



**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA
CENTRO TECNOLÓGICO
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO**

HUGO VERGILIO CURTO NETTO

**MEDIÇÃO DE VAZÃO VIRTUAL: AVALIAÇÃO DE DESEMPENHO DE
SIMULAÇÃO FENOMENOLÓGICA E DE REDE NEURAL EM ESTUDO DE
CASO NA PROVÍNCIA DO PRÉ-SAL**

Vitória, ES
2022



**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA
CENTRO TECNOLÓGICO
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO**

Hugo Vergilio Curto Netto

**MEDIÇÃO DE VAZÃO VIRTUAL: AVALIAÇÃO DE DESEMPENHO DE
SIMULAÇÃO FENOMENOLÓGICA E DE REDE NEURAL EM ESTUDO DE
CASO NA PROVÍNCIA DO PRÉ-SAL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do título de Mestre em Engenharia Mecânica.

Orientador: Prof. Dr. Rogério Ramos.

Vitória, ES
2022

Ficha catalográfica disponibilizada pelo Sistema Integrado de
Bibliotecas - SIBI/UFES e elaborada pelo autor

- C978a Curto Netto, Hugo Vergilio, 1986-
 Medição de vazão virtual: Avaliação de desempenho de simulação
fenomenológica e de rede neural em estudo de caso na província do pré-sal / Hugo
Vergilio Curto Netto. - 2022.
 147 f.: il.
- Orientador: Rogério Ramos.
Dissertação (Mestrado em Engenharia Mecânica) - Universidade Federal do Espírito
Santo, Centro Tecnológico.
1. Engenharia Mecânica. 2. Medição de Vazão Virtual. 3. Escoamento
Multifásico. 4. Medição Multifásica. I. Ramos, Rogério. II. Universidade Federal do
Espírito Santo. Centro Tecnológico. III. Título.

CDU: 621



PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA
CENTRO TECNOLÓGICO
UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO

Medição de Vazão Virtual: Avaliação de Desempenho de Simulação Fenomenológica e de Rede Neural em estudo de caso na província do pré-sal

Hugo Vergilio Curto Netto

COMISSÃO EXAMINADORA

Rogério Ramos

Prof. Dr. Rogério Ramos
Orientador (PPGEM/UFES)

Márcio F. Martins

Prof. Dr. Márcio Ferreira Martins
Examinador Interno (PPGEM/UFES)

Moisés Renato Nunes Ribeiro

Prof. Dr. Moisés Renato Nunes Ribeiro
Examinador Externo (PPGEE/UFES)

Maria Helena Farias

Profa. Dra. Maria Helena Farias
Examinadora Externa (INMETRO)

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal do Espírito Santo como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Mecânica

Vitória (ES), 18 março de 2022.





UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO

PROTOCOLO DE ASSINATURA



O documento acima foi assinado digitalmente com senha eletrônica através do Protocolo Web, conforme Portaria UFES nº 1.269 de 30/08/2018, por
ROGERIO RAMOS - SIAPE 1172939
Departamento de Engenharia Mecânica - DEM/CT
Em 18/03/2022 às 17:43

Para verificar as assinaturas e visualizar o documento original acesse o link:
<https://api.lepisma.ufes.br/arquivos-assinados/381668?tipoArquivo=O>





Docs defesa Hugo

Data e Hora de Criação: 18/03/2022 às 17:51:00

Documentos que originaram esse envelope:

- Ata 303 HUGO VERGILIO CURTO NETTO (RR).pdf (Arquivo PDF) - 2 página(s)
- Aprovação banca HUGO VERGILIO CURTO NETTO (RR).pdf (Arquivo PDF) - 2 página(s)



Hashs únicas referente à esse envelope de documentos

[SHA256]: c504b1316878be84f5c49205d25ed3e0fe0be91fc449183ad440aebac2028493

[SHA512]: 015a8b4221d0df446edacaab79180fc5377a764a054573980d560655bab54c19c7ecd3ff106c907cc0728dfbf1bd85fc0e8a76ffae8d00a8e211acdd03b0d278

Lista de assinaturas solicitadas e associadas à esse envelope



ASSINADO - Marcio Ferreira Martins (marcio.martins@ufes.br)

Data/Hora: 18/03/2022 - 18:10:21, IP: 179.162.69.237, Geolocalização: [-20,308851, -40,294137]

[SHA256]: 4d7c6bd94001690005ed492407ab7bd4857688c643ce506e153abf005d33d3d



ASSINADO - Maria Helena Farias (mhfarias@gmail.com)

Data/Hora: 18/03/2022 - 18:16:05, IP: 189.60.13.104

[SHA256]: e35be84b63faf1774e8d7ad8e2c773383d15060d5f3a315b0ae8d20609a9ffbc



ASSINADO - Moisés Renato Nunes Ribeiro (moises@ele.ufes.br)

Data/Hora: 18/03/2022 - 18:25:33, IP: 191.0.139.141

[SHA256]: cc332189136658fa80ac61cdf276066876f39d3cf3c6b2df096edca841fdb7d1



ASSINADO - Rogério Ramos (ramosrogerio@hotmail.com)

Data/Hora: 18/03/2022 - 21:19:58, IP: 187.36.167.32, Geolocalização: [-20,288947, -40,293875]

[SHA256]: 4462b2294867db46a98c2ca8113ecb57296d10019be678d580701690d2948d

Histórico de eventos registrados neste envelope

18/03/2022 21:19:59 - Envelope finalizado por ramosrogerio@hotmail.com, IP 187.36.167.32

18/03/2022 21:19:58 - Assinatura realizada por ramosrogerio@hotmail.com, IP 187.36.167.32

18/03/2022 21:18:00 - Envelope visualizado por ramosrogerio@hotmail.com, IP 187.36.167.32

18/03/2022 18:25:33 - Assinatura realizada por moises@ele.ufes.br, IP 191.0.139.141

18/03/2022 18:16:05 - Assinatura realizada por mhfarias@gmail.com, IP 189.60.13.104

18/03/2022 18:10:21 - Assinatura realizada por marcio.martins@ufes.br, IP 179.162.69.237

18/03/2022 18:09:39 - Envelope registrado na Blockchain por marcio.martins@ufes.br, IP 179.162.69.237

18/03/2022 18:09:37 - Envelope encaminhado para assinaturas por marcio.martins@ufes.br, IP 179.162.69.237

18/03/2022 17:51:03 - Envelope criado por marcio.martins@ufes.br, IP 179.162.69.237

À minha família pelo apoio incondicional.

À Alini Rodrigues Alberoni, pelo carinho e paciência durante essa jornada.

AGRADECIMENTOS

À Deus pela vida e oportunidade de avançar em um período desafiador para a humanidade.

À Petrobras pelo incentivo ao desenvolvimento técnico.

Ao Professor Rogério Ramos, pela orientação e motivação nesta trajetória.

“All models are wrong, but some are useful”

BOX, G. E. P (1978)

RESUMO

A produção de um poço de petróleo apresenta uma mistura multifásica de óleo, gás, água e sólidos. Para a correta medição de volumes, é necessário separar as fases em um separador de teste, viabilizando a medição monofásica. Uma alternativa seria o uso de medidores multifásicos em linha, porém nem sempre é tecnicamente possível e economicamente viável. Neste cenário, a medição de vazão virtual se apresenta como uma alternativa interessante para um sistema com muitos poços, pois aplica modelos numéricos para calcular as vazões das fases óleo, gás e água, a partir de simples dados de campo, como pressão e temperatura. A medição de vazão virtual por simulação fenomenológica (princípios físicos) adotando um simulador de escoamentos multifásico, bem como a aplicação de redes neurais artificiais (RNA) do tipo *perceptron* multi-camadas (*Multilayer Perceptron* ou *MLP*) com uso da biblioteca *Scikit-Learn* para *Machine Learning* em Python, apresentaram resultados promissores quando aplicados a um conjunto de dados de um poço produtor de óleo do pré-sal. Os resultados simulados foram comparados com a medição em separador de teste, num período de até 325 dias de operação, obtendo erros máximos de aproximadamente 10%, porém com redução significativa quando aplicada gestão de ajuste da modelagem. Este resultado é aderente às referências bibliográficas, valendo ressaltar que é um tema em vigoroso avanço técnico.

Palavras-chave: Medição de Vazão Virtual, Medição Multifásica, Escoamento Multifásico, Aprendizado de Máquina. Machine Learning.

ABSTRACT

Typically, a produced fluid from an oil well is a multiphase mixture of oil, gas, water and solids. For the correct measurement of volumes, it is required to split into single phases in a test separator. An alternative would be applying a Multiphase Flow Meter (MPFM), but it is not always technically possible and economically viable. Virtual Flow Metering (VFM) is another great alternative, especially in applications with many wells, where numerical models calculated the flow rates of the oil, gas and water phases, from simple field data, such as pressure and temperature. The first principles VFM using multiphase flow simulator and multilayer perceptron (MLP) artificial neural network (ANN) using the Scikit-Learn library for Machine Learning in Python, showed promising results when applied to a dataset from a Pre-salt oil well. The results were compared with test separator measuring, in 325 days of operation, with maximum errors of approximately 10%, but better results when applied model adjustment. This is consistent with the references, and highlighting it is a topic in vigorous technical progress.

Keywords: Virtual Flow Metering. Multiphase Flow Meter. Multiphase Flow. Data-Driven. Machine Learning.

LISTA DE FIGURAS

Figura 1 – Exemplo de um sistema de produção offshore. (SILVA, 2019).....	23
Figura 2 – Envelope de fases representativo	24
Figura 3 – Padrão de fluxo em escoamento multifásico horizontal. [7]	25
Figura 4 – Exemplo de sistema com separador de produção e de teste (CORNELIUSSEN et al., 2005).....	25
Figura 5 – Publicações por ano em consulta SCOPUS e Web Of Science pelos termos VFM (<i>Virtual Flow Metering</i>) associando ou não ao termo <i>Data-Driven</i> ou <i>Machine Learning</i>	27
Figura 6 – Comparação das características gerais de modelos mecanicistas, híbrido e por Data-Driven (HOTVEDT, 2022).....	34
Figura 7 – VFM: Modelos para estimar a vazão por poço, validada em um algoritmo de reconciliação (BIKMUKHAMETOV; JASCHKE, 2020).	36
Figura 8 – Tela do simulador de escoamento multifásico MarlimII®.	38
Figura 9 – IPR acima e abaixo da pressão de saturação (pressão de bolha)	40
Figura 10 – Volume de controle infinitesimal em uma tubulação com escoamento ascendente (ALMEIDA, 2013).....	44
Figura 11 – Evolução da modelagem multifásica (SHIPPEN; BAILEY, 2012).	48
Figura 12 – Esquema de um neurônio artificial (CIARELLI, 2019).	50
Figura 13 – Funções de ativação (CIARELLI, 2019).	51
Figura 14 – Exemplo de rede perceptron	52
Figura 15 – Exemplo de rede MLP (CIARELLI, 2019).....	53
Figura 16 – Esquema simplificado do poço.....	59
Figura 17 – Vazão em média de 5min (vermelho) e 30min (preto). A variação está relacionada a dinâmica de controle de nível do vaso separador.....	63
Figura 18 – Vazão em média de 5min (vermelho) e 30min (preto). A variação guarda relação com a dinâmica de controle de nível do vaso separador.....	63
Figura 19 – Critério de estabilidade (filtro de dados), com base na variação da vazão de líquido em média de 30min menor que 5%/30min	64
Figura 20 – Histórico de pressões em pontos do escoamento (P1, P2 e P3)	65
Figura 21 – Histórico de pressões em pontos do escoamento (P4 e P5).....	65
Figura 22 – Histórico de vazão de líquido e pontos selecionados para simulação....	66
Figura 23 – Histórico de pressões e pontos selecionados para simulação (P1, P2 e P3).....	66
Figura 24 – Histórico de pressões e pontos selecionados para simulação (P4 e P5)	67
Figura 25 – BSW histórico.....	69
Figura 26 – RGO de histórico.....	70

Figura 27 – Esquema simplificado do poço e parâmetros (Dados conforme Tabela 4)	73
Figura 28 – Esquema simplificado dos equipamentos submarinos (Dados conforme Tabela 4)	74
Figura 29 – Perfil de temperatura e corrente no trecho submarino	74
Figura 30 – Trechos dos casos estudados	76
Figura 31 – Ajuste black-oil da razão de solubilidade	80
Figura 32 – Ajuste black-oil do volume de formação do óleo	80
Figura 33 – Ajuste black-oil da viscosidade do óleo	81
Figura 34 – Fluxograma simplificado do processo de ajuste de modelo	81
Figura 35 – Histórico de temperatura à jusante do choke (T4)	91
Figura 36 – Análise preliminar das variáveis P4 e P5, indicando boa correlação com a vazão	93
Figura 37 – Análise preliminar das variáveis P4 e P5, indicando boa correlação com a vazão	94
Figura 38 – Análise preliminar da variável T4, indicando boa correlação com a vazão	94
Figura 39 – Esquema simplificado da RNA_P4_P5 configurada	96
Figura 40 – Comparação de perfil de propriedades ao longo do escoamento dos casos 1A e 1B. (a) Pressão; (b) Massa específica do líquido; (c) Temperatura e (d) $dP_{dL_{fricção}}$	97
Figura 41 – Comparação de perfil de propriedades ao longo do escoamento dos casos 2A1, 2A2, 2B1 e 2B2. (a) Pressão; (b) Massa específica do líquido; (c) Temperatura e (d) $dP_{dL_{fricção}}$	98
Figura 42 – Comparação de perfil de propriedades ao longo do escoamento dos casos 3A1, 3A2, 3B1 e 3B2. (a) Pressão; (b) Massa específica do líquido; (c) Temperatura e (d) $dP_{dL_{fricção}}$	100
Figura 43 – Comparação de perfil de propriedades ao longo do escoamento dos casos 4A1, 4A2, 4B1 e 4B2. (a) Pressão; (b) Massa específica do líquido; (c) Temperatura e (d) $dP_{dL_{fricção}}$	101
Figura 44 – Valor de vazão de líquido predita e esperada para os casos 1A e 1B	102
Figura 45 – Erro percentual ao longo do tempo para os casos 1A e 1B	103
Figura 46 – Valor de vazão de líquido predita e esperada para os casos 2A1, 2A2, 2B1 e 2B2	104
Figura 47 – Erro percentual ao longo do tempo para os casos 2A1, 2A2, 2B1 e 2B2	104
Figura 48 – Pressões no PDG (P1) e TPT (P2) e diferença de pressão (P1 – P2) com aumento progressivo, sugestivo para formação de incrustação na coluna de produção.	105
Figura 49 – Valor de vazão de líquido predita e esperada para os casos 3A1, 3A2, 3B1 e 3B2	106

Figura 50 – Erro percentual ao longo do tempo para os casos 3A1, 3A2, 3B1 e 3B2	106
Figura 51 – Pressões no TPT (P2) e na chegada na plataforma (P3) e diferença de pressão P2	107
Figura 52 – Pressões no TPT (P2) e na chegada na plataforma (P3) em uma condição transiente no dia 34.8.	108
Figura 53 – Temperatura medida no TPT (T2) e na chegada na plataforma (T3) ...	109
Figura 54 – Valor de vazão de líquido predita e esperada para os casos 4A1, 4A2, 4B1 e 4B2	110
Figura 55 – Erro percentual ao longo do tempo para os casos 4A1, 4A2, 4B1 e 4B2	110
Figura 56 – Comparação de valores medidos e preditos: (a) RNA_P4_P5; (b) RNA_P4_P5_T4_5N; (c) RNA_P4_P5_T4_10N e (d) RNA_P4_P5_T4_15N	113
Figura 57 – Resultado dos dados medidos e preditos: (a) RNA_P4_P5; (b) RNA_P4_P5_T4_5N; (c) RNA_P4_P5_T4_10N e (d) RNA_P4_P5_T4_15N	114
Figura 58 – Resultados da predição com uso de RNA_P4_P5 para (a) 0-30dias, (b) 30-60dias, (c) 60-90dias, (d) 90-120dias, (e)120-180dias e (f) 180-325dias.....	115
Figura 59 – Resultados da predição com uso de RNA_P4_P5_T4_5N para (a) 0-30dias, (b) 30-60dias, (c) 60-90dias, (d) 90-120dias, (e)120-180dias e (f) 180-325dias	116
Figura 60 – Resultados da predição com uso de RNA_P4_P5_T4_10N para (a) 0-30dias, (b) 30-60dias, (c) 60-90dias, (d) 90-120dias, (e)120-180dias e (f) 180-325dias	117
Figura 61 – Resultados da predição com uso de RNA_P4_P5_T4_15N para (a) 0-30dias, (b) 30-60dias, (c) 60-90dias, (d) 90-120dias, (e)120-180dias e (f) 180-325dias	118
Figura 62 – Diagrama do sistema de teste de Beggs & Brill (1973) para estimativa do gradiente de pressão em escoamento multifásico	139
Figura 63 – Esquema simplificado do experimento de Beggs & Brill (1973) para estimativa do gradiente de pressão em escoamento multifásico	140
Figura 64 – Padrão de fluxo em escoamento multifásico horizontal	141
Figura 65 – Mapa de padrões de fluxo em escoamento multifásico horizontal – Beggs & Brill (1973).....	141
Figura 66 – Fluxograma para determinação do padrão de fluxo se o escoamento fosse horizontal.....	142
Figura 67 – Correção do fator de atrito multifásico (f_{tp})	145
Figura 68 – Elemento discretizado para a avaliação do termo de aceleração	146

LISTA DE TABELAS

Tabela 1 – Dados dos pontos selecionados.....	68
Tabela 2 – Detalhe dos 2 primeiros pontos selecionados para ajuste de modelo.....	71
Tabela 3 – Sumário estatístico dos dados disponíveis.....	72
Tabela 4 – Principais parâmetros do poço	73
Tabela 5 – Correlações Multifásicas e Abreviaturas	76
Tabela 6 - Casos de simulação multifásica aplicados	77
Tabela 7 – Dados do ensaio de liberação diferencial da PVT à 123°C (Resultados em condição padrão, 1 atm e 15.6 °C).....	78
Tabela 8 – Viscosidades do óleo residual do ensaio de liberação diferencial.....	78
Tabela 9 – Ajuste modelo do CASO 1A (Vazão de líquido de referência: 1535 m ³ /d)	82
Tabela 10 – Ajuste de modelo do CASO 1B (Vazão de líquido de referência: 1341 m ³ /d).....	83
Tabela 11 – Ajuste de modelo do CASO 2A1 (Vazão de líquido de referência: 1535 m ³ /d).....	83
Tabela 12 – Ajuste de modelo do CASO 2A2 (Vazão de líquido de referência: 1535 m ³ /d).....	83
Tabela 13 – Ajuste de modelo do CASO 2B1 (Vazão de líquido de referência: 1341 m ³ /d).....	84
Tabela 14 – Ajuste de modelo do CASO 2B2 (Vazão de líquido de referência: 1341 m ³ /d).....	84
Tabela 15 – Ajuste de modelo do CASO 3A1 (Vazão de líquido de referência: 1535 m ³ /d).....	85
Tabela 16 – Ajuste de modelo do CASO 3A2 (Vazão de líquido de referência: 1535 m ³ /d).....	85
Tabela 17 – Ajuste de modelo do CASO 3B1 (Vazão de líquido de referência: 1341 m ³ /d).....	86
Tabela 18 – Ajuste de modelo do CASO 3B2 (Vazão de líquido de referência: 1341 m ³ /d).....	87
Tabela 19 – Ajuste de modelo do CASO 4A1 (Vazão de líquido de referência: 1535 m ³ /d).....	87
Tabela 20 – Ajuste de modelo do CASO 4A2 (Vazão de líquido de referência: 1535 m ³ /d).....	88
Tabela 21 – Ajuste de modelo do CASO 4B1	89
Tabela 22 – Ajuste de modelo do CASO 4B1	89
Tabela 23 – Quadro resumo de resultados	112
Tabela 24 – Quadro resumo de resultados	119

Tabela 25 – Principais vantagens e desvantagens da abordagem por VFM Multifásica	123
Tabela 26 – Principais vantagens e desvantagens da abordagem de VFM por Data Driven	124
Tabela 27 – Relação experimental entre pf e ψ_g	131
Tabela 28 – Coeficientes a, b e c para avaliação da fração de líquido na correlação de Beggs & Brill (1973)	143
Tabela 29 – Coeficientes d, e, f e g para correção de C na correlação de Beggs & Brill (1973).....	144

LISTA DE SIMBOLOS

Símbolo	Descrição
p_{res}	Pressão de reservatório
P_S	Pressão na superfície
T_{res}	Temperatura de reservatório
T_S	Temperatura na superfície
q ou Q	Vazão de fluido
A	Área da seção transversal na equação de Darcy
Δp	Diferencial de pressão
k	Permeabilidade do meio poroso
μ	Viscosidade do fluido
L	Comprimento
IP	Índice de produtividade
q_{max}	Vazão máxima obtida para pressão de fluxo igual a zero no fundo do poço
p_{wf}	Pressão de fluxo no fundo do poço
ρ	Massa específica
F_X	Força resultante na direção x
v	Velocidade de escoamento
$F_{x_{grav}}$	Componente gravitacional da força resultante na direção x
g	Aceleração da gravidade
θ	Ângulo do escoamento em relação à horizontal
$F_{x_{pressão}}$	Componente da força resultante na direção x, devido o diferencial de pressão
P ou p	Pressão no escoamento
$\frac{dA}{dx}$	Derivada da propriedade A (genérica), na direção x
$F_{x_{atrito}}$	Componente da força resultante na direção x, devido ao atrito
τ_w	Tensão tangencial
D	Diâmetro do escoamento
f	Fator de atrito do escoamento
Re_D	Número de Reynolds
ε	Rugosidade absoluta
f_{tp}	Fator de atrito bifásico para escoamento multifásico
x_i	Sinais de entrada de uma rede neural

w_{ki}	Peso das sinapses relativa à saída k, entrada i de em uma rede neural
V_k	Nível de atividade de um neurônio em uma rede neural
$\varphi(V_k)$	Função de ativação
b_k	Bias em um neurônio em rede neural
y_k	Saída k de uma rede neural
E	Erro quadrático entre a saída desejada d_i de uma i-ésima amostra e a saída y
d_i	Saída desejada de uma i-ésima amostra
c	Número de neurônios na camada de saída
d	Número de neurônios na camada de entrada
\dot{M}_t	Vazão mássica total da mistura na condição P&T
\dot{M}_w	Vazão mássica de água na condição P&T
\dot{M}_o	Vazão mássica de óleo na condição P&T
$Q_{liq}^{p,t}$	Vazão volumétrica de líquido bruta na condição P&T
$\rho_m^{p,t}$	Massa específica da mistura na condição P&T
$Q_{liq,corr}^{p,t}$	Vazão volumétrica de líquido corrigida na condição P&T
$Q_o^{p,t}$	Vazão volumétrica do óleo na condição P&T
$BSW_{p,t}$	Teor de água (<i>Basic Sediments and Water</i>) na condição P&T
FE	Fator de Encolhimento da condição P&T para a condição padrão ANP
BSW	Teor de água (<i>Basic Sediments and Water</i>) na condição padrão ANP) de 1atm e 20°C
Q_w^{sc}	Vazão volumétrica de água na condição padrão
Q_{liq}^{sc} ou Q_{liq}	Vazão volumétrica de líquido na condição padrão
Q_o^{sc}	Vazão volumétrica do óleo na condição padrão
$Q_o^{p,t}$	Vazão volumétrica do óleo na condição P&T
Q_w^{pt}	Vazão volumétrica de água na condição P&T
$Q_{liq,f}^{sc}$	Vazão de líquido em condição padrão avaliado ao final do intervalo
$Q_{liq,i}^{sc}$	Vazão de líquido em condição padrão avaliado no início do intervalo
ΔQ_{liq}^{sc}	Varição de vazão de líquido em condição padrão, no intervalo analisado
Δt	Varição do tempo no intervalo analisado
RGO_f ou RGO	Razão gas óleo de formação
Q_g^{sc}	Vazão de gás na condição padrão

T_{ANM}	Temperatura na ANM (Árvore de Natal Molhada) que se encontra no leito marinho
$Prof_{perfurada}$	Profundidade (comprimento vertical) iniciando no leito marinho até os canhoneados
P_b ou P_{sat}	Pressão de bolha ou de saturação
μ_o	Viscosidade do óleo
R_s	Razão de Solubilidade em uma condição P&T
$(V_{g,d})_{std}$	Volume de gás dissolvido na fase óleo, medido nas condições padrão
$(V_o)_{std}$	Volume de óleo, medido nas condições padrão.
B_o	Fator Volume de Formação do Óleo em uma condição P&T
$(V_o)_{p,t}$	Volume da fase óleo (óleo + gás dissolvido) nas condições P&T
$(V_o)_{std}$	Volume de óleo nas condições padrão
$Q_{liq,simulada}^{sc}$	Vazão volumétrica de líquido simulada, na condição padrão
X_{norm}	Dados de entrada normalizados da rede neural
\bar{x}	Média dos dados de entrada da rede neural
σ	Desvio padrão dos dados de entrada da rede neural
x	Dados de entrada originais da rede neural
y_i	i-ésimo valor predito (simulado)
x_i	i-ésimo valor real (medido)
e_i	i-ésimo erro
n	Número de valores comparados no conjunto de dados
p_f	Fator da pressão de bolha
γ_g	Densidade do gás
T	Temperatura
M_o	Massa molar do óleo
ψ_g	Fração molar de gás
γ_o	Densidade do óleo
C	Fator de ajuste para igualar R_s com a RGO na pressão de saturação da PVT
B_{ob}	Fator volume de formação do óleo na pressão de bolha
N_B	Número de correlação para cálculo do Bob
c_o	Compressibilidade do óleo acima do ponto de saturação
μ_{od}	Viscosidade do óleo morto
x, y, z	Coefficientes da correlação de Beggs e Robinson (1975) para a viscosidade de óleo morto
μ_{ob}	viscosidade do óleo vivo, na condição de saturação

a, b	Coeficientes da correlação de Beggs e Robinson (1975) para óleo vivo saturado
m	Coeficiente da correlação de Vazquez e Beggs (1980) para a viscosidade de óleo vivo subsaturado
Z	Fator de compressibilidade do gás
P_{pc}	pressão pseudocrítica
T_{pc}	Temperatura pseudocrítica
P_r	Pressão pseudoreduzida
T_r	Temperatura pseudoreduzida
A, B, C, D, E, F	Coeficientes da correlação de Bill e Beggs (1974) para o fator de compressibilidade
M_a	Massa molar aparente do gás
$(V_g)_{p,t}$	Volume de gás na condição P&T
$(V_g)_{std}$	Volume de gás na condição padrão
B_g	Fator volume de formação do gás
$Prop_{ajustado}$	Propriedade ajustada de uma correlação black-oil
A_1	Fator multiplicador para ajuste de uma propriedade black-oil em relação ao dado de PVT
A_2	Fator de deslocamento linear para ajuste de uma propriedade black-oil em relação ao dado de PVT
V_{sg}	Velocidade superficial do gás
$Q_g^{P,T}$	Vazão de gás na condição P&T
A_{tubo} ou A	Área da tubulação aberta ao escoamento
V_{sl}	Velocidade superficial do líquido
J	Velocidade no centro de volume
Fr	Número de Froude
λ_l	Holdup de líquido
α_l^h	Fração de líquido se o escoamento fosse horizontal
a, b, c	Coeficientes a, b e c para avaliação da fração de líquido na correlação de Beggs & Brill (1973)
ϕ	Fator de correção da inclinação do escoamento na correlação multifásica de Beggs e Brill (1975)
N_{lv}	Número de velocidade do líquido na correlação multifásica de Beggs e Brill (1973)
σ_l	Tensão superficial do líquido
σ_o	Tensão superficial do óleo
σ_w	Tensão superficial da água

f_w	Fração de água na condição P&T
NS	Sobrescrito para a condição sem escorregamento (no slip condition) na correlação multifásica de Beggs e Brill (1973)
o	Subscrito para fase óleo
w	Subscrito para a fase água
l	Subscrito para a fase líquido
S	Fator de correção do fator de atrito na correlação multifásica de Beggs e Brill (1973)
ρ_m	Massa específica da mistura
P_1	Pressão no PDG
T_1	Temperatura no PDG
P_2	Pressão no TPT
T_2	Temperatura no TPT
P_3	Pressão à montante do choke de produção
T_3	Temperatura à montante do choke de produção
P_4	Pressão à jusante do choke de produção
T_4	Temperatura à jusante do choke de produção
$P_{s.g}$ ou P_5	Pressão na entrada do separado de teste

LISTA DE SIGLAS

Sigla	Descrição
ANM	Árvore de Natal Molhada
ANP	Agência Nacional do Petróleo, Gás Natural e Biocombustíveis
AOF	Absolute Open Flow
API	American Petroleum Institute
ASTM	American Society for Testing and Materials
BHP	Bottom Hole Pressure
BHT	Bottom Hole Temperature
BSW	Basic Sediment and Water
CV	Coefficiente de vazão de uma válvula choke
EOS	Equations of State
EWT	Extended Well Test
GVF	Gas Volume Fraction
INMETRO	Instituto Nacional de Metrologia, Qualidade e Tecnologia
IPR	Inflow Performance Relationship
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MLP	Multilayer Perceptron
MPFM	Multiphase flow meters
MPMS	Manual of Petroleum Measurement Standards
PDG	Permanent Downhole Gauge
PU	Fieldware Production Universe
PVT	Relação termodinâmica entre as propriedades de um fluido: pressão, volume específico, temperatura e composição química
RNA	Redes Neurais Artificiais
RTM	Regulamento Técnico de Medição de Petróleo e Gás Natural aprovado pela resolução conjunta ANP/Inmetro nº 1 de 10/06/2013.
STP	Standard Temperature and Pressure
TEC	Thermal Exchange Coefficient
TPT	Transmitter of Pressure and Temperature
VFM	Virtual Flow Metering
WLR	Water Liquid Ratio

SUMÁRIO

1.	INTRODUÇÃO	23
1.1.	DESCRIÇÃO DO PROBLEMA E MOTIVAÇÃO DESTE ESTUDO	26
1.2.	OBJETIVO	28
2.	REVISÃO BIBLIOGRÁFICA	28
2.1.	HISTÓRIA DA MEDIÇÃO DE VAZÃO VIRTUAL (VFM).....	28
2.2.	VISÃO GERAL SOBRE VFM.....	33
2.3.	MODELAGEM MULTIFÁSICA DE UM POÇO DE PETRÓLEO	34
2.4.	REDE NEURAL MLP (<i>Multilayer Perceptron</i>)	49
3.	METODOLOGIA.....	55
3.1.	VISÃO GERAL	55
3.2.	ESPECIFICAÇÕES DOS MEDIDORES E SENSORES	56
3.3.	DADOS DE PRODUÇÃO E PROPRIEDADES DISPONÍVEIS	58
3.4.	MODELAGEM GEOMÉTRICA E TÉRMICA DO POÇO.....	72
3.5.	DEFINIÇÃO DOS CASOS SIMULADOS	75
3.6.	CARACTERIZAÇÃO DOS FLUIDOS	77
3.7.	AJUSTE DOS MODELOS DE ESCOAMENTO MULTIFÁSICO	81
3.8.	DEFINIÇÃO DOS CASOS A SEREM SIMULADOS POR MACHINE LEARNING.....	90
3.9.	AJUSTE DO MODELO MACHINE LEARNING	92
4.	RESULTADOS	97
4.1.	AVALIAÇÃO PRELIMINAR DOS PERFIS DE PROPRIEDADES DO ESCOAMENTO.....	97
4.2.	RESULTADOS EM ABORDAGEM DE SIMULAÇÃO MULTIFÁSICA.....	102
4.3.	RESULTADOS EM ABORDAGEM POR REDES NEURAIS (MLP).....	112
5.	CONCLUSÕES	121
6.	REFERÊNCIAS	126
7.	APÊNDICE A: Correlações Black-Oil	130
8.	APÊNDICE B: Ajuste das correlações Black-Oil com dados PVT	138
9.	APÊNDICE C: Correlação Empírica Beggs e Brill (1973).....	139

1. INTRODUÇÃO

Um sistema de produção de petróleo *offshore* (Figura 1) consiste em poços conectados a uma plataforma através de dutos e equipamentos submarinos, por onde escoam os fluidos produzidos. Estes fluidos são separados na planta de processamento, resultando nas fases óleo, gás e água. A fase óleo é o objetivo principal do processo, sendo o produto produzido e especificado para a venda. A fase gás pode ser especificada para exportação ou re-injeção no reservatório (recuperação secundária) e a fase água é bombeada para poços injetores (recuperação secundária) ou, após especificação conforme normas ambientais, descartada para o mar.




Figura 1 – Exemplo de um sistema de produção offshore. (SILVA, 2019)

O escoamento multifásico se faz presente na indústria do petróleo, particularmente no seguimento de *upstream*, onde há deslocamento dos fluidos produzidos desde a rocha reservatório até a planta de tratamento em uma plataforma.

Conforme a Figura 2, a energia para deslocamento dos fluidos se encontra na pressão disponível na rocha reservatório. Os fluidos se deslocam para a região de menor pressão, atingindo ao longo do escoamento a pressão de saturação (pressão de bolha) no envelope de fases, onde ocorre o aparecimento da fase gasosa. A partir deste ponto, tem-se simplificada 2 fases de interesse (líquido e gás), caracterizando um escoamento bifásico.




Figura 2 – Envelope de fases representativo

Na Figura 2, o ponto R (P_{res} e T_{res}) representa a condição de pressão e temperatura no reservatório (monofásico - fase líquida). À medida que o fluido se desloca para a região de menor pressão, ocorre o surgimento da fase gasosa ao tocar a curva do envelope de fases. O ponto S (P_s e T_s) representa a condição de pressão e temperatura de superfície (ou planta de processamento).

A fase líquida usualmente é uma mistura de petróleo e água, sendo mais justo adotarmos o termo “escoamento multifásico”.

A Figura 3 apresenta, sinteticamente, uma variação possível nos padrões de fluxo ao longo de um escoamento multifásico.




Figura 3 – Padrão de fluxo em escoamento multifásico horizontal. [7]

A medição dos fluidos produzidos em um poço de petróleo é normalmente realizada de forma monofásica após um processo de separação em uma planta de teste (Figura 4). Existem alternativas modernas para medição multifásica, porém apresentam range operacional e incerteza que restringem a aplicação ou requerem cuidados adicionais (CORNELIUSSEN et al., 2005).

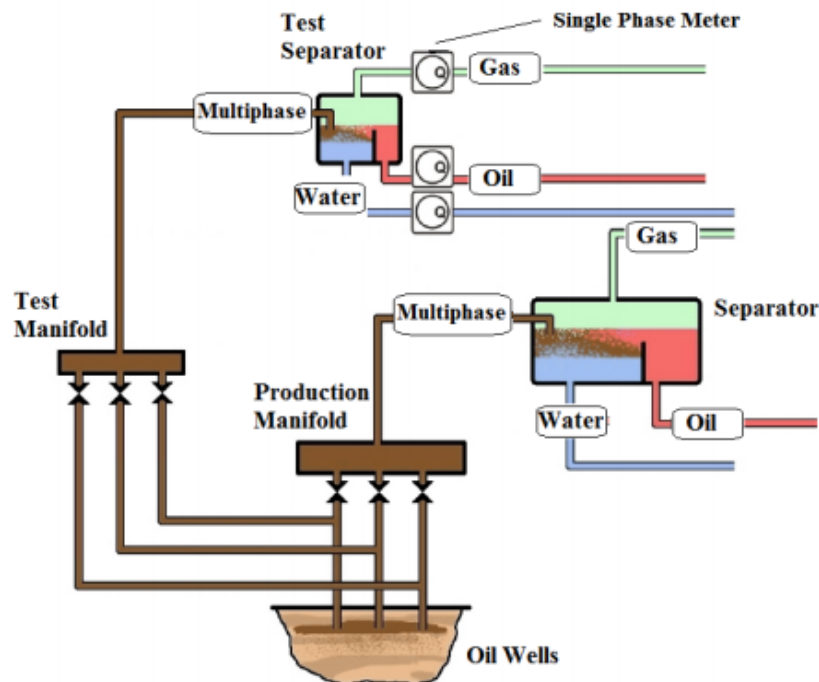


Figura 4 – Exemplo de sistema com separador de produção e de teste (CORNELIUSSEN et al., 2005).

O controle da produção em uma plataforma é feito a partir da medição total das fases separadas óleo, gás e água, não sendo usualmente disponível recurso para a medição contínua individualizada por poço.

Para operação econômica de um sistema de produção, é importante conhecer as vazões de óleo, gás e água de cada poço. Isso permite ao operador tomar decisões críticas sobre otimização, alocação de volumes produzidos, gestão do reservatório e prever o desempenho futuro do campo (VARYAN; HAUG; FONNES, 2015).

A medição individual por poço usualmente é realizada apenas sob demanda técnica ou periodicamente por exigência legal, como por exemplo, no caso do Brasil, o preconizado na Resolução Conjunta ANP/INMETRO Nº 1 de 10/06/2013 [10], que regra sobre teste de poços e seus requisitos técnicos e legais para apropriação da produção em um campo de petróleo.

Tipicamente, na arquitetura vigente em plataformas de produção, um vaso separador de teste realiza a separação das fases com posterior medição monofásica contínua. Essa abordagem de medição contínua, individualizada por poço, é impraticável em uma unidade offshore com vários poços, devido principalmente à limitação de espaço, peso e custo. Outra opção é aplicar sistemas de medição multifásica na linha de fluxo de um poço, porém essa técnica nem sempre é confiável ou economicamente viável (CORNELIUSSEN et al., 2005).

Uma alternativa aos métodos descritos anteriormente é a técnica da medição de vazão virtual ou *virtual flow metering (VFM)*, que consiste em monitorar e processar dados operacionais disponíveis de campo, por exemplo pressão e temperatura e correlacioná-los em modelos numéricos para estimar as vazões de óleo, gás e água (BIKMUKHAMETOV; JASCHKE, 2020).

1.1. DESCRIÇÃO DO PROBLEMA E MOTIVAÇÃO DESTE ESTUDO

A produção total diária de petróleo cru e gás natural no Brasil é de aproximadamente 2,8 milhões de barris e 137 milhões de Nm³ respectivamente. Cerca de 97.1% desta produção proveniente de campos marítimos, em cerca de 475 poços (Dados de Boletim da Produção de Petróleo e Gás Natural – ANP (novembro de 2021 / número 135) [11]).

A produção de petróleo é uma atividade de alto custo, justificando a necessidade de monitoramento contínuo das vazões dos poços, com o propósito de otimização da produção, alocação da produção, gestão do reservatório, gestão de recursos e previsão de produção e receita futura.

Uma ferramenta baseada em medição de vazão virtual pode atender adequadamente este monitoramento de vazões, sem implicar em execução de obras ou custo elevado para instalações de produção.

O avanço de softwares e hardwares tem viabilizado abordagens numérico-computacionais cada vez mais sofisticadas. Na Figura 5, um gráfico mostrando o crescimento de publicações anuais associados aos termos *VFM* (*Virtual Flow Metering*) associado ou não aos termos *Data-Driven* ou *Machine Learning*. As publicações estavam em uma projeção de crescimento até 2020, com queda a partir de 2021, provavelmente pelo impacto negativo da pandemia de COVID-19, na comunidade científica.




Figura 5 – Publicações por ano em consulta SCOPUS e Web Of Science pelos termos *VFM* (*Virtual Flow Metering*) associando ou não ao termo *Data-Driven* ou *Machine Learning*

1.2. OBJETIVO

Este trabalho tem por objetivo estudar a medição de vazão virtual por meio das abordagens fenomenológica e de redes neurais para um conjunto de dados reais de produção de um poço de petróleo offshore.

As vazões simuladas e medidas serão comparadas, para fins de avaliação da performance das abordagens e verificação dos erros médios dos métodos. Finalmente os resultados serão confrontados com a bibliografia de referência.

2. REVISÃO BIBLIOGRÁFICA

2.1. HISTÓRIA DA MEDIÇÃO DE VAZÃO VIRTUAL (VFM)

É fundamental determinar a produção de poços de petróleo, com foco em otimização da produção e gerenciamento de reservatório (VARYAN; HAUG; FONNES, 2015).

A aplicação de medidores de vazão multifásicos (*MPFMs - Multiphase flow meters*), podem atender tal demanda. No entanto, a aplicação de *MPFMs* em vários poços pode ser técnica e economicamente inviável, devido aos altos custos de instalação e manutenção, bem como a restrição de espaço em plataformas offshore (JADID, 2017).

Alternativamente, pode-se adotar a medição de vazão virtual (*Virtual Flow Meter – VFM*), para proporcionar uma estimativa de vazão de óleo, gás e água para todos os poços. Esta técnica baseia-se em modelos de escoamento multifásico dos poços até a instalação de superfície, considerando princípios de mecânica dos fluidos e termodinâmica, principalmente (BIKMUKHAMETOV; JASCHKE, 2020).

Melbø et al. (2003), apresentaram o Sistema de Monitoramento de Poços (*WMS – Well Monitoring System*), que é um sistema para estimativa de vazões de poços em malhas de produção de petróleo. O conceito é adequado inclusive para instalações de produção com pouca instrumentação. A técnica possui recursos que reduzem a

necessidade de testes de poço, permitindo monitoramento e verificação em locais remotos. Foram apresentados resultados promissores qualitativos, mesmo onde os sensores de fundo de poço (*PDG – Permanent Downhole Gauge*) falharam.

McCracken et al. (2006), apresentaram dois estudos de caso. Em ambos, um método de estimativa de vazão baseado em pressão é avaliado. Neste método, modelos de reservatório simples são propostos, para previsão das vazões com base no transiente de pressão de fundo de poço medida (*BHP – Bottom Hole Pressure*). Em um estudo, a produção de reservatórios empilhados (sobrepostos) é reunida em um único poço (multi-zona) de completação inteligente e, no outro caso, avalia-se os poços que estão produzindo de vários reservatórios e agrupados em um único sistema submarino. Os resultados das vazões foram consistentes com as pressões de fundo de poço, capturando os efeitos do diferencial de pressão aplicado.

Haldipur e Metcalf (2008), usaram dados de campo para avaliar o desempenho da técnica de medição de vazão virtual (*VFM*). No trabalho, é mostrado que a tecnologia *VFM* prevê estimativas precisas e confiáveis da vazão de poços, com fator de reconciliação mensal de até 3%, em uma variedade de características de reservatório, variando de sistemas produtores de petróleo à condensado de gás, incluindo uma ampla gama de razões gás-líquido e gás-óleo. Esses autores descreveram um sistema de medição virtual que usa pressão e temperatura de fundo de poço (*PDG*), além das temperaturas e pressões à montante e jusante do choke, e a posição de abertura do *choke*.

Adicionalmente, o sistema *VFM* pode ser usado para detecção de acúmulo de incrustações e detecção de vazamentos, quando devidamente ajustado.

Heddle et al. (2012), descreveram uma metodologia para prever a produção dos poços individualmente, a partir de sensores de pressão e temperatura instalados em poços novos. A metodologia foi implementada em vários poços localizados no Mar do Norte, Golfo do México, Angola, entre outros. Diferentes modelos físicos usando *IPR* e modelos de válvulas *choke* foram usados para prever a produção dos poços.

A metodologia é capaz de reconciliar automaticamente a produção em todos os campos, monitorar problemas de erosão por produção de areia e estimar a pressão

do reservatório nos fechamentos dos poços. A tecnologia indicou que é possível criar um modelo *VFM* capaz de estimar a vazão de cada poço em um campo algumas vezes por hora, em uma ampla gama de tipos de poços, condições de fluidos e condições operacionais, apresentando um erro inferior a 10% entre as vazões medidas e estimadas.

Cramer et al. (2012), descreveram uma ferramenta *VFM* em tempo real, à época, aplicada em cerca de 60% da produção global da Shell, em uma série de projetos *offshore* no Golfo Pérsico e no Golfo do México. O *FieldWare Production Universe (PU)* usa orientação de dados de forma eficaz tanto para operações em condição permanente quanto para transiente nos poços. Os resultados mostraram um fator de reconciliação inferior a 15% para vazão de líquido.

A ferramenta sugerida para aplicação como back-up (reserva) para MPFM's ou para período inicial de operação, anterior ao comissionamento dos sistemas MPFM, e neste caso usa-se modelos multifásicos de escoamento para gerar os dados de treinamento.

Patel et al. (2014), apresentaram um novo método *VFM* para campos pequenos, chamado *Model Based Multiphase Metering (MBMM)*. Como estudo de caso, um pequeno campo de gás e condensado é usado. O método aplica um modelo de escoamento com medições em tempo real que pode competir com tecnologias alternativas como *Multiphase Flow Meters (MPFMs)*, apresentando cerca de 5 a 10% de erro. O modelo é construído pela combinação dos simuladores de modelagem *K-Spice®* e *Leda Flow®*, incluindo os poços, linhas de produção, entrada das instalações e separador de primeiro estágio, além de todas as válvulas nesse circuito.

Amim (2015) avaliou cinco sistemas comerciais para *VFM*, *Prosper®*, *ValiPerformance®*, *LedaFlow®*, *FlowManager®* e *Olga®*. Foram usados dados de pressão e temperatura no fundo do poço, montante e jusante do *choke* submarino, bem como a posição do *choke* para estimar as vazões de óleo e gás. Os dados de vazão de referência foram obtidos de um medidor multifásico (*MPFM*) submarino e utilizados para comparação com os dados simulados e obtenção dos erros.

Os dados geométricos do poço, a PVT do fluido e a curva de performance do choke estavam disponíveis para as 5 empresas participantes do estudo, a fim de criar a modelagem de escoamento.

A 1ª rodada de análise começou avaliando dados estáveis (permanente), sem a aplicação de ajuste de modelo (*tuning*) resultando em erros grandes nas vazões. A 2ª rodada de análise incorporou o ajuste de modelo com dados específicos de vazão mássica, *GVF* (*gas volume fraction*) e *WLR* (*water liquid ratio*). E a 3ª rodada de análise avaliou dados de até 5 meses posteriores, no modelo ajustado da 2ª rodada, e posteriormente incorporando novos pontos de ajuste. Alguns dados fornecidos possuíam erros, e foram avaliados com e sem a exclusão dessa informação nos modelos.

O estudo indicou que há incremento da precisão ao realizar ajuste dos modelos com dados reais, resultando em erros máximos de 5% e 10% para a vazões de óleo e gás, respectivamente. O estudo também concluiu que pequenas variações na massa específica das fases individuais não afetam consideravelmente o resultado da vazão total.

Jadid (2017) apresentou uma metodologia baseada em dados de pressão, temperatura ao longo do poço, bem como a abertura do *choke* para estimar a vazão em poços de petróleo. Os dados de campo disponíveis são de 2 poços de petróleo de um campo de águas profundas, ao longo de 2 anos de produção. Foram selecionados 15 pontos com dados estabilizados de vazão para comparação. Os modelos de escoamento multifásico foram construídos no simulador Pipesim 2013.

O estudo apresentou 6 casos, variando os inputs da modelagem, adicionando dados para melhorar a precisão do modelo, como por exemplo o ajuste de histórico (*tuning*), ao início e também ao final do período de análise (reajuste). Os resultados mostraram um erro médio nas vazões de óleo e gás de 10%.

Goes et al. (2021), aplicaram uma abordagem baseada na queda de pressão através do *choke* de produção e da temperatura à montante do *choke*. Esses dados em conjunto com os dados de fluidos (PVT) e ajustes do modelo com dados de testes disponíveis permitiram o cálculo do coeficiente de descarga (*Cv*) do *choke*, bem como

das propriedades do fluido para cada variação de pressão e temperatura, possibilitando estimar as vazões de óleo e gás individual de 7 poços de petróleo em uma plataforma de produção *offshore* da camada do pré-sal. A soma das vazões diárias individuais dos poços foi confrontada com a vazão total da plataforma obtida por medição fiscal. Os resultados indicaram erros máximos de 3.5% e 3% para vazões de óleo e gás, respectivamente.

Uma abordagem mais moderna trata exclusivamente do uso de dados de campo, ajustados em modelagem matemática, sem a descrição exata da modelagem física do sistema de produção, comumente denominada *Machine Learning*.

Omrani (2018) avaliou a aplicação de redes neurais para estimar a vazão em poços produtores de gás no Mar do Norte. Foram usados dados obtidos por simuladores multifásicos, gerando o *dataset* sintético, aplicado para a rede neural, com 80% dos dados usados para treinamento.

O autor aplicou dois diferentes modelos de redes neurais. O primeiro modelo é baseado em redes neurais artificiais (RNA) do tipo *feedforward (MLP)*, usando a biblioteca de redes neurais do MATLAB. O segundo modelo é o *recurrent neural network (RNN)* do tipo *long-short term memories (LSTM)*, usado para capturar a dependência temporal de algumas variáveis, usando a biblioteca *Keras do Python*.

Nos casos em regime permanente (*steady-state*), a vazão de gás apresentou erro relativo médio tão baixo quanto 1%. Para avaliar o efeito das incertezas no *dataset* simulado, os dados foram perturbados com um desvio padrão de 1% a 20% nos valores médios dos parâmetros. O erro randômico de 10 e 20% nestes parâmetros, conduziram a erros de 8% e 14% na predição de vazão.

O autor concluiu que o método foi capaz de estimar a vazão total de um campo (4 poços testados), bem como a vazão individual dos poços com um erro relativo inferior a 25%.

Andrianov (2018) avaliou a performance qualitativa de redes neurais do tipo LSTM (*Long-Short Term Memory*) em predizer as vazões usando um *dataset* (conjunto de dados) "sintético" (simulação computacional) de um sistema bifásico em condição de golfadas severas e aplicando um *dataset* real de teste de poço. Os resultados

indicaram que o método pode ser considerado como uma ferramenta promissora para previsão das vazões de um poço.

2.2. VISÃO GERAL SOBRE *VFM*

Para a operação econômica dos sistemas de produção, é importante conhecer as vazões de óleo, gás e água de cada poço. Isto permite a otimização da produção, alocação de vazões, gerenciamento de reservatórios e previsão do desempenho futuro do campo (BIKMUKHAMETOV; JASCHKE, 2020).

Anteriormente, o principal método para estimar as vazões de poços era o teste do poço, que consiste em direcionar a produção para um vaso separador de teste dedicado, que promove a separação das fases óleo, gás e água. Essas vazões são então medidas por medidores monofásicos nas saídas do vaso separador (CORNELIUSSEN et al., 2005).

Uma solução alternativa é a medição de vazão virtual (*VFM*). A ideia por trás do *VFM* é monitorar os dados de campo disponíveis e correlacionar em um modelo numérico a fim de estimar as vazões (RASMUSSEN, 2004; TOSKEY, 2011). Os dados de medição geralmente incluem:

- Pressão e temperatura do fundo do poço (*BHP – Bottom Hole Pressure e BHT – Bottom Hole Temperature*).
- Pressão e temperatura a montante do *choke submarino ou em superfície*
- Pressão e temperatura a jusante do *choke submarino ou em superfície*
- Pressão e temperatura na ANM (Árvore de Natal Molhada)
- Posição de abertura do *choke*

Nos últimos anos, o desenvolvimento do conceito de *VFM* resultou em vários métodos para estimar as vazões multifásicas usando dados de campo, e várias empresas desenvolveram sistemas de *VFM* comerciais que são usados por operadores de petróleo e gás em todo o mundo (BIKMUKHAMETOV; JASCHKE, 2020; AMIM, 2015).

Existem duas abordagens principais para *VFM*, a saber:

- VFM por princípios físicos ou fenomenológico;
- VFM por *Data-Driven* (Orientação por dados);

A primeira abordagem resulta da aplicação de modelagem física dos fenômenos de escoamento multifásico esperados no sistema.

A segunda abordagem trata exclusivamente do uso de dados de campo, ajustados em modelagem matemática, sem a descrição exata dos parâmetros físicos do sistema de produção, comumente denominada *Data-Drive* (orientação por dados) ou abordagem por *Machine Learning* (*aprendizado de máquina*).

Hotvedt et al. (2022) apresenta um modelo híbrido (*gray-box modeling*), unindo as duas abordagens anteriores. Os autores utilizaram dados históricos de 4 anos de produção de 10 poços de petróleo e obtiveram resultados promissores em relação a vazão de óleo, com erros variando de 1,8 a 40,6%. A Figura 6 mostra um diagrama com vantagens e desvantagens em relação aos modelos puramente por *Data-driven* ou mecanicistas.

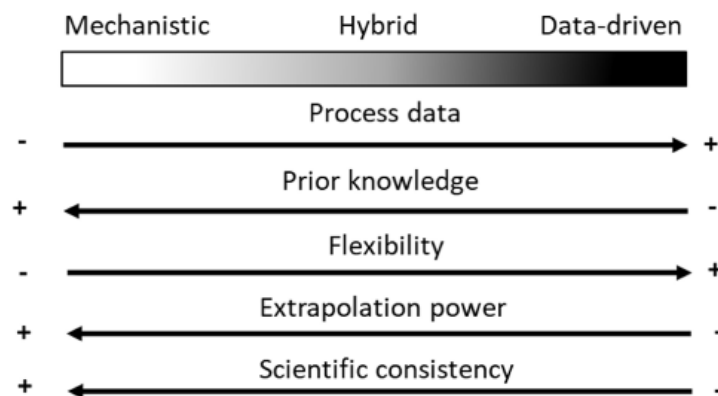


Figura 6 – Comparação das características gerais de modelos mecanicistas, híbrido e por Data-Driven (HOTVEDT, 2022).

2.3. MODELAGEM MULTIFÁSICA DE UM POÇO DE PETRÓLEO

Visão geral – Reservatório até a Planta de produção

Conforme Bikmukhametov e Jaschke (2020), *VFM* por princípios físicos é a forma mais amplamente usada para estimativa de vazões na indústria de produção de petróleo. Isso ocorre porque um grande esforço foi feito nos últimos anos, a fim de descrever cada componente desta aproximação. Isso resultou em um entendimento satisfatório da modelagem de sistemas multifásicos, propriedades de fluidos e otimização computacionais. Como tal, a modelagem baseada em princípios físicos pode ser considerada como um maneira confiável de descrever o comportamento do sistema de produção em geral e os fenômenos em escoamentos multifásicos.

Em resumo, o conceito por trás da modelagem *VFM* por princípios físicos contempla:

- Modelo da propriedade dos fluidos
- Modelo do sistema de produção, incluindo:
 - Modelo de Reservatório (*IPR*)
 - Modelo termo-hidráulico de escoamento
 - Modelo do *choke* (ou demais válvulas de restrição)
- Validação de dados

As propriedades dos fluidos normalmente são obtidas de ensaio de pressão-volume-temperatura (PVT), usadas para criar o modelo do fluido que represente as propriedades sob determinadas condições. Os modelos podem usar a abordagem composicional com Equações de Estado (*Equations of State - EoS*) ou formulação *Black Oil*, esta última com uma breve descrição no apêndice A.

Para *VFM* usando os modelos de princípios físicos, as seguintes etapas são executadas:

1. Criar um modelo de propriedades do fluido que represente os dados da PVT.
2. Criar o modelo físico de escoamento multifásico, com base nas variáveis disponíveis no sistema.
3. Monitorar e validar os dados de medição, remover *outliers* e filtrar ruídos.

4. Selecionar parâmetros de ajuste apropriados, por exemplo, vazões, coeficiente de descarga de *choke*, coeficientes de transferência de calor, etc. e estimar os valores dos parâmetros iniciais.
5. Simular os modelos selecionados na etapa 2, usando as propriedades do fluido da etapa 1 e os valores iniciais dos parâmetros de ajuste da etapa 4.
6. Selecionar os modelos de saída da etapa 5 para os quais as medições estejam disponíveis, por exemplo, pressões e temperaturas no fundo e na cabeça do poço.
7. Executar o algoritmo de reconciliação de dados para minimizar a incompatibilidade entre as saídas do modelo da etapa 6 e os dados de medição validados da etapa 3, ajustando os parâmetros selecionados na etapa 4.
8. Estimar as vazões de óleo, gás e água para cada poço da solução da etapa 7.

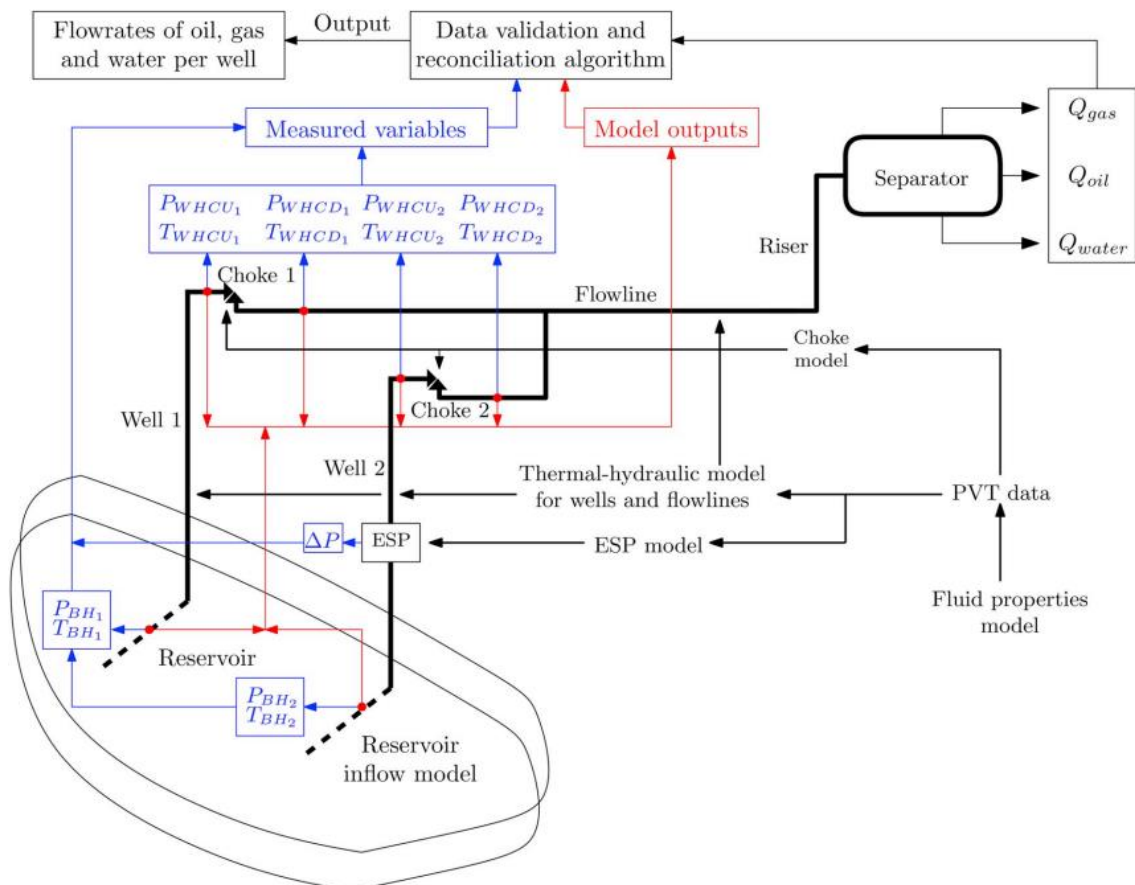


Figura 7 – VFM: Modelos para estimar a vazão por poço, validada em um algoritmo de reconciliação (BIKMUKHAMEDOV; JASCHKE, 2020).

A modelagem de um poço de petróleo *offshore*, com a finalidade de avaliar o comportamento do escoamento multifásico, passa pelas seguintes etapas:

1. Criação do modelo físico de escoamento:
 - a. Trajetória do poço (projeto direcional do poço)
 - b. Trajetória dos dutos submarinos (batimetria dos dutos)
 - c. Propriedades das tubulações (diâmetro, rugosidade, material, propriedades térmicas)
 - d. Configuração do *choke* (diâmetro e curva de CV)

Essa etapa cria o modelo na sua versão sem ajustes, porém já representando minimamente o poço.

2. Adição dos dados para cálculo de transferência de calor:
 - a. Propriedades térmicas dos materiais, meio ambiente e dos fluidos (condutividade, capacidade térmica, difusividade térmica, etc.)
 - b. Perfis de temperatura do meio ambiente

Esta etapa adiciona a capacidade de representação da transferência de calor no modelo criado na etapa 1.

3. Ajuste das propriedades do fluido (PVT) e da reologia do petróleo, caracterizando o comportamento das propriedades da mistura com a variação de pressão e temperatura ao longo do escoamento (viscosidade, massa específica, razão de solubilidades, fator volume de formação, dentre outras)

Essa etapa adiciona ao modelo disponível na etapa 2, a capacidade de representação do fluido real do poço.

4. Ajuste do modelo a partir de dados históricos de campo, permitindo escolha da correlação de fluxo multifásico, ajuste de parâmetros gerais de perda de carga e transferência de calor, a fim de refinar o modelo.

Essa etapa tem como objetivo trazer o modelo disponível na etapa 3 para um nível de exatidão em relação aos dados do histórico de produção, etapa comumente denominada *tuning* (ajuste) da modelagem.

5. Ajuste das propriedades do reservatório para o modelo de escoamento: (*IPR - Inflow Performance Relationship*)

Essa etapa acopla o modelo de escoamento multifásico ajustado disponível na etapa 4, com o modelo simplificado do reservatório de petróleo, adicionando informação que normalmente auxilia na estimativa de vazão total. Nem sempre esse acoplamento é necessário.

A Figura 8 apresenta a tela do simulador de escoamento multifásico MarlimII® (SEMAN, 2020), com a representação geral do poço e linhas submarinas.




Figura 8 – Tela do simulador de escoamento multifásico MarlimII®.

A seguir, serão abordadas em maiores detalhes as principais fases da etapa de construção do modelo de um poço de petróleo.

Modelagem Simplificada das propriedades do Reservatório

Um reservatório de petróleo consiste em uma rocha porosa, tipicamente formada por arenitos (conglomerado de grãos de areia, gerados a partir de sedimentos de granitos ou gnaisses) ou rochas carbonatadas (calcários, dolomitas ou mistura dessas), ou raramente por folhelhos fraturados, siltes, arcósios e rochas ígneas ou metamórficas fraturadas. Nestes poros encontram-se o petróleo, que durante o escoamento apresenta restrição ao fluxo definido pela permeabilidade relativa das fases no meio (ROSA; CARVALHO; XAVIER, 2006).

Darcy (1856), investigou o comportamento de fluxo em meio poroso, e expressou matematicamente, assumindo-se um diferencial de pressão e propriedades do fluido e da rocha conforme a seguir:

$$q = \frac{kA\Delta p}{\mu L} \quad (1)$$

Onde q é a vazão de fluido, A a área da seção transversal, Δp o diferencial de pressão, μ a viscosidade do fluido, L o comprimento do meio poroso e k a permeabilidade do meio poroso.

A equação de Darcy (1) foi estabelecida com certas condições:

- Fluxo isotérmico, “laminar” e permanente
- Fluido incompressível, homogêneo e de viscosidade invariável com a pressão
- Meio poroso homogêneo, que não reage com o fluido

Em um reservatório real de petróleo, o escoamento da rocha para dentro do poço (canhoneado), respeita o princípio avaliado por Darcy (1856), com uma vazão inversamente proporcional ao diferencial de pressão entre o reservatório e a pressão interna da tubulação. Quanto menor a pressão de fundo do poço (*BHP - Bottom Hole Pressure*) maior a vazão que o reservatório alimentará o poço. Essa propriedade de interface de escoamento reservatório x poço é definida simplificada pelo conceito do índice de produtividade (IP).

O índice de produtividade é definido como:

$$IP = \frac{q}{\Delta p} \quad (2)$$

Onde Δp é a diferença de pressão entre o reservatório e a pressão de fluxo no fundo do poço (BHP) (ROSA; CARVALHO; XAVIER, 2006).

Para um reservatório com fluido monofásico e incompressível, a relação (2) indica que a vazão é diretamente proporcional ao diferencial de pressão, e essa relação é válida para o “nó” fundo do poço. Denominamos este comportamento de IPR (*Inflow Performance Relationship*) linear (AHMED, 2019).

Vogel (1968) observou em dados de campo, que quando a pressão de fluxo no fundo do poço cai abaixo da pressão de saturação (pressão de bolha), a IPR desvia da relação linear, como apresentado na Figura 9. Essa característica é devido ao fluxo bifásico de gás e líquido.




Figura 9 – IPR acima e abaixo da pressão de saturação (pressão de bolha)

A IPR associa o potencial de fluxo (q), a diferença entre a pressão estática no reservatório (P_{res}) e a pressão interna no fundo do poço (BHP). A máxima vazão ocorre quando a pressão no fundo do poço (BHP ou p_{wf}) é igual a zero, definida como *Absolute Open Flow* (AOF), para o caso de um fluido monofásico e incompressível é

apresentada conforme Figura 9. Notar que a máxima vazão (q_{max}) para a IPR de Vogel (1968) é menor que a prevista pela IPR linear.

Vogel (1968), comparou diversos poços de reservatórios distintos, que operavam abaixo da pressão de saturação e obteve uma relação para o comportamento geral conforme equação a seguir:

$$\frac{q}{q_{max}} = 1 - 0.2 \left(\frac{p_{wf}}{p_{res}} \right) - 0.8 \left(\frac{p_{wf}}{p_{res}} \right)^2 \quad (3)$$

Onde:

q é a vazão de fluido

q_{max} é a vazão máxima obtida para pressão de fluxo no fundo do poço igual a zero.

p_{wf} é a pressão de fluxo no fundo do poço

p_{res} é a pressão média do reservatório

A vazão máxima (q_{max}) pode ser obtida conhecendo-se um ponto de operação (q_1 , $p_{wf,1}$ e p_{res}). A partir deste cálculo, usa-se a relação (3) para calcular uma vazão (q) dada uma p_{wf} .

A escolha da *IPR* depende basicamente das propriedades do reservatório e do fluido, e alternativamente pode ser obtida por meio de teste de campo, utilizando-se um registrador de pressão no fundo do poço, e realizando-se leituras variadas de vazão com restrições da vazão do poço, desta forma obtém-se de forma mais precisa (sem modelagem) o comportamento daquele poço/reservatório específico.

Modelagem do Fluido (PVT)

Uma amostra do fluido de um poço de petróleo coletada na condição de fundo traz informações químicas e termodinâmicas sobre o comportamento destes, úteis para

avaliação de propriedades de fluxo desde o reservatório, passando pelo sistema de escoamento até a planta de processamento.

A amostra é submetida a ensaios para obter a composição (hidrocarbonetos, CO₂, N₂), para caracterizar o petróleo nas suas fases líquido e gás, bem como avaliação das macro-propriedades (RGO, API e teor de H₂S).

Os ensaios de liberação diferencial e *flash* consistem em manter uma temperatura de referência (tipicamente a do reservatório), e reduzir progressivamente a pressão, obtendo concomitantemente as propriedades das fases óleo e gás (viscosidade, fator de encolhimento do óleo, fator volume de formação do gás, massas específicas, etc.). Tais propriedades são necessárias para ajustar os modelos de fluxo multifásico.

A liberação *flash* consiste em despressurizar a amostra, porém sem remoção da fase gasosa. Já na liberação diferencial, é removido a fase gás em cada *steps* intermediário, e o fato do gás liberado em pressões mais altas não estar presente em pressões mais baixas, limita a atração dos componentes intermediários e pesados para a fase vapor, resultando em um menor encolhimento e conseqüente maior recuperação de óleo no tanque de armazenamento. Esse resultado se deve a fugacidade dos componentes (AHMED, 2007).

Além desses ensaios, há também a avaliação da viscosidade do óleo com a variação de temperatura.

A partir desses resultados, pode-se ajustar um fluido representativo. Existem 2 abordagens principais, composicional e *black-oil*.

A abordagem composicional é recomendada quando há interesse na informação sobre os componentes ao longo do escoamento. Em escoamento onde a fase gás é predominante, quando há forte influência de formação de condensado, ou mesmo fluidos com complexidade na variação das propriedades devido alto teor de CO₂, a abordagem composicional apresenta vantagens para avaliação.

Conforme Whitson e Brule (2020) citados por citado por Jadid (2017), um modelo de fluido composicional é descrito por Equações de Estado (EoS), relações entre pressão, volume e temperatura, que são a base para o cálculo da fase e comportamento volumétrico do fluido produzido.

Conforme Bikmukhametov e Jaschke (2020), a história do desenvolvimento de EoS começa a partir do trabalho fundamental de Van der Waals (1870). Posteriormente, várias modificações e melhorias da equação de Van der Waals foram propostas, para a maioria das aplicações de petróleo e gás, as seguintes modificações são usadas:

- Peng-Robinson (PR) (Peng e Robinson, 1976).
- Redlich-Kwong (RK) (Redlich e Kwong, 1949).
- Soave-Redlich-Kwong (SRK) (Soave, 1972)

Já a abordagem *Black-Oil* é recomendada quando o escoamento é predominantemente de óleo, na ausência de fatores complexos, ou que não apresente interesse na avaliação dos componentes ao longo do escoamento. A abordagem é apresentada no Apêndice A, e foi aplicada neste trabalho.

O modelo *Black Oil* é uma abordagem mais simples, porém útil para caracterização de fluidos de petróleo. Nesta abordagem, óleo e gás são tratados como duas substâncias separadas e suas propriedades são calculadas com base em correlações (Whitson e Brule, 2000) citados por Jadid (2017). Na formulação tradicional, três propriedades principais de PVT são consideradas: fator de volume de formação de óleo (B_o), fator de volume de formação de gás (B_g) e razão gás-óleo (RGO).

Para misturas de hidrocarbonetos voláteis, modelos *Black Oil* modificados foram desenvolvidos, e apresentam a razão gás-óleo como variável principal. Se a água estiver presente no fluido, propriedades adicionais, como fator de volume de formação de água, razão gás-água e teor de água no gás são introduzidos nos cálculos. A descrição completa de ambos os modelos *Black oil* tradicional e modificado para sistemas de água/hidrocarbonetos e para óleos voláteis e sistemas de água / hidrocarbonetos são detalhados na monografia de Whitson e Brule (2000), citados por Jadid (2017).

Sistemas *VFM* com princípios físicos, usualmente suportam as duas abordagens de fluidos aqui descritas resumidamente. Os sistemas *VFM* modernos indicam a abordagem composicional, porém para uso em aplicações dominadas pelo escoamento de óleo e água, o uso da abordagem *Black-Oil* continua satisfatório.

Modelagem do Escoamento Multifásico

Seja um fluido em escoamento monofásico ascendente, em uma tubulação de área transversal constante (A) e diâmetro interno (D), conforme a Figura 10.




Figura 10 – Volume de controle infinitesimal em uma tubulação com escoamento ascendente (ALMEIDA, 2013)

A partir da equação da quantidade de movimento, para hipótese de escoamento unidimensional na direção da tubulação (x) e em regime permanente, tem-se:

$$F_x = \left[\left(\rho + \frac{d\rho}{dx} \frac{dx}{2} \right) \left(v + \frac{dv}{dx} \frac{dx}{2} \right)^2 - \left(\rho - \frac{d\rho}{dx} \frac{dx}{2} \right) \left(v - \frac{dv}{dx} \frac{dx}{2} \right)^2 \right] A \quad (4)$$

Onde ρ é a massa específica do fluido, P é a pressão e v a velocidade, todas as grandezas avaliadas como uma média na seção transversal, devido a abordagem unidimensional ao longo da tubulação (x).

Expandindo a Equação (4) e desprezando os termos com diferenciais de ordem superior, resulta:

$$F_x = \rho v \frac{dv}{dx} dx A \quad (5)$$

A força resultante na direção x (F_x) é composta por três forças, que serão detalhadas a seguir.

A componente do peso do fluido devido à gravidade na direção x é escrita como:

$$F_{x_{grav}} = -\rho(Adx)g \text{ sen } \theta \quad (6)$$

A força devido a diferença de pressão, normal às superfícies de controle abertas ao escoamento, é escrita como:

$$F_{x_{pressão}} = -\left(P + \frac{dP}{dx} \frac{dx}{2}\right) A + \left(P - \frac{dP}{dx} \frac{dx}{2}\right) A = -\frac{dP}{dx} dx A \quad (7)$$

Por fim, há a força tangencial na superfície de controle, devido ao atrito com a parede, no sentido contrário ao escoamento. Será considerada uma tensão tangencial (τ_w):

$$F_{x_{atrito}} = -\tau_w(\pi D) dx = -\tau_w \left(\frac{4}{D}\right) dx A \quad (8)$$

Reescrevendo a equação (5) utilizando (6), (7) e (8), tem-se:

$$\rho v \frac{dv}{dx} dx A = -\rho(Adx)g \text{ sen } \theta - \tau_w \left(\frac{4}{D}\right) dx A - \frac{dP}{dx} dx A \quad (9)$$

Dividindo todos os termos por (dxA) e rearranjando:

$$\frac{dP}{dx} = -\rho g \sin \theta - \rho v \frac{dv}{dx} - \tau_w \left(\frac{4}{D} \right) \quad (10)$$

A equação (10) mostra, basicamente, que o gradiente de pressão ao longo do escoamento pode ser representado como resultado da soma de três termos: gravitacional (mudança de cota), aceleração (mudança de velocidade ao longo de x: dv/dx) e atrito (dissipação viscosa).

$$\frac{dP}{dx} = \left(\frac{dP}{dx} \right)_{\text{gravitacional}} + \left(\frac{dP}{dx} \right)_{\text{aceleração}} + \left(\frac{dP}{dx} \right)_{\text{fricção}} \quad (11)$$

Introduzindo o fator de atrito (f) no termo de fricção, resulta em:

$$\left(\frac{dP}{dx} \right)_{\text{fricção}} = -\frac{1}{2} \rho f \frac{v^2}{D} \quad (12)$$

Reescrevendo (10) usando (12):

$$\frac{dP}{dx} = -\rho g \sin \theta - \rho v \frac{dv}{dx} - \frac{1}{2} \rho f \frac{v^2}{D} \quad (13)$$

O fator de atrito (f) pode ser obtido através de equações conforme a seguir (VIEIRA, 2012):

Para escoamento laminar ($Re_D < 2300$):

$$f = \frac{64}{Re_D} \quad (14)$$

Para escoamento turbulento ($Re_D > 4000$):

- Formulação implícita de Prandtl para tubo liso:

$$\frac{1}{\sqrt{f}} = 2 \log \left(\frac{Re_D \sqrt{f}}{2,51} \right) \quad (15)$$

- Formulação explícita de Colebrook:

$$\frac{1}{\sqrt{f}} = 1,8 \log \left(\frac{Re_D}{7} \right) \quad (16)$$

- Formulação explícita de Nikuradse:

$$\frac{1}{\sqrt{f}} = -2 \log \left(\frac{\varepsilon/D}{3,7} \right) \quad (17)$$

- Formulação implícita de Colebrook-White:

$$\frac{1}{\sqrt{f}} = -2 \log \left(\frac{\varepsilon/D}{3,7} + \frac{2,51}{Re_D \sqrt{f}} \right) \quad (18)$$

- Formulação explícita de Swamee-Jain:

$$f = \frac{0,25}{\left(\log \left(\frac{\varepsilon/D}{3,7} + \frac{5,74}{Re_D^{0,9}} \right) \right)^2} \quad (19)$$

A equação (13) pode ser usada para calcular o gradiente de pressão para escoamentos multifásicos, necessitando de tratamento apropriado das propriedades médias do fluido, além de estimativa adequada do fator de atrito multifásico, que denominamos f_{tp} .

Shippen e Bailey (2012), mostram a evolução das correlações multifásicas, passando do “período empírico” (dominado por análise experimental), “Anos do despertar” (abordagem física para suprir inconsistências dos modelos empíricos) e “período da modelagem” (era atual, uso de conceitos físicos, multi-fluido generalizado baseados na combinação de equações de momento e transições de regime de fluxo, exigindo ainda muitas equações de fechamento).




Figura 11 – Evolução da modelagem multifásica (SHIPPEN; BAILEY, 2012).

O Apêndice C, traz a abordagem empírica apresentada por Beggs e Brill (1973), a fim de corrigir o fator de atrito e o tratamento das propriedades médias. É apenas um exemplo de correlação disponível frente a diversas correlações empíricas e mecanicistas desenvolvidas SHIPPEN; BAILEY, 2012).

Kanin et al. (2019) propõem um modelo preditivo baseado em *machine learning* para resolver escoamentos multifásicos em tubulações, aplicando dados experimentais como *dataset* de treinamento de uma rede neural. Essa é uma abordagem bastante

moderna, puramente matemática/computacional, diferente das abordagens empíricas ou mecanicistas apresentadas anteriormente.

Modelagem Multifásica Aplicada à Medição de Vazão Virtual

Como apresentado nas seções anteriores, um modelo multifásico ajustado de um poço de petróleo permite estimar a vazão produzida das fases. a partir das condições de contorno, tipicamente pressão em pontos do escoamento.

Jadid (2017) e Amim (2015) expõem abordagens da medição de vazão virtual a partir de modelos de escoamento multifásicos, com bons resultados quando comparam os dados simulados dos dados medidos.

Existem diversos desafios neste tipo de abordagem, que estão basicamente relacionados a representatividade do modelo de fluido e de escoamento (correlação) em relação ao caso real. O uso de dados de teste diversos para ajuste do modelo é indispensável para melhor a precisão.

2.4. REDE NEURAL *MLP* (*Multilayer Perceptron*)

Redes Neurais Artificiais (RNA) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência (CIARELLI, 2019).

Características Gerais das Redes Neurais:

- São modelos adaptativos e treináveis a partir de exemplos;
- Podem representar domínios complexos (não lineares);
- São capazes de generalização diante de informação incompleta;
- São robustos a ruídos;
- São capazes de fazer armazenamento associativo de informações;
- Possuem grande paralelismo, o que lhes conferem rapidez de processamento.

Um neurônio artificial é composto pelos seguintes componentes (Figura 12):

- Várias sinapses (entradas), com pesos associados a elas;
- Uma função de soma;
- Uma função de transferência (ou função de ativação);
- Uma saída.




Figura 12 – Esquema de um neurônio artificial (CIARELLI, 2019).

A operação de um neurônio artificial k se resume em:

- Sinais são apresentados à entrada (x_1 à x_m);
- Cada sinal é multiplicado por um peso que indica sua influência na saída da unidade (w_{k1} à w_{km});
- É feita a soma ponderada dos sinais que produz um nível de atividade (v_k);
- A função de ativação $\varphi(v_k)$ tem a função de limitar a saída e introduzir não-linearidade ao modelo;
- As tendências (*bias*) b_k tem o papel de aumentar ou diminuir a influência do valor das entradas;
- É possível considerar o *bias* como uma entrada de valor constante 1, multiplicado por um peso igual a b_k ;

Segundo Bishop (2006), matematicamente, a saída de um neurônio pode ser expressa como:


$$y_k = \varphi(v_k) = \varphi\left(\sum_{j=1}^m w_{kj}x_j + b_k\right) \quad (20)$$

Se forem consideradas *bias* como entrada de valor $x_0 = 1$ e peso $w_{k0} = b_k$, tem-se:


$$y_k = \varphi(v_k) = \varphi\left(\sum_{j=0}^m w_{kj}x_j\right) \quad (21)$$

A Figura 13 apresenta alguns tipos de funções de ativação que podem ser usadas em redes neurais.


- Degrau (ou limiar):



- Sigmoidal:



- Linear:



- Tangente hiperbólica:




Figura 13 – Funções de ativação (CIARELLI, 2019).

A Figura 14 apresenta um exemplo de um neurônio do tipo *perceptron* de duas entradas (x_1 e x_2), além de bias (x_0), e a função de ativação degrau.




Figura 14 – Exemplo de rede perceptron

Minsky e Papert (1969) constataram que um neurônio do tipo *perceptron* só é capaz de resolver problemas cujas classes sejam linearmente separáveis. Eles apresentaram a solução para o problema, usando camadas ocultas intermediárias, dando origem as redes *Perceptron* Múltiplas Camadas (*Multi-Layer Perceptron - MLP*). Na época ainda não era conhecido um algoritmo para ajustar os pesos dessa rede neural.

Rumelhart, Hinton e Williams (1986) introduziram o algoritmo de aprendizado por retropropagação dos erros (*back-propagating errors*). Com este algoritmo era possível realizar o treinamento da rede neural. Esta descoberta, aliada aos avanços computacionais, criaram um ambiente favorável para as pesquisas em neurocomputação e as primeiras conferências sobre a área.

A Figura 15 apresenta um exemplo de rede do tipo *MLP*, com m variáveis na camada de entrada, 2 camadas escondidas (*hidden layers*) e uma camada de saída com 3 variáveis.




Figura 15 – Exemplo de rede MLP (CIARELLI, 2019).

As camadas ocultas (escondidas) possuem a função de realizar as transformações não lineares das entradas inseridas na rede. As camadas ocultas variam de acordo com a função da rede neural e, da mesma forma, as camadas podem variar de acordo com seus pesos associados (BISHOP, 2006).

Cada conexão deve ter seu peso ajustado na fase de treinamento supervisionado, a partir de um conjunto de dados previamente disponíveis. O algoritmo de *backpropagation* consiste em:

1. Inicialização dos pesos (w) e *bias* em valores randômicos entre -0.5 e 0.5 ou entre -1 e 1. Os valores podem ser positivos ou negativos, para melhorar a convergência.
2. A rede processa os dados de entrada (x_i) na direção da saída (y_k), na fase “*Forward*”
3. A saída obtida pela rede é comparada à saída desejada para a amostra. Se esta não estiver correta, o erro é calculado.
4. O erro é propagado a partir da camada de saída até a camada de entrada, na fase “*Backward*”.
5. A cada camada na fase “*backward*”, é obtido o erro na camada bem como o termo de correção dos pesos.

6. Ao final da propagação dos erros, é realizada a atualização dos pesos e reiniciado o processo a partir da etapa 2.

O erro quadrático entre a saída desejada d_i de uma i -ésima amostra e a saída y da rede é dado por:

$$E = (d_i - y)^2 \quad (22)$$

Onde y está em função dos parâmetros da rede. A solução para ajustar os pesos passa por encontrar o gradiente de E . Esse gradiente é obtido a partir da função de ativação assumida, desde que derivável (BISHOP, 2006).

A correção dos pesos das conexões move-se em direção contrária ao gradiente do erro, e é conduzida até:

1. Alcançar um erro quadrático suficiente baixo (predefinido na rede)
2. Quando atingir o número máximo de épocas (época = número de repetições do ciclo de propagação de erro).

Ao final deste processo, a rede estará treinada e pronta para uso.

Existem algumas questões relacionadas à fase de treinamento da rede. Depois de um certo ponto (número de épocas) do treinamento, a rede diverge ao invés de convergir, perdendo capacidade de generalização. Ela passa então a memorizar padrões, incluindo todas as suas peculiaridades (ruídos), ocorrendo o que é chamado de *overfitting* (BISHOP, 2006).

Aumentando-se o número de neurônios na camada escondida aumenta-se a capacidade de mapeamento não-linear da rede, no entanto, quando esse número é excessivamente grande, o modelo pode se sobrepor aos dados ruidosos, estando sujeita novamente ao *overfitting*. Por outro lado, uma rede com poucos neurônios na camada oculta pode não ser capaz de realizar o mapeamento desejado, o que é denominado de *underfitting*. O *underfitting* também pode ser causado quando o treinamento é interrompido de forma prematura (CIARELLI, 2019).

Definição da arquitetura de uma rede:

O número de neurônios nas camadas de entrada e saída é definida pelos dados do problema.

O número de neurônios na camada oculta é geralmente descoberto de forma empírica. Alguns pesquisadores sugerem o uso de uma camada oculta com $2d+1$ neurônios, onde d é o número de neurônios na camada de entrada. Outros dizem que $c(d+1)$ neurônios, onde c é o número de neurônios na camada de saída.

A eficiência do aprendizado em redes multicamadas (MLP) depende da:

- Especificação de arquitetura da rede
- Função de ativação
- Regra de aprendizagem e
- Valores iniciais dos vetores de pesos e bias

Como aplicações de redes MLP podemos citar:

- Reconhecimento de padrões e classificação
- Aproximação de funções e modelagem.

O principal problema de uma rede MLP é o “esquecimento catastrófico”. Ao aprender novas informações, a rede esquece as informações previamente aprendidas (dilema da plasticidade e estabilidade).

3. METODOLOGIA

3.1. VISÃO GERAL

Com o objetivo de inferir a vazão em um poço de petróleo, adotou-se um conjunto de dados reais de campo para criação e aferição de um modelo, posterior obtenção das vazões simuladas e finalmente a comparação com medições de referência.

Os dados disponíveis são de um poço de petróleo em produção por cerca de 325 dias, com medição monofásica das vazões de líquido e gás. Abaixo, seguem os dados detalhados:

- Vazões de óleo e água: Medidor mássico do tipo Coriolis com vazões em média de 5 e 30min
- Vazão de gás: Medição por placa de orifício em média de 5 e 30min
- Ensaio laboratoriais de fator de encolhimento (FE) do óleo, razão de solubilidade (RS) e massa específica do óleo, em análise de pressão-volume-temperatura (PVT) de coleta em separador
- Resultados diários de BSW (*Basic Sediment and Water*)
- Composição do óleo no reservatório (PVT coleta *in situ*)
- Composição do gás (cromatografia) em coleta de separador
- Pressão e temperatura no fundo do poço – PDG (*Permanent Downhole Gauge*)
- Pressão e temperatura na ANM (Arvore de Natal Molhada) – TPT (*Transmitter of Pressure and Temperature*)
- Pressão e temperatura à montante e jusante do *choke* de produção na plataforma
- Pressão à montante do separador de teste
- Nível de líquido do separador de teste
- Status das válvulas do poço *subsea* e na plataforma, para concluir sobre período de poço aberto ou fechado
- Características construtivas do poço e dutos submarinos (batimetrias, composição dos dutos flexíveis e detalhes construtivos do poço)

3.2. ESPECIFICAÇÕES DOS MEDIDORES E SENSORES

Medidor de vazão mássico:

Tipo: Coriolis

Diâmetro: 3"

Modelo: CMF300 // 3700

Fabricante: Micro Motion

Faixa de vazão calibrada: 20 a 72m³/h

Incerteza expandida máxima: 0,24% (conforme certificado de calibração)

Medidor de vazão de gás:

Tipo: Placa de Orifício

Diâmetro do trecho reto: 102,86mm

Diâmetro: 68,57mm

Faixa de vazão calibrada: 2400 a 10500 Nm³/h

Incerteza expandida:

Máximo: 2% para 2400Nm³/h

Normal: <1%. Ex. 0,75% (8000Nm³/h) e 0,77% (10500 Nm³/h)

Sensor do PDG (P1/T1)

Tipo: HPHT Duplo

Fabricante: Halliburton

Modelo: GAUGE SUB-ASSEMBLY, ROC-175, DUAL REDUNDANT
ELECTRONICS, 1.125IN OD, 0-16K PSIA, 25-177C

Faixa de Pressão: 0 a 1100bar

Incerteza da Pressão: + 0,02%

Faixa de Temperatura: 25 a 177 °C

Incerteza da Temperatura: + 0,15°C

Sensor do TPT (P2/T2)

Tipo: TPT-flush

Fabricante: Transcontrol

Modelo: TPT056

Faixa de Pressão: 0 a 690bar (10000psi)

Incerteza da Pressão: + 0,2% Fundo de Escala

Faixa de Temperatura: -10°C a 135°C

Incerteza da Temperatura: + 0,5°C Fundo de Escala

Sensores de Pressão na Plataforma:

Pmont_choke (P3)

Fabricante: SMAR

Tipo: Transmissor de pressão com célula capacitiva

Modelo: LD301

Faixa de Pressão: 0 a 23000kPa (230bar)

Incerteza da Pressão: + 0,04% span

Pjus_choke (P4)

Fabricante: SMAR

Tipo: Transmissor de pressão com célula capacitiva

Modelo: LD301

Faixa de Pressão: 0 a 1600kPa (16bar)

Incerteza da Pressão: + 0,04% span

Ps.g (P5)

Fabricante: SMAR

Tipo: Transmissor de pressão com célula capacitiva

Modelo: LD301

Faixa de Pressão: 0 a 1500kPa (15bar)

Incerteza da Pressão: + 0,04% span

3.3. DADOS DE PRODUÇÃO E PROPRIEDADES DISPONÍVEIS

Os dados disponíveis são de um poço produtor *offshore*, da camada do pré-sal¹, durante teste de longa duração (TLD) ou do original em inglês (*EWT – Extended Well Test*). Este período de teste é usado para avaliação do potencial produtivo e obtenção de dados gerais do reservatório.

¹ Reservatório de Petróleo de grande volume acumulado, que se encontra abaixo da camada de sal. Tal camada possui espessura de até 2 quilômetros, e o intervalo produtor encontra-se entre 5000 e 7000m de profundidade.

A Figura 16 apresenta um esquema do poço, com as variáveis disponíveis tipicamente a cada segundo. Por simplificação no tratamento de dados, são analisados os valores médios estabilizados a cada trinta minutos como referência no período.




Figura 16 – Esquema simplificado do poço

A vazão mássica é obtida na saída do separador, que opera em uma condição P&T (pressão e temperatura) diferente da condição padrão ANP assumida como referência para este trabalho, “[...] Condição em que a pressão absoluta é de **0,101325 MPa e a temperatura de 20°C**, para a qual o volume mensurado do líquido ou do gás é convertido”. (Resolução Conjunta ANP/INMETRO N° 1 DE 10/06/2013, item 3.8, p. 4, grifo nosso).

O medidor de vazão mássica usado é do tipo Coriolis, que obtém diretamente a vazão mássica total da mistura conforme formulação a seguir:

$$\dot{M}_t = \dot{M}_o + \dot{M}_w \quad (23)$$

\dot{M}_t – Vazão mássica total da mistura na condição P&T

\dot{M}_o – Vazão mássica de óleo na condição P&T

\dot{M}_w – Vazão mássica de água na condição P&T

Pressupõe-se que não há gás livre no medidor mássico, devido ao correto controle de nível do vaso separador, podendo ocorrer apenas a presença de gás solubilizado na fase líquida ainda não estabilizada.

A massa específica média da mistura também é obtida no medidor Coriolis, a partir da frequência de oscilação dos tubos de medição, e, portanto, temos:

$$Q_{liq}^{p,t} = \frac{\dot{M}_t}{\rho_m^{p,t}} \quad (24)$$

$Q_{liq}^{p,t}$ – Vazão volumétrica de líquido bruta na condição P&T

$\rho_m^{p,t}$ – Massa específica da mistura na condição P&T

A vazão de líquido é corrigida pela multiplicação dos fatores CPL e CTL no computador de vazão. Esses fatores representam a variação volumétrica pela diferença de pressão e temperatura entre a condição de referência do medidor e a condição P&T medida em operação:

$$Q_{liq,corr}^{p,t} = CPL \cdot CTL \cdot Q_{liq}^{p,t} \quad (25)$$

$Q_{liq,corr}^{p,t}$ – Vazão volumétrica de líquido corrigida na referência do medidor na condição P&T

Os fatores de correção CPL e CTL são obtidos, por exemplo, como especificados na norma API MPMS capítulo 11 (2007), onde são relacionados diretamente com a massa específica do óleo em condição padrão.

A vazão de óleo na condição P&T é obtida conforme a seguir:

$$Q_o^{p,t} = (1 - BSW_{p,t}) \cdot Q_{liq,corr}^{p,t} \quad (26)$$

$Q_o^{p,t}$ – Vazão volumétrica do óleo na condição P&T

$BSW_{p,t}$ – BSW (Basic Sediments and Water) na condição P&T

Existe uma pequena diferença entre BSW obtido em condição padrão em laboratório, e o $BSW_{p,t}$ usado na formulação para medição da vazão na condição P&T. Esta diferença se dá basicamente pelo fator de encolhimento do óleo, que cria uma variação no volume de líquido entre a condição P&T e condição padrão.

O $BSW_{p,t}$ pode ser escrito conforme a seguir:

$$BSW_{p,t} = \frac{FE \cdot BSW}{1 - BSW(1 - FE)} \quad (27)$$

FE – Fator de Encolhimento da condição P&T para a condição padrão ANP.

BSW – BSW (*Basic Sediments and Water*) na condição padrão ANP) de 1atm e 20°C.

$$BSW = \frac{Q_w^{sc}}{Q_{liq}^{sc}} \quad (28)$$

Q_w^{sc} – Vazão volumétrica de água na condição padrão

Q_{liq}^{sc} – Vazão volumétrica de líquido na condição padrão

O valor de BSW é obtido em análise laboratorial, medindo-se o teor de água e sedimentos presentes em uma amostra de volume total conhecido.

O fator de encolhimento (FE) é obtido através de análise laboratorial da variação de volume do óleo na condição que é coletado na saída do separador até a condição padrão, e usualmente é menor que 1, pois há perda de voláteis de óleo resultando em um gás adicional liberado.

A vazão Q_o^{sc} é definida finalmente como:

$$Q_o^{sc} = FE \cdot Q_o^{p,t} \quad (29)$$

Q_o^{sc} – Vazão volumétrica do óleo na condição padrão

$Q_o^{p,t}$ – Vazão volumétrica do óleo na P&T

A água possui variação de volume pequena (coeficiente da ordem de 10^{-4}) para a faixa de pressão e temperatura entre a condição de separação e a condição padrão, e normalmente é tratada como desprezível, resultando em $Q_w^{sc} = Q_w^{p,t}$:

$$Q_w^{sc} \cong Q_w^{p,t} = BSW_{p,t} \cdot Q_{liq,corr}^{p,t} \quad (30)$$

$Q_w^{p,t}$ – Vazão volumétrica da água na condição P&T

A vazão de líquido em condição padrão é finalmente definida como:

$$Q_{liq}^{sc} = Q_o^{sc} + Q_w^{sc} \quad (31)$$

Ou em função das variáveis conhecidas:

$$Q_{liq}^{sc} = \left[FE \cdot \left(1 - \frac{FE \cdot BSW}{1 - BSW(1 - FE)} \right) + \left(\frac{FE \cdot BSW}{1 - BSW(1 - FE)} \right) \right] \cdot Q_{liq,corr}^{p,t} \quad (32)$$

Onde $Q_{liq,corr}^{p,t}$ é obtida do medidor de vazão, FE e BSW disponível de análises laboratoriais.

A fim de se definir um espaço amostral estável, para teste e comparação de modelos de medição virtual, foi realizada uma avaliação dos dados de vazão de líquido na condição padrão ANP, na saída do vaso separador de teste, em períodos médios de cinco e trinta minutos, como apresentado na Figura 17 em um intervalo inicial de quarenta dias.




Figura 17 – Vazão em média de 5min (vermelho) e 30min (preto). A variação está relacionada a dinâmica de controle de nível do vaso separador

A vazão média de cinco minutos apresenta maior dispersão, refletindo a dinâmica de controle de nível. Conforme Figura 18, o nível do vaso separador em média de trinta minutos é mais estável, pois ameniza efeitos de curto período.

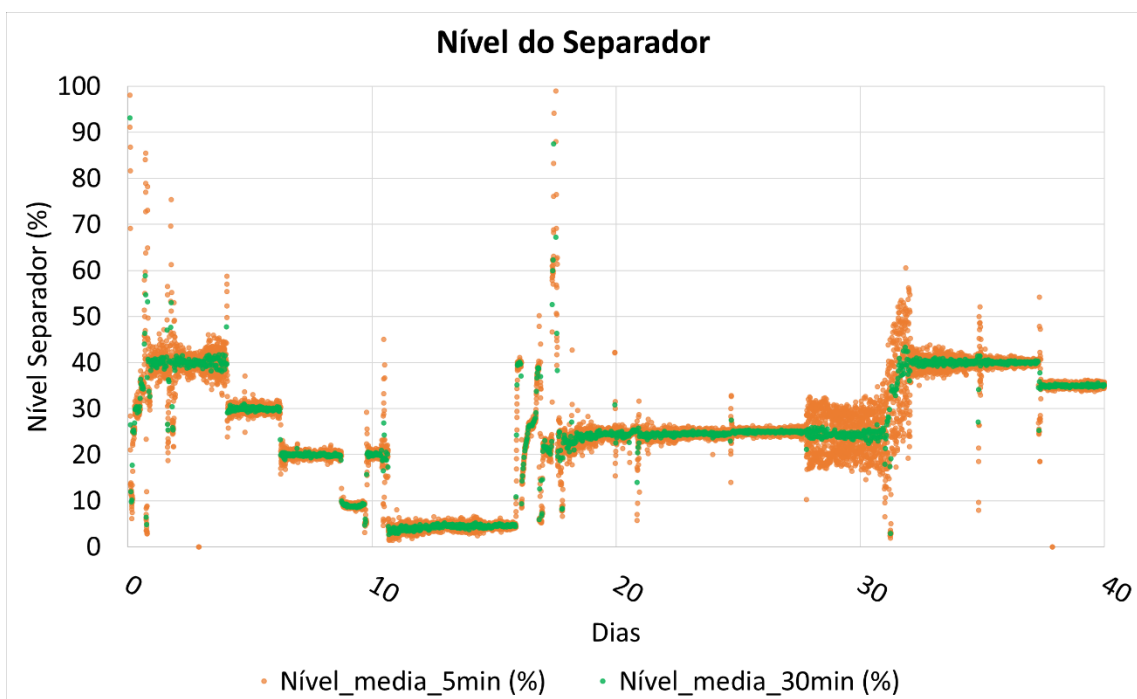


Figura 18 – Vazão em média de 5min (vermelho) e 30min (preto). A variação guarda relação com a dinâmica de controle de nível do vaso separador

Conforme Figura 17 e Figura 18, os valores médios de trinta minutos são mais estáveis e serão considerados para fins de análise. Além disso, há a necessidade de filtrar períodos transientes, conforme proposta a seguir:

$$\text{Variação da vazão (\%/30min)} = 30 \frac{1}{Q_{liq,f}^{sc}} \frac{\Delta Q_{liq}^{sc}}{\Delta t} \quad (33)$$

$$\Delta Q_{liq}^{sc} = Q_{liq,f}^{sc} - Q_{liq,i}^{sc} \quad (34)$$

$Q_{liq,f}^{sc}$ – Vazão de líquido em condição padrão avaliado ao final do intervalo [m³/d]

$Q_{liq,i}^{sc}$ – Vazão de líquido em condição padrão avaliado no início do intervalo [m³/d]

ΔQ_{liq}^{sc} – Variação de vazão de líquido em condição padrão, no intervalo analisado [m³/d]

Δt – Variação do tempo no intervalo analisado [min]

Assumiu-se como critério de estabilidade, a variação máxima na vazão de 5%/30min, resultando no gráfico a seguir:




Figura 19 – Critério de estabilidade (filtro de dados), com base na variação da vazão de líquido em média de 30min menor que 5%/30min

Além dos dados de vazão de líquido consolidados apresentados na figura anterior, temos as pressões ao longo do escoamento nos pontos notáveis (conforme apresentado Figura 16): P1 (PDG – fundo do poço), P2 (TPT – ANM) e P3 (montante do choke de produção) ao longo do período de análise.

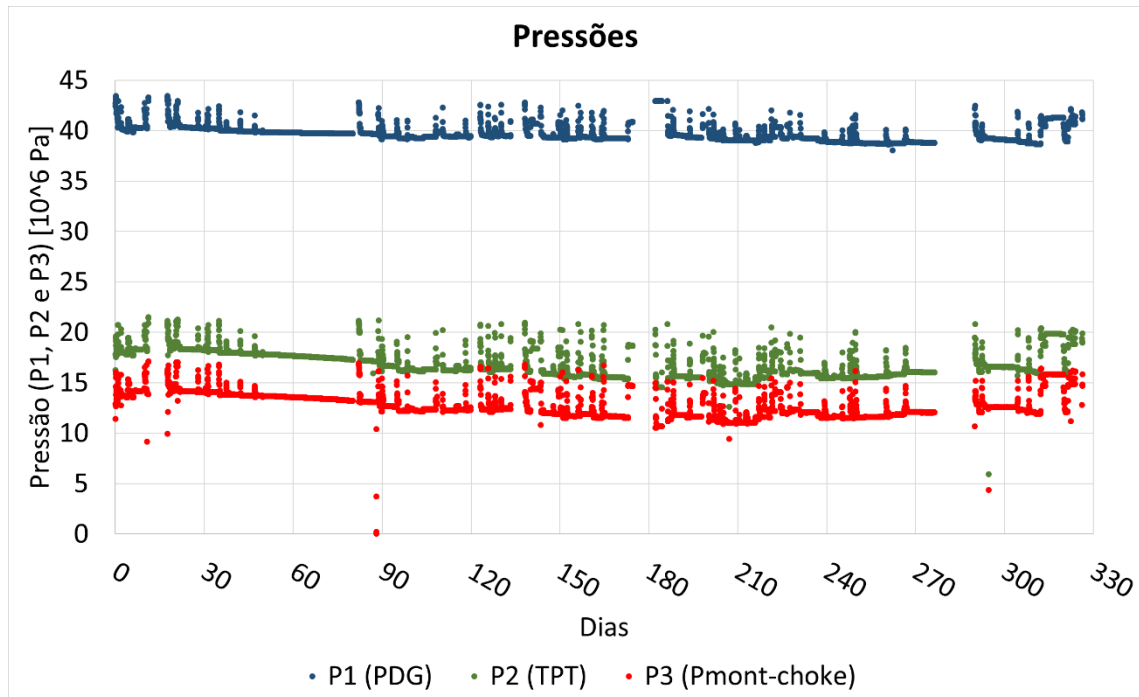


Figura 20 – Histórico de pressões em pontos do escoamento (P1, P2 e P3)

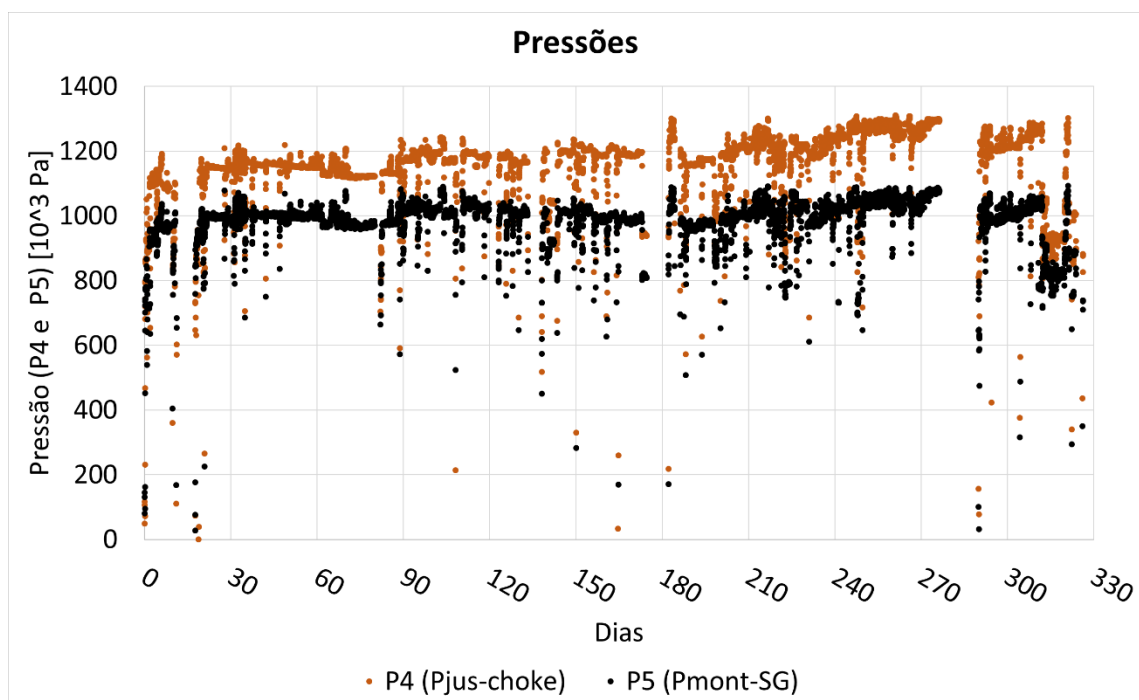


Figura 21 – Histórico de pressões em pontos do escoamento (P4 e P5)

Para a análise de simulação multifásica, foram selecionados vinte pontos conforme Figura 22 à Figura 24:




Figura 22 – Histórico de vazão de líquido e pontos selecionados para simulação

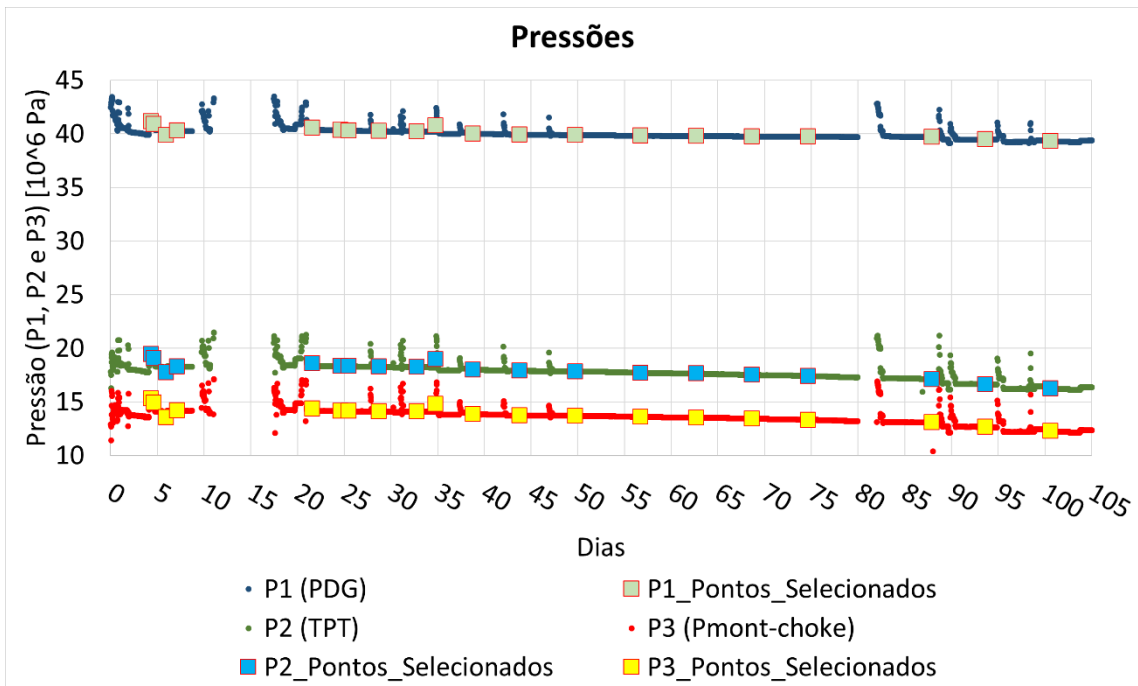


Figura 23 – Histórico de pressões e pontos selecionados para simulação (P1, P2 e P3)

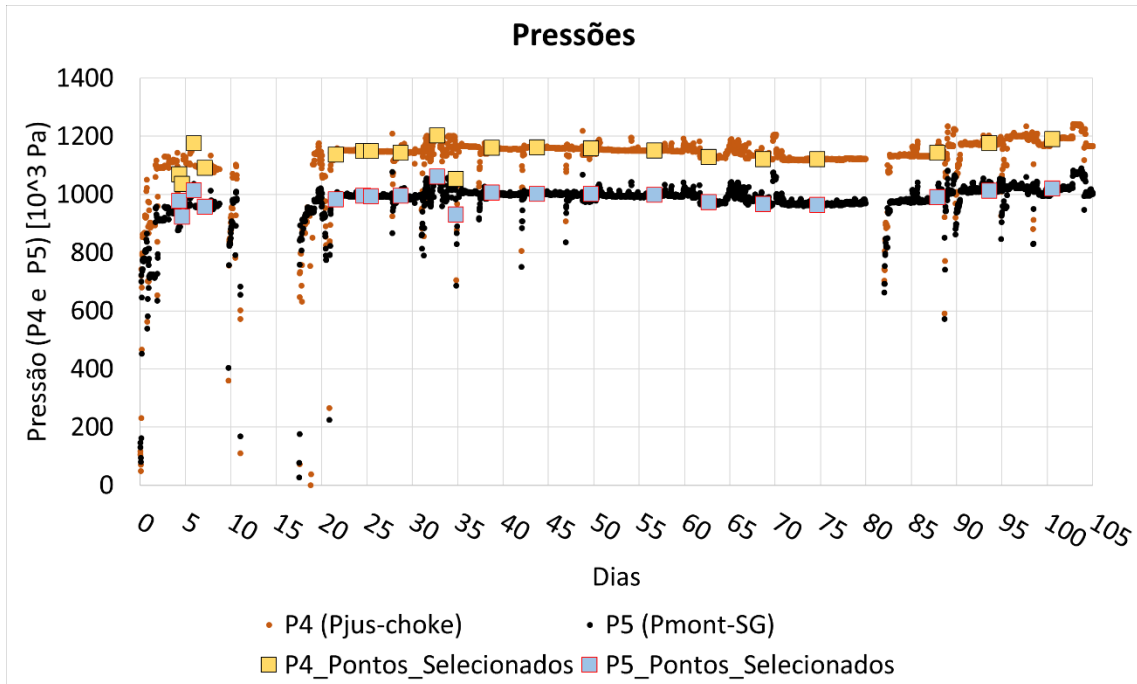


Figura 24 – Histórico de pressões e pontos selecionados para simulação (P4 e P5)

Na Figura 22 são mostrados os dados de vazão selecionados para a simulação, enquanto nas Figura 23 e Figura 24 são mostrados os dados de pressão correspondentes, onde é observada a boa estabilidade desses dados de pressão, ao menos visualmente.

Na Tabela 1, encontram-se listados os dados dos 20 pontos selecionados, em médias de 30 minutos, indicando os valores de vazão na condição padrão ANP e as respectivas pressões em diferentes pontos da instalação.

Tabela 1 – Dados dos pontos selecionados.

Pontos	Data (dias)	Vazão de Líquido (m ³ /d)	Pressões				
			(10 ⁶ Pa)			(10 ³ Pa)	
			P1	P2	P3	P4	P5
1	4,3	1092	41,2	19,4	15,3	1068	977
2	4,6	1229	40,9	19,1	14,9	1036	923
3	5,9	1573	39,9	17,7	13,6	1176	1014
4	7,1	1406	40,3	18,3	14,2	1090	958
5	21,6	1409	40,6	18,6	14,4	1137	982
6	24,6	1460	40,3	18,3	14,2	1149	995
7	25,5	1410	40,3	18,3	14,2	1149	994
8	28,7	1432	40,3	18,3	14,1	1143	996
9	32,8	1383	40,2	18,3	14,1	1202	1060
10	34,8	1215	40,8	19,0	14,8	1054	930
11	38,8	1425	40,0	18,0	13,9	1160	1005
12	43,8	1436	39,9	17,9	13,8	1162	1002
13	49,7	1421	39,9	17,8	13,7	1158	1001
14	56,7	1392	39,8	17,7	13,6	1151	999
15	62,7	1385	39,8	17,7	13,5	1128	972
16	68,7	1383	39,8	17,5	13,5	1121	967
17	74,6	1369	39,8	17,4	13,3	1121	964
18	87,9	1382	39,7	17,1	13,1	1143	990
19	93,6	1454	39,5	16,7	12,7	1175	1012
20	100,6	1477	39,3	16,3	12,3	1189	1020

Os dados disponíveis de BSW e RGO_f (razão gás óleo de formação), apresentados a seguir, mostram que o poço apresentou pouca variação nessas propriedades. Considerando apenas o período após estabilização e durante as coletas de teste oficial (pontos selecionados), o BSW apresentou variação máxima de 2,76% para 0,338%, enquanto o RGO_f apresentou variação máxima de 200,4 para 214,7m³/m³.




Figura 25 – BSW histórico

Conforme Figura 25, o poço apresentou uma presença maior de BSW na abertura, refletindo o período transiente de “limpeza” dos produtos residuais da completção. Após esse período, os ensaios por centrifugação (Conforme API MPMS 10.4) e por método Karl Fischer (Conforme ASTM D 4928) apresentaram valores baixos, entre 0 e 2%.

Por simplificação, assumiu-se os valores registrados nos pontos marcados (BSW_Selecionado) para as simulações multifásicas. O ponto selecionado é tratado como constante e válido até o novo registro.

O RGO_f é definido como a relação entre o volume total de gás proveniente da formação e o volume de óleo, ambos em condição padrão, conforme a seguir:

$$RGO_f = \frac{Q_g^{sc}}{Q_o^{sc}} \quad (35)$$

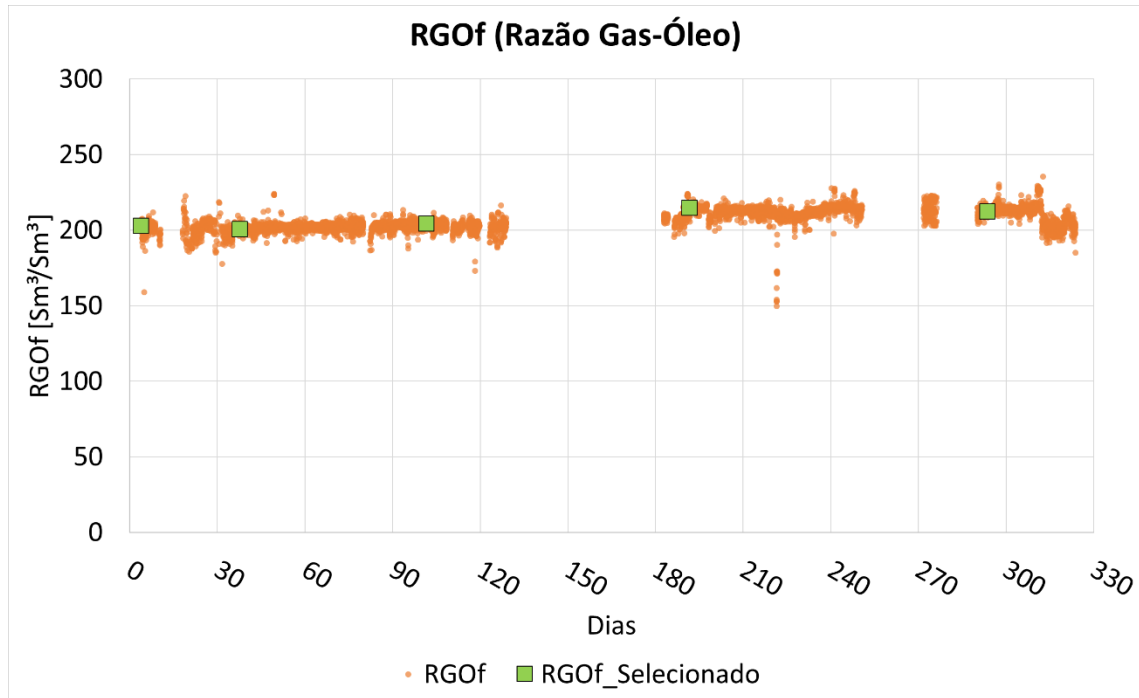


Figura 26 – RGOf histórico

Semelhante ao tratamento dado ao BSW, a Figura 26 apresenta os pontos selecionados para o RGOf (RGOf_Seleccionado). Por simplificação, o ponto selecionado é tratado como constante e válido até o novo registro. Esses são os dados usados para as simulações de escoamento multifásico.

Os primeiros dois pontos foram selecionados para ajuste (*tuning*) dos modelos de simulação multifásica e estão detalhados na Tabela 2:

Tabela 2 – Detalhe dos 2 primeiros pontos selecionados para ajuste de modelo

Variáveis	Ponto de Ajuste do Modelo		Unidades
	A	B	
Data	3,8	37,7	Dias após abertura
Qliq	1535	1341	m ³ /d
RGO _f	203	200	m ³ /m ³
BSW	2,760	0,574	%
FE	0,964	0,963	-
RS	7,16	11,48	m ³ /m ³
PDG (P1)	39,9	40,1	10 ⁶ Pa
PDG (T1)	119,0	119,6	°C
TPT (P2)	17,8	18,2	10 ⁶ Pa
TPT (T2)	94,7	97,1	°C
PT _{mon} (P3)	13,6	14	10 ⁶ Pa
TT _{mon} (T3)	53,1	51,0	°C
PT _{jus} (P4)	1118	1147	10 ³ Pa
TT _{jus} (T4)	42,7	39,6	°C
PT _{mon_SG} (P5)	951	1000	10 ³ Pa
Pres ¹	48,2	48,2	10 ⁶ Pa
IP ²	44,0	41,0	m ³ /d / kgf/cm ²

1: Os dados de Pressão Estática do Reservatório foram estimados com base em fechamentos do poço e avaliação da pressão no *PDG* corrigida para a profundidade do canhoneado.

2: O dado inicial do IP (ponto A) foi avaliado por teste de formação com sonda anterior a abertura do poço para a plataforma. Tal teste avalia a produtividade do poço registrando a pressão de fundo em várias condições de vazão controladas. O IP no ponto B foi avaliado a partir de ajuste em modelo de reservatório, a partir de dado de fechamento do poço (*Build Up*). A unidade de IP foi mantida na forma mais usual, para trazer sensibilidade.

Os pontos denominados A e B na Tabela 2 serão usados para definir os 14 casos de simulação descritos na seção 3.5.

Conforme explicado acima, o BSW e RGO_f são assumidos constantes entre os períodos de atualização dos dados, considerando sua baixa variação, como observado nas Figura 25 e Figura 26, respectivamente. A vazão de líquido (Q_{liq}^{sc}) passa a ser a única variável de interesse na simulação, e a Tabela 1 apresenta os dados

medidos, que serão confrontados com os dados simulados para fins de comparação de método.

A Tabela 3 a seguir apresenta o sumário estatístico das variáveis em todo o período dos dados disponíveis:

Tabela 3 – Sumário estatístico dos dados disponíveis.

Variável	Min	Max	Média	Unidade
RGO	190	225	207,5	m ³ /m ³
BSW	0,338	2,760	1,549	%
P1	38,2	43,3	40,8	10 ⁶ Pa
T1	110	123	116,5	°C
P2	13,7	21,1	17,4	10 ⁶ Pa
T2	60,0	102,1	81,0	°C
Q_{liq}^{sc}	600	2000	1300	m ³ /d
P3	10,3	16,7	13,5	10 ⁶ Pa
T3	30,0	60,0	45,0	°C
P4	834	1294	1064	10 ³ Pa
T4	15,0	50,0	32,5	°C
P5	785	1079	932	10 ³ Pa

3.4. MODELAGEM GEOMÉTRICA E TÉRMICA DO POÇO

Inicialmente foi criado um modelo completo em simulador de escoamento multifásico, contendo as características geométricas do poço, linhas submarinas, válvulas e tubulações até a plataforma.

A Tabela 4, Figura 27 e Figura 28 apresentam um resumo simplificado dos principais parâmetros do poço e sistemas submarinos.

Tabela 4 – Principais parâmetros do poço

Descrição	Valor	Unid.
Diâmetro interno do revestimento de produção	0,217	m
Espessura do revestimento de produção	16,9	mm
Diâmetro interno da coluna de produção	0,12	m
Espessura da coluna de produção	10,36	mm
Condutividade térmica do aço	58	W/mK
Espessura de cimento	30,48	mm
Condutividade térmica do cimento	1,2100	W/mK
Condutividade térmica da rocha	6,5000	W/mK
Comprimento do poço vertical	4030,5	m
Rugosidade da coluna de produção ¹	0,183	mm
Comprimento das linhas submarinas	6000	m
Diâmetro interno das linhas submarinas	6	pol
Rugosidade nas linhas flexíveis ²	0,6	mm
TEC das linhas flexíveis submarinas ³	3,74 a 8,88	W/mK

¹ A rugosidade da coluna de produção depende da qualidade da fabricação, usualmente tratada como ID/1000, onde ID é o diâmetro interno da tubulação. Não há confirmação deste parâmetro, sendo um item disponível para ajuste no modelo.

² A rugosidade em flexíveis é sugerida, conforme API 17B, como ID/250. Não há confirmação deste parâmetro, sendo um item disponível para ajuste no modelo.

³ TEC - *Thermal Exchange Coefficient* – Definido como a taxa de transferência de calor (potência, W), por metro de comprimento de duto, devido à diferença de 1K (ou 1°C) entre as temperaturas de superfície interna e externa.




Figura 27 – Esquema simplificado do poço e parâmetros (Dados conforme Tabela 4)



Figura 28 – Esquema simplificado dos equipamentos submarinos (Dados conforme Tabela 4)

O espaço anular entre o revestimento de produção e coluna de produção foi assumido com água para fins de cálculo térmico, uma vez que não houve preenchimento registrado do anular com gás, pois o poço opera exclusivamente por surgência natural.

O modelo completo foi discretizado em segmentos de no máximo 50 metros.

A temperatura e velocidade de corrente oceânica são obtidas por testes de campo variando a profundidade de coleta em região oceânica representativa. A figura a seguir resume os dados usados no modelo:

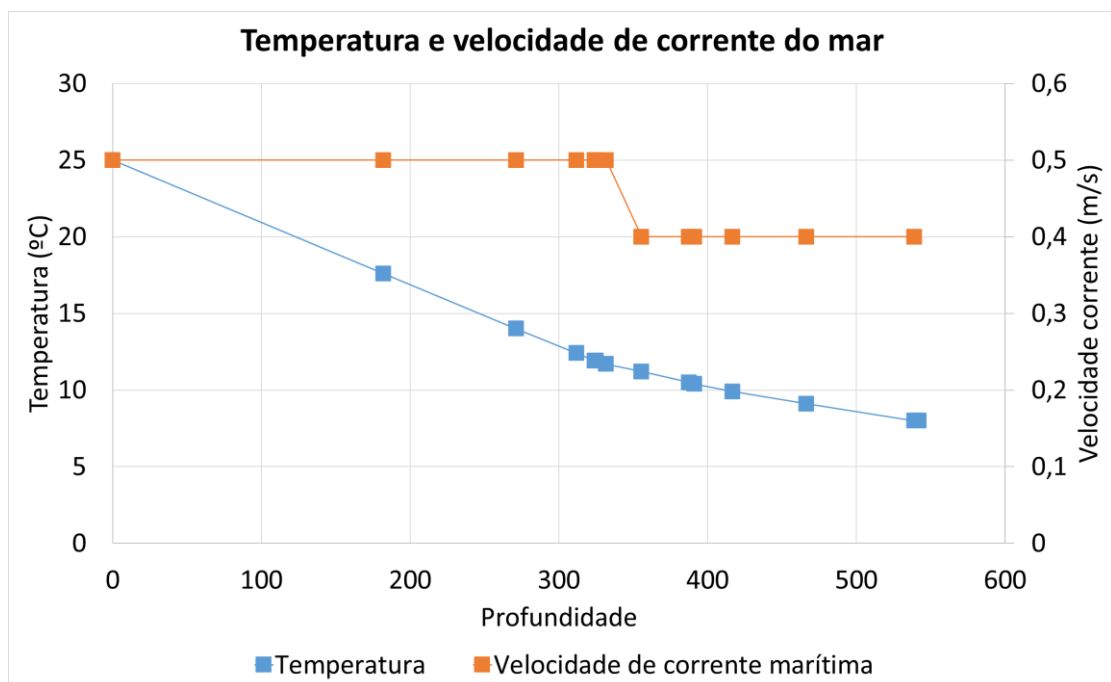


Figura 29 – Perfil de temperatura e corrente no trecho submarino

Para o trecho de poço perfurado, a temperatura na cabeça do poço (ANM – Árvore de Natal molhada) é igual a sugerida para o leito do mar.

O perfil térmico na rocha onde o poço está perfurado, é tratado de forma simplificada variando linearmente com a profundidade, em uma taxa conforme formulação a seguir:

$$\text{Gradiente térmico} = \frac{T_{res} - T_{ANM}}{Prof_{perfurada}} [^{\circ}C/1000m] \quad (36)$$

T_{res} – Temperatura do reservatório de petróleo, na profundidade dos canhoneados (trecho do reservatório aberto ao fluxo) [$^{\circ}C$]

T_{ANM} – Temperatura na ANM (Árvore de Natal Molhada), assumida como igual a do leito marinho [$^{\circ}C$]

$Prof_{perfurada}$ – Profundidade (comprimento vertical) iniciando no leito marinho até os canhoneados

Para o poço em questão foi obtido um gradiente térmico de 27,8 $^{\circ}C/1000m$.

O gradiente geotérmico varia localmente, dependendo basicamente do fluxo regional de calor e da condutividade térmica das rochas. A média global é de cerca de 30 $^{\circ}C/1000m$. A formulação assumida na equação (36) visa ajustar as extremidades do poço, onde são conhecidas as temperaturas por medição local.

3.5. DEFINIÇÃO DOS CASOS SIMULADOS

O modelo de escoamento multifásico completo descrito anteriormente é dividido em trechos menores para simplificação, em função das condições de contorno e variação dos parâmetros do escoamento, gerando casos mais simples, conforme Figura 30.

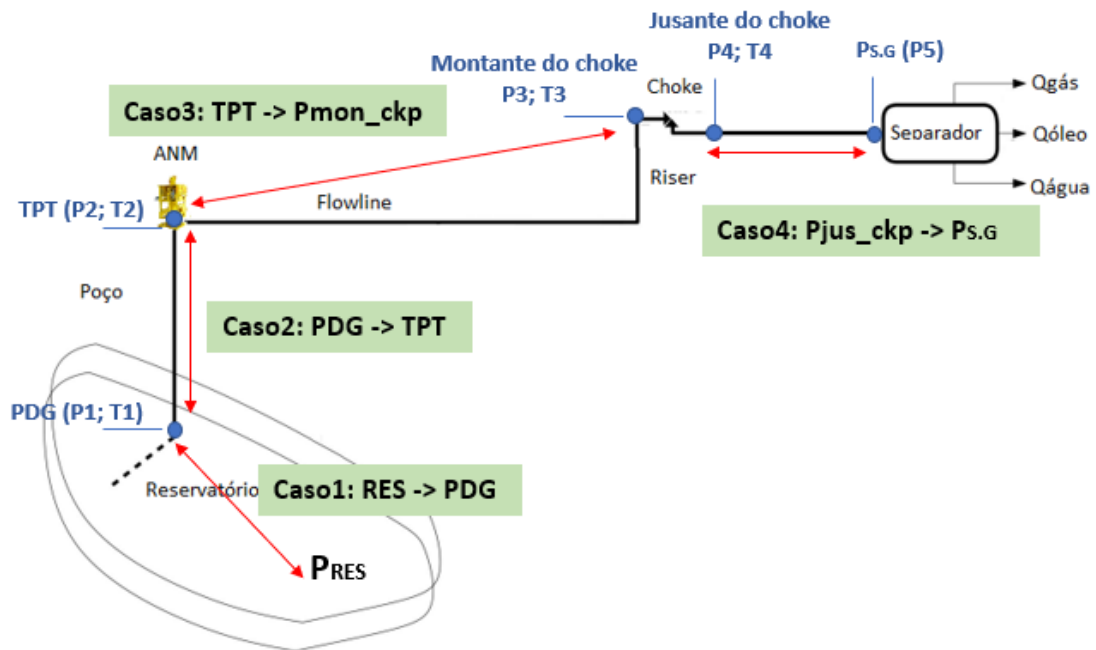


Figura 30 – Trechos dos casos estudados

Além da divisão dos trechos, os casos guardam relação com a correlação multifásica escolhida, conforme Tabela 5 a seguir.

Tabela 5 – Correlações Multifásicas e Abreviaturas

Abreviatura	Nome completo da Correlação
BB	Beggs e Brill (1973)
BBP	Beggs, Brill e Palmer (1979)
DEF	Dukler, Eaton e Flanigan (1969)
DR	Duns e Ros (1963)
HB	Hagedorn e Brown (1965)
Shoham	Shoham (2006)
ORK	Orkiszewski (1967)
MB	Mukherjee e Brill (1985)
AGF	Aziz, Govier & Fogarasi (1972)

Os diversos modelos passam por ajustes, com propósito de aproximar o resultado simulado do resultado de referência. Na sessão 3.7 será apresentado o detalhamento da técnica.

A seguir temos a tabela resumo com os casos estudados:

Tabela 6 - Casos de simulação multifásica aplicados

Casos	Descrição
1A	Modelo até o PDG (P1), com ajuste apenas no ponto A (inicial)
1B	Idem Caso1A, com ajuste adicional no ponto B (intermediário)
2A1	Modelo entre PDG (P1) e TPT (P2), com ajuste apenas no ponto A (inicial) e correlação de fluxo multifásico Orkiszewski
2A2	Modelo entre PDG (P1) e TPT (P2), com ajuste apenas no ponto A (inicial) e correlação de fluxo multifásico Beggs e Brill
2B1	Idem Caso2A1, com ajuste adicional no ponto B (intermediário) com mudança da correlação de fluxo multifásico para Aziz, Govier & Fogarasi
2B2	Idem Caso2A2, com ajuste adicional no ponto B (intermediário)
3A1	Modelo entre TPT (P2) e P _{mont_choke} (P3), com ajuste apenas no ponto A (inicial) e correlação de fluxo multifásico vertical Beggs e Brill e horizontal: Shoham (ângulo de transição: 20°)
3A2	Modelo entre TPT (P2) e P _{mont_choke} (P3), com ajuste apenas no ponto A (inicial) e correlação de fluxo multifásico vertical Beggs e Brill e horizontal Dukler, Eaton e Flanigan (ângulo de transição: 20°)
3B1	Idem Caso3A1, com ajuste adicional no ponto B (intermediário)
3B2	Idem Caso3A2, com ajuste adicional no ponto B (intermediário)
4A1	Modelo entre P _{jus_choke} (P4) e P _{s.g} (P5), com ajuste apenas no ponto A (inicial) e correlação de fluxo multifásico vertical Hagedorn e Brown e horizontal Beggs, Brill e Palmer (ângulo de transição: 20°)
4A2	Modelo entre P _{jus_choke} (P4) e P _{s.g} (P5), com ajuste apenas no ponto A (inicial) e correlação de fluxo multifásico vertical Beggs e Brill e horizontal Dukler, Eaton e Flanigan (ângulo de transição: 20°)
4B1	Idem Caso4A1, com ajuste adicional no ponto B (intermediário) com mudança da correlação de fluxo multifásico vertical para Beggs e Brill e horizontal para Beggs, Brill e Palmer (ângulo de transição: 20°)
4B2	Idem Caso4A2, com ajuste adicional no ponto B (intermediário)

3.6. CARACTERIZAÇÃO DOS FLUIDOS

Os fluidos são abordados por uma aproximação black-oil ajustada com a PVT em coleta de fundo (Tabela 7) e dados de reologia de emulsão disponíveis (Tabela 8). Os dados apresentados neste trabalho são de um poço real, e não poderão ser indicados diretamente (fonte da referência) de forma a manter o sigilo.

Tabela 7 – Dados do ensaio de liberação diferencial da PVT à 123°C (Resultados em condição padrão, 1 atm e 15.6 °C)

Pressão ^(a) (kgf/cm ²)	R _s (m ³ /m ³)	B _o (m ³ /m ³)	Viscosidade do óleo μ _o (cP)
600	245,1	1,731	0,44
550	245,1	1,745	0,42
500	245,1	1,76	0,4
460	245,1	1,774	0,39
430	245,1	1,784	0,38
400	245,1	1,796	0,37
370	245,1	1,808	0,36
340	245,1	1,822	0,34
324,3 (P _b)	245,1	1,83	0,34
290	208,7	1,721	0,38
250	174,4	1,625	0,44
200	137,9	1,523	0,52
150	106,1	1,439	0,63
100	76,4	1,36	0,77
50	48,1	1,282	0,92
0	0	1,088	1,87

^(a): Pressão manométrica

A indústria de produção de petróleo é fortemente influenciada pelos padrões e unidades americanos, e comumente os resultados de análise PVT são expressos em condição standard *STP* (*Standard Temperature and Pressure*), 1atm e 60°F (15,6°C).

Tabela 8 – Viscosidades do óleo residual do ensaio de liberação diferencial

Temperatura (°C)	Viscosidade dinâmica do óleo μ _o (cP)
30	14,56
40	10,28
50	7,59
60	5,81
70	4,59
80	3,72
90	3,08
100	2,6
110	2,23
120	1,94
123	1,87

Definições:

Razão de Solubilidade (Rs) em uma certa condição P&T, é o volume de gás dissolvido na fase óleo, medido nas condições padrão, dividido pelo volume de óleo, medido nas condições padrão.

$$R_s = \frac{(V_{g,d})_{std}}{(V_o)_{std}} \quad (37)$$

Fator Volume de Formação do Óleo (Bo): pode ser definido como o volume da fase óleo (óleo + gás dissolvido) nas condições P&T dividido pelo volume de óleo nas condições padrão.

$$B_o = \frac{(V_o)_{p,t}}{(V_o)_{std}} \quad (38)$$

Além dos itens descritos na tabela anterior, outros dados que também são usados nos modelos de fluidos:

- Pressão de saturação em 324,3 kgf/cm² (31,8 MPa) para temperatura de 123°C.
- API do óleo 31,4.
- Densidade da água de 1,12 devido à alta salinidade do pré-sal.
- Densidade do gás na condição padrão 0,92.

A etapa de ajuste da PVT é iniciada pela seleção das correlações das propriedades que apresentam menor erro ou comportamento semelhante (dado calculado) aos dados medidos. Após essa fase de seleção, aplica-se um ajuste, que visa melhorar os resultados da simplificação black-oil, conforme descrito do Apêndice B.

Para o conjunto de dados, as correlações que melhor se ajustaram foram:

- RS e Pressão de Saturação – Lasater (1958)
- Bo – Glaso (1980)
- Óleo morto – Beggs & Robinson (1975)
- Óleo Vivo:

- $p > p_b$: Vasquez & Beggs (1980)
- $p \leq p_b$: Beggs & Robinson (1975)

As figuras 31, 32 e 33 apresentam os dados medidos, dados calculados pela formulação de melhor aproximação e o dado “corrigido”, este último é um ajuste sobre o valor calculado originalmente, explicado no Apêndice B.




Figura 31 – Ajuste black-oil da razão de solubilidade




Figura 32 – Ajuste black-oil do volume de formação do óleo




Figura 33 – Ajuste black-oil da viscosidade do óleo

3.7. AJUSTE DOS MODELOS DE ESCOAMENTO MULTIFÁSICO

Os modelos dos casos especificados na seção 3.5 devem ser ajustados conforme os pontos A e B especificados na Tabela 2.

A Figura 34 apresenta um fluxograma simplificado do processo de ajuste do modelo de escoamento multifásico.

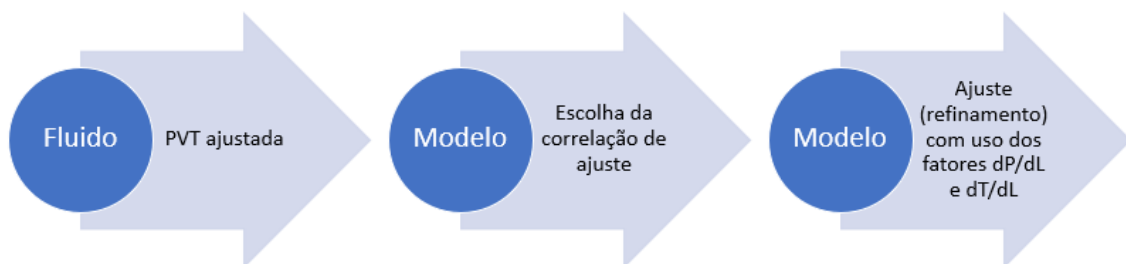


Figura 34 – Fluxograma simplificado do processo de ajuste de modelo

O procedimento se inicia com o ajuste do fluido, conforme demonstrado na seção (3.6), seguindo para escolha das correlações de fluxo multifásico que melhor ajusta os dados históricos da Tabela 2, onde a variável de saída é a vazão de líquido, e as demais variáveis são os dados de entrada.

A partir da escolha da correlação de fluxo multifásico, é realizado um ajuste fino com uso de fatores multiplicadores dP/dL e dT/dL , estabelecendo um erro máximo de 0,5%. Cabe mencionar que existem outras alternativas de ajustes, como por exemplo, o ajuste da rugosidade, alterações de ID (diâmetro interno) nas tubulações em caso de suspeita de obstrução ou perda de espessura das tubulações, entre outros. O erro de ajuste aplicado as Tabelas de 9 a 22 é definido como a seguir:

$$Erro (\%) = 100 \left(\frac{Q_{liq, simulada}^{sc}}{Q_{liq}^{sc}} - 1 \right) [\%] \quad (39)$$

$Q_{liq, simulada}^{sc}$ – Vazão volumétrica de líquido simulada, na condição padrão

A seguir serão apresentados os resultados dos ajustes realizados em cada caso (conforme Tabela 6), mostrando correlações multifásicas testadas, correlações escolhidas (sombreado na tabela) e parâmetros usados para ajuste.

Conforme visto nas Tabelas 1 e 7, o escoamento entre o reservatório e o PDG no fundo do poço (pressão P1) pode ser tratado como monofásico (líquido), pois a pressão de fluxo é maior que a pressão de saturação, 324,3 kgf/cm² (31,8 MPa).

Desta forma os CASOS 1A e 1B não apresentam sensibilidade a escolha da correlação de fluxo multifásico, conforme apresentado nas Tabelas 9 e 10.

Tabela 9 – Ajuste modelo do CASO 1A (Vazão de líquido de referência: 1535 m³/d)

Correlação (Abreviado)	Vazão de Líquido Simulada (m³/d)	Erro (%)	Vazão de Líquido (m³/d) após ajuste - $dP/dL=0.99$	Erro (%) após ajuste
BB	1517,42	-1,14%	1535,2	0,01%
ORK	1517,42	-1,14%		
HB	1517,42	-1,14%		
DR	1517,42	-1,14%		
MB	1517,42	-1,14%		
AGF	1517,42	-1,14%		

Tabela 10 – Ajuste de modelo do CASO 1B (Vazão de líquido de referência: 1341 m³/d)

Correlação (Abreviado)	Vazão de Líquido Simulada (Sm ³ /d)	Erro (%)	Vazão de Líquido (m ³ /d) após ajuste - dP/dL=1.01	Erro (%) após ajuste
BB	1362,57	1,60%	1345,88	0,35%
ORK	1362,57	1,60%		
HB	1362,57	1,60%		
DR	1362,57	1,60%		
MB	1362,57	1,60%		
AGF	1362,57	1,60%		

Nas Tabelas 9 e 10, para os casos 1A e 1B, respectivamente, os modelos ajustados com os dados disponíveis preveem vazão de líquido com erros idênticos. Foi selecionado o modelo de Beggs e Brill (1973) para comparação com a vazão de líquido medida, que após ajuste apresentaram um erro de 0,01% no caso 1A e 0,35% para o caso 1B.

Diferente dos casos anteriores, o escoamento entre o PDG (P1) e o TPT (P2) representa um trecho com presença de gás, pois a pressão do escoamento atinge a pressão de bolha (pressão de saturação), caracterizando um escoamento multifásico, apresentando sensibilidade a alteração das correlações, conforme Tabela 11 à Tabela 14.

Tabela 11 – Ajuste de modelo do CASO 2A1 (Vazão de líquido de referência: 1535 m³/d)

Correlação	Vazão de Líquido Simulada (m ³ /d)	Erro (%)	Vazão de Líquido (m ³ /d) após ajuste dP/dL=0.995	Erro (%) após ajuste
BB	1192,2	-22,33%		
ORK	1489,3	-2,98%	1535,94	0,06%
HB	1288,06	-16,09%		
DR	1235,72	-19,50%		
MB	1305,41	-14,96%		
AGF	1367,48	-10,91%		

Tabela 12 – Ajuste de modelo do CASO 2A2 (Vazão de líquido de referência: 1535 m³/d)

Correlação	Vazão de Líquido Simulada (m ³ /d)	Erro (%)	Vazão de Líquido (m ³ /d) após ajuste dP/dL=0.976	Erro (%) após ajuste
BB	1192,2	-22,33%	1537,8	0,18%
ORK	1489,3	-2,98%		
HB	1288,06	-16,09%		
DR	1235,72	-19,50%		
MB	1305,41	-14,96%		
AGF	1367,48	-10,91%		

Os casos 2A1 e 2A2 são relativos ao ajuste no ponto operacional A.

No caso 2A1 (Tabela 11) o menor erro de modelagem é dado pela correlação de Orkiszewski (1967), com uma diferença em relação à vazão medida de referência em -2,98%, e 0,06% após o ajuste de dP/dL. O caso 2A2 visa observar a sensibilidade da escolha da correlação multifásica em relação ao caso 2A1. No caso 2A2 (Tabela 12), optou-se por selecionar a correlação de Beggs e Brill (1973), resultando inicialmente em uma diferença em relação à vazão medida de -22,33%, porém após o ajuste foi alcançado um erro de 0,18%.

Tabela 13 – Ajuste de modelo do CASO 2B1 (Vazão de líquido de referência: 1341 m³/d)

Correlação	Vazão de Líquido Simulada (m ³ /d)	Erro (%)	Vazão de Líquido (m ³ /d) após ajuste - dP/dL=1.0013	Erro (%) após ajuste
BB	1212,16	-9,62%		
ORK	1471,2	9,70%		
HB	1290,98	-3,74%		
DR	1246,36	-7,07%		
MB	1309,77	-2,34%		
AGF	1364	1,70%	1345,27	0,31%

Tabela 14 – Ajuste de modelo do CASO 2B2 (Vazão de líquido de referência: 1341 m³/d)

Correlação	Vazão de Líquido Simulada (Sm ³ /d)	Erro (%)	Vazão de Líquido (m ³ /d) após ajuste - dP/dL=0.992	Erro (%) após ajuste
BB	1212,16	-9,62%	1340,86	-0,02%
ORK	1471,2	9,70%		
HB	1290,98	-3,74%		
DR	1246,36	-7,07%		
MB	1309,77	-2,34%		
AGF	1364	1,70%		

Os casos 2B1 e 2B2 são relativos ao ajuste no ponto operacional B.

Para o caso 2B1 (Tabela 13), o melhor ajuste inicial foi obtido com o modelo Aziz, Govier & Fogarasi (1972), resultando em uma diferença com a vazão medida de 0,31% após ajuste. O caso 2B2 visa observar a sensibilidade da escolha da correlação multifásica em relação ao caso 2B1, onde optou-se pela escolha da correlação de Beggs e Brill (1973), que apresentou um erro de -0,02% após o ajuste.

O escoamento entre o TPT (P2) e o P_{mont_choke} (P3) também representa um trecho com presença de gás, caracterizando um escoamento multifásico, além de forte variação das propriedades P&T, apresentando grande sensibilidade à alteração das correlações, conforme consta nos dados das Tabela 15 à Tabela 18 para os casos 3A1, 3A2, 3B1 e 3B2, respectivamente.

Tabela 15 – Ajuste de modelo do CASO 3A1 (Vazão de líquido de referência: 1535 m³/d)

Correlação (Vert/ Hor)	Vazão de Líquido Simulada (m³/d)	Erro (%)	Vazão de Líquido (m³/d) após ajuste dP/dL=0.955 / dT/dL=0.85	Erro (%) após ajuste
HB / DEF	2073,25	35,07%		
HB / BBP	1193,4	-22,25%		
BB / DEF	1891,76	23,24%		
BB / BBP	1177,47	-23,29%		
Shoham / Shoham	1254,75	-18,26%		
BB / BB	1119,71	-27,05%		
BB / Shoham	1284,79	-16,30%	1.530,66	-0,28%
DR / Shoham	1225,49	-20,16%		
DR / DEF	1970,05	28,34%		
Shoham / DEF	2003,67	30,53%		

Tabela 16 – Ajuste de modelo do CASO 3A2 (Vazão de líquido de referência: 1535 m³/d)

Correlação (Vert/ Hor)	Vazão de Líquido Simulada (m³/d)	Erro (%)	Vazão de Líquido (m³/d) após ajuste dP/dL=1.073 / dT/dL=0.85	Erro (%) após ajuste
HB / DEF	2073,25	35,07%		
HB / BBP	1193,4	-22,25%		
BB / DEF	1891,76	23,24%	1536,91	0,13%
BB / BBP	1177,47	-23,29%		
Shoham / Shoham	1254,75	-18,26%		
BB / BB	1119,71	-27,05%		
BB / Shoham	1284,79	-16,30%		
DR / Shoham	1225,49	-20,16%		
DR / DEF	1970,05	28,34%		
Shoham / DEF	2003,67	30,53%		

As Tabela 15 e Tabela 16 apresentam o ajuste de simulação para o CASO 3, aplicado ao ponto operacional A.

No CASO 3, entre a Arvore de Natal Molhada e a válvula choke, existe transição de escoamento horizontal e vertical. Cabe mencionar que para todos os casos com

mudança de inclinação, assumiu-se um ângulo de transição de 20° para seleção das correlações, significando que até um ângulo de 20° usa-se a correlação “horizontal” e acima, adota-se a correlação “vertical”.

Para o CASO 3, torna-se necessário combinar modelos de escoamento adequados. Assim, na modelagem 3A1, a diferença entre a vazão simulada e a vazão medida, após ajuste, é de -0,28% para a combinação dos modelos de Beggs e Brill (1973) no trecho vertical e Shoham (2006) no trecho horizontal.

Na modelagem 3A2, a fim de avaliar a sensibilidade da escolha das correlações em relação ao caso 3A1, optou-se pela combinação de Beggs e Brill (1973) no trecho vertical e Dukler, Eaton & Flanigan (1969) no trecho horizontal, resultando em um erro de 0,13% após ajuste, na vazão simulada em relação a vazão medida no ponto operacional A.

Os modelos 2B1 e 3B2 utilizando a referência do ponto B, e o resumo de ajustes encontra-se nas Tabela 17 Tabela 18, para diferentes combinações entre modelos de escoamento horizontal e vertical.

Tabela 17 – Ajuste de modelo do CASO 3B1 (Vazão de líquido de referência: 1341 m³/d)

Correlação (Vert/ Hor)	Vazão de Líquido Simulada (m ³ /d)	Erro (%)	Vazão de Líquido (m ³ /d) após ajuste dP/dL=0.98 / dT/dL=0.82	Erro (%) após ajuste
HB / DEF	1954,2	45,71%		
HB / BBP	1119,2	-16,55%		
BB / DEF	1768,32	31,85%		
BB / BBP	1104,71	-17,63%		
Shoham / Shoham	1162,24	-13,34%		
BB / BB	1055,87	-21,27%		
BB / Shoham	1193,06	-11,04%	1.342,64	0,11%
DR / Shoham	1129,03	-15,82%		
DR / DEF	1849,39	37,90%		
Shoham / DEF	1885,46	40,59%		

Tabela 18 – Ajuste de modelo do CASO 3B2 (Vazão de líquido de referência: 1341 m³/d)

Correlação (Vert/ Hor)	Vazão de Líquido Simulada (m ³ /d)	Erro (%)	Vazão de Líquido (m ³ /d) após ajuste dP/dL=1.076 / dT/dL=0.80	Erro (%) após ajuste
HB / DEF	1954,2	45,71%		
HB / BBP	1119,2	-16,55%		
BB / DEF	1768,32	31,85%	1.345,99	0,36%
BB / BBP	1104,71	-17,63%		
Shoham / Shoham	1162,24	-13,34%		
BB / BB	1055,87	-21,27%		
BB / Shoham	1193,06	-11,04%		
DR / Shoham	1129,03	-15,82%		
DR / DEF	1849,39	37,90%		
Shoham / DEF	1885,46	40,59%		

No caso 3B1, o menor erro é 0,11% após ajuste, obtido com a combinação de Beggs e Brill (1973) no trecho vertical e Shoham (2006) no trecho horizontal, enquanto no caso 3B2, o menor erro simulado é de 0,36% após ajuste, para a combinação Beggs e Brill (1973) e Dukler, Eaton & Flanigan (1969), nos trechos vertical e horizontal respectivamente.

Semelhante ao CASO 3, o CASO 4 também apresenta forte sensibilidade a escolha das correlações de escoamento multifásico. O resumo dos ajustes pode ser visto a seguir nas Tabela 19, Tabela 20, Tabela 21 e Tabela 22.

Tabela 19 – Ajuste de modelo do CASO 4A1 (Vazão de líquido de referência: 1535 m³/d)

Correlação (Vert/ Hor)	Vazão de Líquido Simulada (m ³ /d)	Erro (%)	Vazão de Líquido (m ³ /d) após ajuste dP/dL=1 / dT/dL=1	Erro (%) após ajuste
HB / DEF	1797,45	17,10%		
HB / BBP	1533,21	-0,12%	Sem ajuste	
BB / DEF	1577,92	2,80%		
BB / BBP	1383,09	-9,90%		
Shoham / Shoham	2452,77	59,79%		
BB / BB	1383,09	-9,90%		
BB / Shoham	2087,73	36,01%		
DR / Shoham	2528,06	64,70%		
DR / DEF	1714,04	11,67%		
Shoham / DEF	1643,23	7,05%		

Tabela 20 – Ajuste de modelo do CASO 4A2 (Vazão de líquido de referência: 1535 m³/d)

Correlação (Vert/ Hor)	Vazão de Líquido Simulado (m ³ /d)	Erro (%)	Vazão de Líquido (m ³ /d) após ajuste dP/dL=1.08 / dT/dL=1	Erro (%) após ajuste
HB / DEF	1797,45	17,10%		
HB / BBP	1533,21	-0,12%		
BB / DEF	1577,92	2,80%	1529,86	-0,33%
BB / BBP	1383,09	-9,90%		
Shoham / Shoham	2452,77	59,79%		
BB / BB	1383,09	-9,90%		
BB / Shoham	2087,73	36,01%		
DR / Shoham	2528,06	64,70%		
DR / DEF	1714,04	11,67%		
Shoham / DEF	1643,23	7,05%		

As Tabela 19 e Tabela 20 apresentam o ajuste de simulação para o CASO 4, aplicados ao ponto operacional A.

No caso 4A1, o menor erro é -0,12% mesmo anterior ao ajuste de dPdL e por isso não é requerido ajuste adicional. Este resultado foi obtido com a combinação de correlações Hagedorn e Brown (1965) no trecho vertical e Beggs, Brill e Palmer (1979) no trecho horizontal. Já no caso 4A2, criado para avaliar a sensibilidade das correlações em relação ao caso 4A1, o menor erro é -0,33% (após ajuste), com a combinação de correlações Beggs e Brill (1973) no trecho vertical e Dukler, Eaton & Flanigan (1969) no trecho horizontal.

O resumo de ajustes dos modelos 4B1 e 4B2, utilizando a referência do ponto B, encontra-se nas Tabela 21 e Tabela 22, para diferentes combinações entre modelos de escoamento horizontal e vertical.

Tabela 21 – Ajuste de modelo do CASO 4B1

Correlação (Vert/ Hor)	Vazão de Líquido Simulada (m ³ /d)	Erro (%)	Vazão de Líquido (m ³ /d) após ajuste dP/dL=1.03 / dT/dL=1	Erro (%) após ajuste
HB / DEF	1732,59	29,19%		
HB / BBP	1490,19	11,11%		
BB / DEF	1516,69	13,09%		
BB / BBP	1360,62	1,45%	1345,7	0,34%
Shoham / Shoham	2324,8	73,34%		
BB / BB	1360,62	1,45%		
BB / Shoham	1516,95	13,11%		
DR / Shoham	2415,06	80,07%		
DR / DEF	1645,56	22,70%		
Shoham / DEF	1564,41	16,65%		

Tabela 22 – Ajuste de modelo do CASO 4B1

Correlação (Vert/ Hor)	Vazão de Líquido Simulada (m ³ /d)	Erro (%)	Vazão de Líquido (m ³ /d) após ajuste dP/dL=1.05 / dT/dL=1	Erro (%) após ajuste
HB / DEF	1732,59	29,19%		
HB / BBP	1490,19	11,11%		
BB / DEF	1516,69	13,09%	1336,21	-0,37%
BB / BBP	1360,62	1,45%		
Shoham / Shoham	2324,8	73,34%		
BB / BB	1360,62	1,45%		
BB / Shoham	1516,95	13,11%		
DR / Shoham	2415,06	80,07%		
DR / DEF	1645,56	22,70%		
Shoham / DEF	1564,41	16,65%		

Conforme Tabela 21 e Tabela 22, no caso 4B1, o menor erro é 0,34% (após ajuste), com a combinação de correlações Beggs e Brill (1973) no trecho vertical e Beggs, Brill e Palmer (1979) no trecho horizontal. No caso 4B2, o menor erro é -0,37% (após ajuste), com a combinação de correlações Beggs e Brill (1973) e Dukler, Eaton & Flanigan (1969), nos trechos vertical e horizontal, respectivamente.

Os modelos ajustados conforme apresentado anteriormente estão disponíveis para simular os pontos selecionados conforme Tabela 1 e avaliação de precisão caso a caso.

Concluindo essa etapa de comparação e seleção de modelos de escoamento e considerando as diferentes situações encontradas em uma instalação de produção,

observa-se a viabilidade de se obter simulações que proporcionam diferenças nas vazões simuladas e reais, menores que 0,4%, quando aplicadas aos dados operacionais (Pontos de ajuste).

Deve-se levar em consideração que os modelos assumem hipóteses, tais como:

- Fluido black-oil representativo
- Correlações selecionadas para um único ponto, representativas para uma faixa operacional do sistema
- Regime permanente
- Propriedades do escoamento dependentes apenas da pressão e temperatura
- Condições de contorno constantes (perfil térmico e de velocidade do meio, propriedades térmicas dos materiais e do meio)
- BSW e RGO_f assumidos como constantes no intervalo entre os pontos operacionais A e B

Essas condições são simplificações em relação a um sistema de produção real. Dessa forma, as simulações foram consideradas satisfatórias para a finalidade deste trabalho, porém com limitações já conhecidas na própria concepção da técnica.

3.8. DEFINIÇÃO DOS CASOS A SEREM SIMULADOS POR MACHINE LEARNING

Adotou-se um *dataset* contendo dados úteis dos cinco primeiros dias de produção, contendo vazão líquida (Figura 19), pressões em superfície (Figura 21) e temperatura à jusante do choke (Figura 35). 99% desse período foi considerado para treinamento da rede neural (RNA) e 1% para teste, apenas para sensibilidade do R². O teste estatístico real usará os resultados preditos pela RNA (simulação) comparada aos valores medidos (referência).




Figura 35 – Histórico de temperatura à jusante do choke (T4)

A RNA possui diversas configurações a critério do analista, normalmente de forma empírica:

- Número de camadas ocultas
- Número de neurônios nas camadas ocultas
- Número máximo de iterações
- Tolerância (erro aceitável)
- Solver: Algoritmo de Otimização
- Função de Ativação
- Taxa de aprendizado

Foram estabelecidas 4 modelagens em RNA, todas com apenas 1 camada oculta, conforme a seguir:

1. RNA_P4_P5: Modelagem com 2 variáveis de entrada
 - a. P4 – Pressão à jusante do choke
 - b. P5 – Pressão montante do Separador
 - c. 10 neurônios na camada oculta
2. RNA_P4_P5_T4_5N: Modelagem com 3 variáveis de entrada

- a. P4 – Pressão à jusante do choke;
 - b. P5 – Pressão montante do Separador
 - c. T4 – Temperatura à jusante do choke de produção
 - d. 5 neurônios na camada oculta
3. RNA_P4_P5_T4_10N: Modelagem com 3 variáveis de entrada
- a. P4 – Pressão à jusante do choke;
 - b. P5- Pressão montante do Separador;
 - c. T4 – Temperatura à jusante do choke de produção
 - d. 10 neurônios na camada oculta
4. RNA_P4_P5_T4_15N: Modelagem com 3 variáveis de entrada
- a. P4 – Pressão à jusante do choke;
 - b. P5- Pressão montante do Separador;
 - c. T4 – Temperatura à jusante do choke de produção
 - d. 15 neurônios na camada oculta

Uma vez obtida as RNAs treinadas com um R^2 satisfatório, estas são usadas para prever a vazão de líquido nos próximos 30, 60, 90, 120, 180 e 325 dias.

Finalmente, as vazões estimadas pelas RNAs foram comparadas às vazões medidas, para análise estatística.

3.9. AJUSTE DO MODELO MACHINE LEARNING

A modelagem desenvolvida neste trabalho foi elaborada com uso da biblioteca Scikit-Learn para Machine Learning em Python (PEDREGOSA, 2011).

Inicialmente foi realizado um estudo das variáveis disponíveis (Figura 19, Figura 20, Figura 21 e Figura 35), de forma a achar uma tendência satisfatória entre as pressões, temperaturas e vazões de líquido.

Uma posição favorável, selecionada para explorar o potencial da técnica, está representada na Figura 30, no caso 4, na forma da tubulação que transita entre a válvula choque e o vaso separador. Essa posição é favorável por estar à bordo, seca, em local de relativo fácil acesso, manutenção e monitoramento. A pressão do escoamento na entrada e saída são nomeadas por P4 e P5, respectivamente, e a temperatura na entrada, nomeada como T4.

Conforme Figura 36 e Figura 37, a diferença de pressão (P4-P5) apresentou uma boa correlação com a vazão de líquido.




Figura 36 – Análise preliminar das variáveis P4 e P5, indicando boa correlação com a vazão




Figura 37 – Análise preliminar das variáveis P4 e P5, indicando boa correlação com a vazão

Conforme Figura 38, a temperatura à jusante do choke (T4) apresentou uma boa correlação com a vazão de líquido.




Figura 38 – Análise preliminar da variável T4, indicando boa correlação com a vazão

Conforme conceito lógico da Navalha de Ockham (1341), deve-se preferir o modelo com maior simplicidade. A avaliação inicial é que o modelo sugerido RNA_P4_P5 é suficientemente simples, com uso de apenas duas variáveis de entrada: P4 e P5 e obtendo a vazão de líquido. Além dessa abordagem, a adição da temperatura (T4) visa observar o comportamento dos resultados.

Foi realizada a normalização dos dados de entrada do *dataset* (5 dias iniciais de dados), forma recomendada para proceder com o algoritmo de ajuste da rede neural MLP (*backpropagation*).

A normalização é conforme formulação a seguir:

$$X_{norm} = \frac{(x - \bar{x})}{\sigma} \quad (40)$$

X_{norm} – Dados de entrada normalizados

\bar{x} – Média dos dados de entrada

σ – Desvio padrão

x – Dados de entrada originais

X normalizado é igual a razão entre o valor de x original subtraído da média e o desvio padrão.

Os dados normalizados são então divididos em dois conjuntos, um com 99% do *dataset* para treinar a RNA e 1% para teste de performance. Essa estratégia foi adotada para usar praticamente todo o *dataset* como treinamento e deixar os dados de predição futura para comparação e análise com os dados medidos.

As redes MLP RNA possuem a seguinte configuração:

- Número máximo de iterações = 1000
- Tolerância do treinamento = 0,0001
- Método matemático solucionador = LBFGS (Algoritmo de Broyden–Fletcher–Goldfarb–Shanno de memória limitada)

- Função de ativação = “relu” (rectified linear unit function), retorna $f(x) = \max(0, x)$
- Taxa de aprendizado = “adaptive” (taxa de aprendizado constante no início, enquanto o treinamento continua reduzindo o erro. Cada vez que duas épocas consecutivas falham em diminuir o erro, a taxa de aprendizado atual é dividida por 5).

Após configurada a RNA, aplica-se o *dataset* de treinamento. Essa etapa consiste em ajustar os pesos das sinapses respeitando a tolerância definida através de algoritmo *backpropagation*.

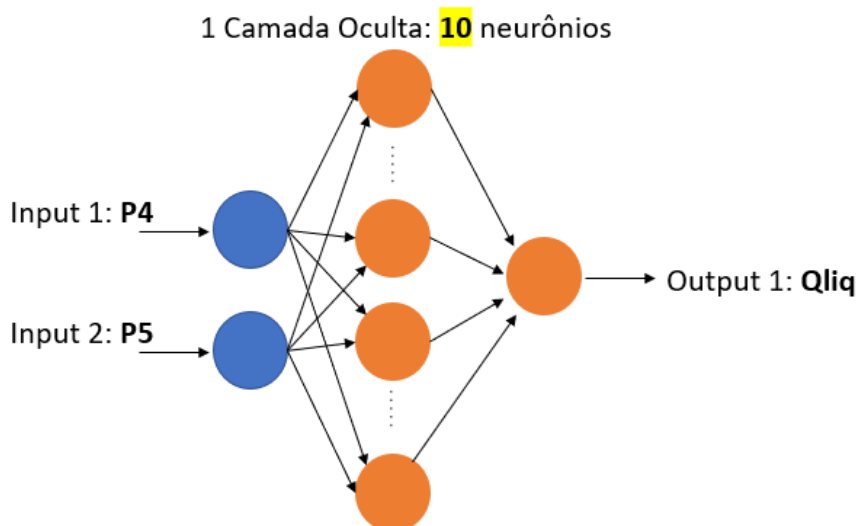


Figura 39 – Esquema simplificado da RNA_P4_P5 configurada

Com a RNA treinada, pode-se estimar as vazões de líquido conforme exposto na seção 3.8.

A Figura 39 é apenas um exemplo para o caso da RNA_P4_P5. Os demais modelos RNA seguem o mesmo esquema, com adição de uma 3ª variável de entrada (T4) e mudança do número de neurônios na única camada oculta.

4. RESULTADOS

4.1. AVALIAÇÃO PRELIMINAR DOS PERFIS DE PROPRIEDADES DO ESCOAMENTO

Inicialmente, para fins de avaliação das propriedades ao longo do escoamento (perfis de propriedades), assumimos o ponto 14 (Tabela 1), como situação de comparação. A seguir tem-se gráficos com a comparação dos casos.

O CASO 1, modelo entre o reservatório e o PDG, apresenta os perfis conforme Figura 40.

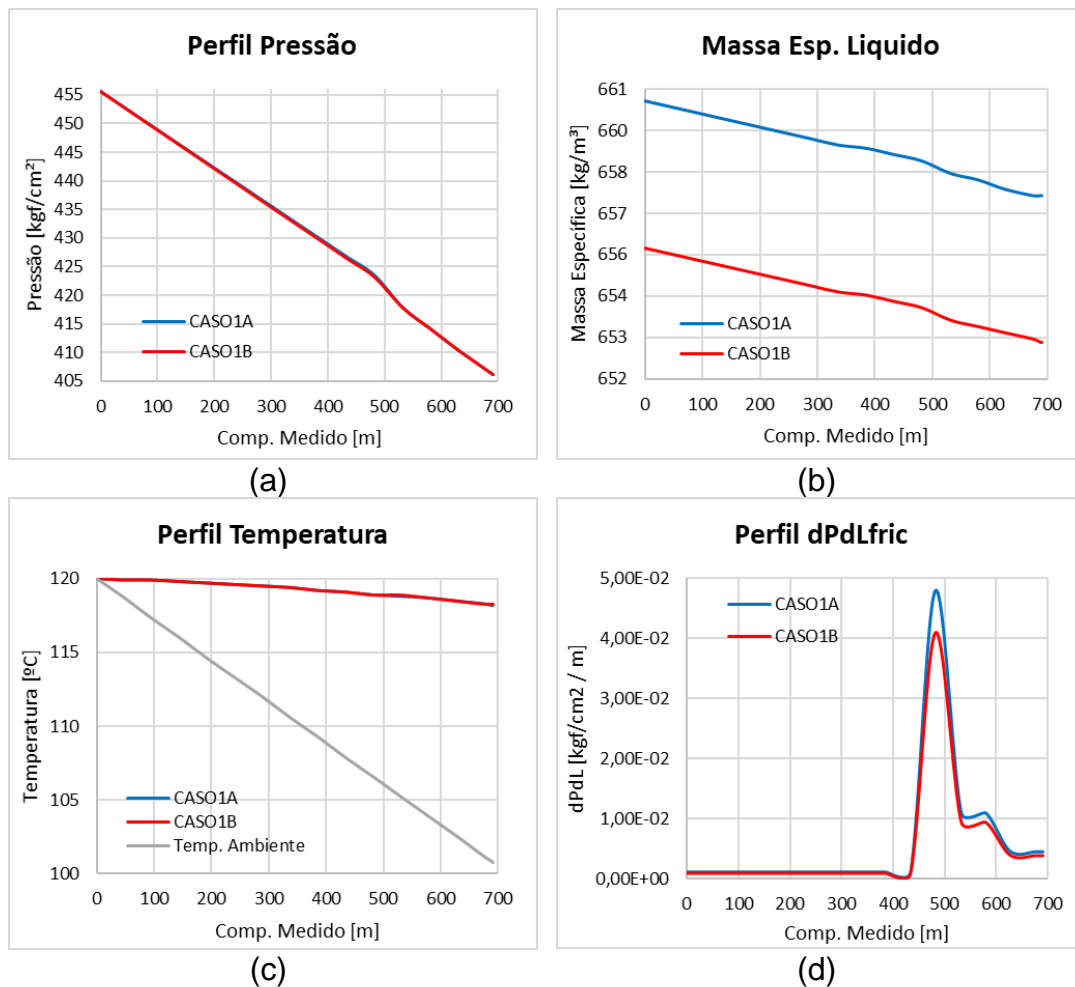


Figura 40 – Comparação de perfil de propriedades ao longo do escoamento dos casos 1A e 1B. (a) Pressão; (b) Massa específica do líquido; (c) Temperatura e (d) $dPdL_{\text{fricção}}$

A Tabela 2 apresenta pequenas diferenças nas propriedades de reservatório, Pres e IP, nos pontos A e B. O mesmo ocorre para o BSW. Essas diferenças que ocasionam as alterações nos perfis.

A Figura 40 apresenta os perfis de algumas propriedades ao longo do escoamento, destacando que o menor BSW no Ponto B, usado no ajuste do caso 1B, gera as diferenças na massa específica do líquido Figura 40 (b) e também no fator de fricção dPdL, Figura 40 (d). Cabe destacar que o pico no valor do fator de fricção dPdLfric é atribuído a uma mudança de diâmetro da tubulação (coluna de produção), que ocasiona aumento da velocidade de escoamento e conseqüentemente aumento da perda de carga. A diferença no perfil de pressão e temperatura é pequena, conforme Figura 40 (a) e (c).

O CASO 2, modelo do poço, entre PDG e ANM, apresenta os perfis conforme Figura 41.

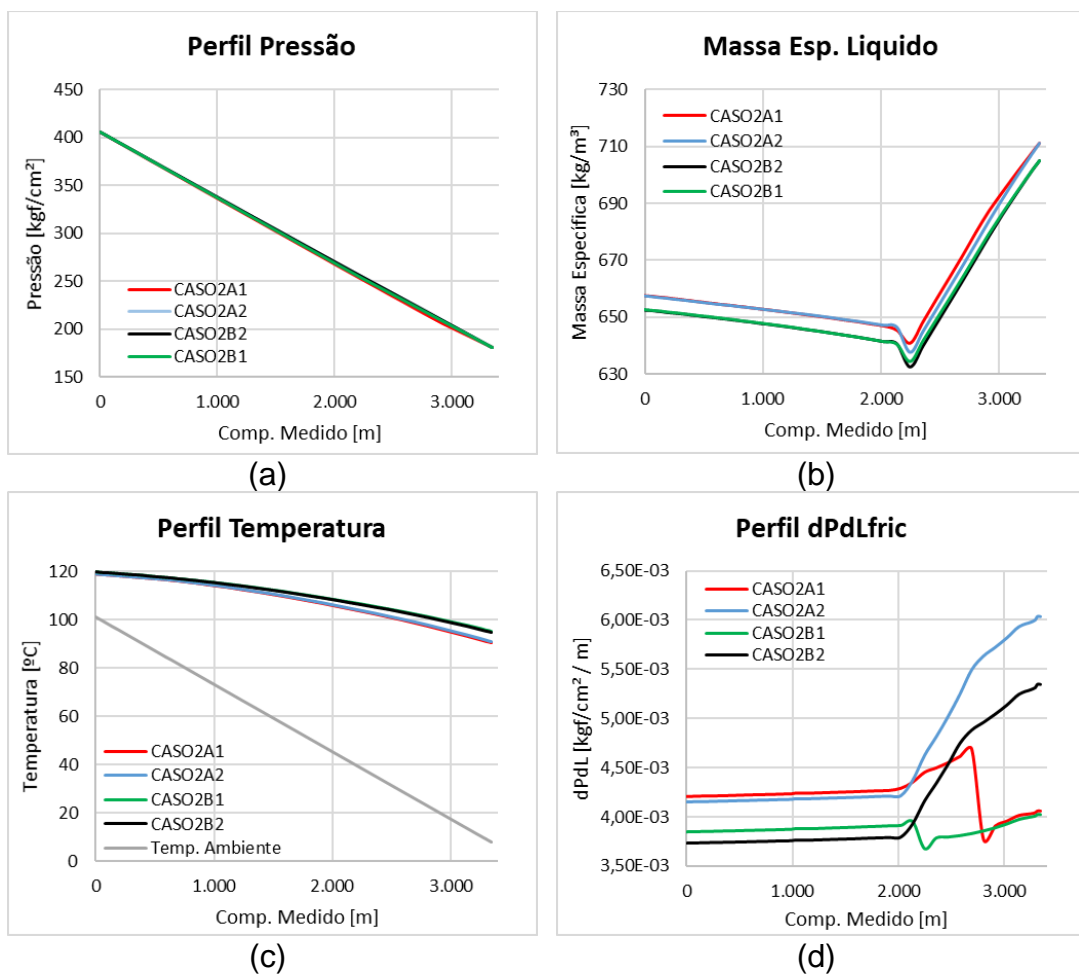


Figura 41 – Comparação de perfil de propriedades ao longo do escoamento dos casos 2A1, 2A2, 2B1 e 2B2. (a) Pressão; (b) Massa específica do líquido; (c) Temperatura e (d) dPdLfricção

Na Figura 41 (b), semelhante ao observado no CASO1A/B, tem-se uma redução no perfil de massa específica justificado pela atualização para um BSW menor no ponto B (CASO2B1 e CASO2B2). O perfil de temperatura do fluido, Figura 41 (c), apresenta uma pequena alteração, influenciado pelo transiente de aquecimento nos cerca de 3400m de rocha perfurada (CASO2B1 e 2B2 mais quente).

Conforme Figura 41 (d), o dP_{dL} fricção sofre forte variação após a pressão de escoamento atingir a pressão de saturação no escoamento. Neste ponto ocorre a liberação de gás, iniciando o escoamento multifásico e a partir deste ponto teremos a influência do tratamento numérico dado pelas correlações multifásicas selecionadas caso a caso, que justificam os resultados distintos. Apesar dos diferentes modelos, o perfil de pressão, Figura 41 (a), é praticamente idêntico, pois honra-se o PDG e o TPT como condições de contorno, obtendo a vazão que ajusta essa condição.

O CASO 3, modelo do trecho submarino entre ANM e plataforma, apresenta os perfis conforme Figura 42.

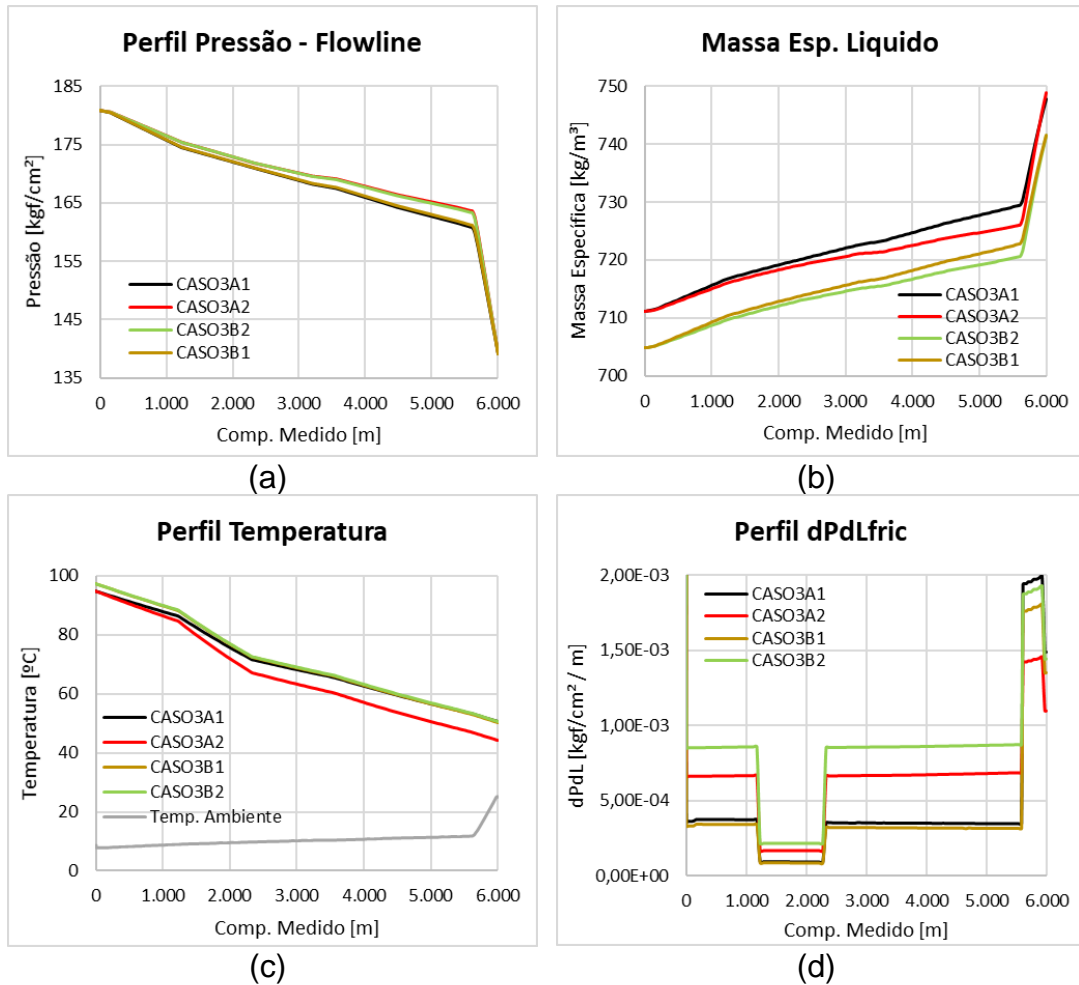


Figura 42 – Comparação de perfil de propriedades ao longo do escoamento dos casos 3A1, 3A2, 3B1 e 3B2. (a) Pressão; (b) Massa específica do líquido; (c) Temperatura e (d) dPdLfricção

A variável de saída da simulação é a vazão de líquido, honrando as pressões de entrada e saída do modelo. Esta condição implica em perfis de pressão, temperatura e massa específica de líquido com pouca variação para o mesmo ponto de ajuste, ocorrendo alteração devido principalmente à variação do BSW entre os pontos de ajuste A e B, Figura 42 (a), (b) e (c).

A Figura 42 (d) apresenta o comportamento da variável dPdLfricção, com forte influência da subida do riser, onde ocorre redução da pressão, resultando em expansão do gás, aumento do holdup de gás, e conseqüentemente da velocidade superficial das fases. Entre aproximadamente 1200 e 2200 metros, ocorre uma redução do dPdLfric devido a ser um trecho de maior dimensão da *flowline*, o que implica na redução de velocidade local e conseqüentemente menor perda de carga por fricção.

O CASO 4, modelo no trecho na plataforma entre o ponto a jusante do choke e a entrada do separador de teste, apresenta os perfis conforme Figura 43.

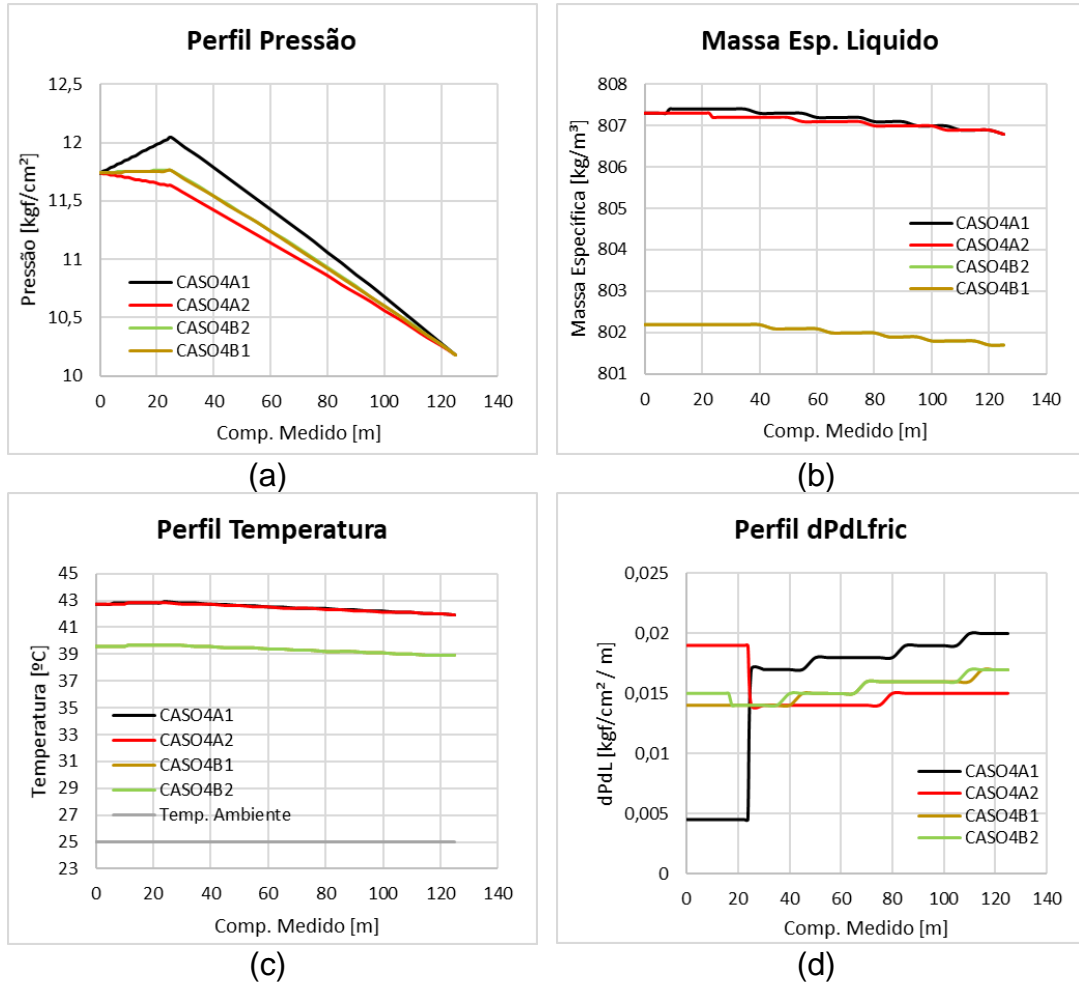


Figura 43 – Comparação de perfil de propriedades ao longo do escoamento dos casos 4A1, 4A2, 4B1 e 4B2. (a) Pressão; (b) Massa específica do líquido; (c) Temperatura e (d) dPdLfricção

Semelhante ao observado no CASO 3, no CASO 4 o cálculo para obtenção da vazão de líquido, honrando as pressões de entrada e saída do modelo, implica em perfis de temperatura e massa específica de líquido com pouca variação para o mesmo ponto de ajuste, ocorrendo alteração devido principalmente à variação do BSW entre os pontos de ajuste A e B, Figura 43 (b) e (c).

A condição de simulação e as correlações multifásicas selecionadas resultaram em variação observável no perfil de pressão, Figura 43 (a), entre os casos, ajustados para o mesmo ponto, vide CASO4A1 e CASO 4A2.

A Figura 43 (d) apresenta o comportamento da variável $dP_{dLfricção}$, com forte variação, devido às correlações selecionadas, e o tratamento ao cálculo de perda de carga dada por cada uma delas.

4.2. RESULTADOS EM ABORDAGEM DE SIMULAÇÃO MULTIFÁSICA

Os resultados simulados por ocasião da preparação dos modelos (Tabela 9 a Tabela 22), aplicados aos dados da Tabela 1, serão mostrados por gráficos de valor predito versus valor esperado. O valor predito é o próprio resultado do modelo (simulação) e o dado esperado é conforme a medição de referência também disponível na Tabela 1.

O erro percentual da vazão predita (simulada) em relação a vazão medida (dado de referência) é calculado conforme equação (39).

Os casos 1A e 1B, gerados a partir de modelos entre o reservatório (canhoneado) e o PDG (P1) apresentam os resultados conforme Figura 44. As diferenças percentuais estão na Figura 45.




Figura 44 – Valor de vazão de líquido predita e esperada para os casos 1A e 1B




Figura 45 – Erro percentual ao longo do tempo para os casos 1A e 1B

Os resultados para os casos 1A e 1B indicam que há uma tendência crescente da vazão predita em modelos que usam as propriedades de reservatório (Pres e IP) como dados de entradas constantes. Isto ocorre, pois estes modelos não capturam uma possível redução de Pres e/ou IP, podendo superestimar a vazão líquida simulada. Observa-se a necessidade de ajustes no modelo periodicamente, dependendo da característica do poço e do reservatório. Para o poço avaliado, há uma sugestão de ajuste a cada 30 dias aproximadamente, como visto no ajuste do caso 1B, com menores erros em relação ao caso 1A.

Os casos 2A1, 2A2, 2B1 e 2B2, gerados a partir de modelos de escoamento vertical ascendente no poço entre o PDG (P1) e o TPT (P2), apresentam os resultados conforme Figura 46. As diferenças percentuais estão na Figura 47.

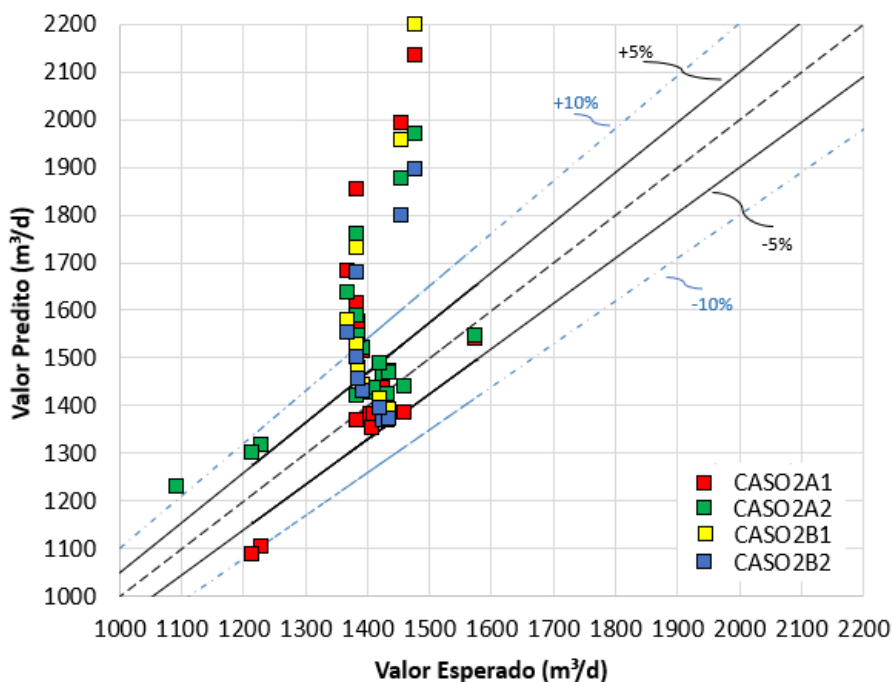


Figura 46 – Valor de vazão de líquido predita e esperada para os casos 2A1, 2A2, 2B1 e 2B2




Figura 47 – Erro percentual ao longo do tempo para os casos 2A1, 2A2, 2B1 e 2B2

Conforme observado nas Figura 46 e Figura 47, apesar do ajuste nos casos 2B1 e 2B2, todos os modelos apresentaram um incremento significativo e progressivo no erro após o dia 40. Este resultado sugere um aumento na perda de carga na coluna de produção, o que poderia ser um indício de incrustação por exemplo. Neste caso o

modelo VFM poderia indicar um desvio operacional, com necessidade de ajuste na modelagem ou escolha de outro modelo.

Na Figura 47, os modelos atualizados (CASO2B1 e CASO2B2) apresentaram menor erro, fruto do ajuste mais próximo ao ponto de verificação (Ponto 14). Os ajustes na correlação, fator dPdL, tempo de poço aberto, atualização de BSW e RGO_f se mostraram eficazes em reduzir erro na modelagem para o caso do trecho entre PDG e TPT.

A Figura 48 apresenta a diferença de pressão entre o PDG (P1) e TPT (P2) até o dia 100, onde é observado um incremento, sugestivo para incrustação na coluna de produção do poço.




Figura 48 – Pressões no PDG (P1) e TPT (P2) e diferença de pressão (P1 – P2) com aumento progressivo, sugestivo para formação de incrustação na coluna de produção.

Os casos 3A1, 3A2, 3B1 e 3B2, são modelos gerados a partir do escoamento no trecho de dutos submarino, tipicamente com grande extensão e considerável variação de pressão e temperatura, bem como das propriedades do fluido e do escoamento. Estes casos, definidos entre o TPT (P2) e o sensor à montante do *choke* na plataforma

Pmont_choke (P3), apresentam os resultados conforme Figura 49. As diferenças encontram-se na Figura 50.




Figura 49 – Valor de vazão de líquido predita e esperada para os casos 3A1, 3A2, 3B1 e 3B2




Figura 50 – Erro percentual ao longo do tempo para os casos 3A1, 3A2, 3B1 e 3B2

Conforme Figura 50, os primeiros dias apresentaram maior erro, possivelmente devido ao efeito transiente, observado anteriormente na Figura 25, onde ainda havia redução progressiva do BSW do poço e também explica a variação do diferencial de pressão (P2-P3) observado na Figura 51. O modelo do CASO 3A1 aparentemente foi mais sensível a esta variação.




Figura 51 –Pressões no TPT (P2) e na chegada na plataforma (P3) e diferença de pressão P2

O modelo do caso 3A1 apresentou maior erro inicialmente, porém, permaneceu com erros menores que 5% entre os dias 20 e 90. Existe um ponto com erro de 17% no dia 34,8, que foi interpretado como um ponto transiente, conforme pode ser confirmado na figura abaixo:




Figura 52 –Pressões no TPT (P2) e na chegada na plataforma (P3) em uma condição transiente no dia 34.8.

O modelo do caso 3A2 teve desempenho inferior quando comparado ao 3A1 e, após o dia 50, os erros ultrapassaram 10%. Já o modelo 3B2 apresenta erros menores que 5%, mostrando o potencial do ajuste periódico. O modelo 3B1 se manteve com desempenho semelhante ao modelo 3A1, com erros menores que 5% até o dia 80, e posteriormente o erro ultrapassou 10%, ponto sugestivo para novo ajuste.

A Figura 53 apresenta a variação de temperatura no TPT (T2) e na chegada da plataforma (T3) até o 40º dia, onde é possível observar um incremento na temperatura no TPT (T2) de 94 até cerca de 98°C. O modelo foi ajustado conforme ponto A, com uma temperatura de fluido constante na entrada dos casos 3A1 e 3A2 com 94,7 °C. Um modelo aplicando a variação na variável temperatura no TPT (T2) poderia acrescentar maior acurácia nos resultados.




Figura 53 – Temperatura medida no TPT (T2) e na chegada na plataforma (T3)

É esperado que um poço demore vários dias após a abertura inicial para aquecer a região perfurada (rocha) e gerar um gradiente térmico mais estável. Este fenômeno transiente impacta diretamente no perfil térmico e propriedades do escoamento. A partir do 50º dia aproximadamente, o perfil térmico torna-se mais estável.

Finalmente tem-se a avaliação para o caso 4, onde foi avaliada a variação de pressão apenas em pontos na plataforma. De uma forma geral, os resultados em todos os modelos são considerados satisfatórios, com erros menores que 10%, exceto para o ponto inicial que possivelmente teve uma influência de fenômeno transiente após a abertura do poço.

O ajuste no ponto B trouxe o modelo para erros menores que 5%, comprovando a necessidade de atualização do modelo com dados ao longo do tempo, de forma a melhorar a precisão. Este resultado indica a possibilidade para uma modelagem relativamente simples de VFM.




Figura 54 – Valor de vazão de líquido predita e esperada para os casos 4A1, 4A2, 4B1 e 4B2




Figura 55 – Erro percentual ao longo do tempo para os casos 4A1, 4A2, 4B1 e 4B2

A análise estatística dos resultados foi feita com base nos erros absoluto e percentual médio, conforme a seguir:

MAE (*Mean Absolute Error*) é a medida do erro absoluto médio entre os valores preditos (simulados) e os valores reais (medidos), e definido pela formulação a seguir:

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} = \frac{\sum_{i=1}^n |e_i|}{n} \quad (41)$$

y_i – i-ésimo valor predito (simulado)

x_i – i-ésimo valor real (medido)

e_i – i-ésimo erro

n – Número de valores comparados no conjunto de dados

MAPE (*Mean Absolute Percentage Error*) é a medida do erro absoluto percentual médio entre os valores preditos (simulados) e os valores reais (medidos), e definido pela formulação a seguir:

$$MAPE = 100\% \frac{1}{n} \sum_{i=1}^n \frac{|y_i - x_i|}{|x_i|} \quad (42)$$

A Tabela 23 apresenta o quadro resumo dos resultados dos casos analisados por simulação multifásica.

Tabela 23 – Quadro resumo de resultados

Caso	MAE - Mean Absolute Error Vazão de líquido (m³/d)	MAPE – Mean Absolute Percentage Error (%)
CASO1A	113,7	8,1
CASO1B	79,1	4,1
CASO2A1	172,0	12,5
CASO2A1(*)	70,3	5,5
CASO2A1(**)	360,9	25,4
CASO2B1	148,1	10,8
CASO2B1(*)	68,6	5,4
CASO2B1(**)	295,9	20,7
CASO2A2	133,9	9,7
CASO2A2(*)	47,8	3,7
CASO2A2(**)	293,7	20,7
CASO2B2	105,0	7,6
CASO2B2(*)	48,3	3,8
CASO2B2(**)	210,3	14,8
CASO3A1	75,5	5,8
CASO3B1	102,9	7,7
CASO3A2	116,7	8,4
CASO3B2	90,3	6,4
CASO4A1	88,0	6,5
CASO4B1	55,5	4,1
CASO4A2	83,9	6,1
CASO4B2	58,2	4,3

(*) Simulação excluindo o período em que os resultados sugerem que há presença de obstrução na coluna do poço.

(**) Simulação apenas com o período em que os resultados sugerem que há presença de obstrução na coluna do poço.

4.3. RESULTADOS EM ABORDAGEM POR REDES NEURAIS (MLP)

A seguir serão apresentados os resultados obtidos com a aplicação pela abordagem de medição de vazão virtual por Data Driven com uso de redes neurais, conforme as Figura 56 e Figura 57.

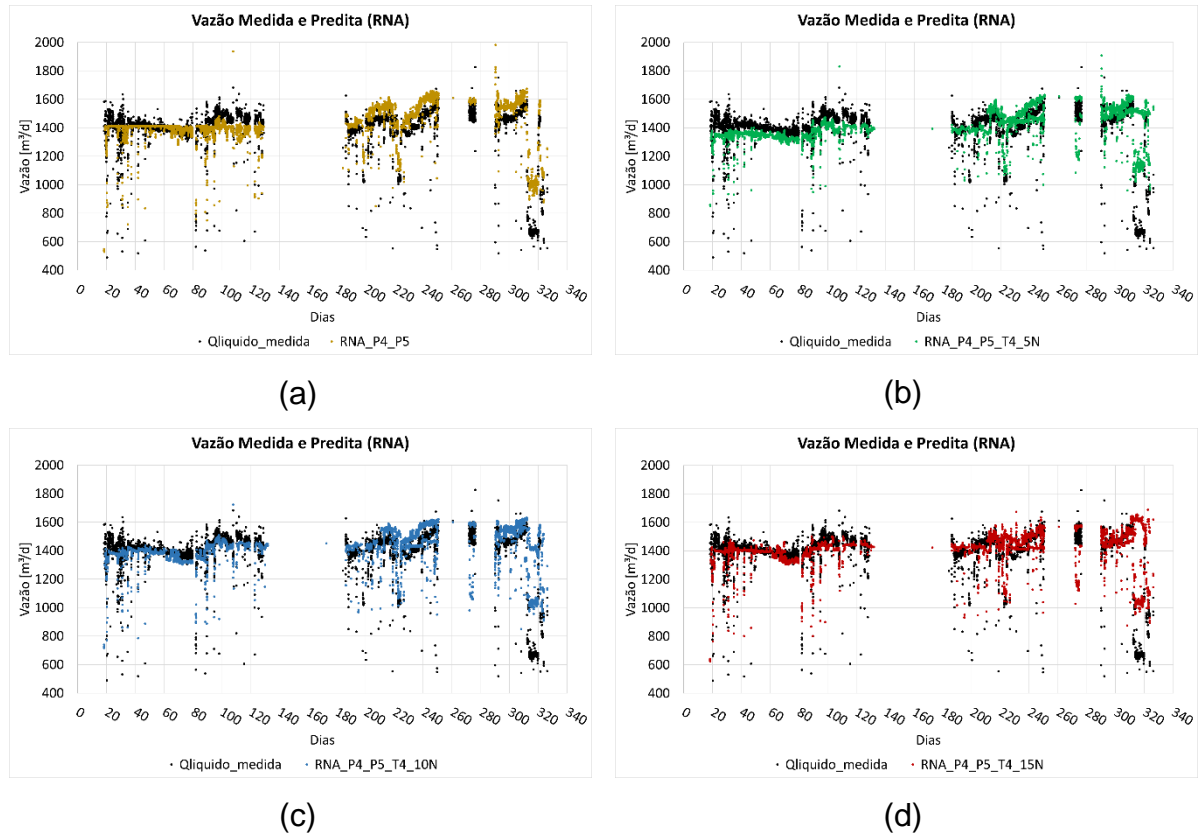
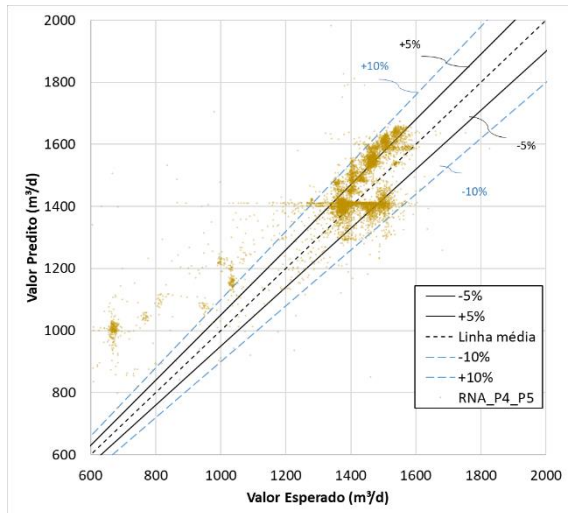



Figura 56 – Comparação de valores medidos e preditos: (a) RNA_P4_P5; (b) RNA_P4_P5_T4_5N; (c) RNA_P4_P5_T4_10N e (d) RNA_P4_P5_T4_15N

As Figura 56 e Figura 57 apresentam os resultados para todo o intervalo analisado. É possível observar um bom comportamento geral dos valores preditos em relação as vazões medidas, mesmo com a aplicação de apenas 5 dias de dados para treinamento com predição extrapolada para até 325 dias.


É possível notar uma melhora na aproximação dos dados simulados para os modelos mais complexos, vide melhor aproximação do modelo RNA_P4_P5_T4_15N. Apesar disso, todos os modelos apresentaram um distanciamento no caso da baixa vazão observada ao final do período.




(a)



(b)



(c)



(d)

Figura 57 – Resultado dos dados medidos e preditos: (a) RNA_P4_P5; (b) RNA_P4_P5_T4_5N; (c) RNA_P4_P5_T4_10N e (d) RNA_P4_P5_T4_15N

As Figura 58, Figura 59, Figura 60 e Figura 61 apresentam os resultados separados por período, para verificação do comportamento ao longo do tempo dos 4 modelos de RNA analisados.. Observada tendência de crescimento do erro ao longo do tempo, coerente com o distanciamento dos dados preditos, em relação a data de treinamento. Aparentemente este fator carrega uma influência sobre os resultados, neste caso, sugestivo para uma nova rodada de treinamento da RNA.

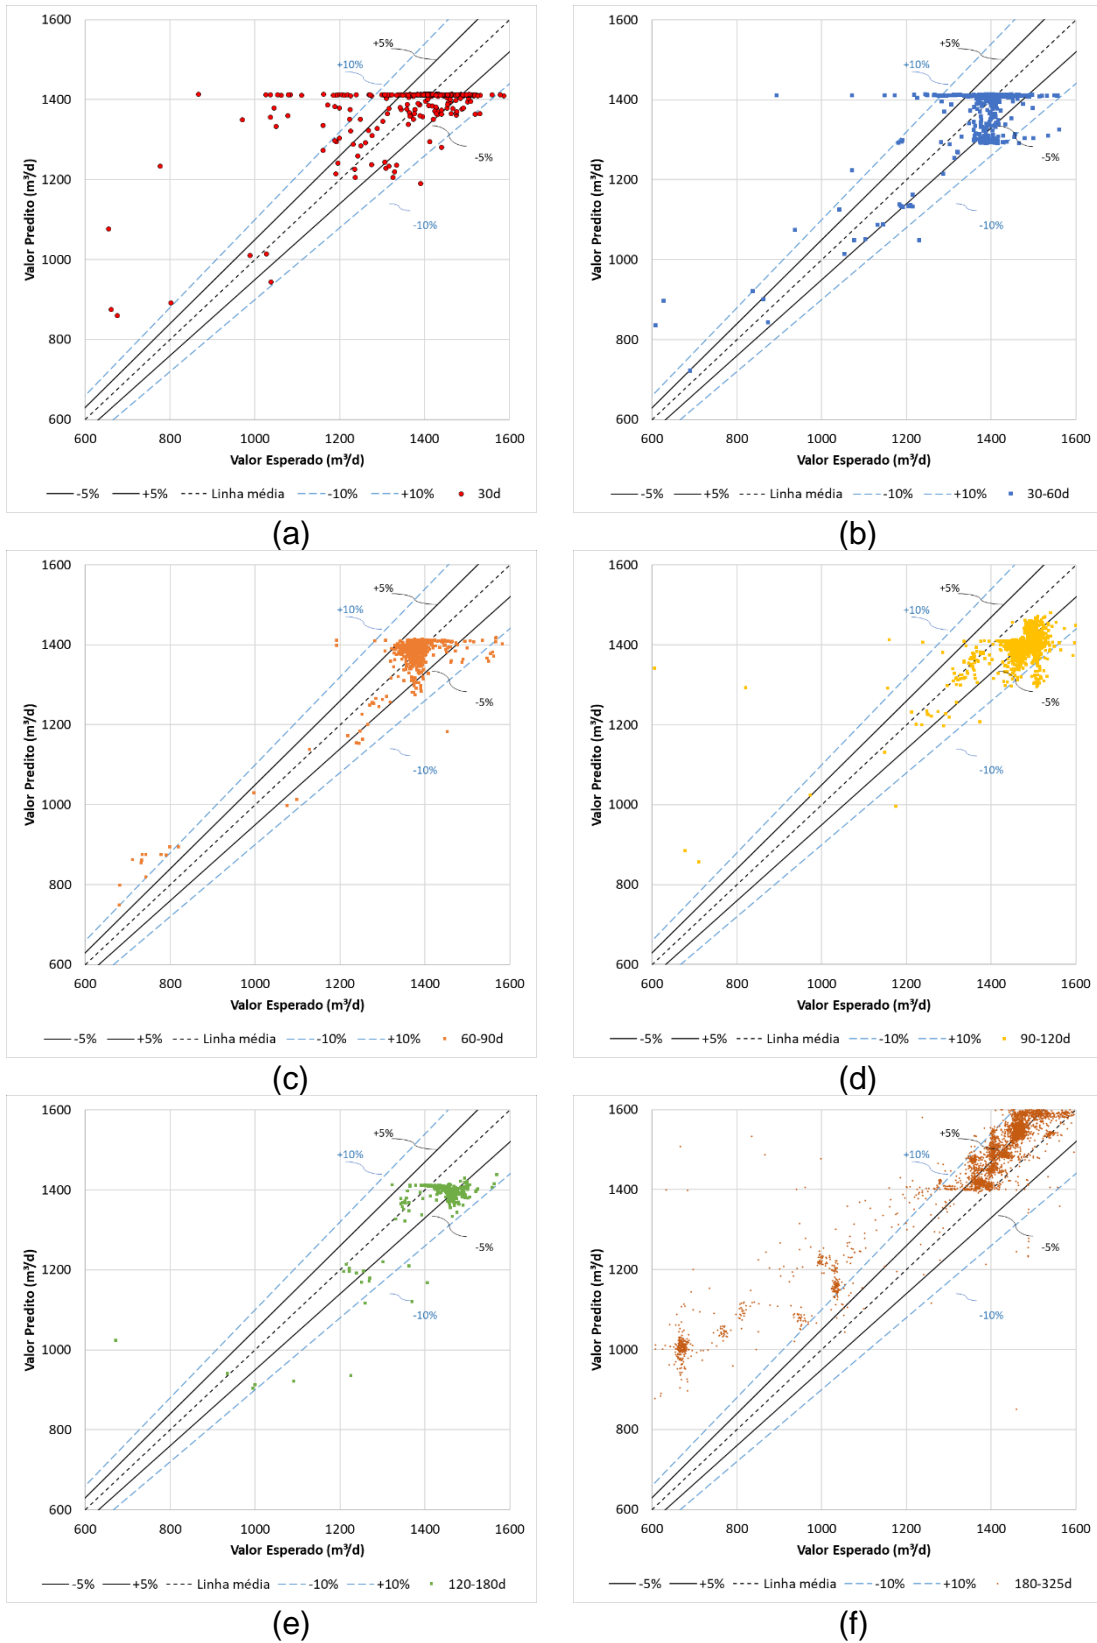


Figura 58 – Resultados da predição com uso de RNA_P4_P5 para (a) 0-30dias, (b) 30-60dias, (c) 60-90dias, (d) 90-120dias, (e)120-180dias e (f) 180-325dias

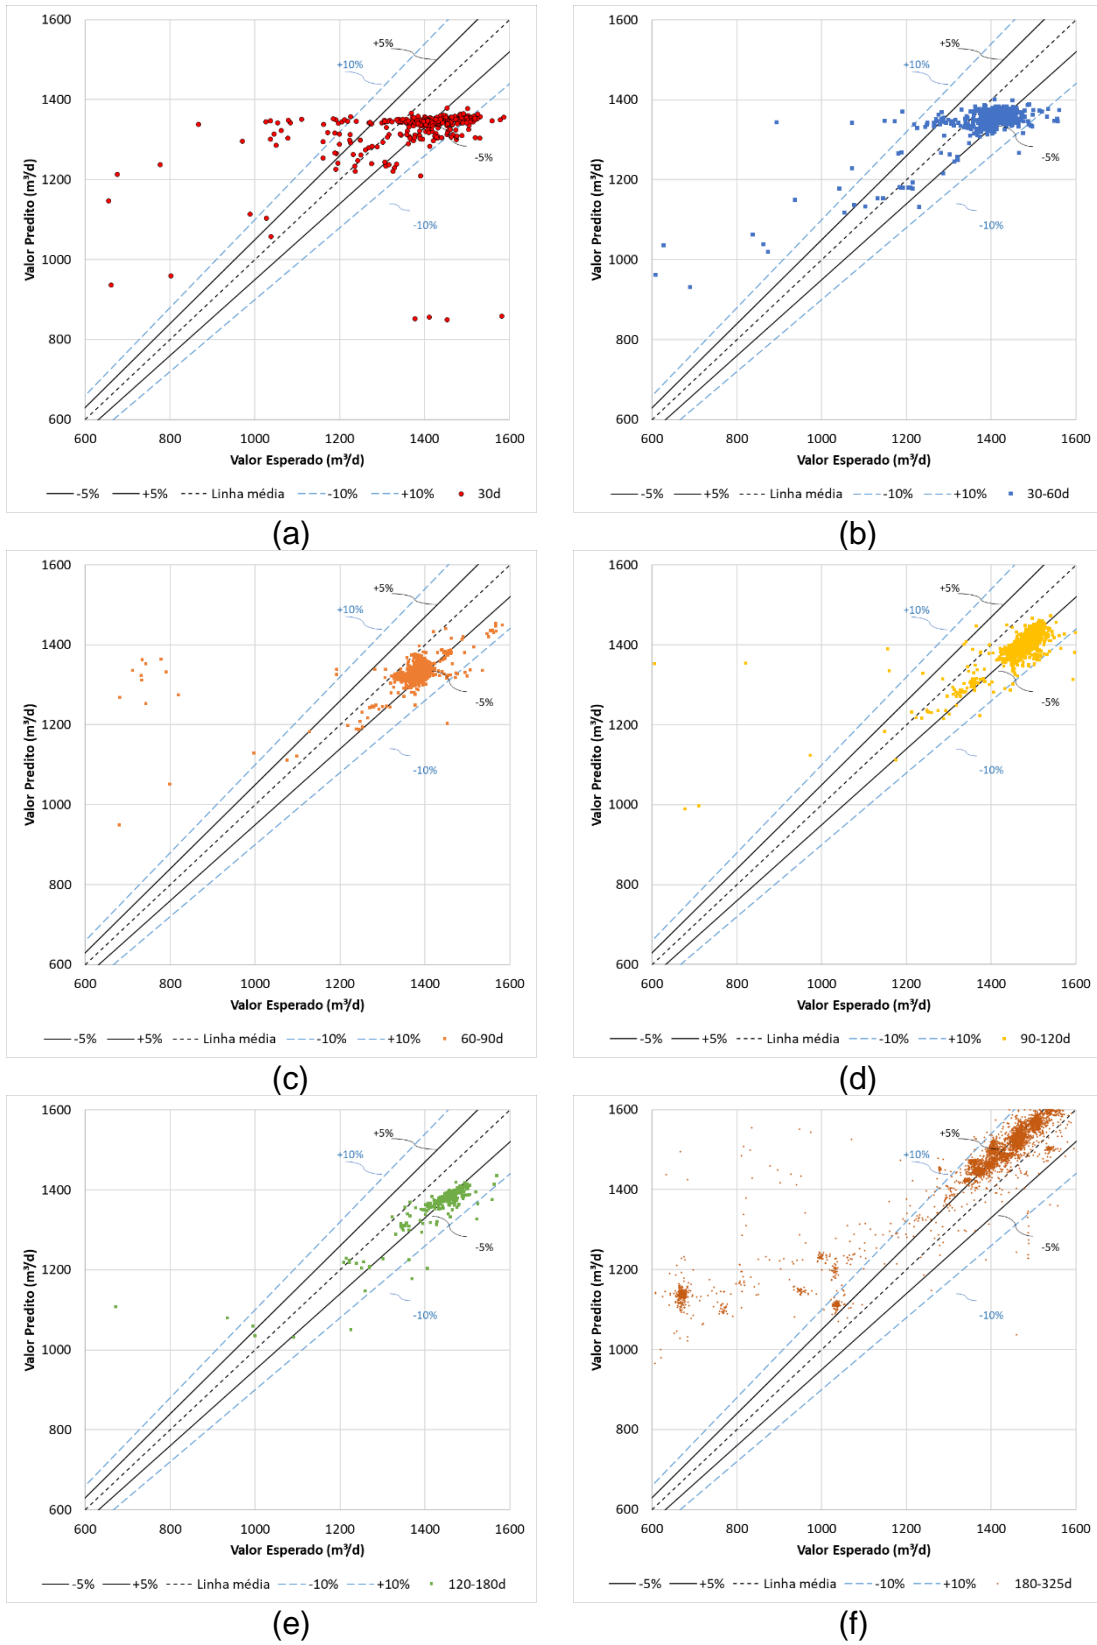


Figura 59 – Resultados da predição com uso de RNA_P4_P5_T4_5N para (a) 0-30dias, (b) 30-60dias, (c) 60-90dias, (d) 90-120dias, (e)120-180dias e (f) 180-325dias

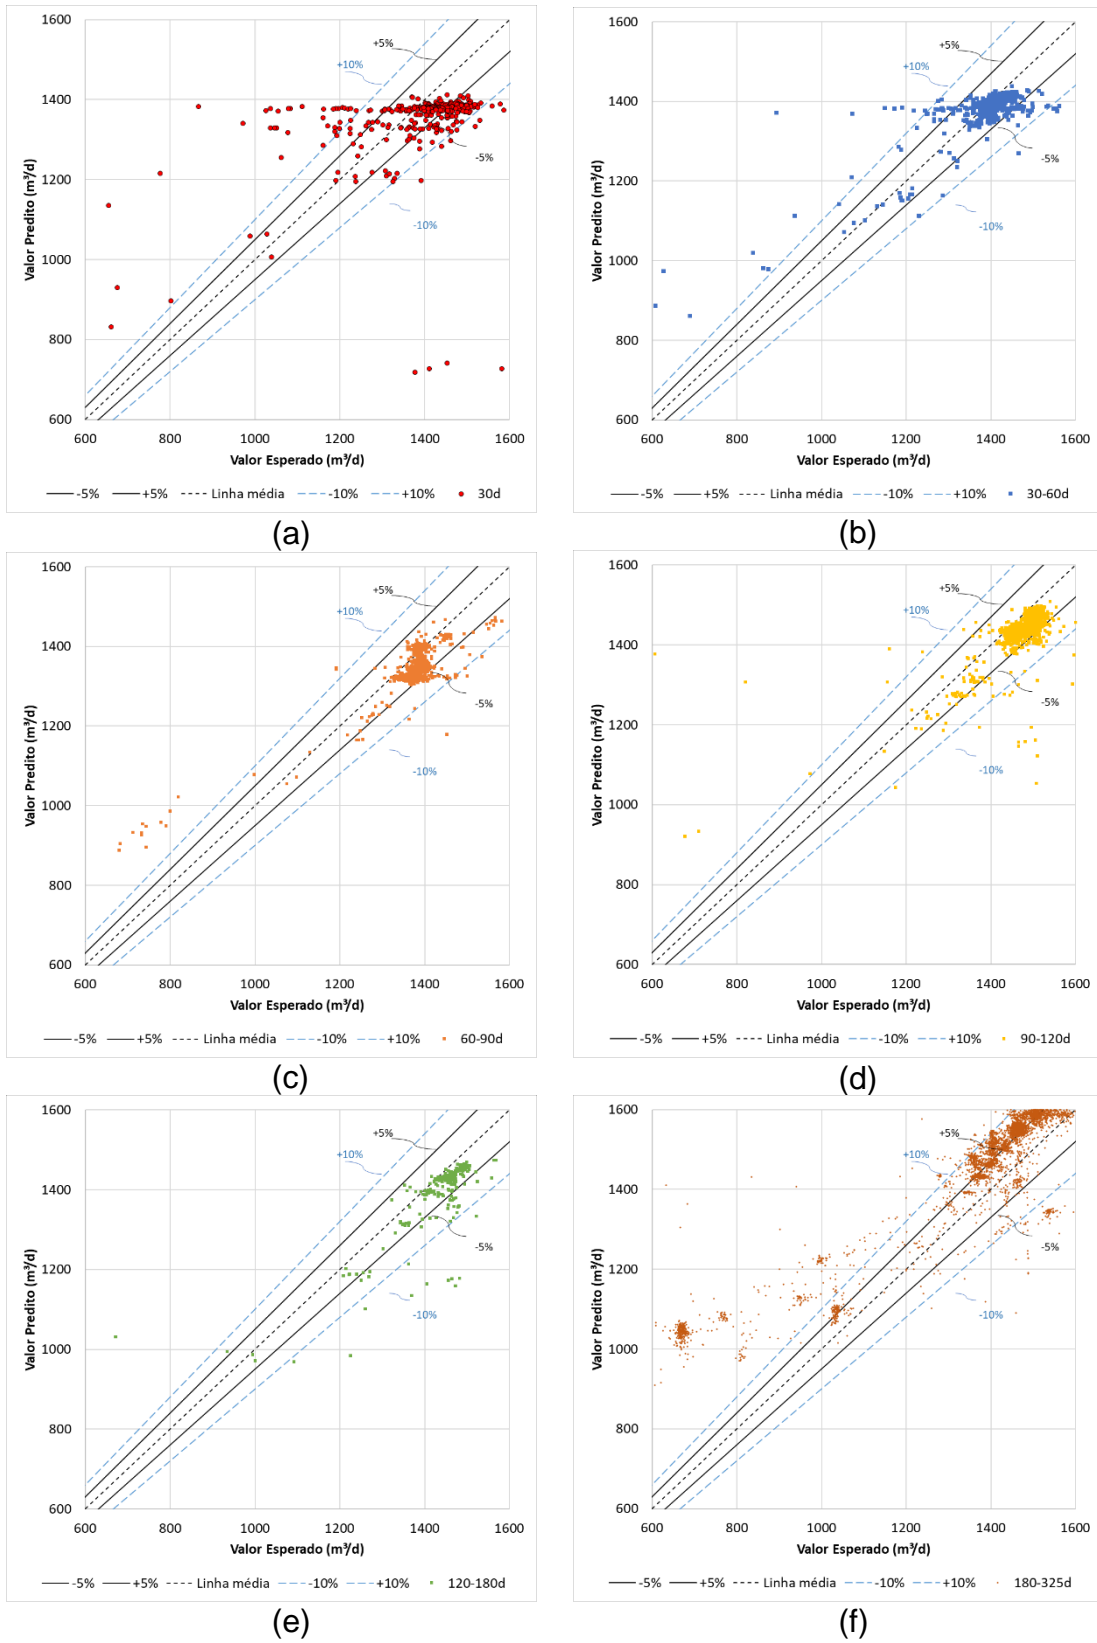


Figura 60 – Resultados da predição com uso de RNA_P4_P5_T4_10N para (a) 0-30dias, (b) 30-60dias, (c) 60-90dias, (d) 90-120dias, (e)120-180dias e (f) 180-325dias

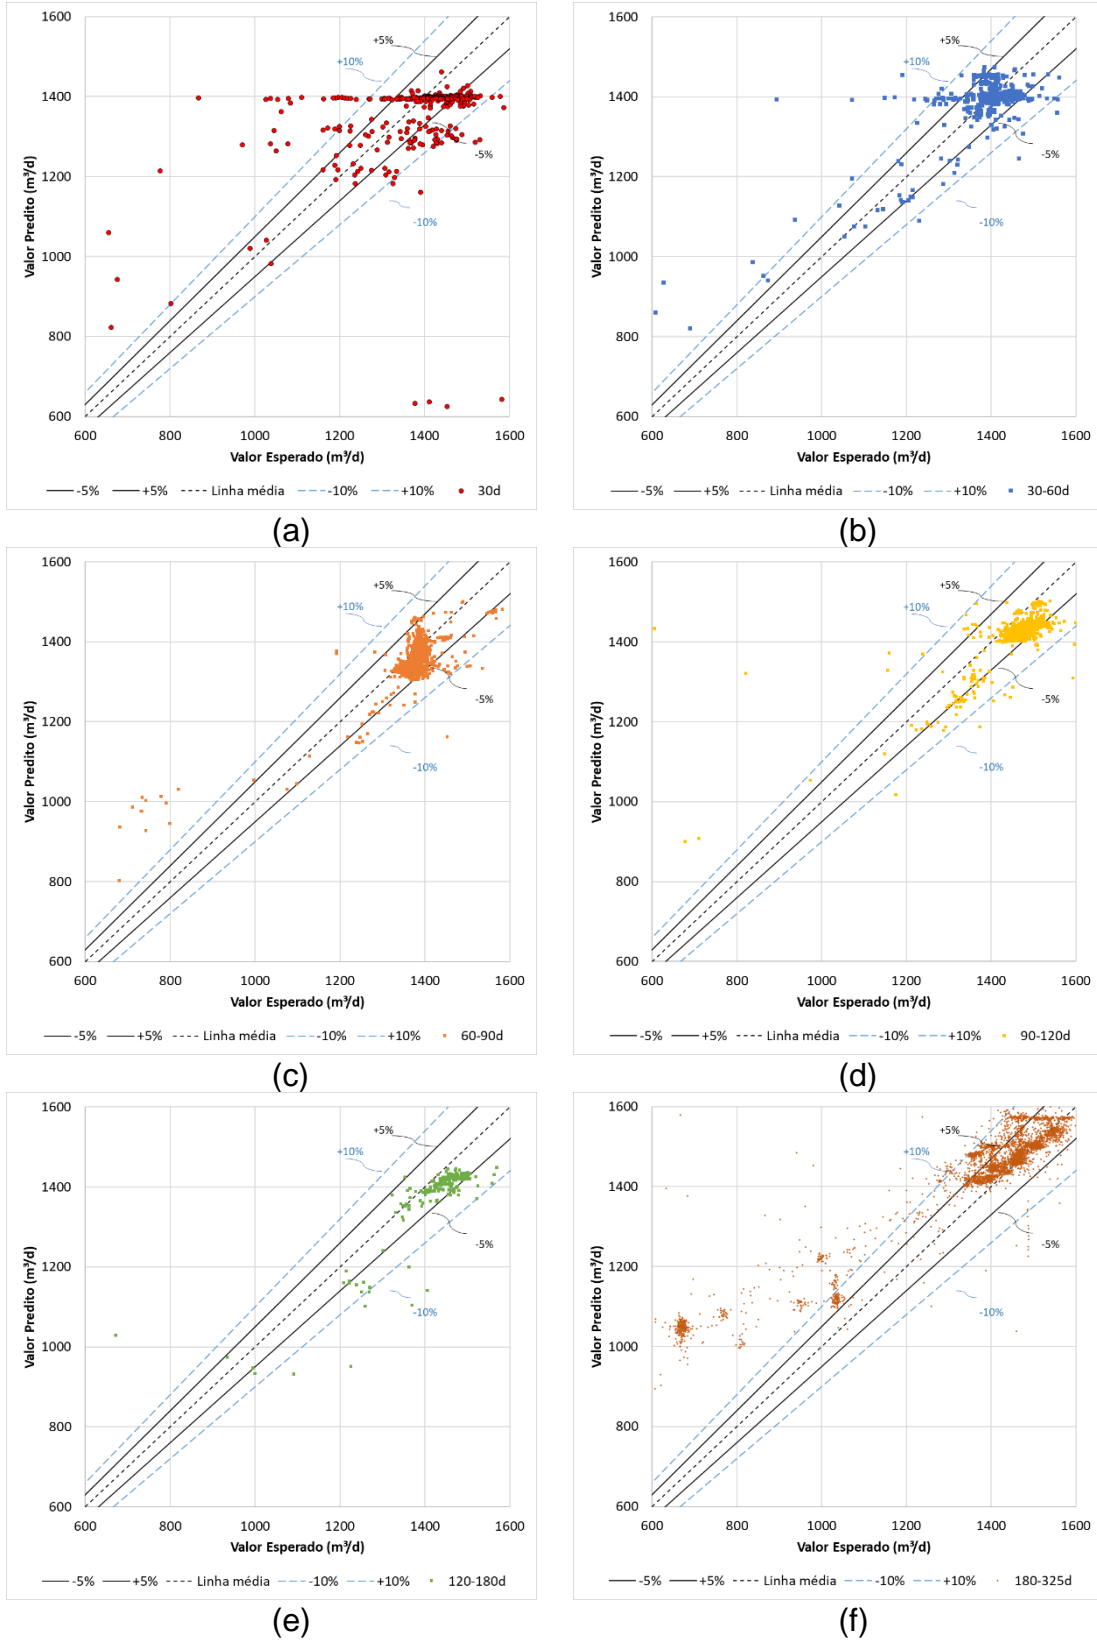


Figura 61 – Resultados da predição com uso de RNA_P4_P5_T4_15N para (a) 0-30dias, (b) 30-60dias, (c) 60-90dias, (d) 90-120dias, (e)120-180dias e (f) 180-325dias

A Tabela 24 apresenta o quadro resumo dos resultados para a simulação de medição de vazão virtual por abordagem *Data Driven* por RNA.

Tabela 24 – Quadro resumo de resultados

Modelo	Período	MAE - <i>Mean Absolute Error</i> Vazão de líquido (m ³ /d)	MAPE – <i>Mean Absolute Percentage Error</i> (%)
RNA_P4_P5	0 a 325d	77,5	6,62
	0 a 30d	73,3	5,90
	30 a 60d	31,7	2,46
	60 a 90d	27,4	2,10
	90 a 120d	72,5	4,95
	120 a 180d	103,9	7,75
	180 a 325d	102,5	9,20
RNA_P4_P5_T4_5N	0 a 325d	88,5	7,84
	0 a 30d	105,6	8,16
	30 a 60d	59,8	4,49
	60 a 90d	59	4,69
	90 a 120d	77,4	5,33
	120 a 180d	90,6	6,86
	180 a 325d	103,9	9,99
RNA_P4_P5_T4_10N	0 a 325d	75,3	6,53
	0 a 30d	86,5	6,74
	30 a 60d	29,1	2,27
	60 a 90d	45,7	3,49
	90 a 120d	40,3	2,80
	120 a 180d	76,2	5,91
	180 a 325d	100,4	9,12
RNA_P4_P5_T4_15N	0 a 325d	59,5	5,50
	0 a 30d	80,4	6,28
	30 a 60d	30,4	2,36
	60 a 90d	36,8	2,87
	90 a 120d	54	3,73
	120 a 180d	56,1	4,62
	180 a 325d	71,8	7,26

Na Tabela 24 são apresentados os resultados dos 4 modelos em RNA, segregados por período de avaliação. Os itens sombreados na tabela, indicam os resultados em todo o período de avaliação (0 a 325 dias) para cada modelo.

De forma geral, os modelos se comportaram com um erro percentual médio absoluto (MAPE) inferior à 10% para todos os períodos. Nota-se uma melhora nos resultados

nos casos com adição da variável temperatura T4, exceto para o caso RNA_P4_P5_T4_5N, possivelmente devido ao número insuficiente de neurônios na camada oculta. Com um maior número de neurônios na camada oculta (10 ou 15), a melhora nos modelos foi nítida, justificada pela maior capacidade de mapeamento não-linear da rede com esse ajuste.

Há uma tendência de aumento do MAPE nos períodos mais distantes do ponto de treinamento, justificado pela mudança possível nas variáveis do poço. Nos dados observados na Figura 56, há um período final de grande restrição do poço, com vazões da ordem de 600m³/d, muito distante do range do *dataset* usado para o treinamento. Apesar do poder de generalização das RNA's, é esperado que o erro aumente nestas condições. O período entre 180 e 325 dias, sugere necessidade de novo treinamento, devido ao distanciamento entre os dados preditos e a data original de treinamento.

O melhor modelo foi o RNA_P4_P5_T4_15N, com MAPE de 5,5% no período total, e MAPE máximo verificado no período de 180 a 325d de 7,26%.

Em relação a abordagem RNA, verifica-se que o uso de apenas 131 pontos para treinamento possibilitou a simulação de 8063 pontos preditos, com tempo de simulação inferior a 1 segundo, sendo nitidamente uma vantagem do ponto de vista de gasto computacional em relação aos modelos multifásicos abordados na seção 4.2.

Como desvantagem, observa-se a necessidade de pontos para treinamento com variação suficiente para gerar um modelo com capacidade de generalização (predição de pontos distantes aos observados no *dataset* de treinamento).

5. CONCLUSÕES

Os resultados obtidos pelas análises representam um conjunto de dados para um poço submarino, satélite, surgente, com baixa variação no BSW e RGO_f no período analisado.

Sobre a abordagem por modelagem multifásica:

Para os modelos por simulação multifásica, adotando a estatística do erro percentual médio absoluto (MAPE), obteve-se um erro máximo de $\pm 8,4\%$ (CASO 3A2), exceto pelo maior erro observado nos modelos do CASO 2 (A1/A2/B1 e B2), devido à influência sugestiva para obstrução na coluna de produção. Este é um resultado importante, pois relaciona a fragilidade da abordagem multifásica com a mudança física dos modelos. Ao excluir o período sugestivo para presença da formação de obstrução, o erro nestes casos é de no máximo 5,5% (CASO2A1).

De forma geral há uma dependência dos resultados simulados em relação ao tempo, visto que a atualização com o uso do ponto operacional B reduziu o erro, exceto para os CASOS 3A1 e 3B1. Não há uma explicação clara ainda para essa exceção, que possivelmente se deve a não representatividade do ajuste para os pontos posteriores simulados, mostrando a susceptibilidade desta abordagem em relação ao ajuste e correlações escolhidas, podendo ser influenciada pelo usuário do método e suas escolhas de ajuste.

Não foi observado um caso nitidamente de melhor desempenho em relação aos demais, porém cabe destaque para a aplicação no trecho topside (CASO 4), usualmente com maior facilidade de adição de sensores, e confirmação de viabilidade para aplicação em VFM.

Sobre a abordagem por Data Driven:

Os resultados para a abordagem por Data Driven usando RNA MLP foram bons, com erro percentual médio absoluto (MAPE) máximo de 9,99% no intervalo de 180 a 325

dias no modelo RNA_P4_P5_T4_5N, porém erros menores para intervalos mais próximos do ponto de treinamento.

O melhor resultado global foi obtido com o modelo RNA_P4_P5_T4_15N, com um MAPE de 5,5%, bastante satisfatório para a aplicação.

Na simulação por RNA MLP notou-se o aumento de erro com o tempo, especialmente após 180 dias, sugerindo a influência desta variável nos resultados. Neste caso, possivelmente a RNA exige novo treinamento com dados atualizados, para melhorar a aproximação.

A adição da variável temperatura T4 e o aumento do número de neurônios na camada oculta resultou em melhores resultados globais, provavelmente por aumentar a capacidade de mapeamento não-linear.

A RNA MLP apresentou uma grande vantagem em relação ao tempo computacional, nas fases de treinamento e testes (fase de ajuste) bem como tempo computacional de predição, com resultado surpreendente de 8063 pontos (relativos a 325 dias) simulados em menos de 1 segundo.

Como desvantagem, a RNA MLP requer um número maior de dados para treinamento quando comparado a modelagem multifásica (que só requer um ponto para gerar um modelo). Além da quantidade de dados, exige-se variação suficiente destes, para permitir a criação de um modelo generalista (capacidade de extrapolação).

Sobre a comparação geral de vantagens e desvantagens das abordagens por simulação multifásica e por Data Driven:

Tabela 25 – Principais vantagens e desvantagens da abordagem por VFM Multifásica

Abordagem	Vantagem	Desvantagem
Modelagem Multifásica	Requer poucos dados históricos, teoricamente apenas 1 ponto é suficiente para gerar um ajuste de modelo	Requer detalhamento do modelo, com propriedades dos fluidos, dimensional do escoamento, ajustes diversos
	Possibilidade de especificar o modelo conforme os dados de sensores disponíveis, escolhendo o trecho que melhor convém ao caso estudado	Susceptível a mudança do modelo, como em caso de obstruções ao fluxo, ou por exemplo a variação das propriedades do fluido
	Criação de modelos mesmo sem dados históricos para ajuste, porém neste caso possivelmente com maior erro.	Necessidade de conhecimento específico em simulação multifásica para criação do modelo
	Possibilidade de aplicação adicional como ferramenta de diagnóstico, a partir dos perfis de propriedades.	Maior influência do analista, devido à questões específicas de ajuste, como a escolha de correlações multifásicas e interpretações das mudanças na modelagem com o tempo

Tabela 26 – Principais vantagens e desvantagens da abordagem de VFM por Data Driven

Abordagem	Vantagem	Desvantagem
Data Driven (RNA MLP)	Não há necessidade de detalhar o modelo físico	Requer um maior número de dados com variação, para gerar uma rede RNA devidamente treinada e generalista
	Possibilidade de especificar o modelo conforme os dados de sensores disponíveis, escolhendo o trecho que melhor convém ao caso estudado	Susceptível a mudança do modelo, como em caso de obstruções ao fluxo, ou por exemplo a variação das propriedades do fluido
	Não há necessidade de conhecimento específico em modelagem multifásica para criar uma ferramenta de medição de vazão virtual.	Não é possível criar um modelo sem dados históricos de ajuste.
	Menor influência do analista, devido à questões específicas de ajuste, como a escolha de correlações multifásicas e interpretações das mudanças na modelagem com o tempo	Não há resultado para o perfil de propriedades de escoamento, o que impossibilita o uso como ferramenta adicional de diagnóstico.

Sobre as limitações gerais das abordagens de medição de vazão virtual:

A modelagem para monitoramento e alocação de produção em poços de petróleo deve ser vista como uma melhoria em relação ao processo previsto na Resolução Conjunta ANP/INMETRO N° 1 de 10/06/2013 [10].

Cabe aqui mencionar as principais limitações do método:

1. Uso de BSW e RGO_f constantes do teste em separador mais recente.

O modelo não avalia alterações de BSW ou RGO_f.

Essa condição normalmente é aceitável. O controle de BSW é feito por análise diária em laboratório e o RGO_f é um parâmetro que não muda sem uma justificativa conhecida, por exemplo: produção de capa de gás no reservatório.

Em caso de mudança perceptível nos parâmetros, sugere-se realizar novo teste em separador, atribuindo nova calibração do modelo multifásico.

2. Modelo de Simulação pode sofrer mudança

Alguns fatores levam à mudança do modelo de simulação, como obstrução por incrustação nas linhas e coluna de produção, mudança na corrente de fluido impactando a viscosidade (uso de desemulsificante), IPR mudando por dano no reservatório (obstrução por asfaltenos, finos, rompimento de telas de gravel, etc.)

3. Dado de Entrada (normalmente Pressão) ruidoso ou com erro (falta de calibração ou mal funcionamento).

No caso de dados ruidosos, é necessário tratamento por média móvel por exemplo. Além disso é fundamental garantir a confiabilidade dos sensores usados na modelagem por meio de rotinas de calibração.

6. REFERÊNCIAS

- [1] BIKMUKHAMETOV, T.; JASCHKE, J. **First principles and machine learning virtual flow metering**: a literature review. *Journal of Petroleum Science Engineering* v. 184, p. 1–26, 2020.
- [2] JADID, K. M. **Performance evaluation of multiphase flow models applied to virtual flow metering**. 2017. 107 f. Dissertation - The Department of Petroleum Engineering, Louisiana State University and Agricultural and Mechanical College. 2017.
- [3] OMRANI, P. S. et al. **Improving the accuracy of virtual flow metering and back-allocation through machine learning**. In: Abu Dhabi International Petroleum Exhibition & Conference. SPE-192819-MS. 2018.
- [4] SCIKIT LEARN, Machine Learning in Python – Disponível em: <<https://scikit-learn.org/stable/>>. Acesso em 15 ago. 2021
- [5] SEMAN L. O. et. al. **Derivative-free parameter tuning for a well multiphase flow simulator**. *Journal of Petroleum Science Engineering* v. 192, 2020.
- [6] SILVA, F. R. G da. **Formação de Laços na Zona Crítica de Contato de um Riser Flexível**. 2019. 104 f. Monografia – Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas da Universidade Federal do ABC – UFABC, Santo André.
- [7] Padrões de fluxo em escoamento horizontal - Disponível em: <https://www.thermal-engineering.org/what-is-flow-pattern-two-phase-flow-definition/>. Acesso em 14 fev. 2022.
- [8] CORNELIUSSEN, S. et al. **Handbook of Multiphase Flow Metering**, Norwegian Society for Oil and Gas Measurement (NFOGM). 2005.
- [9] VARYAN, R.; HAUG, R. K.; FONNES, D. G. **Investigation on the Suitability of Virtual Flow Metering System as an Alternative to the Conventional Physical Flow Meter**. In: SPE/IATMI Asia Pacific Oil & Gas Conference and Exhibition, Indonesia. SPE-176432-MS. 2015
- [10] AGÊNCIA NACIONAL DE PETRÓLEO. Resolução Conjunta ANP/INMETRO Nº 1 de 10/06/2013, DOU de 12 de junho de 2013.
- [11] Boletim da Produção de Petróleo e Gás Natural – ANP (Novembro de 2021 / número 135). Disponível em: <https://www.gov.br/anp/pt-br/centrais-de-conteudo/publicacoes/boletins-anp/bmp/2021/2021_11_boletim.pdf>. Acesso em 10 jan. 2022.
- [12] SHIPPEN M.; W. J. BAILEY. **Steady-State Multiphase Flow - Past, Present, and Future, with a Perspective on Flow Assurance**. *Energy Fuels*, vol. 26, p. 4145–4157, 2012.
- [13] ALMEIDA, A. R. **Escoamento e Transferência de Calor em Produção de Petróleo**. Curso oferecido pela Petrobras, Rio de Janeiro, 2013.

- [14] AMIM, A. **Evaluation of commercially available virtual flow meters (VFM systems)**. In: Offshore Technology Conference. OTC-25764-MS. 2015.
- [15] ROSA, A. J.; CARVALHO, R. S.; XAVIER, J. A. D. **Engenharia de Reservatório de Petróleo**. Rio de Janeiro: Editora Interciência, 2006.
- [16] AHMED, T. **Reservoir Engineering Handbook** (Fifth Edition), p. 457-544. Chapter 7 - Oil Well Performance. Elsevier Inc. 2019.
- [17] VOGEL, J. V. **Inflow performance relationships for solution-gas drive wells**. J. Pet. Technol. SPE-1476-PA. p. 83-92, 1968.
- [18] AHMED, T. **Equations of State and PVT Analysis**. Elsevier Inc, p. 331-456, 2007.
- [19] AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCOMBUSTÍVEIS, Resolução Conjunta ANP/INMETRO Nº 1 DE 10/06/2013.
- [20] AMERICAN PETROLEUM INSTITUTE, **Manual of Petroleum Measurement Standards Chapter 11 - Physical Properties Data**, Section 1: Temperature and Pressure Volume Correction Factors for Generalized Crude Oils, Refined Products, and Lubricating Oils. 2007.
- [21] PEDREGOSA, F., VAROQUAUX, G., GRAMFORT, A., MICHEL, V., THIRION, B., GRISEL, O., BLONDEL, M., PRETTENHOFER, P., WEISS, R., DUBOURG, V., VANDERPLAS, J., PASSOS, A., COURNAPEAU, D., BRUCHER, M., PERROT, M., DUCHESNAY, E. **Scikit-learn: machine learning in Python**. J. Mach. Learn. Res. 12, p. 2825–2830, 2011.
- [22] GOES, M. R. R. T. et al. **Virtual flow metering of oil wells for a pre-salt field**. Journal of Petroleum Science Engineering. v. 203, 2021.
- [23] ANDRIANOV, N. **A machine learning approach for virtual flow metering and forecasting**. IFAC-Pap. p. 191-196, 2018.
- [24] BEGGS, H. D.; BRILL, J. P. **A Study of Two-Phase Flow in Inclined Pipes**. J. Pet. Technol. 25 (05), p. 607–617. SPE-4007-PA. 1973.
- [25] VIEIRA, R. **Escoamento em Tubulações**. Curso oferecido pela Petrobras, Salvador, 2012.
- [26] KANIN, E. A. et al. **A predictive model for steady-state multiphase pipe flow: Machine learning on lab data**. Journal of Petroleum Science Engineering v. 180 p. 727–746, 2019.
- [27] BISHOP, C. M. **Pattern Recognition and Machine Learning**. Springer-Verlag, New York, 2006.
- [28] CIARELLI, P. M. **Aprendizado de Máquina**. Disciplina ministrada para o curso de Mestrado em Engenharia Elétrica da UFES, Vitória. 2019
- [29] HOTVEDT, M. et al. **On gray-box modeling for virtual flow metering**. Control Engineering Practice 188, 104974. 2022
- [30] LASATER, J. A. **Bubble point pressure correlation**. J. Petrol. Technol. Vol. 10 (5a edição), p. 65-67, SPE-957-G. 1958.

- [31] GLASØ, Ø. **Generalized Pressure-Volume-Temperature Correlations**. J. Pet. Technol., p. 785-795. 1980.
- [32] VAZQUEZ, M. E.; AND BEGGS, H. D. **Correlations for Fluid Physical Property Prediction**. J. Pet. Technol. p. 968-970; 1980.
- [33] SUTTON, R. P.; FARAHAD, F. F. **Evaluation of Empirically Derived PVT Properties for Gulf of Mexico Crude Oils**. SPE Reservoir Engineering, p. 79-86. fevereiro de 1990.
- [34] AHMED, T. **Reservoir Engineering Handbook (Fourth Edition)**, p. 29-135. Chapter 2 - Reservoir-Fluid Properties. Elsevier Inc. 2010.
- [35] GUO B.; GHALAMBOR A. **Natural Gas Engineering Handbook (Second Edition)**, p. 13-33. Chapter 2 - Properties of Natural Gas. Elsevier Inc. 2012.
- [36] BAHADORI, A. **Fluid Phase Behavior for Conventional and Unconventional Oil and Gas Reservoirs**. Lismore: Elsevier, 2016.
- [37] MELBØ, H. et. al. **Software That Enables Flow Metering of Well Rates With Long Tiebacks and With Limited or Inaccurate Instrumentation**. OTC-15363-MS, Offshore Technology Conference, Texas, 2003.
- [38] MCCRACKEN, M.; CHORNEYKO, D. M. **Rate Allocation Using Permanent Downhole Pressures**. SPE-103222-MS, SPE Annual Technical Conference and Exhibition, Texas, 2006
- [39] HALDIPUR, P.; METCALF, G. D. **Virtual Metering Technology Field Experience Examples**. OTC-19525-MS, Offshore Technology Conference, Texas, 2008.
- [40] HEDDLE, R.; FOOT, J.; REES, H. **ISIS Rate & Phase: Delivering Virtual Flow Metering for 300 Wells in 20 Fields**. SPE-150153-MS, SPE Intelligent Energy International, Utrecht, 2012.
- [41] CRAMER, R. et al. **Virtual Measurement Value during Start Up of Major Offshore Projects**. IPTC-14518-MS, International Petroleum Technology Conference, Bangkok, 2012.
- [42] PATEL, P. et al. **Model Based Multiphase Metering and Production Allocation**. OTC-25457-MS, Offshore Technology Conference-Asia, Kuala Lumpur, 2014.
- [43] MINSKY, M.; PAPERT, S. **Perceptrons: An Introduction to Computational Geometry**. MIT Press, 1969.
- [44] RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning representations by back-propagating error**. Nature Vol. 323, p. 533-536, 1986.
- [45] PAYNE G. A.; PALMER C. M.; BRILL J. P., BEGGS H. D. **Evaluation of Inclined-Pipe Two-Phase Liquid Holdup and Pressure-Loss Correlations Using Experimental Data**, J. Petrol. Technol. 31, p. 1198–1208, 1979.
- [46] DUKLER, A. E. **Gas-Liquid Flow in Pipelines Research Results**. AGA, 1969.

- [47] DUNS J., H.; ROS, N. C. J. **Vertical Flow of Gas and Liquid Mixtures in Wells.** 6th World Petroleum Congress, Frankfurt, p. 19-26,1963.
- [48] HAGEDORN, A. R.; BROWN, K. E. **Experimental Study of Pressure Gradients Occurring During Continuous Two-Phase Flow in Small Diameter Vertical Conduits,** J. Pet. Tech., 1965.
- [49] SHOHAM, O. **Mechanistic modeling of gas-liquid two-phase flow in pipes.** 1^a ed. Texas-USA: Society of Petroleum Engineers, 2006.
- [50] ORKISZEWSKI, J. **Predicting Two-Phase Pressure Drops in Vertical Pipe.** J Pet Technol 19 (06). SPE-1546-PA. p. 829–838, 1967.
- [51] MUKHERJEE, H.; BRILL, J. P. **Pressure Drop Correlations for Inclined Two-Phase Flow.** J. Energy Resour. Technol. 107(4). p. 549-554, 1985.
- [52] AZIZ, K.; GOVIER, G.W.; FOGARASI, M. **Pressure Drop in Wells Producing Oil and Gas.** J. Cdn. Pet. Tech., 1972.

APÊNDICE

7. APÊNDICE A: Correlações Black-Oil

Reservatórios de petróleo classificados como Black-Oil abrangem uma grande variedade de óleos, caracterizados por possuírem um fator de encolhimento pequeno, densidade menor que 45 °API, razão gás-óleo inicial (Rsi) inferior a 400 m³/m³ e fator volume-formação (Bo) inferior a 2 m³/m³.

No estudo com simuladores multifásicos, utiliza-se a modelagem denominada de “black-oil”, obtendo-se resultados bastante representativos.

A.1: Razão de Solubilidade

Existem várias correlações para determinar a razão de solubilidade em óleos com característica Black-Oil. A correlação selecionada nessa dissertação foi a sugerida por Lasater (1958), com formulação apresenta a seguir:

Cálculo do fator da pressão de bolha (ou pressão de saturação):

$$p_f = 0.080576 \frac{p_b \gamma_g}{T} \quad (43)$$

O fator 0,080576 é para compatibilizar as unidades usadas na fórmula

p_b – Bubble point Pressure (Pressão de bolha ou de saturação) [kPa]

p_f - Bubble point pressure, factor (Fator da pressão de bolha) [-]

γ_g - gas specific gravity (densidade do gás) [-]

T - Temperature (Temperatura) [K]

Estimar y_g , que é a fração molar de gás, conforme tabela abaixo por interpolação:

Tabela 27 – Relação experimental entre p_f e ψ_g

P_f	ψ_g
0,17	0,05
0,3	0,1
0,43	0,15
0,58	0,2
0,75	0,25
0,94	0,3
1,19	0,35
1,47	0,4
1,74	0,45
2,1	0,5
2,7	0,55
3,29	0,6
3,8	0,65
4,3	0,7
4,9	0,75
5,7	0,8
6,7	0,85

Calcular a razão de solubilidade (R_s), conforme a seguir:

$$R_s = 23895.9\gamma_o \frac{\psi_g}{M_o(1-\psi_g)}.C \quad (44)$$

C é o fator de ajuste para igualar R_s com a RGO (razão gás óleo total) no ponto de saturação disponível no ensaio PVT.

M_o é a massa molar do óleo, em kg/kmol, dada pela equação:

$$M_o = 630 - 10API \quad (45)$$

O grau API é definido por:

$$API = \frac{141,5}{\gamma_o} - 131,5 \quad (46)$$

Cabe mencionar que a máxima razão de solubilidade possível de um óleo é limitada ao valor da Razão Gas Óleo (RGO) obtido do ensaio PVT. Se a equação (44) fornecer valor superior, deve-se limitar na RGO.

API - degree API of the oil [-]

y_g – gas mole fraction (fração molar de gás) [-]

R_s – Solution gas oil ratio (razão de solubilidade) [Sm^3/Sm^3]

γ_o - oil specific gravity (densidade do óleo) [-]

M_o - oil mass molar (massa molar do óleo) [kg/kmol]

RGO – Razão gás óleo (GOR – gas oil fraction) do óleo na condição de reservatório, obtido na amostra de fundo da PVT.

C é o fator de ajuste para igualar R_s com a RGO na pressão de saturação da PVT.

A.2: Volume de formação do óleo (B_o) em sistemas saturados

Para o volume de formação do óleo em sistemas saturados ($p \leq p_b$), adotou-se a correlação de Glasø (1980), com formulação apresenta a seguir:

$$B_{ob} = 1 + 10^{[-6.58511 + 2.291329 \log N_B - 0.27683 (\log N_B)^2]} \quad (47)$$

$$N_B = \left(\frac{R_s}{0,1801175} \right) \left(\frac{\gamma_g}{\gamma_o} \right)^{0.526} + 0.968 \left[(T - 273,15) \frac{9}{5} + 32 \right] \quad (48)$$

B_{ob} - Oil Formation Volume Factor (Fator volume de formação do óleo) na pressão de bolha.

N_B - Correlating number for calculating FVF (Número de correlação para cálculo do B_{ob})

A.3: Volume de formação do óleo em sistemas subsaturados

Para os casos em que o óleo se encontra subsaturado ($p > p_b$), ocorre uma compressão adicional, exigindo uma correção em relação ao volume estimado para o caso saturado ($p < p_{\text{sat}}$). Neste trabalho adotou-se a correlação de Vazquez and Beggs (1980), conforme formulação a seguir.

$$B_o = B_{ob} \exp[-c_o(p - p_b)] \quad (49)$$

$$c_o = \frac{\left(5R_s + 17,2 \left[9 \frac{(T - 273,15)}{5} + 32\right] - 1180\gamma_g + 12,61API - 1433\right)}{(14503,8 \cdot p)} \quad (50)$$

p - pressão [kPa]

c_o - compressibilidade do óleo acima do ponto de saturação [kPa⁻¹]

A.4: Viscosidade do óleo morto

A correlação usada para óleo morto é conforme a proposta por Beggs & Robinson (1975), e formulada a seguir [33]:

$$\mu_{od} = 10^x - 1 \quad (51)$$

Onde

$$x = y \left((T - 273,15) \frac{9}{5} + 32 \right)^{-1.163} \quad (52)$$

$$y = 10^z \quad (53)$$

$$z = 3.0324 - 0.02023API \quad (54)$$

μ_{od} - viscosidade do óleo morto (cP)

x, y, z - são coeficientes da correlação de Beggs e Robinson

A.5: Viscosidade do óleo vivo saturado

Para dos casos de óleo saturado ($p \leq p_b$), a correlação para a viscosidade do óleo vivo selecionada foi a de Beggs & Robinson (1975), e formulada conforme a seguir [33]:

$$\mu_{ob} = a(\mu_{od})^b \quad (55)$$

Onde:

$$a = 10.715 \left(\frac{R_s}{0,1801175} + 100 \right)^{-0.515} \quad (56)$$

$$b = 5.44 \left(\frac{R_s}{0,1801175} + 150 \right)^{-0.338} \quad (57)$$

μ_{ob} - viscosidade do óleo vivo, na condição de saturação (cP)

a, b são coeficientes da correlação de Beggs e Robinson

A.6: Viscosidade do óleo vivo subsaturado

Para dos casos de óleo subsaturado ($p > p_{sat}$), a correlação para a viscosidade do óleo vivo selecionada foi a de Vazques and Beggs (1980), e formulada conforme a seguir:

$$\mu_o = \mu_{ob} (p/p_b)^m \quad (58)$$

Onde

$$m = 2.6 \left(\frac{p}{6.894757} \right)^{1.187} 10^{[(-3.9 \times 10^{-5}) \left(\frac{p}{6.894757} - 5 \right)]} \quad (59)$$

μ_o - viscosidade do óleo vivo subsaturado (cP)

m – coeficiente da correlação de Vazquez&Beggs

A.7: Compressibilidade do gás (Z)

Diversas estimativas do fator de compressibilidade estão disponíveis a partir do desenvolvimento de Standing & Katz (1954), que estudaram experimentalmente a massa específica de amostras de gás saturado, obtendo cartas gráficas correlacionando o fator de compressibilidade em função das propriedades pseudocríticas [13].

A correlação de Brill e Beggs (1974) fornece o fator de compressibilidade com acurácia suficiente para aplicações em engenharia, e possui a seguinte formulação [35]:

Se a composição do gás não é conhecida, mas dispomos da densidade do gás, a pressão e temperatura pseudocríticas podem ser determinadas conforme a seguir:

$$P_{pc} = 709,604 - 58,718\gamma_g \quad (60)$$

$$T_{pc} = 170,491 + 307,344\gamma_g \quad (61)$$

P_{pc} - pressão pseudocrítica, psia

T_{pc} - temperatura pseudocrítica, °R

A temperatura e pressão pseudoreduzidas são obtidas conforme a seguir:

$$T_r = \frac{1,8T}{T_{pc}} \quad (62)$$

Obs, o fator 1,8 é para conversão das unidades (T[K]; T_{pc} [°R])

$$P_r = 0,145038 \frac{p}{P_{pc}} \quad (63)$$

Obs, o fator 0,145038 é para conversão das unidades (p[kPa]; P_{pc} [psi])

P_r - pressão pseudoreduzida, [-]

T_r - temperatura pseudoreduzida, [-]

Finalmente temos a rotina para obtenção do fator de compressibilidade do gás (Z).

$$A = 1,39(T_r - 0,92)^{0,5} - 0,36T_r - 0,1 \quad (64)$$

$$B = (0,62 - 0,23T_r)P_r + \left(\frac{0,066}{T_r - 0,86} - 0,037 \right) P_r^2 + \frac{0,32P_r^6}{10^E} \quad (65)$$

$$C = 0,132 - 0,32\log(T_r) \quad (66)$$

$$D = 10^F \quad (67)$$

$$E = 9(T_r - 1) \quad (68)$$

$$F = 0,3106 - 0,49T_r + 0,1824T_r^2 \quad (69)$$

$$Z = A + \frac{1 - A}{e^B} + CP_r^D \quad (70)$$

Z – Fator de compressibilidade do gás [-]

A, B, C, D, E, F – Coeficientes da correlação de Bill e Beggs para o fator de compressibilidade.

A.8: Viscosidade do gás

Lee, Gonzales e Eakin (1966) apresentaram uma relação semi-empírica para o cálculo da viscosidade de gases naturais. Os autores expressaram a viscosidade do gás conforme equação a seguir [34]:

$$\mu_g = 10^{-4} K \exp \left[X \left(\frac{0,062428 \rho_g}{62,4} \right)^Y \right] \quad (71)$$

O fator 0,062428 é um conversor de kg/m³ para lb/ft³ da formulação original

Onde:

$$K = \frac{(9,4 + 0,02M_a)(1,8T)^{1,5}}{209 + 19M_a + (1,8T)} \quad (72)$$

$$X = 3,5 + \frac{986}{(1,8T)} + 0,01M_a \quad (73)$$

$$Y = 2,4 - 0,2X \quad (74)$$

$$M_a = 28,96\gamma_g \quad (75)$$

ρ_g - Density (massa específica do gás) [kg/m³]

M_a - apparent molecular weight of the gas (massa molar aparente do gás) [kg/kmol]

A.9: Fator volume de formação do gás (B_g)

O fator volume de formação do gás expressa a razão entre o volume ocupado por uma massa de gás na condição P,T dada, em relação ao volume ocupado na condição padrão. Conforme formulação a seguir [34]:

$$B_g = \frac{(V_g)_{p,t}}{(V_g)_{std}} \quad (76)$$

$$B_g = Z \frac{p_{std} T}{T_{std} p} \quad (77)$$

8. APÊNDICE B: Ajuste das correlações Black-Oil com dados PVT

O ajuste das correlações apresentadas originalmente no Apêndice A se dá por meio dos fatores A_1 (multiplicador) e A_2 (deslocamento linear) conforme abaixo:

$$Prop_{ajustado} = A_1(Prop_{calc}) + A_2$$

Onde Prop é a propriedade de interesse simulada por uma correlação (viscosidade, R_s , B_o , etc.)

Os valores de A_1 e A_2 são obtidos pelo critério dos mínimos quadrados, obtendo a mínima diferença entre os dados ajustados e medidos da propriedade.

Uma hipótese básica envolvida é que os fatores de ajuste, obtidos para uma temperatura específica de análise, permanecem válidos para qualquer temperatura.

9. APÊNDICE C: Correlação Empírica Beggs e Brill (1973)

Beggs e Brill (1973) desenvolveram um experimento para estimar o gradiente de pressão em um escoamento bifásico de ar e água, sugerindo correções nas propriedades médias da mistura, bem como correção do fator de fricção (f_{tp}).

As Figura 62 e Figura 63 a seguir apresentam o aparato de teste utilizado.




Figura 62 – Diagrama do sistema de teste de Beggs & Brill (1973) para estimativa do gradiente de pressão em escoamento multifásico

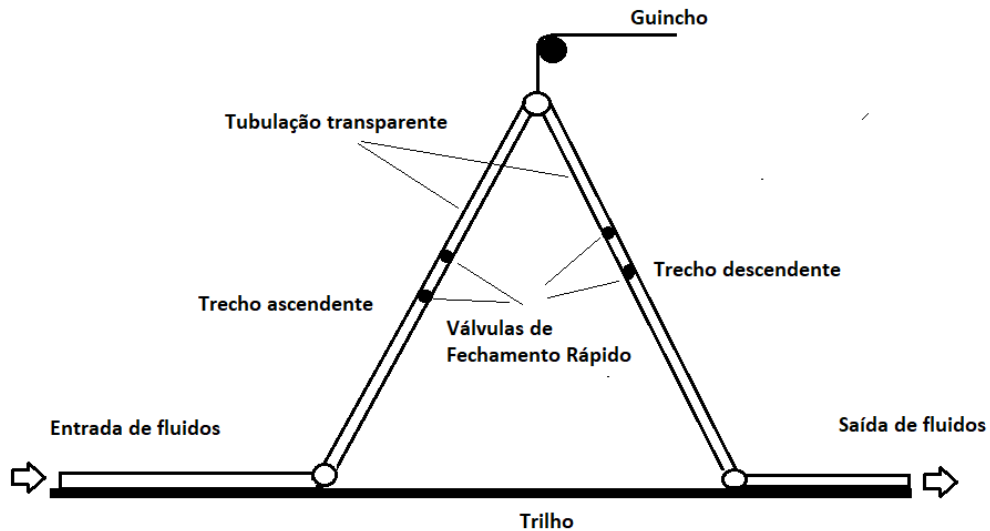


Figura 63 – Esquema simplificado do experimento de Beggs & Brill (1973) para estimativa do gradiente de pressão em escoamento multifásico

O experimento apresentado na (Figura 63) consistia em escoar uma mistura de ar (0 a 300 Mscf/d) e água (0 a 1000 bpd) com vazões conhecidas, através de um a tubulação de diâmetro 1" e 1 1/2", com comprimento total de 90ft, transparente e inclinável entre -90° e $+90^{\circ}$, sendo possível registrar o padrão de fluxo (ex. bolhas, segregado, golfadas, etc.), bem como a leitura de pressão ao longo do escoamento (0 a 0,8 psi/ft). As válvulas de fechamento rápido permitiam avaliar a proporção de ar e água, denominada fração de vazios (q_g) no trecho.

A correlação de Beggs e Brill (1973) se baseia no padrão de escoamento que existiria se o tubo estivesse na horizontal. Desta forma teríamos inicialmente três categorias:

- Segregado
- Intermitente
- Distribuído




Figura 64 – Padrão de fluxo em escoamento multifásico horizontal

A partir do experimento foi elaborado o mapa de fluxo a seguir:




Figura 65 – Mapa de padrões de fluxo em escoamento multifásico horizontal – Beggs & Brill (1973)

Conhecendo as vazões de gás e líquido é possível calcular as grandezas a seguir:

- Velocidade superficial do gás:

$$V_{sg} = \frac{Q_g^{P,T}}{A_{tubo}} = \frac{Q_g^{P,T}}{A} \tag{78}$$

- Velocidade superficial do líquido:

$$V_{sl} = \frac{Q_{liq}^{P,T}}{A_{tubo}} = \frac{Q_{liq}^{P,T}}{A} \tag{79}$$

- Velocidade no centro de volume:

$$J = V_{sg} + V_{sl} \tag{80}$$

- Número de Froude (Fr):

$$Fr = 0,373 \frac{J^2}{D} \quad (ft/s, in) \quad (81)$$

- Holdup de líquido:

$$\lambda_l = \frac{Q_{liq}^{P,T}}{Q_{liq}^{P,T} + Q_g^{P,T}} = \frac{V_{sl}}{V_{sl} + V_{sg}} \quad (82)$$

Necessário determinar o padrão de fluxo em que o escoamento se enquadraria se fosse horizontal:

$$Fr_1^{trans} = 316\lambda_l^{0,302} \quad (83)$$

$$Fr_2^{trans} = 0,0009252\lambda_l^{-2,4684} \quad (84)$$

$$Fr_3^{trans} = 0,1\lambda_l^{-1,4516} \quad (85)$$

$$Fr_4^{trans} = 0,5\lambda_l^{-6,738} \quad (86)$$

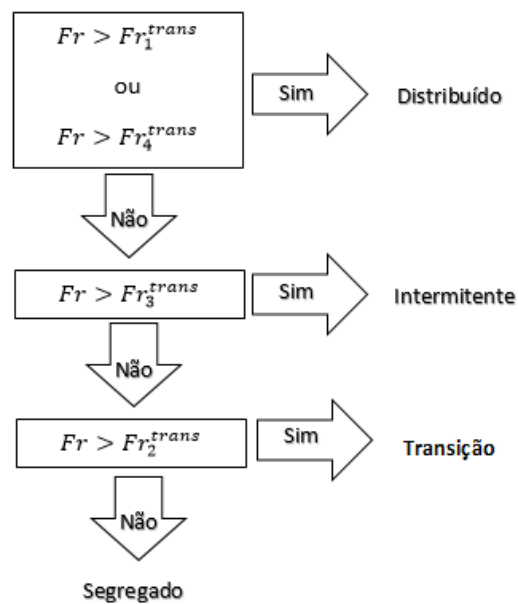


Figura 66 – Fluxograma para determinação do padrão de fluxo se o escoamento fosse horizontal

Determinação da fração de líquido se o escoamento fosse horizontal (α_l^h)

$$\alpha_l^h = \text{Max} \left(\lambda_l; a \frac{(\lambda_l)^b}{(Fr)^c} \right) \quad (87)$$

Tabela 28 – Coeficientes a, b e c para avaliação da fração de líquido na correlação de Beggs & Brill (1973)

Regime	a	b	c
Segregado	0.98	0.4846	0.0868
Intermitente	0.845	0.5351	0.0173
Distribuído	1.065	0.5824	0.0609

Para o caso de padrão de transição, deve-se interpolar conforme abaixo:

$$\alpha_l^{h,transição} = A\alpha_l^{h, segregado} + B\alpha_l^{h, intermitente} \quad (88)$$

$$A = \frac{Fr_3^{trans} - Fr}{Fr_3^{trans} - Fr_2^{trans}} \quad (89)$$

$$B = 1 - A \quad (90)$$

$$\alpha_l^{h, transição} = \text{Min}(\text{Max}(\lambda_l; \text{valor da equação (88)}); 1) \quad (91)$$

Correção para a inclinação do escoamento (θ):

$$\alpha_l = \alpha_l^h \Phi \quad (92)$$

$$\Phi = 1 + C[\text{sen}(1,8\theta) - 0,333[\text{sen}(1,8\theta)]^3] \quad (93)$$

Onde θ é o ângulo com a horizontal

Definição do número de velocidade do líquido (N_{lv})

$$N_{lv} = 1,938V_{sl} \left(\frac{\rho_l}{\sigma_l} \right)^{0,25} \left(\frac{ft}{s}, \frac{lb}{ft^3}, \text{dina/cm} \right) \quad (94)$$

$$\sigma_l = f_w \sigma_w + (1 - f_w) \sigma_o \quad (95)$$

$$\rho_l = f_w \rho_w + (1 - f_w) \rho_o \quad (96)$$

$$f_w = \frac{Q_w^{P,T}}{Q_o^{P,T} + Q_w^{P,T}} \quad (97)$$

O parâmetro C é dado por:

$$C = \text{Max}[(1 - \lambda_l) \ln(d \lambda_l^e N_{lv}^f Fr^g), 0] \quad (98)$$

Tabela 29 – Coeficientes d, e, f e g para correção de C na correlação de Beggs & Brill (1973)

Inclinação	Regime	d	e	f	g
$\theta > 0$	Segregado	0.011	-3.768	3.539	-1.614
	Inermitente	2.96	0.305	-0.4473	0.0978
	Distribuído	Sem Correção - C = 0			
$\theta < 0$	Todos	4.7	-0.3692	0.1244	-0.5056

Para o calcula do número de Reynolds, os autores propuseram adotar a condição de não escorregamento (*No Slip Condition*):

$$Re^{NS} = d \frac{\rho^{NS} J D}{\mu^{NS}} \quad (99)$$

d = 1 (SI) ou 124 (Sistema americano)

$$\rho^{NS} = \lambda_l \rho_l + (1 - \lambda_l) \rho_g \quad (100)$$

$$\mu_l = f_w \mu_w + (1 - f_w) \mu_o \quad (101)$$

$$\mu^{NS} = \lambda_l \mu_l + (1 - \lambda_l) \mu_g \quad (102)$$

Temos então a correção para o fator de fricção, conforme a seguir:

$$f_{tp} = f e^S \quad (103)$$

$$y = \frac{\lambda_l}{\alpha_l^2} \quad (104)$$

$$S = \begin{cases} \text{Se } 1 < y < 1,2 \rightarrow \ln(2,2y - 1,2) \\ \text{Senão} \rightarrow \frac{\ln(y)}{-0,0523 + 3,182 \ln(y) - 0,8725(\ln(y))^2 + 0,01853(\ln(y))^4} \end{cases}$$

A formulação original de S possui uma descontinuidade em $y = 1$. Os autores propuseram então uma modificação, adotando $S=0$ para $y=1$, variando linearmente até S avaliado em $y=1,2$.

O valor de (f) na equação (103) é obtido conforme equações de (14) a (19).

A Figura 67, a seguir, apresenta graficamente o termo e^S da equação (103) em função de y da equação (104). Este termo representa a correção do fator de atrito multifásico em relação ao fator de atrito obtido para a metodologia de fluxo monofásico.




Figura 67 – Correção do fator de atrito multifásico (f_p)

Temos agora o ferramental disponível para calcular o gradiente de pressão ao longo do comprimento.

Para um escoamento multifásico, podemos reescrever a equação (13) como a seguir:

$$\frac{\partial P}{\partial x} = -\rho_m g \sin \theta - \frac{\partial(\rho_m J^2)}{\partial x} - \frac{1}{2} \rho_m f_{tp} \frac{|J|}{D} \quad (105)$$

$$\rho_m = \alpha_l \rho_l + (1 - \alpha_l) \rho_g \quad (106)$$

O termo de aceleração embora usualmente desprezado, pode ser obtido conforme a seguir:




Figura 68 – Elemento discretizado para a avaliação do termo de aceleração

$$\frac{\partial(\rho_m J^2)}{\partial x} = \frac{(\rho_m J^2)_{i+1} - (\rho_m J^2)_i}{\Delta x} \quad (107)$$

Ou seja, é necessário avaliar as propriedades médias nas seções de entrada (i) e saída (i+1) da célula (i), e não somente na condição de pressão média central da célula.