  e  $Z_p$  são constantes e as demais são dadas:

$$\rho_a = \frac{M_\omega P_a}{T_a R} \quad (\text{A.3a})$$

$$\rho_m = \frac{m_{gt} + m_{ot} - \rho_o L_{bh} A_{bh}}{L_\omega A_\omega} \quad (\text{A.3b})$$

$$P_a = \left( \frac{T_a R}{V_a M_\omega} + \frac{g H_a}{L_a A_a} \right) m_{ga} \quad (\text{A.3c})$$

$$P_{wh} = \frac{T_\omega R}{M_\omega} \left( \frac{m_{gt}}{L_\omega A_\omega + L_{bh} A_{bh} - \frac{m_{ot}}{\rho_o}} \right) \quad (\text{A.3d})$$

$$P_{\omega i} = P_{\omega h} + g \rho_m H_\omega + \Delta_{fric_\omega} \quad (\text{A.3e})$$

$$P_{bh} = P_{\omega i} + g \rho_m H_{bh} + \Delta_{fric_{bh}} \quad (\text{A.3f})$$

$$P_m = P_{rh} + g \rho_m H_{bh} + \Delta_{fric_r} \quad (\text{A.3g})$$

Em que:  $\varepsilon$  é a rugosidade do tubo,  $Re$  é o número de Reynolds,  $D_t$  é o diâmetro do tubo,  $U_m$  é a velocidade média do fluido,  $U_g$  é a velocidade do gás,  $U_o$  é a velocidade do óleo,  $L_t$  é o comprimento do tubo,  $V_t$  é o volume tubo,  $\alpha_l$  é a fração volumétrica no tubo,  $\rho_g$  é a densidade do gás e  $\mu$  é viscosidade do fluido.

$P_{rh}$  é a pressão no topo do *riser*, ( $M_\omega$ ) peso molecular do gás, ( $T_a$ ) temperatura do anular, ( $T_\omega$ ) temperatura do *tubing*, ( $R$ ) constante universal dos gases, ( $L_{bh}$ ), ( $A_{bh}$ ) e ( $H_{bh}$ ) são o comprimento, a área e a altura entre a válvula operadora e o fundo no poço, ( $L_\omega$ ), ( $A_\omega$ ) e ( $H_\omega$ ) são o comprimento, a área e a altura entre a válvula operadora e o topo do poço, ( $L_a$ ), ( $A_a$ ) e ( $H_a$ ) são o comprimento, a área e a altura do anular, ( $V_a$ ) volume do anular, ( $\rho_o$ ) densidade do reservatório, altura do anular, ( $g$ ) gravidade e por fim,  $\Delta_{fric}$  e a pressão por fricção.

$$\frac{1}{\sqrt{\lambda_t}} = -1.8 \log \left[ \left( \frac{\varepsilon/D_t}{3.7} \right)^{1.11} + \frac{6.9}{Re} \right] \quad (\text{A.4a})$$

$$\Delta_{fric} = \frac{\alpha_l \lambda_t \rho_m U_m^2 L_t}{2 D_t} \quad (\text{A.4b})$$

$$\alpha_l = \frac{m_{or} + \rho_o L_{bh} A_{bh}}{V_t} \quad (\text{A.4c})$$

$$U_o = \frac{4w_{po}}{\rho_m \pi D_t^2} \quad (\text{A.4d})$$

$$U_g = \frac{4w_{pg}}{\rho_g \pi D_t^2} \quad (\text{A.4e})$$

$$U_m = U_o + U_g \quad (\text{A.4f})$$

$$Re = \frac{\rho_m U_m D_t}{\mu} \quad (\text{A.4g})$$

$$\rho_g = \frac{m_{gt}}{V_t - \frac{m_{ot}}{\rho_o}} \quad (\text{A.4h})$$