



AMAURI MATAMOUROS VICENTE NAKASHIMA

**DESENVOLVIMENTO DE REDES NEURAIIS UTILIZANDO
TÉCNICA ULTRASSÔNICA E NÚMEROS ADIMENSIONAIS
PARA A DETERMINAÇÃO DA FRAÇÃO DE VAZIO E
PADRÕES DE ESCOAMENTOS MULTIFÁSICOS
REPRESENTATIVOS DA INDÚSTRIA DO PETRÓLEO**

Campinas

2015



UNIVERSIDADE ESTADUAL DE CAMPINAS
Faculdade de Engenharia Química

AMAURI MATAMOUROS VICENTE NAKASHIMA

**DESENVOLVIMENTO DE REDES NEURAIS UTILIZANDO
TÉCNICA ULTRASSÔNICA E NÚMEROS ADIMENSIONAIS
PARA A DETERMINAÇÃO DA FRAÇÃO DE VAZIO E
PADRÕES DE ESCOAMENTOS MULTIFÁSICOS
REPRESENTATIVOS DA INDÚSTRIA DO PETRÓLEO**

Dissertação de Mestrado Apresentada ao Programa de Pós Graduação em Engenharia Química da Faculdade de Engenharia Química da Universidade Estadual de Campinas para Obtenção do Título de Mestre em Engenharia Química.

Orientador: Profa. Dra. Ana Maria Frattini Fileti
Co-orientador: Prof. Dr. Ricardo Dias Martins de Carvalho

ESTE EXEMPLAR CORRESPONDE À VERSÃO FINAL DA TESE DEFENDIDA PELO ALUNO AMAURI MATAMOUROS VICENTE NAKASHIMA, E ORIENTADO PELA PROFA. DRA. ANA MARIA FRATTINI FILETI

A handwritten signature in black ink, appearing to read "Ana Maria Frattini Fileti", is written over a horizontal line.

Profa. Dra. Ana Maria Frattini Fileti

Campinas
2015

Ficha catalográfica
Universidade Estadual de Campinas Biblioteca da
Área de Engenharia e Arquitetura Elizangela
Aparecida dos Santos Souza - CRB 8/8098

N145d Amauri, Matamouros Vicente Nakashima, 1988-
Desenvolvimento de redes neurais utilizando técnica ultrassônica e números adimensionais para a determinação da fração de vazio e padrões de escoamentos multifásicos representativos da indústria do petróleo / Amauri Matamouros Vicente Nakashima. – Campinas, SP : [s.n.], 2015.

Orientador: Ana Maria Frattini Fileti.
Coorientador: Ricardo Dias Martins de Carvalho.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Química.

1. Redes neurais. 2. Escoamento multifásico. 3. Ultrassom. I. Fileti, Ana Maria Frattini, 1965-. II. Carvalho, Ricardo Dias Martins de. III. Universidade Estadual de Campinas. Faculdade de Engenharia Química. IV. Título.

Informações para Biblioteca Digital

Título em outro idioma: Development of neural networks using ultrasonic technic and dimensionless numbers to determine the void fraction and multiphase flow patterns representative of the oil industry

Palavras-chave em inglês:

Neural networks

Multiphase flow

Ultrasound

Área de concentração: Sistemas de Processos Químicos e Informática

Titulação: Mestre em Engenharia Química

Banca examinadora:

Ana Maria Frattini Fileti [Orientador]

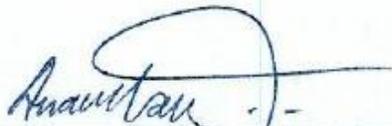
Flávio Vasconcelos da Silva

Valdir Estevam

Data de defesa: 31-07-2015

Programa de Pós-Graduação: Engenharia Química

Dissertação de Mestrado defendida por Amauri Matamouros Vicente Nakashima e aprovada em 31 de julho de 2015 pela banca examinadora constituída pelos doutores:



Prof(a). Dr(a). Ana Maria Frattini Fileti
(Orientador)



Prof. Dr. Flavio Vasconcelos da Silva



Prof. Dr. Valdir Estevam

RESUMO

Esta pesquisa teve como finalidade o desenvolvimento de redes neurais artificiais (RNA) para a determinação da fração de volume de gás (FVG) e de padrões de escoamentos multifásicos representativos da indústria do petróleo (IPDE). Os modelos neurais foram treinados por meio do algoritmo Levenberg-Marquardt com regularização bayesiana, considerado um padrão em otimizações não-lineares, além de ser um modo sofisticado de melhorar a generalização do modelo. Para cada variável a ser predita, duas redes neurais distintas foram criadas com entradas diferentes, sendo combinadas para gerar a saída desejada (FVG ou IPDE). Usando uma abordagem fenomenológica, foram formados números adimensionais, representativos das forças atuantes no escoamento bifásico líquido-gás, usados como entrada. As redes foram treinadas com um extenso banco de dados encontrado na literatura para escoamentos bifásicos verticais ascendentes e horizontais. Numa segunda abordagem, a técnica ultrassônica foi utilizada. Dados de atenuação acústica foram tratados e transformados em razão de energia, usada como entrada do modelo. Duas montagens experimentais permitiram a obtenção dos dados acústicos. A primeira utilizou óleo mineral como fase contínua em um circuito fechado de escoamento, provido de câmera de filmagem rápida para reconhecimento do padrão IPDE. A segunda usou um protótipo de medidor multifásico ultrassônico instalado em uma coluna vertical. Testes de retenção de gás (FVG) foram realizados usando petróleo como fase contínua, com diferentes viscosidades. O sistema neural final composto das duas redes neurais desenvolvidas (grupos adimensionais e ultrassom) usou um peso de 0,1 para a RNA dos grupos adimensionais e 0,9 para a RNA ultrassônica. Usando os dados do experimento de Gonçalves (2013), foi possível obter um erro médio de 3,8% para FVG e 99% de acerto na previsão de IPDE, confirmando a potencialidade das técnicas utilizadas para o desenvolvimento de um medidor multifásico industrial.

PALAVRAS CHAVES:

Redes neurais, escoamento multifásico, técnica ultrassônica, atenuação acústica, números adimensionais

ABSTRACT

This research aims at developing artificial neural networks (ANN) to determine the gas volume fraction (GVF) and the flow patterns in multiphase flows representative of the oil industry (FPI). The neural models were trained using Levenberg-Marquardt algorithm with Bayesian regularization, which is considered a standard regarding non-linear optimizations. Furthermore, it is a sophisticated way to improve the generalization of the model. Two distinct neural networks with different inputs were created to each variable to be predicted. They were combined to generate the desired output (GVF or FPI). Through a phenomenological approach, dimensionless numbers representative of the competing forces within two-phase liquid-gas flows were formed and used as inputs. The ANNs were trained with an extensive database found in the literature for horizontal and upward vertical two-phase flows. In a second approach, ultrasonic technique was used. Acoustic attenuation data were treated and transformed into energy ratio, used as inputs of the model. Using two experimental setups, it was possible to obtain the acoustic data. The first one used mineral oil as continuous phase in a closed circuit flow, with a high-speed filming camera for FPI pattern recognition. The other setup used an ultrasonic multiphase flow-metering prototype installed in a vertical column. Tests of gas retention (GVF) were carried out using crude oil as continuous phase, with different viscosities. The final neural system composed by the two developed neural networks (dimensionless groups and ultrasound) used a 0.1 weight for the dimensionless groups' ANN and a 0.9 weight for the ultrasound ANN. Using data from Gonçalves (2013)'s experiment it was possible to obtain an average error of 3.8% for GVF and 99% of correct answers in FPI prediction, thus testifying the potential of the used techniques to the development of an industrial multiphase flow metering device.

KEYWORD: Neural networks, multiphase flow, ultrasonic technique, acoustic attenuation, dimensionless numbers.

SUMÁRIO

1. INTRODUÇÃO	1
1.1. OBJETIVOS	2
2. REVISÃO BIBLIOGRÁFICA	5
2.1. Medidores multifásicos e suas tecnologias	5
2.2. Números adimensionais	10
2.3. Conclusão	15
3. FUNDAMENTOS TEÓRICOS	17
3.1. ESCOAMENTOS MULTIFÁSICOS	17
3.2. ULTRASSOM	21
3.3. REDES NEURAIIS	27
3.3.1. Perceptrons de múltiplas camadas	29
3.3.2. Algoritmo de treinamento	30
3.4. NÚMEROS ADIMENSIONAIS	32
4. METODOLOGIA	35
4.1. ESCOLHA DO ÍNDICE NUMÉRICO DE PADRÃO DE ESCOAMENTO (IPDE)	35
4.2. EXPERIMENTOS USANDO A TÉCNICA ULTRASSÔNICA	36
4.2.1. Circuito Vertical para simulação de escoamentos multifásicos (GONÇALVES, 2013)	37
4.2.2. Protótipo ultrassônico utilizando petróleo	43
4.3. ANÁLISE DOS NÚMEROS ADIMENSIONAIS	45
4.3.1. Seleção preliminar dos números adimensionais	45
4.3.2. Seleção final dos grupos adimensionais	52
4.3.3. Banco de dados da literatura	52
4.4. ARQUITETURA DAS REDES NEURAIIS	55
4.4.1. Ultrassom	55
4.4.2. Números Adimensionais	58
4.5. COMBINAÇÃO FINAL DAS REDES NEURAIIS	60
5. RESULTADOS E DISCUSSÃO	63
5.1. RNA ULTRASSOM	63

5.2. RNA NÚMEROS ADIMENSIONAIS	71
5.3. Protótipo Ultrassônico	81
5.3.1. Ultrassom.....	81
5.3.2. Números Adimensionais	86
5.4. Combinação das RNAs dos grupos adimensionais e o ultrassônico.....	86
6. CONCLUSÃO	93
7. REFERÊNCIAS	97
ANEXO A.....	103

AGRADECIMENTOS

Gostaria de agradecer aos meus pais, Rosalina Rosa Nakashima e Mauro Hideo Nakashima, pelo amor incondicional, pelos anos de dedicação, cuidado e esforços realizados durante toda a minha educação e formação profissional. A eles devo todas as minhas conquistas.

Ao meu marido Pedro Nuno Matamouros Martins Nakashima Vicente pelo carinho, amor e companheirismo. Seu apoio e paciência em todos os momentos foram fundamentais para enfrentar todos os desafios que tenho vivido. Obrigado por me encorajar e sonhar junto comigo.

Agradeço também à minha irmã Ketlen Keiko Nakashima, pela amizade, apoio, momentos de descontração e também pelas saídas culturais.

Agradeço aos professores da FEQ (Faculdade de Engenharia Química) pelos conhecimentos adquiridos ao longo de minha graduação e mestrado e em especial aos professores do DESQ.

Um agradecimento muito especial à minha orientadora Prof^a. Dr^a. Ana Maria Frattini Fileti por ter dado essa oportunidade, pelos conselhos e ensinamentos. Devo muito à sua ajuda a enfrentar todos os desafios e por ter compreendido e apoiado em algumas decisões na minha vida.

Ao meu co-orientador Prof. Dr. Ricardo Dias Martins de Carvalho pelo aprendizado, ajuda e por tirar todas as minhas dúvidas e auxiliar nas correções.

Meus cumprimentos aos meus amigos pela torcida e por terem me proporcionado momentos de alegria e diversão. Mesmo alguns estando longe, sei que posso contar.

Gostaria de agradecer a UNICAMP e a CNPQ pela bolsa de estudos concedida.

Por fim, agradeço a todos que direta ou indiretamente apoiaram e contribuíram para a realização e conclusão deste trabalho e etapa da minha vida.

LISTA DE FIGURAS

Figura 1 Padrões de escoamento horizontais	18
Figura 2. Padrões de escoamento verticais	18
Figura 3. Espectro de frequência do ultrassom e suas aplicações mais comuns.....	23
Figura 4 Reflexão e transmissão de uma onda plana oblíqua ao plano da interface entre dois fluidos com impedâncias acústicas diferentes	24
Figura 5 representações esquemáticas do campo de som: (a) bolhas dispersas; (b) bolhas; (c) bolhas de Taylor incipientes; (d) anular	26
Figura 6. Modelo não linear de um neurônio	28
Figura 7. Arquitetura de um <i>perceptron</i> de múltiplas camadas com duas camadas ocultas.....	29
Figura 8. Comparação entre dados ajustados adequadamente e dados ajustados em excesso (sobre ajuste)	32
Figura 9 - Visão esquemática da instrumentação ultrassônica e montagem experimental (LRF – UNIFEI).	38
Figura 10 - Vista esquemática da instrumentação ultrassônica	40
Figura 11 - Sistema de aquisição dos dados ultrassônicos.....	40
Figura 12 – Montagem do experimento com o carretel (LESQ/UNICAMP).....	43
Figura 13. Trecho da tabela ‘Dados de Operação 1’	53
Figura 14. Trecho da tabela ‘Dados de Operação 2’	54
Figura 15. Trecho da tabela ‘Propriedades Físicas’	55
Figura 16. Trecho da tabela ‘Grupos Adimensionais’	55
Figura 17. Esquema do sistema da predição final de FVG e de IPDE.	61
Figura 18 - Arquitetura das redes neurais desenvolvidas tanto para FVG quanto para Padrão de escoamento.	66
Figura 19. Desempenho da RNA para a identificação de padrão de escoamento para as tubulações de 1 e 2 polegadas com banco de dados de validação.	68
Figura 20. Comparação entre os valores de IPDE (padrões de escoamento) previstos pela rede e os valores experimentais versus vetores.....	68
Figura 21. Resultado da RNA para previsão de FVG para as tubulações de 1 e 2 polegadas mostrando erro médio do resultado total de 4,2%.	69

Figura 22. Comparação entre os valores de FVG previstos pela rede, os valores experimentais versus vetores.....	70
Figura 23. Resultado para o grupo de validação da RNA de previsão de FVG com números adimensionais e erro médio de $\pm 7\%$	74
Figura 24. Comparação de resposta da RNA para FVG e da literatura para cada vetor do banco de dados de validação.....	75
Figura 25 Resultado para o grupo de validação da RNA de previsão de IPDE com números adimensionais	78
Figura 26 Comparação de resposta da RNA para IPDE e da literatura para cada vetor do banco de dados de validação.....	78
Figura 27 Tendências no sensor 0°	83
Figura 28 Tendências no sensor de 45°	83
Figura 29 Tendências no sensor de 135°	84
Figura 30 Tendências no sensor de 180°	84
Figura 31 Resultado para o sistema neural combinado para previsão de FVG	88
Figura 32 Comparação de resposta para FVG experimental e do sistema neural combinado para cada vetor do banco de dados.....	89
Figura 33 Resultado para o sistema neural combinado para previsão de IPDE	90
Figura 34 Comparação de resposta para IPDE experimental e do sistema neural combinado para cada vetor do banco de dados.....	90

LISTA DE TABELAS

Tabela 1 Grupos adimensionais selecionados por Shaikh e Aldahhan (2003) para previsão da fração de vazão média em colunas de bolhas.	14
Tabela 2 Grupos adimensionais selecionados por Duns e Ros (1963) para a descrição de escoamentos bifásicos verticais ascendentes.	15
Tabela 3 Classificação de escoamentos bifásicos verticais para desenvolvimento da rede neural	20
Tabela 4 Classificação dos escoamento horizontais no presente estudo	21
Tabela 5 Valores de coeficiente de reflexão (R_i) e transmissão (T_i) em interfaces planas de interesse neste trabalho.	25
Tabela 6 Correlação do índice usado para o Padrão de Escoamento e seu intervalo numérico.....	36
Tabela 7 Composição dos escoamentos multifásicos testados	37
Tabela 8 Condições operacionais para os experimentos de escoamentos multifásicos	41
Tabela 9 - Composição da fase contínua testada nos experimentos	44
Tabela 10: Grupos adimensionais pertinentes ao presente estudo.....	46
Tabela 11: Grupos adimensionais selecionados preliminarmente para entrada da rede neural (escoamento bifásico)	48
Tabela 12. Números adimensionais utilizados como entradas da rede neural.....	51
Tabela 13 Combinação de pesos para avaliação de pesos padrão do sistema neural..	62
Tabela 14. Treinamentos para determinação da melhor arquitetura da rede neural com dados ultrassônicos para resposta em fração de vazão.....	64
Tabela 15. Treinamentos para determinação da melhor arquitetura da rede neural com dados ultrassônicos para resposta em padrão de escoamento	65
Tabela 16. Número de dados disponíveis para cada tipo de padrão de escoamento (montagem experimental item 4.2.1).....	66
Tabela 17. Avaliação dos resultados das RNAs usando-se o conjunto de validação	71
Tabela 18 Relação de estudos da literatura completados com dados sintéticos	71
Tabela 19. Treinamentos para determinação da melhor arquitetura da rede neural com números adimensionais e resposta FVG	72

Tabela 20. Treinamentos para determinação da melhor arquitetura da rede neural com números adimensionais e resposta IPDE	73
Tabela 21 Avaliação do desempenho da RNA dos números adimensionais para previsão de FVG para cada estudo da literatura.	76
Tabela 22 Avaliação do desempenho da RNA dos números adimensionais para previsão de FVG para cada padrão de escoamento	77
Tabela 23 Avaliação do desempenho da RNA dos números adimensionais para previsão de IPDE para cada estudo da literatura.	79
Tabela 24 Avaliação do desempenho da RNA dos números adimensionais para previsão de IPDE para cada padrão de escoamento	80
Tabela 25 Desvio padrão da leitura da FVG para cada amostra de petróleo.....	85
Tabela 26 Teste de pesos para previsão de FVG	87
Tabela 27 Teste de pesos para previsão de IPDE	87
Tabela 28 Comparação do erros médios calculados das previsões das redes neurais dos grupos adimensionais, ultrassônica e sistema combinado para os sistemas que preveem FVG e IPDE.....	91

LISTA DE ABREVIATURAS E SIGLAS

- AH – Anular em escoamento horizontal.
- AV – Anular em escoamento vertical.
- BH – Bolhas dispersas em escoamento horizontal.
- BV – Bolhas dispersas em escoamento vertical.
- EIT – Tomografia de impedância elétrica.
- FVG – Fração de volume de gás.
- IPDE – Índice numérico de padrão de escoamento multifásico.
- IT – Intermitente em escoamento vertical.
- LESQ-Laboratório de Engenharia de Sistemas Químicos.
- LRF – Laboratório de Refrigeração de Ar Condicionado.
- MLP – Perceptron de múltiplas camadas.
- MMF – medidores multifásicos.
- MRI – Imagem de ressonância magnética.
- PNN – Rede neural probabilística.
- RBF – Rede neural de função de base radial.
- RNA – Redes neurais artificiais.
- SF – Pistonado em escoamento horizontal.
- SR – Estratificado rugoso em escoamento horizontal.
- ST – Estratificado em escoamento horizontal.
- UNICAMP – Universidade Estadual de Campinas.
- UNIFEI – Universidade Federal de Itajubá.
- UPDV – Velocímetro Doppler de pulso ultrassônico.

LISTA DE SÍMBOLOS

Letras Latinas

- a – Parâmetro de inclinação da função sigmoide
A – Ar
 b_k – Bias aplicado ao neurônio k
c – Velocidade do som (m/s)
 c_p – Calor específico à pressão constante (J/kg K)
D – Diâmetro da tubulação (m)
 D_R – Razão de densidades
E – Energia do pulso ultrassônico (V^2s)
 \bar{e} – Erro médio
 E_o – Número de Eötvös
 E_w – Regularizador de decaimento de peso
F – Função erro
Fr – Número de Froude
 Fr_{TP} – Número de Froude do escoamento bifásico
g – fase gasosa
G – Velocidade mássica (kg/m^2s)
I – Intensidade Acústica (W/m^2)
j – Velocidade superficial (m/s)
k – Condutividade térmica (W/m K)
l – fase líquida
 Mo – Número de Morton
n – número total de pesos da rede neural
 N_D – Número do diâmetro
 N_G – Número da viscosidade do gás
 N_{GV} – Número de velocidade de gás
 N_L – Número da viscosidade do líquido
 N_{LV} – Número de velocidade do líquido
O – Óleo
P – Poliamida

p – Pressão (bar)
 p_{atm} – Pressão atmosférica (bar)
 P_o – Amplitude de pressão acústica (Pa)
 q – Número total de vetores
 r – Resistência acústica específica
 Re – Número de Reynolds
 Re_{SG} – Número de Reynolds da velocidade superficial do gás
 Re_{SL} – Número de Reynolds da velocidade superficial do líquido
 Re_{TP} – Número de Reynolds do escoamento bifásico
 R_I – Coeficiente de reflexão
 S – Areia
 s – fração seca = G_G/G
 SSE – Soma quadrática dos erros
 T – temperatura ($^{\circ}C$)
 T_I – Coeficiente de transmissão
 u_g – Velocidade da fase gasosa (m/s)
 u_{gu} – velocidade de deriva da fase gasosa (m/s)
 u_k – Saída do combinador linear
 u_l – Velocidade da fase líquida (m/s)
 W – água
 We – Número de Weber
 We_{TP} – Número de Weber modificado
 w_{kj} – Peso sináptico da sinapse j pertencente ao neurônio k
 x – Coordenada espacial (m)
 \dot{x} – Variável não normalizada
 \dot{x}_{max} – Valor máximo da variável não normalizada
 \dot{x}_{min} – Valor mínimo da variável não normalizada
 x_n – Entrada n da rede neural
 y – Variável normalizada
 y_k – Sinal de saída do neurônio
 y_{max} – Valor máximo da variável normalizada

y_{\min} – Valor mínimo da variável normalizada

Letras Gregas

α – Coeficiente de absorção (Np/m)

α_c – Coeficiente de absorção clássico (Np/m)

α_g – Fração de vazio FVG

α_k – Coeficiente de absorção térmico (Np/m)

α_s – Coeficiente de absorção viscoso – Stokes (Np/m)

α_w – Peso da função erro

β_w – Peso da função erro

ε – Rugosidade (μm)

η – Coeficiente de viscosidade de cisalhamento (Pa.s)

θ – Ângulo de inclinação da tubulação (rad)

λ_l – Razão de velocidades superficiais.

μ - viscosidade dinâmica (Pa.s ou cP)

ρ_g – massa específica do gás (kg/m^3)

ρ_l – massa específica do líquido (kg/m^3)

ρ_o – massa específica da fase contínua (kg/m^3)

σ – Tensão superficial (N/m)

φ – Função de ativação

ψ – Ângulo de contato (rad)

ω – frequência angular (rad/s)

ϕ_I – Condição de referência

ϕ_{II} – Condição do escoamento multifásico

γ – razão dos calores específicos

1. INTRODUÇÃO

De forma geral, escoamento multifásico consiste na passagem simultânea de duas ou mais fases em um sistema como canal, tubulação ou duto.

Os fluidos extraídos de poços de petróleo raramente são líquidos ou gases puros. Na maioria das vezes, emergem como misturas multifásicas. Tradicionalmente, as vazões são medidas separando-se primeiro cada fase e, em seguida, lançando mão de técnicas convencionais de medições monofásicas (FALCONE *et al.*, 2010). A necessidade de medidores de escoamentos multifásicos surge quando é necessário ou desejável medir a vazão a montante dos separadores. A desvantagem das técnicas de medições multifásicas atuais é a necessidade de calibração prévia para toda a variedade de fluidos e condições operacionais na indústria do petróleo. O uso de redes neurais artificiais (RNAs), desde que alimentadas cumulativamente com informações destas variedades de fluidos e condições operacionais, pode ser uma solução para esse problema.

Ainda de acordo com Falcone *et al.* (2010), a natureza não-linear de escoamentos multifásicos mostra-se como um grande obstáculo na obtenção de medições de vazões confiáveis. As redes neurais artificiais fornecem o mapeamento e a correlação não-linear entre variáveis de entrada e saída, sendo, portanto, uma ferramenta poderosa para lidar com essas não linearidades.

Conforme exposto por Haykin (2001) a era moderna das redes neurais começou com o trabalho pioneiro de McCulloch e Pitts (1943). No seu artigo, eles descrevem um cálculo lógico das redes neurais que unificava os estudos de neurofisiologia e da lógica matemática. McCulloch e Pitts mostraram que uma rede assim constituída realizaria, a princípio, cálculos de qualquer função computável.

Cerca de 15 anos após a publicação desse clássico artigo, uma nova abordagem foi introduzida por Rosenblatt (1958) em seu trabalho sobre *perceptron*, um método inovador de aprendizagem supervisionada. Durante toda a década de 1960, achava-se que as redes neurais poderiam realizar qualquer coisa. Contudo, Minsky e Papert (1969) demonstraram matematicamente que existem limites fundamentais para o que os perceptrons de camada única poderiam calcular e, em um breve capítulo,

afirmavam que não havia razão para supor que essas limitações poderiam ser superadas por múltiplas camadas.

Isto contribuiu para a perda do interesse em redes neurais na década de 1970. Este impasse apenas foi superado por Ackley *et al.* (1985) no desenvolvimento da conhecida máquina de Boltzmann, que foi a primeira rede neural de múltiplas camadas bem sucedida.

Em 1986, foi então relatado o desenvolvimento do algoritmo de retro propagação (back-propagation), que emergiu como o algoritmo de aprendizagem mais popular para o treinamento de perceptrons de múltiplas camadas. Desde então, as redes neurais tem ganhado importância e continuarão a crescer em teoria, projeto e aplicações (HAYKIN, 2001).

Neste trabalho são apresentados os fundamentos das redes neurais, assim como a metodologia aplicada para o desenvolvimento de RNAs focadas no reconhecimento de padrões de escoamentos e na identificação da fração de volume de gás (FVG) para escoamentos multifásicos. A grande vantagem da abordagem usada neste trabalho é o uso da técnica ultrassônica por um equipamento não intrusivo, aliada também à utilização de uma abordagem fenomenológica através dos números adimensionais. Pode-se obter, portanto, uma combinação de modelos neurais robusta para a finalidade proposta.

1.1. OBJETIVOS

O principal objetivo deste trabalho foi o desenvolvimento de redes neurais artificiais que preveem o tipo de padrão de escoamento multifásico através de um índice numérico de padrão de escoamento (IPDE) e determinam a fração de vazio (FVG).

Os objetivos específicos são:

- I. Desenvolver e avaliar o desempenho de RNA tendo como entrada a razão de energia de atenuação acústica;
- II. Avaliar os grupos adimensionais a serem usados como entrada da RNA;
- III. Aumentar e diversificar o banco de dados da literatura, procurando ter o maior número possível de pontos, condições operacionais e fluidos utilizados;

- IV. Desenvolver e avaliar o desempenho de RNA tendo como entrada grupos adimensionais;
- V. Desenvolver e avaliar o desempenho de um sistema neural composto pela RNA ultrassônica e pela RNA com os grupos adimensionais;
- VI. Avaliar o desempenho de predição de todas as redes neurais desenvolvidas quando exposta a novos dados extraídos de experimento utilizando petróleo como fase contínua.

2. REVISÃO BIBLIOGRÁFICA

2.1. Medidores multifásicos e suas tecnologias

O monitoramento e controle das diversas fases que compõem o escoamento multifásico na indústria petrolífera se faz necessário. De forma geral, os medidores multifásicos (MMF) podem ser usados para diversas funções, tais como para substituir os separadores de testes, monitoramento de poços individuais, sistemas de elevação artificial e mesmo a produção total de um campo de petróleo (GONÇALVES, 2013). Diversas técnicas têm sido utilizadas por estes medidores para a identificação tanto das vazões de cada fase quanto para os padrões de escoamento. Cada técnica usa diferentes princípios físicos para a medição e determinação de diversos parâmetros e propriedades (fração volumétrica, velocidade interfacial, conteúdo de água na fase líquida (watercut) etc.) (SALGADO, 2010). Falcone *et al.* (2010) discutem detalhadamente cada técnica e instrumentos que são utilizados mais frequentemente na indústria. Dentre eles valem destacar o uso da radiação gama (BISHOP; JAMES, 1993; HARTLEY *et al.*, 1995; ROACH *et al.*, 1995; ÅBRO *et al.*, 1999; SALGADO, 2010; ROSHANI *et al.*, 2014), impedância (DYKESTEEN *et al.*, 1985; MI *et al.*, 1997; MI *et al.*, 1998; MI *et al.*, 2001; JAWORSKI; DYAKOWSKI, 2005), micro-ondas (BO; NYFORS, 2002; ARMIN, 2004), pressão diferencial, atenuação acústica, infravermelho e tomografia.

Muitas dessas técnicas utilizam conjuntamente as redes neurais como solução nas MMFs. Falcone *et al.* (2010) destacam que um dos maiores obstáculos para se obter informações confiáveis de parâmetros do escoamento é a natureza não-linear dos escoamentos multifásicos. Uma das ferramentas mais populares é o uso de redes neurais artificiais.

Bishop e James (1993) utilizaram densitometria de raio gama com duas energias (662 keV (Cs^{137}) e 1,33 MeV (Co^{60})) para a obtenção do regime de escoamento e a partir dela a fração de vazio em escoamento multifásico em gás, óleo e água. Foram usados três feixes verticais e três horizontais, unidirecionais, e seis detectores pontuais. Foi introduzido o conceito da técnica de rede neural artificial para a análise dos dados de densitometria de raio gama e determinar a fração de vazio e o

padrão de escoamento. O estudo concluiu que a rede neural é uma poderosa ferramenta para a análise dos dados de densitometria de raio gama, permitindo a determinação da fração de vazio e do padrão de escoamento com uma alta exatidão.

Åbro *et al.* (1999) desenvolveram um sistema em que foi utilizada a atenuação de raios gama de feixes múltiplos de baixa energia usando ²⁴¹Am para a determinação da FVG e regime de escoamento bifásico de óleo e gás em tubulação, com fluxos homogêneo, anular e estratificado. Eles utilizaram redes neurais artificiais para converter os espectros obtidos por múltiplos feixes de raios gama em uma classificação de padrão de escoamento para se obter a FVG. Foram usados espectros de raio gama simulados através do código computacional EGS4 baseado no método de Monte Carlo. Conseguiu-se determinar a fração de vazio com um erro de 3% para todos os regimes de escoamento e os três tipos de regime foram sempre corretamente distinguidos.

O trabalho de Roshani *et al.* (2014) teve como objetivo prever a porcentagem de óleo, água e ar em escoamento multifásico anular. Utilizou-se a técnica de duplo feixe de raios gama, obtendo seus dados através de simulação com o algoritmo Monte Carlo (MCNP). Como a RNA é um método apropriado para lidar com problemas de predição e classificação, foi utilizada esta técnica, usando-se um *perceptron* multicamadas modelado no MATLAB®. Os resultados mostraram uma boa concordância entre os valores previstos pela rede e os valores simulados, obtendo-se erros negligenciáveis entre eles.

Os estudos anteriormente citados são baseados em uma técnica radioativa, apesar de não intrusivas. Contudo, Arora (2009) discute as vantagens que os MMFs não radioativos tem sobre MMFs radioativos. MMFs não radioativos são muito mais baratos em sua construção. Além disso, os gastos operacionais são muito menores porque se eliminam todos os custos associados às exigências de segurança, meio ambiente e saúde.

Tsoukalas *et al.* (1997) desenvolveram um medidor de fração de vazio por impedância. Utilizando-se um sistema neuro-fuzzy, foi possível prever os padrões de escoamento. Mostrou-se também que os sinais elétricos representando a condutância do meio podem ser usados para inferir parâmetros cruciais do escoamento.

Mi *et al.* (1998) utilizaram um medidor multifásico não intrusivo de impedância com múltiplos eletrodos para medição de FVG. Este medidor fornece sinais de entrada para uma RNA, com modelos de aprendizagem supervisionado e auto organizável, que é usada para identificar os regimes de fluxo vertical ascendente ar-água. Os resultados experimentais mostram que as flutuações de FVG obtidas pelo medidor podem ser relacionadas com as características dos padrões de escoamento. A RNA resultante executou de maneira satisfatória a identificação do regime de escoamento. Contudo, houve algumas desvantagens: os resultados das medidas são facilmente afetados pela variação de temperatura; o tubo tem que ser feito de material não condutor para se garantir que este esteja eletricamente isolado; este procedimento somente se adapta aos casos de fluxo bifásico, especialmente onde a diferença dos coeficiente dielétricos e de condutividade entre as fases líquida e gasosa seja preferencialmente alta. Mi *et al.* (2001) continuam a utilizar RNA com aprendizagem supervisionada e auto organizável. Nesse sistema foi usada como entrada a impedância do escoamento bifásico. Para se evitar qualquer julgamento subjetivo e erros de instrumentos, foi feita a simulação teórica do escoamento bifásico vertical. Os resultados demonstraram conclusivamente que as RNAs são excelentes classificadoras de regime de escoamento.

O uso da impedância em dispositivos para caracterizar os escoamentos multifásicos datam dos anos 1960. Contudo, o método de impedância pode ser muito sensível ao padrão de escoamento em um canal e está sujeito ao problema de inversão, ou seja, quando, por exemplo, em um escoamento muda-se a fase contínua de óleo para água, a detecção deve mudar de capacitância para condutância (FALCONE *et al.*, 2010).

Meribout *et al.* (2010) desenvolveram um dispositivo para medição em tempo real de vazões multifásicas de óleo, gás e água. Foi composto de diversos sensores acústicos e elétricos, cujos sinais foram digitalizados e processados por RNA. Entretanto, as respostas dos sensores são dependentes do padrão de escoamento. Além disso, o problema de se identificar o padrão de escoamento como condição preliminar para se obter uma maior redução dos dados foi resolvido dividindo-se os dados de acordo com a faixa de fluxo de massa. Esta solução é satisfatória para

experimentos em escala laboratorial, no entanto não é uma solução viável para escoamentos reais.

Gonçalves (2013) utiliza em seu estudo o ultrassom. A técnica ultrassônica tem apresentado resultados promissores na medição multifásica, sendo já bem estabelecida em outras áreas da engenharia como, por exemplo, na medição da vazão de escoamentos monofásicos, ensaios não destrutivos para detecção de falhas e ultrassonografia médica. No que tange às vantagens da técnica ultrassônica na medição multifásica, pode-se citar: não-radiativa, não-intrusiva, de baixo preço, utilização de sensores robustos disponíveis comercialmente e possibilidade de operação em ambientes hostis como, por exemplo, em águas profundas e fluidos corrosivos.

Uma revisão bastante completa do uso da técnica ultrassônica no contexto de MMFs pode ser encontrada em Carvalho e Bannwart (2010). Os sinais ultrassônicos são uma informação rica e a técnica preenche os requisitos de transmissão de sinal a longa distância, e operações em condições extremas. Em Jones *et al.* (1986), atenuação acústica foi usada para medir a fração de vazão em escoamentos água-ar no padrão bolhas. Foi desenvolvido um modelo semi-empírico de interação da onda acústica com o escoamento bifásico.

A técnica ultrassônica também foi usada para medir as frações das fases dispersas em escoamentos bifásicos e trifásicos (ar-óleo; óleo-esferas de vidro; ar-óleo-esferas de vidro) (VATANAKUL *et al.*, 2004; ZHENG; ZHANG, 2004). Zheng e Zhang (2004) observaram que a atenuação acústica aumentava exponencialmente com o aumento da área interfacial de ambas as fases gás e sólida. As bolhas de ar causaram um aumento no tempo de trânsito acústico. Vatanakul *et al.* (2004) confirmaram essa observação e também verificaram que o espalhamento estatístico no tempo de trânsito e a amplitude do sinal aumentaram na medida em que a quantidade de gás aumentava.

Mais recentemente, Carvalho *et al.* (2009); Tanahashi (2010) apresentaram uma detalhada discussão sobre o formato da onda ultrassônica e como seu formato se reflete na computação dos parâmetros acústicos. Os autores então correlacionaram a atenuação acústica dos sinais com a FVG para escoamento de água-ar vertical ascendente em tubulação de acrílico de 2 polegadas de diâmetro interno. Grangeiro

(2010) e Tanahashi *et al.* (2010) estenderam o trabalho e demonstraram que a técnica ultrassônica tem potencial de prover informação em tempo real sobre a estrutura de escoamentos horizontais intermitentes como também estimar as vazões individuais do líquido e gás para esse padrão específico.

As desvantagens existentes atualmente com relação às técnicas ultrassônicas, assim como a maioria das MMFs disponíveis, está na necessidade de calibração prévia. Uma longa discussão sobre calibração em MMFs pode ser encontrada em Corneliussen *et al.* (2005). Os autores discutem que os elementos de medida primárias de um MMF geralmente podem ser calibradas através de procedimentos padrões similares àqueles usados em medidas de escoamentos monofásicos. No entanto, ao contrário do que acontece com os medidores monofásicos, a saída das medidas primárias de um MMF é usada como entrada para um algoritmo avançado de processamento de sinal para o cálculo da vazão de cada fase. A calibração é então limitada, pois um produto específico usado como fluido de calibração pode não ser representativo de um outro produto de outro poço.

Levando em conta essas limitações, uma solução pode ser o uso de RNAs. Como citado anteriormente, várias MMFs já as utilizam.

Shaikh e Aldahhan (2003) desenvolveram uma RNA que prevê o volume de gás em um reator de coluna de bolhas usando números adimensionais como entrada. Malayeri *et al.* (2003) utilizaram RNA de base radial (RBF) utilizando como entradas para o treinamento os parâmetros adimensionais razão de vazão volumétrica modificada, razão de diferença de densidade e o número adimensional de Weber para prever a fração de vazio em sistemas submetidos a diferentes temperaturas. A predição da RNA resultou em FVG com erro relativo médio de 3,6% para o conjunto de treinamento e 5,8% para dados não vistos no treinamento. Além disso, os autores comprovaram que os resultados experimentais e os obtidos pela rede são qualitativamente consistentes.

Rosa *et al.* (2010) usaram três tipos de RNA em sua investigação de identificar padrões de escoamento multifásicos (*perceptron* multicamada, MLP; função de base radial, RBF; e rede neural probabilística, PNN). Seu estudo mostrou que os três tipos tiveram performances semelhantes, sendo o *perceptron* mais vantajoso

comparado ao RBF e ao PNN. O RBF usa um algoritmo que frequentemente cai em um mínimo local enquanto que o PNN exige um esforço computacional muito grande.

Inoue *et al.* (2013) desenvolveram uma RNA para a identificação dos padrões de escoamento bifásico horizontal e vertical de água-ar (bolhas dispersas, estratificado, estratificado rugoso, pistonado e anular). Foram utilizados grupos adimensionais que embarcaram todas as forças competidoras que ocorrem em um escoamento multifásico. Tomou-se o cuidado de se incluir nos grupos apenas variáveis usadas rotineiramente na indústria. Uma base de dados inicial foi criada para o treinamento e validação da rede. Contudo, não foram feitos estudos mais aprofundados no que tange à relevância de cada número adimensional, portanto não sendo a configuração ótima para as entradas da RNA. A RNA desenvolvida classificou de maneira precisa os padrões de escoamento, tendo apenas pequenos desvios. Deve-se salientar, no entanto, que a base de dados utilizada não era muito grande e com a maior parte sendo de escoamento tendo água como fase contínua.

2.2. Números adimensionais

Ao escolher parâmetros ou grupos adimensionais de entrada para a presente rede neural, deve-se primeiramente considerar quais efeitos físicos devem ser levados em consideração. Neste sentido, seja primeiramente uma discussão de variáveis independentes relacionadas por outros autores. Das cinco variáveis identificadas por Shaikh e Aldahhan (2003) como determinantes da fração de vazão média, quatro se aplicam diretamente a qualquer escoamento líquido-gás (somente a geometria do dispersor é específica a reatores químicos). Estas variáveis são:

- Velocidade superficial do gás;
- Diâmetro da tubulação;
- Pressão de operação;
- Propriedades físicas do líquido.

Dukler *et al.* (1964) realizaram uma análise de similaridade para determinação de parâmetros pertinentes à descrição da perda de carga em escoamentos bifásicos líquido-gás. Desta análise, emergiram formulações genéricas do número de Reynolds e do número de Euler como parâmetros importantes para a

correlação das forças atuantes no escoamento bifásico. A análise de similaridade permitiu ainda a obtenção de expressões genéricas para a densidade e viscosidade da mistura bifásica. Estas expressões são, no seu conjunto, função dos seguintes parâmetros e propriedades:

- Densidade do gás;
- Densidade do líquido;
- Viscosidade do gás;
- Viscosidade do líquido;
- Fração volumétrica do líquido;
- Distribuição de vazios na seção transversal (padrão de escoamento);
- Fração volumétrica do gás na seção transversal (fração de vazio média);
- Vazão volumétrica do gás;
- Vazão volumétrica do líquido;
- Distribuição de velocidades do gás;
- Distribuição de velocidades do líquido;
- Gradiente de pressão;
- Dimensão característica.

Godbole *et al.* (2011) realizaram uma comparação entre correlações para a determinação da fração de vazio em diferentes padrões de escoamentos bifásicos verticais ascendentes. Os seguintes parâmetros ou grupos adimensionais são recorrentes nas várias correlações para escoamentos líquido-gás sem mudança de fase:

- Ângulo de inclinação da tubulação: θ
- Número de Froude do escoamento: $\frac{(j_g + j_l)^2}{gD}$
- Razão de densidades: $\frac{\rho_g}{\rho_l}$
- Tensão superficial: σ
- Velocidade de deriva da fase gasosa: u_{gu}
- Velocidade superficial do gás: j_g
- Velocidade superficial do líquido: j_l

Nem todas as variáveis ou parâmetros que compõem as expressões para as descrições do escoamento bifásico de Dukler *et al.* (1964) e Godbole *et al.* (2011) são realmente independentes. Muitas delas ou são resultado de cálculos intermediários ou são variáveis dependentes do ponto de vista do modelo neural que se pretende desenvolver. O modelo de Dukler *et al.* (1964), por exemplo, tenta levar em conta as muitas variáveis que governam o fenômeno e, por esta razão, envolve muitas variáveis impraticáveis na indústria como variáveis de entrada da presente rede neural, tais como, frações volumétricas de gás e de líquido, padrão de escoamento e distribuição de velocidades. Além disso, no presente trabalho a fração de vazio e o padrão de escoamento foram considerados variáveis dependentes do ponto de vista da rede neural.

A dimensão característica como variável de entrada pressupõe a especificação prévia da geometria a ser tratada pela rede neural. No caso de tubos circulares, a geometria é suficientemente caracterizada pelo ângulo de inclinação e o seu diâmetro.

O gradiente de pressão presente no modelo de Dukler *et al.* (1964) poderia ser uma das variáveis de entrada da rede neural desde que fossem feitas também medidas diferenciais da pressão. Todavia, o gradiente de pressão é um dos objetivos das simulações numéricas do escoamento. Com relação à pressão de operação, utilizada como variável de entrada por Shaikh e Aldahhan (2003), cabe a pergunta se sua influência já não é suficientemente levada em conta pelas propriedades físicas dos fluidos (densidade do gás, principalmente) ou se ela deve ser uma variável de entrada por si própria.

A rugosidade da superfície interna do tubo tampouco foi considerada como uma variável independente relevante por Shaikh e Aldahhan (2003), Dukler *et al.* (1964) e Godbole *et al.* (2011). Entretanto, pela sua influência sobre a magnitude das forças viscosas, é de se esperar que a rugosidade tenha alguma influência sobre o padrão de escoamento. Por outro lado, este efeito deve ser pequeno comparado, por exemplo, aos efeitos da viscosidade dos próprios fluidos.

Da discussão acima podem ser listadas as seguintes variáveis como pertinentes, e talvez suficientes, para a descrição confiável de escoamentos bifásicos líquido-gás:

1. Geometria do escoamento;
2. Dimensão característica (diâmetro da tubulação, dimensão característica do espaço anular, etc.);
3. Ângulo de inclinação da tubulação;
4. Rugosidade da superfície interna da tubulação;
5. Velocidade superficial do gás;
6. Velocidade superficial do líquido;
7. Velocidade de deriva da fase gasosa;
8. Densidade do líquido;
9. Viscosidade dinâmica do líquido;
10. Tensão superficial do líquido;
11. Densidade do gás;
12. Viscosidade dinâmica do gás;
13. Gradiente de pressão;

Como são 13 variáveis, torna-se necessária a análise dimensional a fim de se reduzir o número de variáveis de entrada e experimentos para desenvolvimento e validação da rede neural. A este respeito, a Tabela 1 mostra os grupos adimensionais identificados por Shaikh e Aldahhan (2003) como mais adequados à previsão da fração de vazio média em colunas de bolhas. Deve-se observar que a expressão para o número de Reynolds não corresponde exatamente ao número de Reynolds do gás. Aparentemente, esta expressão tenta descrever a razão entre forças de inércia de bolhas de gás, espalhadas por uma seção transversal de diâmetro D , que se movem contra a viscosidade de um líquido em repouso. Esta definição do número de Reynolds obviamente não se aplica a escoamentos multifásicos da indústria petrolífera, pois neste caso todas as fases se movem.

Analogamente, o número de Froude também é dado somente em termos da velocidade do gás, pois a fase líquida não se desloca. A este respeito, deve-se

observar que Guzhov *et al.* (1967) utilizaram o número de Froude do escoamento no caso de escoamentos bifásicos (Eq. 1) :

$$Fr = \frac{(j_g + j_l)^2}{gD} \quad \text{Eq. 1}$$

Duns e Ros (1963) utilizaram as variáveis ρ_L, g, σ para a formação de escalas e grupos adimensionais para o caso específico de escoamentos bifásicos verticais ascendentes (Tabela 2). A razão para a escolha da tensão superficial se deve ao fato desta propriedade influir no tamanho de bolhas e gotas presentes em diferentes padrões de escoamento bifásico. Foram feitos os seguintes comentários acerca dos grupos adimensionais formados:

- Devido à elevada turbulência do gás, o efeito de μ_g foi considerado desprezível.
- O efeito de ρ_g também foi considerado desprezível exceto a altas pressões, quando esta propriedade assume valores maiores.
- O efeito da rugosidade, ε , pode ser desprezado em tubos verticais.
- O efeito do ângulo de contato, ψ , também é desprezível se a parede estiver sempre molhada.

Tabela 1 Grupos adimensionais selecionados por Shaikh e Aldahhan (2003) para previsão da fração de vazio média em colunas de bolhas.

Denominação	Expressão	Significado Físico
Número de Reynolds do gás	$Re_g = \frac{(\rho_l - \rho_g)u_g D}{\mu_l}$	Inércia do gás / viscosidade do líquido
Número de Froude do gás	$Fr_g = \frac{u_g^2}{gD}$	$\frac{\text{Forças de inércia}}{\text{Forças gravitacionais}}$
Razão entre o número de Eötvös e o número de Morton	$\frac{Eo}{Mo} = \frac{\rho_l^2 D^2 \sigma_l^2}{\mu_l^4}$	$\frac{\text{inércia} \times \text{capilaridade}}{\text{Forças viscosas}}$
Razão de densidades	$D_R = \frac{\rho_g}{\rho_l}$	Efeito da pressão

Tabela 2 Grupos adimensionais selecionados por Duns e Ros (1963) para a descrição de escoamentos bifásicos verticais ascendentes.

Denominação	Expressão
Número da velocidade do líquido	$N_{LV} = j_l \left(\frac{\rho_L}{\sigma g} \right)^{1/4}$
Número da velocidade do gás	$N_{GV} = j_g \left(\frac{\rho_L}{\sigma g} \right)^{1/4}$
Número da viscosidade do líquido	$N_L = \mu_l \left(\frac{g}{\rho_L \sigma^3} \right)^{1/4}$
Número da viscosidade do gás	$N_G = \mu_g \left(\frac{g}{\rho_L \sigma^3} \right)^{1/4}$
Razão de densidades	$D_R = \frac{\rho_g}{\rho_l}$
Número do diâmetro	$N_D = D \left(\frac{\rho_L g}{\sigma} \right)^{1/2}$
Rugosidade relativa	$\frac{\varepsilon}{d}$
Ângulo de contato	ψ
Ângulo de inclinação da tubulação	θ

Com base nestas considerações, Duns e Ros (1963) mantiveram apenas N_{LV} , N_{GV} , N_D , N_L e θ como suficientes para a descrição do gradiente de pressão, padrão de escoamento e fração de vazio dos escoamentos bifásicos verticais ascendentes por eles estudados.

Baseando-se na análise desses estudos, foi possível iniciar a seleção dos grupos adimensionais para a entrada da rede neural.

2.3. Conclusão

Conclui-se que os medidores multifásicos tem ganhado cada vez mais importância na indústria do petróleo. Várias tecnologias tem sido desenvolvidas nos últimos anos, tendo o uso de redes neurais se destacado para lidar com as complexidades e não linearidades dessas tecnologias. Dentre essas tecnologias uma que tem se mostrado promissora é o uso do ultrassom por ser uma técnica não invasiva e não radioativa.

Também vale destacar a seleção e o uso de grupos adimensionais que embarcam as forças atuantes no escoamento multifásico como entrada de redes neurais. Inoue *et al.* (2013) serviram de base para a segunda parte do desenvolvimento

deste trabalho. As RNAs tendo grupos adimensionais como entradas partiram do desenvolvimento prévio descrito na Seção 2.2. O banco de dados foi expandido abarcando mais dados da literatura envolvendo outros fluidos como fase contínua no escoamento multifásico. Diferentemente de Inoue *et al.* (2013), a RNA pode prever a FVG. Por fim, este trabalho fez uma análise dos números adimensionais usados na RNA.

3.FUNDAMENTOS TEÓRICOS

3.1. ESCOAMENTOS MULTIFÁSICOS

O escoamento multifásico é de grande interesse para a indústria, pois muitos de seus processos contemplam o transporte de misturas em mais de uma fase. Na indústria do petróleo, por exemplo, a prospecção de óleo bruto de poços geralmente leva ao transporte de óleo misturado com areia, gás natural, e água para as plataformas. Além disso, há o transporte dessa mistura multifásica, da plataforma até a costa, para seu posterior tratamento nas refinarias.

Falcone *et al.* (2010) indicam os seguintes fatores como os principais que regem os padrões de escoamento multifásicos:

- Propriedades físicas das fases, suas frações e velocidades;
- Pressão e temperatura de operação;
- Diâmetro da tubulação, formato, inclinação e rugosidade;
- Presença de algum acidente na tubulação, tanto a jusante como a montante (e.g. cotovelos, válvulas, junções T, etc.);
- Tipo de escoamento: estado estacionário, pseudo-estacionário ou transiente.

Para a determinação dos padrões de escoamento, geralmente coletam-se dados de vazões e propriedades dos fluidos observando através de uma seção transparente da tubulação o padrão de escoamento (TAITEL; DUKLER, 1976). Entretanto, como pontua Manabe (2001), a determinação visual do padrão é uma interpretação subjetiva. Isto porque os padrões de escoamento multifásicos não são únicos e suas transições geralmente são um processo gradual. Por isso, na literatura é possível encontrar diversas classificações.

Dentre os vários escoamentos multifásicos, o escoamento bifásico líquido-gás é o que tem a maior quantidade de estudos na literatura e é também bastante representativa na indústria do petróleo e gás. Falcone *et al.* (2010) descreve a classificação do escoamento bifásico remetendo a aplicações para a indústria do petróleo e gás. As Figuras 1 e 2 mostram a classificação do escoamento bifásico na horizontal e na vertical ascendente (FALCONE *et al.*, 2010):

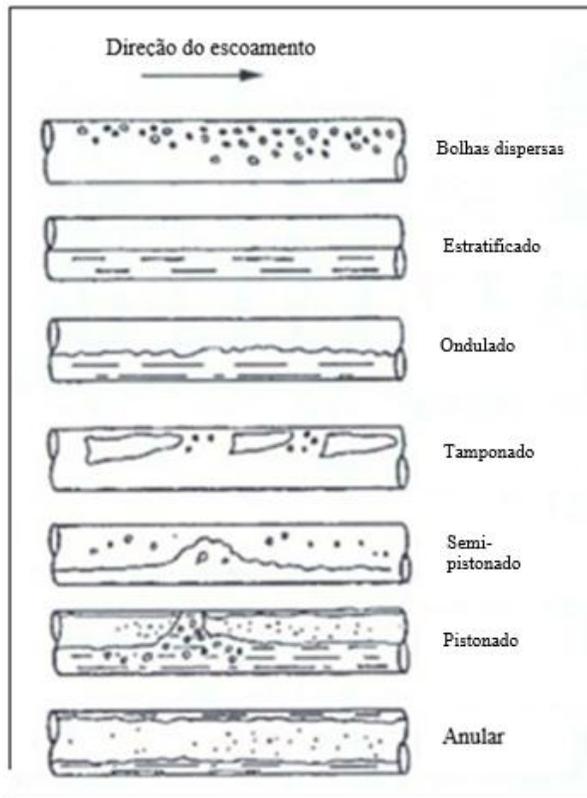


Figura 1 Padrões de escoamento horizontais
 Fonte: adaptado de Falcone *et al.* (2010)

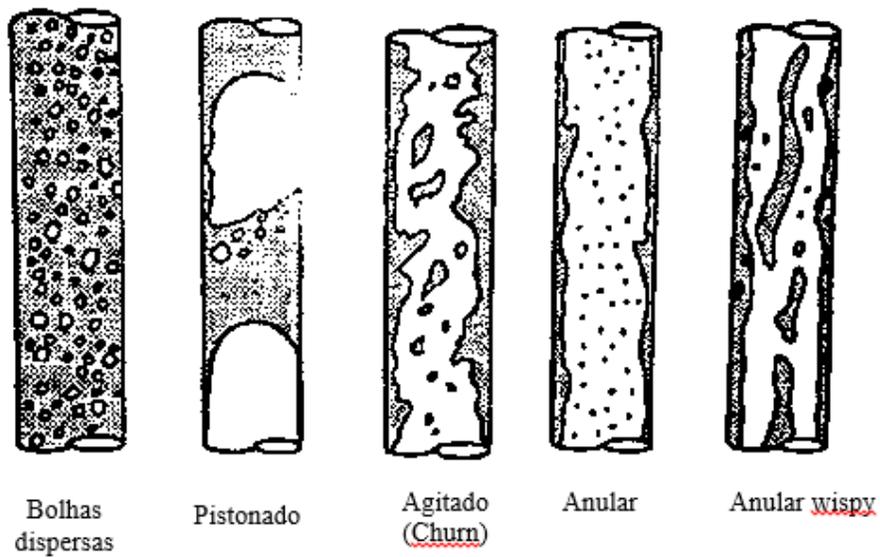


Figura 2. Padrões de escoamento verticais
 Fonte: adaptado de Falcone *et al.* (2010)

Na Figura 1, que representa o escoamento horizontal, percebe-se que há a tendência para estratificação de fases líquida e gás, o que não ocorre no escoamento vertical. Os padrões nos escoamentos horizontais tendem a ser mais complexos pois forças gravitacionais que agem na direção normal do escoamento induzem assimetrias. Isso faz com que a fase mais pesada se acumule no fundo da tubulação (HETSRONI, 1982).

Uma referência particularmente importante para este projeto é o estudo realizado por Manabe (2001) e Manabe *et al.* (2001). Estes autores realizaram um importante estudo sobre padrões de escoamento de petróleo e gás natural a pressões significativamente acima da ambiente. Foi investigada a transferência de calor convectiva de escoamento bifásico líquido-gás de petróleo e gás natural teoricamente e experimentalmente. Antes porém, foram necessários testes de validação de padrões de escoamento a alta pressão. Foram, então, desenvolvidos mapas de padrões de escoamento experimentais para escoamentos horizontais, verticais e inclinados a $+1^\circ$ ascendentes. Também investigou-se o efeito da pressão na fronteira de transição em padrões de escoamento bifásico. As observações experimentais foram feitas em duas pressões de operação diferentes (200 e 450 psia). A classificação adotada para os padrões de escoamentos verticais foi:

- Bolhas (Bubbly flow);
- Bolhas dispersas (dispersed bubble flow);
- Pistonado (slug flow);
- Agitado (churn flow);
- Anular (annular).

Para os padrões horizontais e inclinados Manabe (2001) utilizou a seguinte classificação:

- Bolhas dispersas (dispersed bubbles);
- Estratificado (stratified smooth);
- Estratificado rugoso (stratified wavy);
- Pistonado (intermittent);
- Anular (anular);

Inoue *et al.* (2013) conduziram uma revisão bibliográfica para agrupar os diversos padrões de escoamento encontrados na literatura (CAREY, 1992; THOMAS, 2004; SHOHAN, 2006; FALCONE *et al.*, 2010; ROSA *et al.*, 2010) em grupos maiores de acordo com a classificação usual utilizada pela Petrobras. As Tabelas 1 e 2 apresentam um resumo dos padrões de escoamento utilizados nos diversos estudos e sua classificação de acordo com o que foi utilizado neste trabalho.

Tabela 3 Classificação de escoamentos bifásicos verticais para desenvolvimento da rede neural

Padrão	Presente Estudo	Sigla	Denominação na Literatura				
			Rosa et al., 2010	Shoham, 2006	Carey, 1992	Falcone et al., 2010	Thomas, 2004
Bolhas	Bolhas Dispersas	BV	-	<i>Bubble Flow</i>	-	-	Bolhas
Bolhas Dispersas			<i>Bubbly flow</i>	<i>Dispersed Bubbles</i>	<i>Bubbly flow</i>	<i>Bubble Flow</i>	-
Calotas Esféricas			<i>Spherical Caps</i>	-	-	-	-
Pistonado	Intermitente	IT	<i>Stable Slug</i>	<i>Slug Flow</i>	<i>Slug Flow</i>	<i>Slug Flow</i>	Golfadas
Agitado			-	<i>Churn Flow</i>	<i>Churn Flow</i>	<i>Churn Flow</i>	-
Pistonado Instável			<i>Unstable Slug</i>	-	-	-	-
Semianular	Anular	AV	<i>Semi Annular</i>	-	-	-	-
Transição			-	-	-	-	Transição
Anular Wispy			-	-	<i>Wispy Annular Flow</i>	<i>Wispy Annular Flow</i>	-
Anular			<i>Annular</i>	<i>Annular Flow</i>	<i>Annular Flow</i>	<i>Annular Flow</i>	Nevoeiro

Fonte: adaptado de Inoue *et al.* (2013)

Tabela 4 Classificação dos escoamento horizontais no presente estudo

Padrão	Presente Estudo	Sigla	Denominação na Literatura		
			Falcone et al., 2010	Shoham, 2006	Thomas 2004
Bolhas Dispersas	Bolhas Dispersas	BH	<i>Bubble Flow</i>	<i>Dispersed Bubble Flow</i>	Bolhas
Estratificado Liso	Estratificado	ST	<i>Stratified Flow</i>	<i>Stratified Smooth Flow</i>	Estratificado
Estratificado Ondulado			<i>Wavy Flow</i>	<i>Stratified Wavy Flow</i>	Ondulado
Estratificado Rugoso	Estratificado Rugoso	SR	<i>Semi-Slug Flow</i>	-	-
Anular Ondulado			-	<i>Wavy Annular Flow</i>	-
Escoamento Tamponado	Pistonado	SF	<i>Plug Flow</i>	-	Tampão
Pistonado			<i>Slug Flow</i>	<i>Slug Flow</i>	Golfada
Bolhas Alongadas			-	<i>Elongated Bubble Flow</i>	-
Anular	Anular	AH	<i>Annular</i>	<i>Annular Flow</i>	Anular

Fonte: adaptado delnoue *et al.* (2013)

3.2. ULTRASSOM

As tecnologias de medição de escoamentos multifásicos têm cada vez mais importância para o desenvolvimento econômico de campos de exploração, em particular em campos marginais e em águas profundas. Para o transporte econômico e de maneira segura do petróleo dos reservatórios até as instalações de armazenamento e/ou processamento, é necessário haver métodos de medição de fluxo multifásico sem a necessidade de separar as diferentes fases (MANABE *et al.*, 2001). Além disso, Gonçalves (2013) pontua que a utilização de medidores multifásicos reduz o número de equipamentos que seriam necessários para a separação de fases. Isto leva à redução de custos, peso e espaço ocupado pelos mesmos, em especial nos testes de poços, onde os separadores de fase são pesados, volumosos e de alto custo. Os medidores

multifásicos também podem fornecer informações em tempo real, permitindo a otimização de sistemas como bombas centrífugas submersíveis.

Inoue *et al.* (2013) e Carvalho *et al.* (2009) reafirmam o crescente interesse que a indústria tem tido em técnicas não invasivas para a medição de variáveis importantes do escoamento multifásico, tais como o padrão de escoamento, fração de vazio e vazão de gás, sendo que técnicas não invasivas são de grande importância.

Powell (2008) discute o uso de cinco métodos não invasivos: Imagem de ressonância magnética (MRI), Velocímetro Doppler de pulso ultrassônico (UPDV), Tomografia de Impedância elétrica (EIT), radiografia por Raio-X, e radiografia por nêutrons. Seu estudo chega à conclusão que a técnica mais versátil é o MRI.

Assim, para este trabalho, é importante decidir qual é a técnica mais vantajosa para aplicações práticas. Carvalho *et al.* (2009), a respeito do trabalho de Powell (2008), afirmam que apesar da versatilidade do MRI, o equipamento é caro e logisticamente desvantajoso: o aparato experimental necessariamente deve estar ao lado do equipamento do MRI, separando o medidor do laboratório de mecânica dos fluidos, aonde seria mais prático tê-lo. Além disso, a técnica ainda está em fase laboratorial.

A técnica escolhida para este projeto é a técnica de ultrassom. Esta decisão foi tomada baseada nos estudos de Carvalho *et al.* (2009). Carvalho afirma que a técnica de ultrassom já é bem estabelecida em aplicações práticas, seus equipamentos são de fácil acesso comercialmente e a preços relativamente baixos. Há ainda a vantagem de serem compactos. Gonçalves (2013) acrescenta que a técnica do ultrassom pode ser posta em operação em ambientes hostis, como em águas profundas e fluidos corrosivos, o que torna esta técnica ideal para a aplicação proposta.

Os estudos de Carvalho *et al.* (2009) relacionaram a atenuação acústica de sinais ultrassônicos com a fração de vazio e com o padrão de escoamento em escoamentos bifásicos água-ar verticais ascendentes. Portanto, baseado neste estudo, supõe-se ser possível estender sua aplicação, usando a atenuação acústica como entrada de uma rede neural que preveja o padrão de escoamento ou a FVG.

O ultrassom é uma forma de onda mecânica que se propaga em meios materiais com frequências acima de 20 kHz. Em meios fluidos, o ultrassom se comporta

do mesmo modo que o som audível, porém com comprimentos de onda bem mais curtos (GONÇALVES, 2013).

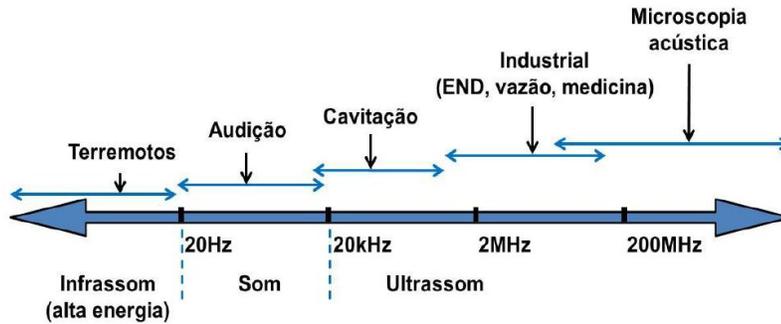


Figura 3. Espectro de frequência do ultrassom e suas aplicações mais comuns.

Em escoamentos multifásicos, a dissipação acústica resulta de um efeito combinado de dissipação na fase contínua, na medida em que a onda se propaga no meio e dissipação na interface entre fases (GONÇALVES, 2013).

Na fase contínua, a intensidade acústica decai de acordo com a seguinte equação (KINSLER *et al.*, 2000):

$$I(x) = (P_0 e^{-\alpha x})^2 / 2\rho_0 c = I(0) e^{-2\alpha x} \quad \text{Eq. 2}$$

Em que P_0 e $I(0)$ são, respectivamente, a amplitude de pressão acústica e intensidade em $x = 0$ e α é o coeficiente de absorção em nepers por metro (Np/m).

A absorção na fase contínua ocorre devido a diferentes mecanismos dependendo do tipo de fluido. A teoria acústica clássica considera a absorção viscosa e termal devido às compressões e rarefação do fluido como o único mecanismo presente. Portanto, o coeficiente de absorção é dado por:

$$\alpha_c = \alpha_s + \alpha_k = \frac{\omega^2}{2\rho_0 c^3} \left[\frac{4}{3} \eta + \frac{(\gamma - 1)k}{c_p} \right] \quad \text{Eq. 3}$$

A teoria da absorção clássica tem sido verificada como estando de bom acordo com os resultados para líquidos viscosos, portanto espera-se que ela valha também para óleos.

Quando uma onda acústica entra em um líquido que contém bolhas, ela pode ser atenuada por fenômenos interfaciais, como a reflexão, refração, absorção e

espalhamento. A Figura 4 ilustra o fenômenos de reflexão e transmissão em uma interface entre dois fluidos com impedâncias acústicas diferentes.

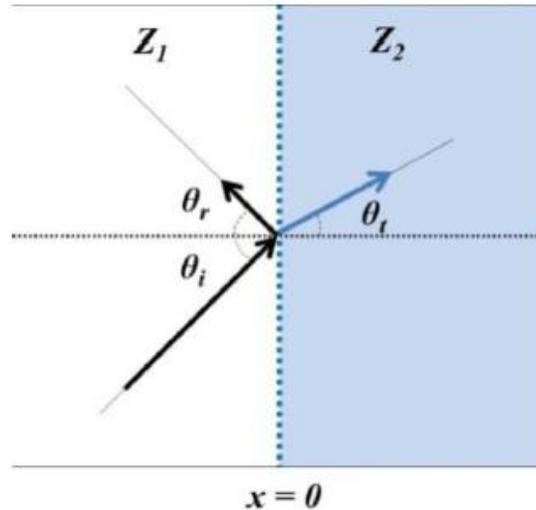


Figura 4 Reflexão e transmissão de uma onda plana oblíqua ao plano da interface entre dois fluidos com impedâncias acústicas diferentes

Fonte: Adaptado de Kinsler *et al.* (2000)

Para grandes estruturas gasosas, como as bolhas de Taylor e a parte gasosa em escoamentos anulares, a reflexão da onda acústica na interface óleo-ar é esperado ser o principal mecanismo de dissipação. A partir de algumas suposições simplificadoras, a intensidade de reflexão e coeficiente de transmissão são dados, respectivamente, por:

$$R_I = \left(\frac{1 - r_1/r_2}{1 + r_1/r_2} \right)^2 = \left(\frac{r_2/r_1 - 1}{r_2/r_1 + 1} \right)^2 \quad \text{Eq. 4}$$

$$T_I = 4 \frac{r_1/r_2}{(1 + r_1/r_2)^2} = 4 \frac{r_2/r_1}{(r_2/r_1 + 1)^2} \quad \text{Eq. 5}$$

Nas equações Eq. 4 e 4 o subscrito 1 e 2 referem-se aos meios que compõe cada interface.

A Tabela 5 mostra valores de coeficientes acústicos de reflexão e transmissão nas interfaces de interesse nesse estudo. Visto que o coeficiente de

transmissão na interface óleo-acrílico é alto ($T_i=0,777$), espera-se que uma porção significativa da energia do pulso emitido pelo sensor de 0° entre no escoamento multifásico. A interface óleo-ar tem o maior coeficiente de reflexão ($R_i \sim 1$), sendo este tipo de mistura responsável por um alto grau de espalhamento do feixe ultrassônico. Por outro lado, em interfaces óleo-água, o espalhamento do feixe é praticamente nulo, havendo grande energia transmitida através da mistura e alcançando o transdutor posicionado a 180° do emissor.

Tabela 5 Valores de coeficiente de reflexão (R_i) e transmissão (T_i) em interfaces planas de interesse neste trabalho.

Interface	R_i	T_i
Óleo – Acrílico	0,223	0,777
Óleo – Ar	0,999	0,001
Óleo – Vidro	0,645	0,355
Óleo – Água	0,014	0,986

A Figura 5 representa quatro situações de grande importância:

- (a) Esparsamente povoada por bolhas;
- (b) Densamente povoada por bolhas;
- (c) Presença de grande estrutura de gás, como bolhas de Taylor;
- (d) Corpo gasoso do escoamento anular preenche quase toda a seção transversal, deixando apenas um filme líquido fino ao redor.

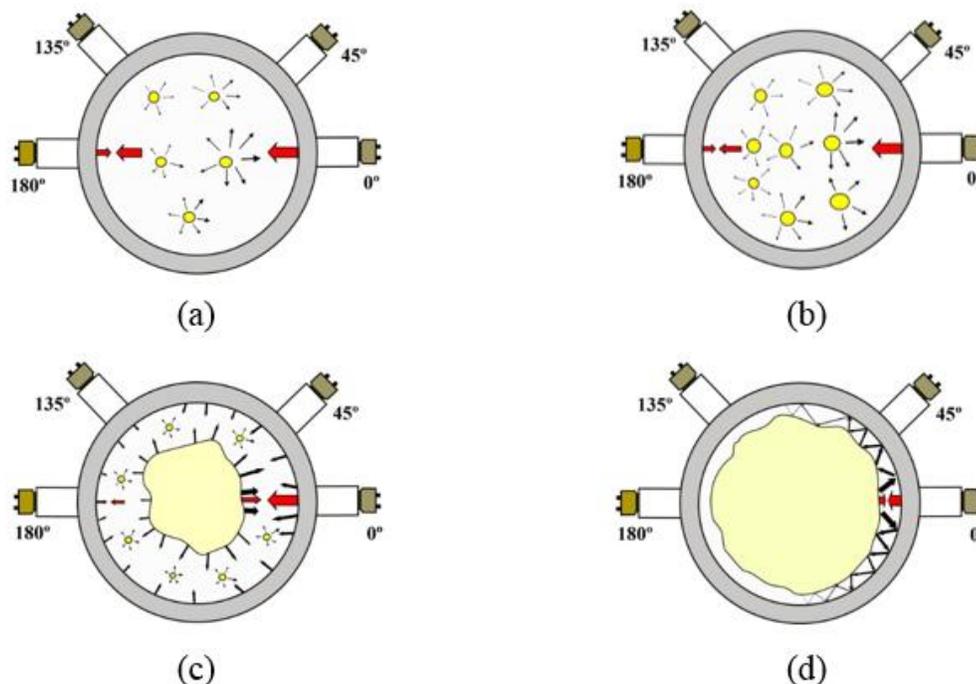


Figura 5 representações esquemáticas do campo de som: (a) bolhas dispersas; (b) bolhas; (c) bolhas de Taylor incipientes; (d) anular

Na figura (a) pouca energia acústica é espalhada para os lados. Como o campo acústico é “perfurado” por apenas poucas pequenas bolhas, uma quantidade substancial da energia acústica é transmitida pela fase contínua até o lado oposto da tubulação.

Quando a seção transversal fica mais densamente povoada por bolhas com tamanhos relativamente maiores (figura b), a energia espalhada para os lados aumenta. O bloqueio do feixe acústico aumenta e a quantidade de energia transmitida pela fase contínua até o lado oposto diminui de acordo.

Os mecanismos de dissipação no caso da figura (c) são distintos. O campo acústico é, nesse caso, feito na maior parte por reflexões do feixe ultrassônico, que vai e volta entre o ar-óleo e a interface óleo-acrílico ao longo da circunferência do tubo. A cada reflexão em alguma interface, uma quantidade substancial de energia é perdida para a parede da tubulação. A porção da energia acústica que é diretamente transmitida através da fase contínua diminui à medida em que as estruturas de gás coalescidas ficam maiores. Além disso, as pequenas bolhas dispersas também

contribuem para espalhar essa energia. A porção para o feixe acústico refletido diretamente de volta para fora da interface ar-óleo da grande estrutura de gás aumenta, transmitindo assim uma informação muito significativa sobre o desenvolvimento dos padrões de fluxo.

Finalmente, o mecanismo de dissipação para o padrão de fluxo anular pode ser entendido como um desenvolvimento dos mecanismos explicados acima. Como mostrado na figura (d), a película líquida na parede é muito mais fina do que no caso anterior e o feixe ultrassônico tem agora que ir e voltar muitas vezes mais à medida que progride. Consequentemente, o sinal morre muito mais rápido. Quanto mais fina for a película de líquido, menos energia alcança o outro lado da tubulação. A porção para o feixe acústico refletido diretamente de volta para fora da interface ar-óleo da grande estrutura de gás é ainda maior que no caso anterior.

3.3. REDES NEURAIS

Os escoamentos multifásicos apresentam uma natureza extremamente não linear, e uma das ferramentas mais populares para lidar com essas não linearidades é a Rede Neural Artificial (RNA). Uma de suas aplicações particulares é a identificação de padrões de escoamento multifásicos de forma associada a instrumentos de medição, o que garante uma alta precisão de predição (FALCONE *et al.*, 2010).

Shaikh e Aldahhan (2003) e Bhat e Mcavoy (1990) explicam que as Redes Neurais Artificiais imitam o sistema nervoso biológico, em que vários elementos são altamente interconectados através de conexões com pesos, tais quais as sinapses. O ajuste dos pesos destes elementos é o que se chama aprendizado. A aprendizagem é feita através de treinamento pela exposição de uma série de exemplos de elementos de entrada e saída, em que o algoritmo iterativamente faz os ajustes dos pesos. A RNA, então, é capaz de generalizar o conhecimento adquirido. Essa capacidade de aprender por meio de exemplos é a principal característica das RNAs.

A unidade básica de uma rede neural artificial, tal qual no sistema nervoso humano, é o neurônio. Cada neurônio apresenta um conjunto de elos sinápticos lineares (um bias aplicado externamente e um elo de ativação), que ponderam os sinais de entrada de cada neurônio. A soma ponderada dos sinais de entrada determina o

valor introduzido no neurônio em questão. Por meio do elo de ativação, o valor induzido no neurônio é utilizado para determinar os valores de saída através de uma função de ativação, como ilustrado na Figura 6 (HAYKIN, 2001).

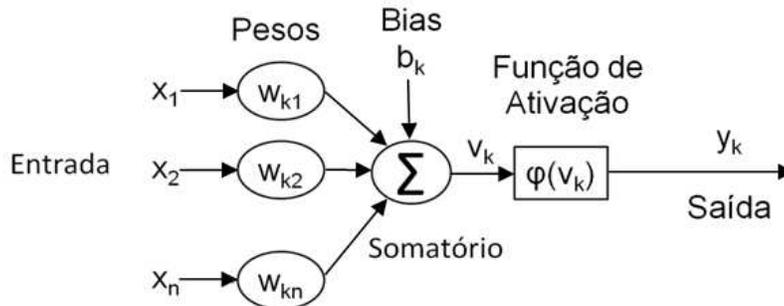


Figura 6. Modelo não linear de um neurônio

Em termos matemáticos, pode-se descrever um neurônio k através do seguinte par de equações:

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad \text{Eq. 6}$$

$$y_k = \varphi(u_k + b_k) \quad \text{Eq. 7}$$

A função de ativação φ é responsável por introduzir a não linearidade ao sistema. Na construção de redes neurais artificiais a função sigmoide é a mais comum. Ela tem a forma de um “s” e é definida como uma função estritamente crescente. Além disso, sua mais importante característica é ser continuamente diferenciável, exigência fundamental para o algoritmo de retro propagação de erro (error back-propagation). Um exemplo de função sigmoide é a função logística (Eq. 8), cuja utilização também tem motivação biológica, pois procura levar em conta a fase refratária de neurônios reais (HAYKIN, 2001):

$$\varphi(u_k) = \frac{1}{1 + \exp(-au_k)} \quad \text{Eq. 8}$$

3.3.1. Perceptrons de múltiplas camadas

As RNAs usadas nesse trabalho são do tipo *perceptron* de múltiplas camadas. Esta consiste de um conjunto de neurônios organizados em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. O sinal de entrada é propagado para frente para cada neurônio, passando camada por camada (HAYKIN, 2001).

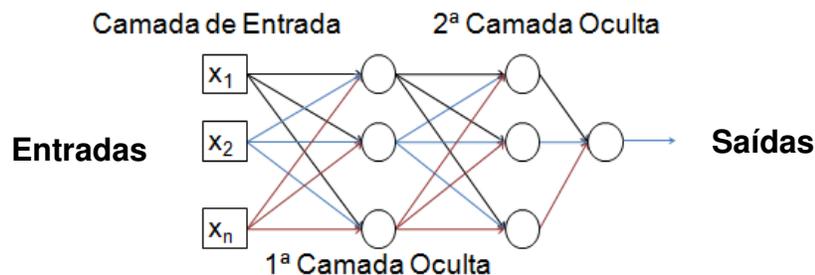


Figura 7. Arquitetura de um *perceptron* de múltiplas camadas com duas camadas ocultas.

Um *perceptron* de múltiplas camadas tem três características distintivas (HAYKIN, 2001):

1. O modelo de cada neurônio da rede inclui uma função de ativação não-linear. A presença de não-linearidade é importante porque, do contrário, a relação de entrada-saída da rede poderia ser reduzida àquela de um *perceptron* de camada única;
2. A rede contém uma ou mais camadas de neurônios ocultos. Estes neurônios ocultos capacitam a rede a aprender tarefas complexas extraindo progressivamente as características mais significativas dos padrões de entrada;
3. A rede exibe um alto grau de conectividade determinado pelas sinapses da rede. Uma modificação na conectividade da rede requer uma mudança na população das conexões sinápticas ou de seus pesos.

É através da combinação destas características, juntamente com a habilidade de aprender da experiência através de treinamento, que o *perceptron* de múltiplas camadas deriva seu poder computacional. Os perceptrons de múltiplas camadas têm sido aplicados com sucesso para resolver diversos problemas difíceis através do seu treinamento de forma supervisionada (HAYKIN, 2001). Eles também são considerados como um aproximador universal de funções, pois permitem mapear qualquer função linear ou não-linear (SALGADO, 2010).

3.3.2. Algoritmo de treinamento

A propriedade que é de importância primordial para uma rede neural é a sua habilidade de aprender a partir de seu ambiente e de melhorar o seu desempenho através da aprendizagem. A melhoria do desempenho ocorre com o tempo de acordo com alguma medida preestabelecida. Uma rede neural aprende acerca do seu ambiente através de um processo iterativo de ajustes aplicados a seus pesos e níveis de bias. Idealmente, a rede se torna mais instruída sobre o seu ambiente após cada iteração do processo de aprendizagem (HAYKIN, 2001).

O aprendizado em redes neurais pode ser dividido entre supervisionado e não-supervisionado. A técnica não-supervisionada é baseada na correlação entre as entradas da rede. Por outro lado, a técnica supervisionada é baseada em uma comparação direta entre a saída da rede e o valor desejado. Sua formulação usual é a minimização de uma função erro entre o valor de saída real e o valor desejado, por exemplo o erro médio ao quadrado, variando-se os pesos sinápticos. Muitos algoritmos de otimização, como o gradiente descendente ou algoritmos genéticos, para citar alguns, podem ser aplicados de forma a se minimizar a função erro (STRANEO, 2013).

Um algoritmo de treinamento supervisionado muito popular é o algoritmo de retro propagação de erro baseado na regra de aprendizagem por correção de erro apresentado por Rumelhart e McClelland (1986). Este algoritmo realiza aproximações locais para o mapeamento de entradas e saídas da rede e é empregado para classificar, aproximar funções e prever ou verificar tendências (SALGADO, 2010).

A aprendizagem é realizada em dois passos, a propagação e a retro propagação. Na primeira fase, os pesos sinápticos da rede são todos fixos, o sinal de

entrada passa por todas as camadas da rede até que esta produza um sinal de saída. A retro propagação por sua vez consiste no ajuste dos pesos sinápticos de acordo com uma regra de correção de erro. O erro neste caso consiste na diferença entre a resposta real esperada com a resposta apresentada pela rede. Este sinal é enviado para trás através da rede contra a direção das conexões, daí o nome retro propagação do erro. Os pesos sinápticos são ajustados de modo a aproximar o máximo possível a resposta real com a resposta calculada pela rede.

Este trabalho utiliza como treinamento a retro propagação de erro com o algoritmo Levenberg-Marquardt com regularização bayesiana. Levenberg-Marquardt é um método Gauss-Newton que, em princípio, converge mais rapidamente que os métodos baseados no gradiente descendente (HAGAN; MENHAJ, 1994). Este método é desenvolvido para se atingir uma velocidade de treinamento de segunda ordem sem ter que computar a matriz Hessiana, que é estimada usando os gradientes. Pode-se considerar o algoritmo de Levenberg-Marquardt um padrão quando se trata de otimizações não-lineares (HIRSCHEN; SCHÄFER, 2006).

À medida que o treinamento se desenvolve, o erro tende a diminuir e a rede a sobre ajustar aos valores deste conjunto e, por consequência, a rede pode perder a sua capacidade de generalização (SALGADO, 2010). A regularização é normalmente a primeira escolha para se melhorar a generalização (LAMPINEN; VEHTARI, 2001).

A regularização é um modo sofisticado de melhorar a generalização. Modifica-se a função objetivo que, normalmente, é a soma quadrática dos erros, ao adicionar um termo que consiste na média do quadrado da soma dos pesos da RNA. Usa-se um termo de penalidade na função erro, definida como (HIRSCHEN; SCHÄFER, 2006):

$$F = \alpha_w SSE + \beta_w E_w \quad \text{Eq. 9}$$

Em que E_w é o regularizador de decaimento de peso definido como:

$$E_w = \frac{1}{n} \sum_{k,j=1}^n w_{kj}^2 \quad \text{Eq. 10}$$

A variável n é o número total de pesos na rede neural e SSE é a soma quadrática dos erros. Os parâmetros α_w e β_w determinam o quanto o regularizador de decaimento de peso está envolvido na função erro F . A otimização desses parâmetros reguladores requerem a computação da matriz Hessiana no ponto mínimo. Utiliza-se, então, o algoritmo de otimização Levenberg-Marquardt para estimar a matriz Hessiana (HAGAN; MENHAJ, 1994). Usando a regularização bayesiana os pesos e bias tem valores pequenos, o que força a rede a responder suavemente, evitando o sobre ajuste (Figura 8).

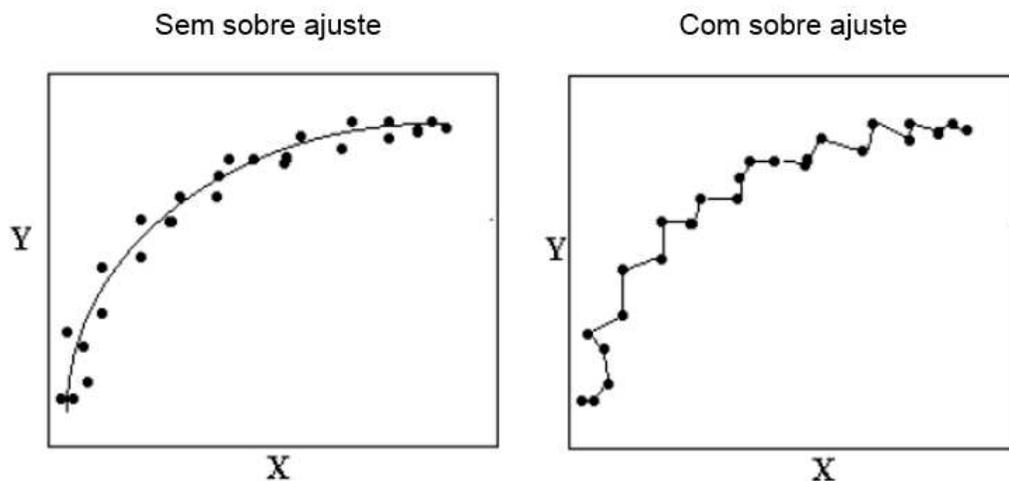


Figura 8. Comparação entre dados ajustados adequadamente e dados ajustados em excesso (sobre ajuste)

3.4. NÚMEROS ADIMENSIONAIS

Este presente estudo pretende fazer uso da rede neural tendo como entradas tanto os valores de atenuação acústica de ultrassom, como de propriedades físicas importantes para o escoamento na forma de números adimensionais.

Segundo White (2011), análise dimensional é um método para reduzir o número e a complexidade de variáveis experimentais que afetam um determinado fenômeno físico, usando técnicas específicas de modo a agrupar variáveis em uma forma adimensional.

Shaikh e Aldahhan (2003) propuseram as seguintes etapas para o desenvolvimento de uma rede neural para determinação da fração de vazio em reatores químicos do tipo coluna de bolhas:

- (a) Revisão bibliográfica para coleta de dados a serem usados no treinamento e validação da rede;
- (b) Análise dimensional a fim de se determinar possíveis grupos adimensionais a serem usados no desenvolvimento da rede;
- (c) Decisão acerca da arquitetura da rede neural a ser desenvolvida;
- (d) Regressão neural e análise estatística para seleção dos grupos adimensionais a serem usados como dados de entrada da rede;
- (e) Validação estatística da rede neural.

Shaikh e Aldahhan (2003) realizaram um trabalho minucioso de seleção dos grupos adimensionais a serem usados como dados de entrada para a rede. Métodos de correlação cruzada foram usados para se verificar a dependência entre os grupos adimensionais de entrada e de saída. Deve-se certificar que, dentro do conjunto de grupos de entrada ou de saída, os grupos adimensionais não são dependentes entre si. A confiabilidade ou eficiência dos vários conjuntos de grupos adimensionais foi verificada comparando-se diretamente os resultados da rede neural com os valores experimentais. Mais especificamente, os critérios para comparação do desempenho dos conjuntos de grupos adimensionais foram a minimização do erro médio relativo, minimização do desvio padrão e o valor do coeficiente de correlação, R , entre entrada e saída (que deveria ser próximo da unidade).

Conforme mencionado acima, o trabalho desenvolvido por Shaikh e Aldahhan (2003) é voltado totalmente para colunas de bolhas. Estes equipamentos geralmente operam a baixas velocidades do líquido, que, por esta razão, tem pouca ou nenhuma influência sobre a fração de vazio média. Além disso, as correlações utilizadas por estes autores para comparação com os resultados da rede neural aparentemente referem-se todas a colunas de bolhas. Portanto, suas conclusões não são necessariamente válidas para escoamentos da indústria petrolífera. Porém, a

metodologia utilizada e a minúcia na aplicação desta conferem grande confiabilidade ao trabalho.

No trabalho de Inoue *et al.* (2013), oito grupos adimensionais, baseados nas forças competidoras que ocorrem em escoamentos bifásicos, foram selecionados como entradas da rede neural, que classificava padrões de escoamento para o sistema água-ar. O presente trabalho será uma continuação do realizado por Inoue *et al.* (2013), propondo-se um aumento da base de dados utilizados para treinamento, uma revisão minuciosa dos grupos adimensionais de entrada e sua utilização para uma nova rede neural que fará a predição da fração de volume de gás e padrão de escoamento a partir dos grupos adimensionais escolhidos.

4.METODOLOGIA

No presente capítulo serão apresentados todos os passos realizados na elaboração deste trabalho. A Seção 4.1 mostra a escolha do índice numérico IPDE para os padrões de escoamentos usados. A Seção 4.2 descreve a montagem e o procedimento dos dois experimentos para a obtenção dos dados ultrassônicos. A Seção 4.3 descreve como foi feita a seleção dos grupos adimensionais e a montagem do banco de dados usado no treinamento da RNA. Finalmente, as Seções 4.4 e 4.5 descrevem o procedimento de desenvolvimento e treinamento das redes neurais, determinação da arquitetura e a combinação final dessas redes em um sistema neural alimentado por dados ultrassônicos e grupos adimensionais.

4.1. ESCOLHA DO ÍNDICE NUMÉRICO DE PADRÃO DE ESCOAMENTO (IPDE)

Inoue *et al.* (2013) conduziram um estudo sobre os padrões de escoamento propostos por diferentes autores. A partir desse estudo, os padrões de escoamento foram agrupados de acordo com os padrões normalmente utilizados na indústria do petróleo. As Tabelas 1 e 2 na Seção 3.1 mostram um resumo dos estudos reunidos por Inoue *et al.* (2013). Para escoamentos verticais ascendentes, as três principais categorias foram bolhas dispersas, intermitente e anular. Contudo, na presente investigação, foi preliminarmente verificado que melhores resultados eram alcançados quando se separava o padrão agitado (churn) do grupo intermitente. Desta forma, para a identificação dos padrões pelas redes neurais, foram atribuídos números de identificação como mostrado na Tabela 6.

No estudo de Inoue *et al.* (2013) também foi verificado que a precisão na detecção dos padrões pela RNA variava dependendo da ordem em que se apresentavam os valores numéricos de cada padrão. O menor erro foi empiricamente encontrado quando os diversos padrões de escoamento eram ordenados de acordo com sua ocorrência quando, a uma determinada vazão fixa de líquido, aumentava-se a vazão de gás gradativamente.

Tabela 6 Correlação do índice usado para o Padrão de Escoamento e seu intervalo numérico

Padrão de escoamento	Índice de padrão de escoamento	Intervalo numérico
Horizontal		
Bolhas dispersas	0,1	0 – 0,2
Estratificado	0,3	>0,2 – 0,4
Estratificado rugoso	0,5	>0,4 – 0,6
Pistonado	0,7	>0,6 – 0,8
Anular	0,9	>0,8 – 1,0
Vertical		
Bolhas dispersas	1,1	1,0 – 1,2
Intermitente	1,3	>1,2 – 1,4
Churn	1,5	>1,4 – 1,6
Anular	1,7	>1,6 – 1,8

Um intervalo de $\pm 0,1$ foi adotado para cada padrão de escoamento. O uso de intervalos está de acordo com a realidade física, em que as transições entre padrões são graduais. Não fixando valores discretos para cada padrão, mas sim intervalos, permitiu que a RNA tivesse um melhor número de acertos de suas respostas.

4.2. EXPERIMENTOS USANDO A TÉCNICA ULTRASSÔNICA

Duas montagens experimentais foram utilizadas para a coleta de dados provenientes do uso de instrumentação ultrassônica. A primeira montagem incluiu uma estação de filmagem rápida para possibilitar a classificação do padrão de escoamento exato do intervalo de gravação dos dados ultrassônicos. Neste caso, para facilitar a visualização foi utilizado óleo mineral em substituição ao petróleo. Na segunda montagem experimental, um protótipo de uma sonda ultrassônica foi construído e acoplado a uma tubulação vertical para testes com petróleo na determinação de frações de vazios.

4.2.1. Circuito Vertical para simulação de escoamentos multifásicos (GONÇALVES, 2013)

A montagem experimental e a instrumentação usada nestes testes de escoamento multifásico estão ilustradas na Figura 9 e encontram-se instalados no Laboratório de Refrigeração e Ar Condicionado (LRF) na Universidade Federal de Itajubá (UNIFEI). Os experimentos foram realizados por Gonçalves (2013) usando tanto 1 como 2 polegadas de diâmetro interno de tubo de acrílico vertical.

Neste circuito, foram realizados experimentos com escoamentos bifásicos óleo-ar, óleo-água e óleo-sólidos bem como escoamentos trifásicos e quadrifásicos (óleo-água-ar-sólidos) em diferentes padrões de escoamento. A fase contínua pode ser tanto água como óleo, entretanto, para o banco de dados da RNA, utilizou-se apenas o óleo como fase contínua. Devido à dificuldade em se trabalhar com petróleo, foi utilizado óleo mineral USP ($\rho = 814.5 \text{ kg/m}^3$ e $\mu = 41.36 \text{ cP}$ a $20 \text{ }^\circ\text{C}$).

A Tabela 7 mostra a composição dos vários tipos de escoamentos testados. Os dados foram obtidos para os tubos de 1 e 2 polegadas para as várias combinações de fases. Para 1 polegada, acrescentou-se uma fase de poliamida para a medição de velocidade utilizando-se a técnica Doppler, no entanto seus resultados não estiveram no escopo deste trabalho.

Tabela 7 Composição dos escoamentos multifásicos testados

Diâmetro interno [polegadas]	Composição	Componente				
		Óleo Mineral	Ar	Poliamida (1% w/w)	Areia (1% w/w)	Água (10% v/v)
1	O-A	X	X			
	O-A-P	X	X	X		
	O-A-P-S	X	X	X	X	
	O-A-P-S-W	X	X	X	X	X
2	O-A	X	X			
	O-A-W	X	X	X		
	O-A-W-S	X	X		X	X

A estação ultrassônica está localizada a 6 m da base da tubulação e duas válvulas de fechamento rápido foram usadas para a medição da fração de vazio (FVG). O sistema fecha uma seção de aproximadamente 1 metro de comprimento do tubo, em

volta da seção de teste ultrassônico. Uma estação de filmagem rápida está localizada logo a jusante da seção de teste. As vazões podem ser ajustadas através de inversores de frequência que controlam a rotação das bombas. Na base de cada tubo há um meio poroso pelo qual ar comprimido é injetado.

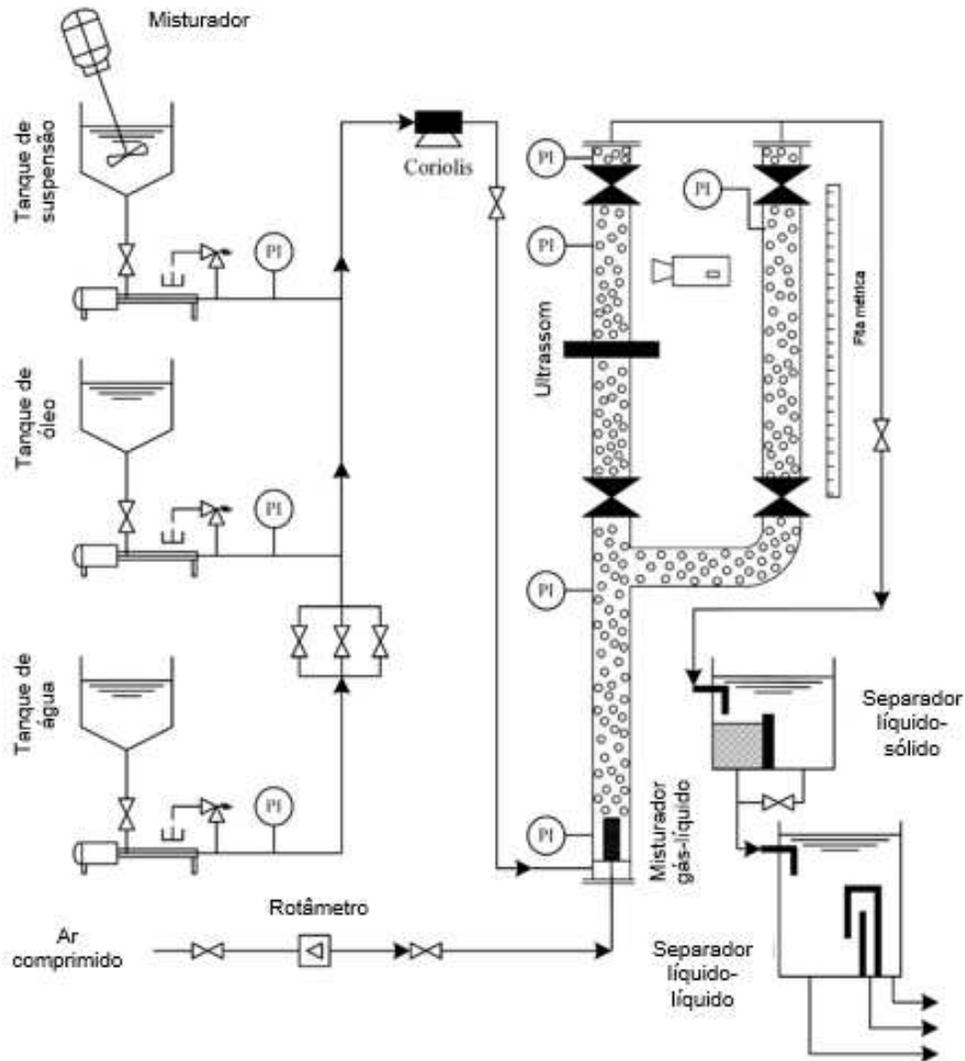


Figura 9 - Visão esquemática da instrumentação ultrassônica e montagem experimental (LRF – UNIFEI).

Fonte: adaptado de Gonçalves (2013)

A vazão de líquido foi medida através de um medidor de vazão do tipo Coriolis, modelo Rheonik RHM12, que inclui um termômetro com precisão de $\pm 1^\circ\text{C}$. A vazão de ar foi medida por um medidor do tipo rotâmetro da marca Cole-Parmer (3 a 30

± 0.1 LPM). A pressão dentro da tubulação foi medida por um manômetro Bourdon (0 a 4 psi ± 0.2 psi). A pressão atmosférica foi obtida por um barômetro. O ar no ponto de injeção foi assumido como à temperatura ambiente, medida por um termômetro de bulbo de precisão ± 0.5 °C. Esta suposição subestima a temperatura do ar comprimido, porém o erro no cálculo da vazão de ar na estação ultrassônica não é significativo. A câmera de alta velocidade usada é de resolução 512 x 512, 5000 fps REDLAKE Motion Pro X4.

A instrumentação ultrassônica foi mantida o mais simples possível, pois a intenção será utilizá-la para aplicações em tempo real da indústria do petróleo e gás. Transdutores ultrassônicos de 13 mm de diâmetro, Panametrics Videoscan 2.25 MHz, foram colocados em adaptadores de acrílico como mostrado em detalhe na Figura 10. Do ponto de vista estatístico, o escoamento foi considerado radialmente simétrico, portanto apenas metade da circunferência foi instrumentada. O uso de apenas quatro transdutores permite um menor uso do CPU durante os testes e também a geração de arquivos menores. O sensor a 0° é um transdutor pulso-eco modelo DHC706-RM enquanto que os sensores a 45°, 135° e 180° são apenas receptores modelo V106-RM. O pulsador usado foi um Olympus 5077PR, que permite ajustes na largura do pulso e, por isso, uma maior eficiência na excitação do transdutor de cristal do V106-RM. Os dados ultrassônicos foram adquiridos por meio da placa de aquisição da National Instruments PXIe-1062Q, utilizando-se do software LabVIEW®. As conexões #1 a #4 na Figura 11 mandam o sinal acústico recebido para o PXI, que por sua vez transfere os dados para o computador. A conexão #5 garante a sincronização entre o pulsador e o PXIe-1062Q. Assim, cada vez que um pulso ultrassônico é emitido, o pulsador manda um sinal para o PXI para que as janelas de tempo para a aquisição de dados sejam configuradas. A conexão #8 assegura a sincronização entre as filmagens e os dados ultrassônicos. Os dados, então, foram tratados no MatLab® e armazenados em planilhas do Microsoft Excel.

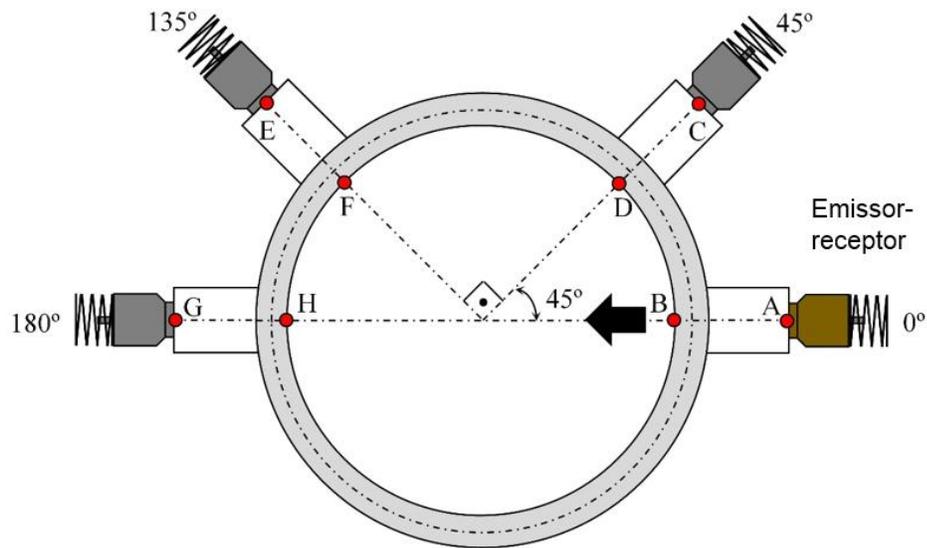


Figura 10 - Vista esquemática da instrumentação ultrassônica

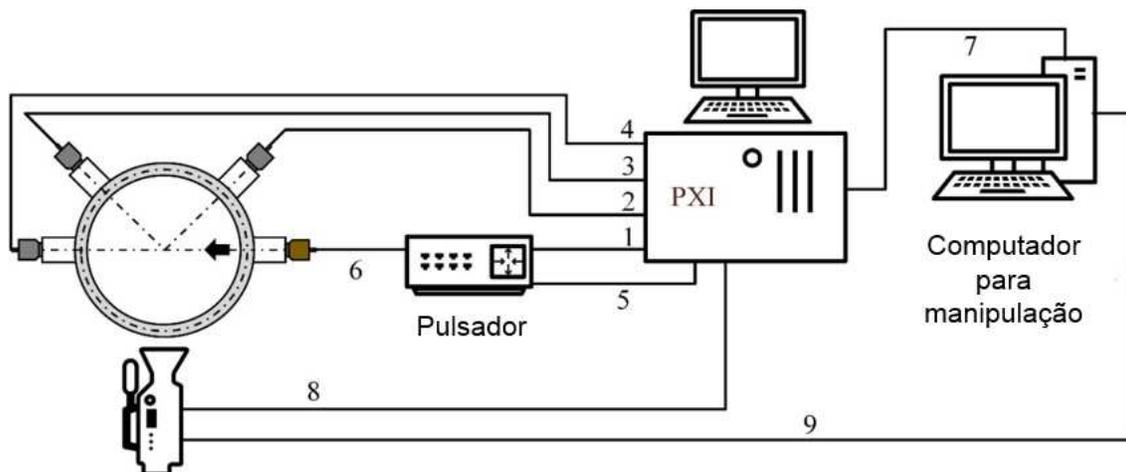


Figura 11 - Sistema de aquisição dos dados ultrassônicos

A Tabela 8 mostra as variações das condições operacionais testadas por Gonçalves (2013). A FVG sofre variações de 0 a 85% e, para 2 polegadas, de 0 a 35% devido às limitações do aparato experimental. Para simular areia, foram utilizadas esferas de vidro de 80 – 600 μ m em diâmetro. Portanto, as velocidades superficiais de líquido, j_L , medidas nesses casos são valores aproximados, visto que as partículas sólidas escoam junto com o líquido no coriolis. Além disso, medições de temperatura

foram feitas no começo e no final de cada série de testes, de forma a possibilitar o cálculo das propriedades físicas do fluido.

Tabela 8 Condições operacionais para os experimentos de escoamentos multifásicos

Diâmetro Tubulação [polegadas]	Composição	Parâmetro				
		FVG [%]	j_l [m/s]	j_g [m/s]	T [°C]	$p_{seção\ teste}$ [kgf/cm ²]
1	O-A	0 – 83	0,10 – 0,30	0 – 0,17	24	0,5
	O-A-P	0 – 85	0,10 – 0,26	0 – 0,37	22	0,4
	O-A-P-S	0 – 84	0,10 – 0,30	0 – 0,10	21	0,4
	O-A-P-S-W	0 – 82	0,10 – 0,28	0 – 0,16	24	0,7
2	O-A	1 – 33	0,05 – 0,17	0 – 0,02	30	0,4
	O-A-W	0 – 36	0,04 – 0,17	0 – 0,04	31	0,5
	O-A-W-S	0 – 36	0,04 – 0,17	0 – 0,02	27	0,5

O-A: Óleo-Ar

O-A-P: Óleo-Ar-Poliamida

O-A-P-S: Óleo-Ar-Poliamida-Areia

O-A-P-S-W: Óleo-Ar-Poliamida-Areia-Água

O-A-W-S: Óleo-Ar-Água-Areia

O-A-W: Óleo-Ar-Água

A taxa de aquisição dos dados ultrassônicos foi colocada em 20MHz. O intervalo de amostragem e a taxa de geração de pulso foi de 7,5 segundos e 2kHz, respectivamente. Portanto, cada amostra possui 15.000 pulsos. O intervalo de 7,5 segundos permite uma amostragem representativa da topologia do escoamento. A taxa de geração de pulso de 2 kHz pelo pulsador foi determinada considerando-se o deslocamento do fluxo entre os pulsos para as velocidades máximas superficiais.

Segundo Gonçalves (2013), foram estabelecidas várias condições de FVG para a amostragem. Inicialmente tentou-se incrementos de aproximadamente 2,5% na FVG, sendo que se retiravam 5 amostras em cada condição. No intervalo entre amostras, esperou-se dois minutos, tempo necessário para transferir os dados para o computador. Contudo, as vazões de líquido e gás para as FVG desejadas foram previamente calculadas baseadas no modelo homogêneo, o que não correspondeu à FVG medida pelo sistema de válvulas. Portanto, os incrementos na FVG e o número de amostras acústicas para cada condição variou à medida em que os padrões se desenvolviam.

A energia contida em cada pulso acústico recebido por cada transdutor é calculada integrando-se a intensidade do sinal, I , ao longo do tempo de duração do

senal. A razão de energia para qualquer transdutor foi definida como a energia carregada por cada pulso ($E_{\phi II}$) dividido por um sinal de referência ($E_{\phi I}$), *i.e.* a energia máxima que pode ser recebida pelo mesmo transdutor. Para os sensores a 0° e 180° , a máxima energia foi quando apenas a fase contínua passava pela tubulação. O seguinte cálculo foi feito (Eq. 11)

$$\frac{E_{\phi II}}{E_{\phi I}} = \frac{\int_{t_1}^{t_2} (I_{\phi II})^2 dt}{\int_{t_1}^{t_2} (I_{\phi I})^2 dt} \quad \text{Eq. 11}$$

Para os sensores de 45° e 135° , não há energia refletida para os lados quando apenas a fase contínua passa pela tubulação. Nesses casos, o denominador da equação Eq. 11 foi substituído pela condição de máxima reflexão lateral em escoamento bifásico óleo-ar, a qual foi verificada ocorrer quando o tubo é densamente preenchido com bolhas discretas. Portanto, a razão de energia para os transdutores de 0° e 180° caem sempre na faixa de 0 a 1, enquanto que para os de 45° e 135° , a faixa pode ficar um pouco acima da unidade quando gotículas de água ou partículas sólidas aumentam as reflexões laterais.

Como os dados acústicos obtidos experimentalmente são muito grandes, um programa no MATLAB® foi feito de modo a tratar os dados brutos e realizar o cálculo da Eq. 11. Basicamente os dados são convertidos em uma matriz tridimensional onde uma dimensão são as tensões elétricas (que é a intensidade I) em cada ponto de cada pulso. Outra dimensão são os pulsos. E uma terceira dimensão são os transdutores (4 (0° , 45° , 135° e 180°)). Cada amostra é composta de 15000 pulsos, sendo cada pulso um conjunto de tensões ao longo do tempo de medição. Primeiramente deve-se determinar a janela de atividade. A partir daí o primeiro passo é cortar os pontos de cada pulso que estão fora da janela de atividade. Depois eleva-se o pulso ao quadrado e faz a soma de todas as tensões. Essa tensão somada de cada pulso, dará a energia instantânea de cada pulso. Em seguida tira-se a média dessas energias instantâneas em relação a todos os pulsos dessa amostra. Por fim, calcula-se a razão de energia

escolhendo o denominador conforme explicado anteriormente. É este o parâmetro que foi utilizado como entrada da rede neural.

4.2.2. Protótipo ultrassônico utilizando petróleo

Esta montagem experimental foi idealizada por Maurício de Melo Freire Figueiredo como parte integrante de seu trabalho de mestrado na UNIFEI. É um novo experimento que teve a finalidade de se testar o protótipo ultrassônico utilizando-se como fluido amostras de petróleo cedidas pelo LabPetro - UNICAMP. O protótipo possui uma estação ultrassônica com quatro sensores conforme Figura 10 da Seção 4.2.1. Por razões de confidencialidade, os detalhes do projeto não são aqui fornecidos.

A montagem experimental consistiu em uma tubulação vertical de 2 polegadas de diâmetro interno e composta de três partes: a parte inferior em tubulação de aço, a parte seguinte consistiu no carretel ultrassônico (protótipo) e, na parte superior, uma tubulação de acrílico de forma a se poder verificar a expansão da coluna de líquido. A Figura 12 mostra a montagem: à esquerda um desenho esquemático e à direita o experimento montado no Laboratório de Engenharia de Sistemas Químicos (LESQ) da Faculdade de Engenharia Química da UNICAMP.

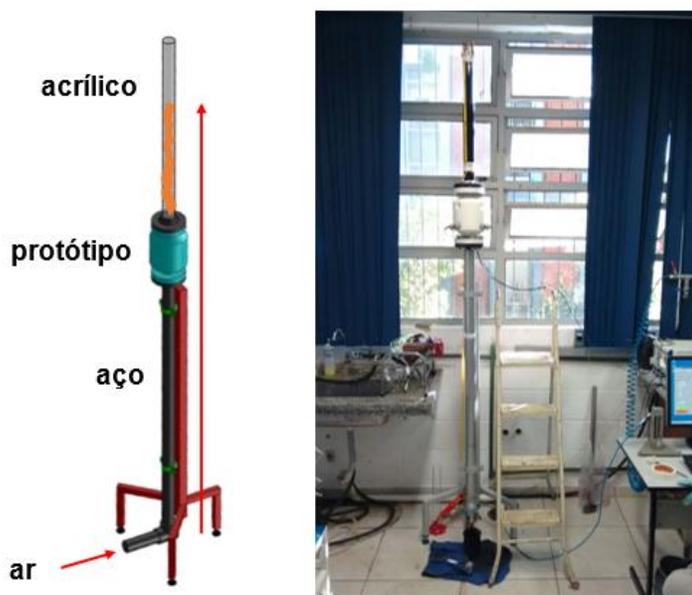


Figura 12 – Montagem do experimento com o carretel (LESQ/UNICAMP)

Duas amostras diferentes foram disponibilizadas pelo LabPetro, uma de óleo pesado (viscosidade de 4,5 logcP) e outra de óleo mais leve (viscosidade de 1,3 logcP). Para os experimentos com óleo pesado, não foi possível utilizá-lo puro, pois este era muito viscoso, impossibilitando o experimento. Por conta desse problema o óleo foi diluído com diesel em diversas proporções, de modo a se obter dados ultrassônicos com petróleo com diversas viscosidades (propriedade física importante na formação dos padrões de escoamentos multifásicos). A Tabela 9 mostra as várias composições usadas no experimento. O óleo mais leve foi utilizado puro. A título de comparação, o óleo mineral usado no experimento do Gonçalves (2013) possui uma viscosidade $\mu = 41.36$ cP a 20°C.

Tabela 9 - Composição da fase contínua testada nos experimentos

Nº Medição	Composição do Líquido	μ[cP]	ρ[kg/m³]	T (°C)
1	Petróleo pesado + 25,3% diesel	853,6	944,0	25
2	Petróleo pesado + 31,3% diesel	412,2	937,4	25
3	Petróleo pesado + 36,8% diesel	233,7	931,5	25
4	Petróleo pesado + 41,9% diesel	138,7	923,4	25
5	Petróleo leve	22,01	879,1	20

A taxa de aquisição dos dados ultrassônicos foi colocada em 20MHz. O intervalo de amostragem e a taxa de geração de pulso foi de 10 segundos e 2kHz, respectivamente. Portanto, cada amostra possui 20 000 pulsos.

O experimento foi feito com a fase contínua (petróleo) em repouso. Inicialmente preencheu-se a tubulação de petróleo nas condições especificadas até 2 m. Na extremidade inferior, injetou-se ar comprimido, controlando sua vazão através de um rotâmetro (1 – 10 $\pm 0,1$ LPM). Em seguida, mediu-se o quanto a fase contínua se expande usando-se uma fita métrica. A partir dessa expansão foi calculada a FVG, considerando-se o volume expandido como o volume de ar. Foram feitas as medições ultrassônicas para o banco de dados de treinamento da rede neural variando-se a vazão de ar comprimido de 0 a 5,5 LPM, iniciando-se a primeira medida com ar

comprimido na vazão de 1 LPM e incrementando-se 0,5 LPM para cada fração de vazio até 5,5 LPM. Para cada medida foram feitas 5 amostras ultrassônicas. Também foram feitas medidas para serem usadas como banco de dados para validação da rede neural. Neste caso, a primeira medida foi iniciada com vazão de ar em 1,25 LPM até 5,25 LPM, incrementando-se 0,5 LPM para cada medição. Foram feitas 2 amostras para cada condição.

Para se obter o parâmetro acústico (Eq. 11) a ser utilizado pela rede neural, foi tomado o mesmo método utilizado no experimento descrito na seção 4.2.1.

4.3. ANÁLISE DOS NÚMEROS ADIMENSIONAIS

4.3.1. Seleção preliminar dos números adimensionais

A seleção preliminar dos números adimensionais partiram da análise de estudos da literatura previamente selecionados, conforme Seção 2.2. Como a rede neural a ser desenvolvida deverá abarcar escoamentos verticais ascendentes e escoamentos horizontais, devem-se considerar as forças, e os grupos adimensionais, atuantes em uma situação mais geral. As forças atuantes em escoamentos bifásicos em caso geral são:

- Força inercial do gás: $\rho_g u_g^2$ $\left[\frac{kg}{m s^2} \right]$
- Força inercial do líquido: $\rho_l u_l^2$ $\left[\frac{kg}{m s^2} \right]$
- Força viscosa do gás: $\frac{\mu_g u_g}{D}$ $\left[\frac{kg}{m s} \right]$
- Força viscosa do líquido: $\frac{\mu_l u_l}{D}$ $\left[\frac{kg}{m s} \right]$
- Força gravitacional do gás: $\rho_g g D$ $\left[\frac{kg}{m s^2} \right]$
- Força gravitacional do líquido: $\rho_l g D$ $\left[\frac{kg}{m s^2} \right]$
- Forças de capilaridade: $\frac{\sigma_l}{D}$ $\left[\frac{kg}{s^2} \right]$

Portanto, os grupos adimensionais selecionados devem descrever a ação destas forças, formando um grupo menos numeroso possível. A Tabela 10 mostra uma

lista dos grupos adimensionais pertinentes ao presente estudo entre aqueles apresentados por todos os autores citados acima. Foram introduzidos ainda os números de Reynolds com base na velocidade superficial do líquido e do gás, pois são os mais comumente usados.

Tabela 10: Grupos adimensionais pertinentes ao presente estudo.

Denominação / Referência	Expressão	Significado Físico
Número de Reynolds da velocidade superficial do líquido	$Re_{SL} = \frac{(1-s)GD}{\mu_L}$	Força de inércia do líquido / Força viscosa do líquido
Número de Reynolds da velocidade superficial do gás	$Re_{SG} = \frac{sGD}{\mu_G}$	Força de inércia do gás / Força viscosa do gás
Número de Reynolds do escoamento bifásico	$Re_{TP} = \frac{Re_{SL}}{(1-\alpha_g)}$	
Número de Froude do escoamento bifásico	$Fr = \frac{(j_g + j_l)^2}{gD}$	$\frac{\text{Forças de inércia}}{\text{Forças gravitacionais}}$
Razão entre o número de Eötvös e o número de Morton	$\frac{Eo}{Mo} = \frac{\rho_l^2 D^2 \sigma_l^2}{\mu_l^4}$	$\frac{\text{inércia} \times \text{capilaridade}}{\text{Forças viscosas}}$
Razão de densidades	$D_R = \frac{\rho_g}{\rho_l}$	Efeito da pressão
Número da velocidade do líquido	$N_{LV} = V_{SL} \left(\frac{\rho_L}{\sigma g} \right)^{1/4}$	
Número da velocidade do gás	$N_{GV} = V_{SG} \left(\frac{\rho_L}{\sigma g} \right)^{1/4}$	
Número do diâmetro	$N_D = d \left(\frac{\rho_L g}{\sigma} \right)^{1/2}$	
Número da viscosidade do líquido	$N_L = \mu_L \left(\frac{g}{\rho_L \sigma^3} \right)^{1/4}$	
Número da viscosidade do gás	$N_G = \mu_G \left(\frac{g}{\rho_L \sigma^3} \right)^{1/4}$	
Rugosidade relativa	$\frac{\varepsilon}{d}$	
Ângulo de contato	ψ	
Ângulo de inclinação da tubulação	θ	

Em vista do grande número de grupos adimensionais, faz-se necessária uma seleção com base nos fenômenos físicos pertinentes aos escoamentos multifásicos. Além disto, os grupos escolhidos deveriam permitir, em condições laboratoriais, uma varredura em uma faixa mais ampla de modo que seu efeito sobre as variáveis de saída da rede neural pudesse realmente ser testado.

Deve-se ter em mente ainda que a relevância de um grupo adimensional está ligada à configuração do escoamento e às condições de operação. Por exemplo, o número de Froude, de grande importância em escoamentos horizontais e inclinados, se torna irrelevante no caso de escoamentos verticais. Neste caso, as forças gravitacionais não são determinantes da topologia do escoamento e, portanto, não faz sentido incluir o número de Froude entre os grupos de entrada. Assim sendo, faz-se a seguir uma seleção preliminar dos grupos adimensionais para cada configuração ou geometria do escoamento.

A Tabela 11 apresenta os grupos adimensionais selecionados. Observa-se uma distinção entre as definições do número de Reynolds do escoamento bifásico. Embora a definição na Tabela 10 seja mais corrente, a definição na Tabela 11 parece ser uma maneira simples de se levar em conta o efeito da aceleração do escoamento devido à presença do gás e o conseqüente aumento da turbulência no interior da tubulação. Além disso, a definição na Tabela 11 tem a vantagem adicional de não incluir a fração de vazio, lembrando-se aqui que este parâmetro deve ser uma das saídas da rede neural.

A importância do número de Froude está ligada aos fenômenos de estratificação verificados em escoamentos quase horizontais. Assim sendo, foi proposta uma nova definição do número de Froude com base no critério de transição de escoamentos quase horizontais em golfadas para bolhas dispersas ao mesmo tempo em que se tenta abarcar o efeito de aceleração do escoamento pelo gás (HETSRONI, 1982).

$$Fr_{TP} = \frac{(j_l + j_g)^2}{Dg \cos \theta} \sqrt{\frac{\rho_l - \rho_g}{\rho_l}} \quad \text{Eq. 12}$$

O número de Weber não consta explicitamente da Tabela 10, porém pode-se mostrar que:

$$We_l = \frac{\rho_l j_l^2 D}{\sigma} = N_{LV}^2 N_D = \frac{\text{forças de inércia}}{\text{forças de capilaridade}} \quad \text{Eq. 13}$$

As forças de capilaridade adquirem importância no caso de escoamentos em tubos de pequeno diâmetro ou quando as densidades do gás e do líquido são próximas, isto é, escoamentos a altas pressões. As forças de capilaridade também são importantes nos fenômenos de coalescência das bolhas. Um conceito que tenta capturar esse fenômeno é o diâmetro crítico das bolhas, isto é, o diâmetro acima do qual as bolhas se tornam deformáveis e tendem a coalescer. O diâmetro crítico é dado por (INOUE *et al.*, 2013):

$$d_{crit} = constante \times \sqrt{\frac{\sigma}{(\rho_l - \rho_g)g}} \quad \text{Eq. 14}$$

Tabela 11: Grupos adimensionais selecionados preliminarmente para entrada da rede neural (escoamento bifásico)

Denominação	Expressão	Significado Físico
Número de Reynolds do escoamento bifásico	$Re_{TP} = \frac{\rho_l(j_l + j_g)D}{\mu_l}$	Força inercial do líquido incluindo aceleração pelo gás / forças viscosas
Número de Froude do escoamento bifásico	$Fr_{TP} = \frac{(j_l + j_g)^2}{Dg \cos \theta} \sqrt{\frac{\rho_l - \rho_g}{\rho_l}}$	
Número de Weber considerando diâmetro crítico da bolha	$We_{TP} = \frac{\rho_l(j_l + j_g)}{\mu_l} \sqrt{\frac{\sigma}{(\rho_l - \rho_g)g}}$	
Razão de velocidades superficiais	$\lambda_l = \frac{j_l}{j_l + j_g}$	Fração de líquido quando não há deslizamento entre as fases
Razão de pressões	$\frac{p}{p_{atm}}$	

Decidiu-se então que, além de se usar o número de Weber em sua definição tradicional, seria conveniente se tentar definir um grupo adimensional que considerasse em um só tempo forças de capilaridade, forças inerciais, forças viscosas e a turbulência no escoamento causada pela efeito de aceleração do gás. Reconhecendo que o termo:

$$\frac{\mu_l}{\rho_l(j_l + j_g)} \quad \text{Eq. 15}$$

tem unidades de comprimento, ele pode ser combinado com a expressão para o diâmetro crítico a fim de se obter um novo grupo adimensional. O resultado consta da Tabela 11 e é:

$$We_{TP} = \frac{\rho_l(j_l + j_g)}{\mu_l} \sqrt{\frac{\sigma}{(\rho_l - \rho_g)g}} \quad \text{Eq. 16}$$

Outra combinação de parâmetros que não consta explicitamente da Tabela 10 é:

$$\lambda_l = \frac{j_l}{j_l + j_g} = \frac{N_{LV}}{N_{LV} + N_{GV}} \quad \text{Eq. 17}$$

A razão de velocidades superficiais, λ_l , é uma medida da fração de líquido quando não há deslizamento entre as fases. Três motivos levaram a sua escolha como um dos grupos de entrada: (i) pode ser variada facilmente em laboratório; (ii) foi utilizada por Greskovich e Shrier (1972) para correlacionar, juntamente com o número de Froude, a frequência de ocorrência de pistões no escoamento pistonado e (iii) é um dos parâmetros utilizados para estudar o desempenho da BCS (Bomba Centrífuga Submersa) no LabPetro-UNICAMP.

A escolha da pressão, na forma adimensional, se deve às seguintes razões: (i) influi diretamente no tamanho das bolhas e, portanto, na topologia das fases; (ii) influi diretamente no desprendimento de gás do petróleo; (iii) foi uma das variáveis

selecionadas por Shaikh e Aldahhan (2003) como determinantes da fração de vazio média em colunas de bolhas; (iv) tem-se mostrado um parâmetro importante para caracterização do desempenho da BCS existente no LabPetro-UNICAMP.

Os grupos adimensionais listados na Tabela 11 são funções das seguintes variáveis:

- Dimensão característica (diâmetro da tubulação), dimensão característica do espaço anular, etc.);
- Ângulo de inclinação da tubulação;
- Pressão de operação;
- Velocidade superficial do gás;
- Velocidade superficial do líquido;
- Densidade do líquido;
- Viscosidade dinâmica do líquido;
- Tensão superficial do líquido;
- Densidade do gás;

As forças envolvidas nos grupos adimensionais na Tabela 11 são:

- | | | |
|-----------------------------------|-----------------------|-----------------------------------|
| • Força inercial do líquido: | $\rho_l u_l^2$ | $\left[\frac{kg}{m s^2} \right]$ |
| • Força viscosa do líquido: | $\frac{\mu_l u_l}{D}$ | $\left[\frac{kg}{m s} \right]$ |
| • Força gravitacional do gás: | $\rho_g g D$ | $\left[\frac{kg}{m s^2} \right]$ |
| • Força gravitacional do líquido: | $\rho_l g D$ | $\left[\frac{kg}{m s^2} \right]$ |
| • Forças de capilaridade: | $\frac{\sigma_l}{D}$ | $\left[\frac{kg}{s^2} \right]$ |

Este conjunto de variáveis satisfaz o primeiro requisito para desenvolvimento da presente rede neural, qual seja, os dados de entrada da rede devem fazer parte daqueles obtidos cotidianamente na indústria petrolífera. As propriedades físicas são medidas regularmente em laboratório; os parâmetros de operação são conhecidos da própria aplicação; a pressão é monitorada continuamente e estimativas das velocidades superficiais são dadas pela engenharia de reservatório.

Com relação às forças envolvidas, somente as forças inerciais e viscosas do gás não constam diretamente das forças abarcadas pelos grupos adimensionais propostos. Por outro lado, espera-se que o efeito viscoso do gás seja pequeno, pois ele não será a fase contínua em nenhum dos escoamentos considerados no presente projeto. Quanto às forças inerciais, a nova definição do número de Reynolds e de Froude tenta levar em consideração o efeito da aceleração do escoamento produzido pelo gás por meio da soma $j_l + j_g$.

Por fim, conforme o que foi descrito anteriormente, a Tabela 12 resume os números adimensionais que são utilizados para o desenvolvimento da rede neural.

Tabela 12. Números adimensionais utilizados como entradas da rede neural

Denominação	Expressão	Significado Físico
Número de Reynolds do gás	$Re_g = \frac{\rho_g j_g D}{\mu_g}$	$\frac{\text{Forças Inerciais}}{\text{Forças Viscosas}}$
Número de Reynolds do líquido	$Re_l = \frac{\rho_l j_l D}{\mu_l}$	$\frac{\text{Forças Inerciais}}{\text{Forças Viscosas}}$
Número de Reynolds do escoamento bifásico	$Re_{TP} = \frac{\rho_l (j_l + j_g) D}{\mu_l}$	Força inercial do líquido incluindo aceleração pelo gás / forças viscosas
Número de Froude do escoamento bifásico	$Fr_{TP} = \frac{(j_l + j_g)^2}{Dg \cos \theta} \sqrt{\frac{\rho_l - \rho_g}{\rho_l}}$	$\frac{\text{Forças de Inércia}}{\text{Forças Gravitacionais}}$
Número de Weber	$We_l = \frac{\rho_l j_l^2 D}{\sigma}$	$\frac{\text{Forças de inércia}}{\text{Forças de capilaridade}}$
Número de Weber considerando diâmetro crítico da bolha	$We_{TP} = \frac{\rho_l (j_l + j_g)}{\mu_l} \sqrt{\frac{\sigma}{(\rho_l - \rho_g)g}}$	
Razão de velocidades superficiais	$\lambda_l = \frac{j_l}{j_l + j_g}$	Fração de líquido quando não há deslizamento entre as fases
Razão de pressões	$\frac{p}{p_{atm}}$	

4.3.2. Seleção final dos grupos adimensionais

Para o início do desenvolvimento da rede, foi necessário fazer uma pré-seleção das variáveis de entrada que serão introduzidas à rede. Foram escolhidos oito grupos adimensionais. Para a seleção final será analisada a matriz de pesos e bias da primeira camada.

A análise de pesos e bias é o modo mais simples e direto de se verificar a relevância de alguma entrada para a RNA. Quanto menores forem os valores em módulo dos pesos e bias de uma entrada da rede, supondo que as outras entradas tenham pesos e bias significativamente maiores, menor é sua importância e relevância para o sistema. Com isso, pode haver a possibilidade de se eliminar alguma variável de entrada. Quanto menor o número de entradas, mais simples o modelo neural.

Portanto, seguindo este procedimento espera-se diminuir o número de entradas da RNA. Para tal, uma arquitetura preliminar de rede neural foi desenvolvida para a avaliação de cada entrada da rede. Neste caso a RNA criada possui duas camadas ocultas, a primeira tendo oito neurônios e a segunda tendo três. Além disso o treinamento foi realizado apenas três vezes.

4.3.3. Banco de dados da literatura

Uma extensa pesquisa na literatura foi feita a fim de estender o banco de dados para treinamento da RNA com números adimensionais. Este banco de dados foi feito através da cooperação do professor Nicolas Rios Ratkovich e seus orientados da *Universidad de los Andes*, que juntaram e organizaram as informações coletadas. Para se enquadrar no banco de dados o estudo deveria ser de escoamento bifásico líquido-gás. Procurou-se dar preferência para aqueles em que a fase líquida fosse composta por petróleo, mas também utilizaram-se diversos outros fluidos, de modo a se ter uma grande diversidade em termos de propriedades físicas.

A partir da discussão tratada na seção 4.3.1, pôde-se montar um arquivo Excel composto de diversas planilhas reunindo as principais informações referentes a cada experimento. Estas informações são:

- Dados de operação, como temperatura, pressão, geometria do experimento, etc.;
- Propriedades físicas dos fluidos nas condições operacionais,
- Cálculo dos grupos adimensionais.

Também foi criada outra planilha para registrar as principais tabelas e equações usadas para o cálculo de algumas propriedades físicas não disponibilizadas pelos estudos usados.

A Figura 13 ilustra um exemplo de preenchimento da primeira planilha, intitulada Dados de Operação 1. Esta planilha contém os dados relevantes da configuração geométrica do aparato experimental. Como já discutido, o ângulo de inclinação e o tamanho do diâmetro interno da tubulação são os parâmetros geométricos principais utilizados nos grupos adimensionais. Além disso, acrescentou-se os dados de comprimento do último acidente a montante até o ponto de medição principal do experimento (ou seja, o ponto onde se determinava os valores alvo FVG e/ou padrão de escoamento) e também o comprimento à jusante deste ponto. Estes comprimentos eram usados para se determinar a razão L/D, que indica se o escoamento bifásico já se encontra completamente desenvolvido. Por fim, preenche-se o material em que a tubulação é feita, os fluidos utilizados no experimento e se o escoamento é horizontal, inclinado, vertical ascendente ou descendente.

BANCO DE DADOS PARA DESENVOLVIMENTO DE REDE NEURAL

Autor(es)	Tubulação						Material	Fluidos	Configuração do Escoamento
	Ângulo de Inclinação	Diâmetro [mm]	Comprimento Montante [m]	Comprimento Jusante [m]	L/D Montante	L/D Jusante			
Manabe 2001	90	52.5	16.15	9.145	307.6	174.2	aço inox	óleo cru - gás natural	Vertical, ascendente
Manabe 2001	90	52.5	16.15	9.145	307.6	174.2	aço inox	óleo cru - gás natural	Vertical, ascendente
Rosa et al. 2010	90	26	6.7	1.3	257.7	50.0	Visualização - Plexiglas	Água / Ar	Vertical, ascendente
Rosa et al. 2010	90	26	6.7	1.3	257.7	50.0	Visualização - Plexiglas	Água / Ar	Vertical, ascendente

Figura 13. Trecho da tabela 'Dados de Operação 1'

A Figura 14 ilustra um exemplo de preenchimento da planilha Dados de Operação 2. Nela encontram-se as pressões e temperaturas de operação de acordo com o sensor mais próximo do ponto de medição principal do aparato experimental. Utiliza-se a pressão de operação. Nelas também são colocadas as velocidades superficiais das fases líquida e gás. As velocidades superficiais são dados essenciais

pois são utilizados em quase todos os grupos adimensionais. Por fim, estão os parâmetros de saída FVG e padrões de escoamento. A FVG varia de 0 a 1 enquanto a classificação de padrões segue a numeração indicada na Tabela 6 da Seção 4.1. Quando o estudo apresentava uma classificação própria dos padrões de escoamento, era necessário reclassificá-la para o correspondente padrão usado neste trabalho.

Um problema particular encontrado é que muitas vezes os autores publicam dados com os padrões de escoamento, porém sem sua correspondência com a fração de vazio ou vice-versa. É de grande interesse estender o banco de dados para incluir a fração de vazio, portanto, esses dados estão sendo obtidos através de dados sintéticos de fração de vazio ou padrão de escoamento. Esses dados sintéticos são obtidos através de simulações 3D (OLGA) da montagem experimental e condições de escoamento dos artigos selecionados da literatura. Estas simulações foram realizadas por grupo de pesquisa da Universidad de los Andes (Colômbia) sob responsabilidade do Professor Nicolas Rios Ratkovich.

BANCO DE DADOS PARA DESENVOLVIMENTO DE REDE NEURAL

Autor(es)	Pressão de Operação [bars]	Temperatura de Operação [°C]	Velocidades Superficiais [m/s]		Fração de Vazio [%]	Padrões de Escoamento		
			Gás	Líquido		código num.	Padrão Original	Presente Estudo
Manabe 2001	31.9920	55.2	0.13	0.84	0.1216	1.1	B	BV
Manabe 2001	14.4431	51.7	0.21	0.95	0.16641	1.3	I	IT
Rosa et al. 2010	0.946	24.0	0.67	1.21	0.19	1.1	SC	BV
Rosa et al. 2010	0.946	24.0	1.00	0.36	0.57	1.3	SS	IT,

Figura 14. Trecho da tabela ‘Dados de Operação 2’

A Figura 15 apresenta a planilha Propriedades Físicas. Nela estão as propriedades físicas que são usadas nos cálculos dos números adimensionais, conforme discutido na Seção 4.3.1. Preferência foi dada sempre a valores de propriedades físicas fornecidas pelo próprio artigo. No entanto, quando um valor de propriedade física de algum fluido nas condições do experimento não estava disponível, outras bibliografias eram usadas para a sua determinação.

BANCO DE DADOS PARA DESENVOLVIMENTO DE REDE NEURAL

Autor(es)	Líquido			Gás	
	Densidade [kg/m ³]	Viscosidade [Pa.s]	Tensão Superficial [(N/m) x 10 ³]	Densidade [kg/m ³]	Viscosidade [Pa.s]
Manabe 2001	801.1	3.22E-03	14.74	23.62	1.291E-05
Manabe 2001	805.4	3.22E-03	14.74	10.83	1.291E-05
Rosa et al. 2010	997.1	9.20E-04	72.16	1.11	1.825E-05
Rosa et al. 2010	997.1	9.20E-04	72.16	1.11	1.825E-05

Figura 15. Trecho da tabela 'Propriedades Físicas'

Finalmente, a Figura 16 mostra a planilha Grupos Adimensionais. Nela são feitos os cálculos de todos os números adimensionais de cada ponto experimental. Estes valores comporão a matriz de dados de entrada para a rede neural.

Autor(es)	p / P _{atm}	Número de Reynolds			Número de Weber	Número de Weber modificado	Razão de Velocidades Superficiais	Número de Froude
		Gás	Líquido	Bifásico				
Manabe 2001	31.57	1.28E+04	1.10E+04	1.27E+04	9.77E+02	3.38E+02	0.86	4.14E+06
Manabe 2001	14.25	9.39E+03	1.25E+04	1.53E+04	1.25E+03	4.01E+02	0.82	4.43E+06
Rosa et al. 2010	0.93	1.06E+03	3.41E+04	5.30E+04	5.14E+02	5.54E+03	0.64	5.66E+06
Rosa et al. 2010	0.93	1.58E+03	1.01E+04	3.83E+04	4.55E+01	4.01E+03	0.26	8.45E+06

Figura 16. Trecho da tabela 'Grupos Adimensionais'

4.4. ARQUITETURA DAS REDES NEURAIIS

4.4.1. Ultrassom

Foram duas as redes neurais desenvolvidas: uma para predição de FVG e uma para predição de IPDE.

Para o desenvolvimento das redes neurais, fez-se necessário separar o banco de dados em 75% para treinamento e 25% para teste de validação. Foi utilizado um algoritmo que separa automaticamente os 25% dos dados. Como o conjunto para validação deve ser representativo e perpassar por toda a faixa de dados, primeiramente organizou-se em ordem crescente de fração de vazio (FVG) ou padrão de escoamento

(IPDE), de acordo com o caso. Isto permite que o algoritmo pegue de maneira igualmente espaçada os dados ao longo de toda a matriz de dados.

No desenvolvimento das redes neurais artificiais para aplicações em escoamentos multifásicos, a variável de saída FVG é contínua entre 0 e 100%, enquanto que os padrões de escoamento possuem valores discretos. Conseqüentemente, essas duas variáveis de saída constituem tipos bem distintos, que não podem ser tratadas por uma única rede neural do tipo *feedforward* utilizado neste estudo. Por esse fator não foi usada apenas uma RNA para as duas variáveis de saída.

As redes neurais foram treinadas utilizando como entradas os valores da razão de energia média captadas pelos transdutores ultrassônicos usados em ambos os experimentos citados nas seções 4.2.1 e 4.2.2. Portanto, a camada de entrada tem 4 neurônios, cada um recebendo os valores de razão de energia de um dos transdutores (0°,45°,135°,180°). Como o conjunto de dados acústicos usados como entrada da rede não são funções de superfície suave, o número de camadas ocultas deve ser maior que um (HAYKIN, 2001). Tendo como base sempre a arquitetura mais simples possível decidiu-se por utilizar duas camadas intermediárias e não um número maior, pois um maior número de camadas apenas acrescentaria complexidade ao sistema, sem ganhos significativos. Também optou-se pelo uso de RNA do tipo *perceptron* multicamada baseado no estudo de Rosa *et al.* (2010).

Em seguida, alguns parâmetros preliminares foram definidos. Primeiramente, decidiu-se pela utilização do método de Levenberg-Marquardt, com regularização bayesiana (trainbr) por ser este o método mais robusto entre aqueles no programa computacional utilizado (MatLab®). Por meio dele, o treinamento da rede foi realizado em tempo relativamente curto e, devido ao termo bayesiano na função objetivo, não há risco de ocorrer sobre-ajuste (overfitting), uma vez que o treinamento é cessado no momento em que o menor erro possível na generalização é atingido.

O número de neurônios foi determinado empiricamente testando-se diversas combinações de 1 a 6 neurônios na primeira camada oculta e de 1 a 3 neurônios na segunda camada oculta. Avaliou-se o desempenho de cada rede através da soma dos erros ao quadrado (SSE) e do erro médio (Eq. 18) gerados ao rodar a RNA com o banco de dados de validação, não vistos durante o treinamento.

$$\bar{\epsilon} = \left(\frac{SSE}{q} \right)^{1/2} \quad \text{Eq. 18}$$

O número máximo de passos (épocas) foi estabelecido em 10^3 e o objetivo (goal) foi determinado em função da soma dos erros ao quadrado do conjunto de treinamento (SSE). Neste sentido, foram feitas considerações a respeito das incertezas típicas nas medições de vazões usando medidores de vazão multifásicos. Falcone *et al.* (2010) resume o intervalo de incertezas indicados por diversos autores para diferentes cenários; a incerteza para a vazão da massa líquida usando-se medidores multifásicos está entre 10 a 20%. Na presente investigação, usou-se como guia que o SSE nos resultados da RNA não deveria exceder, em termos de FVG, os desvios usuais. Em vista disto e do número de vetores totais usados no banco de treinamento (aproximadamente 347 vetores, cada vetor sendo o conjunto das 4 razões de energia de cada sensor e a resposta em termos de FVG ou IPDE), determinou-se que o SSE para predição de FVG e IPDE seria 10^2 e 10^{-1} , respectivamente. Desta forma, o treinamento da rede irá parar quando o valor de SSE ficar abaixo desses valores limites ou quando se atingir o número máximo de épocas. O uso do valor default do MatLab® para SSE, que é de 10^{-4} , poderia provocar sobre-ajuste, modelando também os erros/incertezas de medição.

Prosseguiu-se, então, com a escolha das funções matemáticas dos neurônios de cada camada. Para as duas camadas intermediárias, decidiu-se pela função logística sigmoide (logsig), pois como citado na Seção 3.3, o fato dessa função ter “motivação biológica” a torna uma das mais comuns no desenvolvimento de RNAs. Já para a camada de saída optou-se pela função puramente linear (purelin), pois para o neurônio de saída apenas há o interesse de combinar os sinais vindos da camada oculta. .

O processo de treinamento seguiu os seguintes passos:

1. 100 tentativas de treinamento da rede neural utilizando os 75% do banco de dados previamente separados;
2. Inicialização, a cada treinamento, de valores aleatórios de pesos e bias;

3. Os pesos e bias obtidos eram salvos sempre quando, após um treinamento, atingia-se um valor de SSE (calculado com o conjunto de teste de validação) menor que o anterior;
4. Teste de validação: apresentação à melhor rede neural treinada os 25% do banco de dados previamente separados para teste, salvando-se a resposta (saída da RNA) para cada vetor apresentado;
5. Comparação por um gráfico de dispersão os valores previstos pela rede (output) com os valores verdadeiros (target). Gera-se também um coeficiente de correlação R^2 , que deve ser o mais próximo de 1.

Este procedimento foi adotado para que a chance da minimização cair no mínimo global fosse maximizado. Uma rotina no Matlab® realizou automaticamente esses 100 testes (Anexo A).

4.4.2. Números Adimensionais

Foram duas as redes neurais desenvolvidas: uma para predição de FVG e outra para a predição de IPDE. Para o desenvolvimento das redes neurais, fez-se necessário separar o banco de dados em 75% para treinamento e 25% para teste de validação. Como já citado na seção 4.4.1, um algoritmo separou os 25% dos dados. Como o conjunto para validação deve ser representativo e perpassar toda a faixa de dados, primeiramente organizou-se em ordem crescente de fração de vazão (FVG) ou padrão de escoamento (IPDE), de acordo com o caso. Isto permite que o algoritmo pegue de maneira igualmente espaçada os dados ao longo de toda a matriz de dados.

A rede neural para os grupos adimensionais tem como entradas os valores calculados dos números adimensionais. Estas entradas, assim como o valor desejado (seja FVG ou IPDE), devem passar primeiramente por uma normalização numa escala de -1 a 1. Este procedimento faz-se necessário para que, durante o treinamento, não houvesse um favorecimento de influência de algum grupo adimensional apenas por seus valores em módulo serem maior que outros. No caso de dados ultrassônicos esse procedimento não foi adotado pois a razão de energia já é uma variável “normalizada” entre 0 e 1. No MatLab® fez-se uso da função MAPMINMAX, que além de normalizar os valores na faixa de -1 a 1, também armazena os valores de máximo e mínimo usados para a normalização. Assim, quando se apresentarem novos dados à rede

neural já treinada, estes dados novos serão normalizados com a mesma referência utilizada no treinamento da RNA. Segue a equação de normalização usada pela função MAPMINMAX (Eq. 19).

$$y = \frac{(y_{max} - y_{min}) * (\hat{x} - \hat{x}_{min})}{(\hat{x}_{max} - \hat{x}_{min})} + y_{min}$$

Eq. 19

Tendo como base sempre a arquitetura mais simples possível, decidiu-se por utilizar duas camadas intermediárias em uma RNA do tipo *perceptron* de múltiplas camadas, conforme explicado na seção 4.4.1.

Os parâmetros da RNA foram os mesmos empregados na RNA com dados ultrassônicos. Decidiu-se pela utilização do método de Levenberg-Marquardt, com regularização bayesiana (trainbr) por ser este o método mais robusto entre aqueles no programa computacional utilizado (MatLab®). Por meio dele, o treinamento da rede foi realizado em tempo relativamente curto e, devido ao termo bayesiano na função objetivo, não há risco de ocorrer sobre-ajuste (overfitting).

O número de neurônios foi determinado empiricamente testando-se diversas combinações de 1 a 8 neurônios na primeira camada oculta e de 1 a 3 neurônios na segunda camada oculta. Diferentemente do item 4.4.1, foi usado como critério o valor de SSE e erro médio gerados ao testar a RNA com um grupo de dados de dois estudos da literatura que sejam representativos em termos de FVG e IPDE e que não tenham sido vistos durante o treinamento.

O número máximo de passos (épocas) foi estabelecido em 10^3 e o objetivo (goal) foi determinado em função da soma dos erros ao quadrado do conjunto de treinamento (SSE). Determinou-se que o SSE para predição de ambos FVG e IPDE seriam de 10^{-1} , pois nesse segundo caso, a FVG foi usada em sua forma racional, variando-se de 0 a 1. O número de vetores totais usados no banco de treinamento foi de 1355 vetores, cada vetor sendo o conjunto dos 8 números adimensionais e a resposta em termos de FVG ou IPDE. Desta forma, o treinamento da rede para quando o valor de SSE ficar abaixo desses valores limites ou quando se atingir o número

máximo de épocas. O uso do valor default do MatLab® para SSE, que é de 10^{-4} , poderia provocar sobre-ajuste, modelando também os erros/incertezas de medição.

Prosseguiu-se, então, com a escolha das funções matemáticas dos neurônios de cada camada. Para as duas camadas intermediárias, decidiu-se pela função logística sigmoide (logsig). Já para a camada de saída optou-se pela função puramente linear (purelin).

O processo de treinamento seguiu os seguintes passos:

1. 100 tentativas de treinamento da rede neural utilizando os 75% do banco de dados previamente separados;
2. Inicialização, a cada treinamento, de valores aleatórios de pesos e bias;
3. Os pesos e bias obtidos eram salvos sempre quando, após um treinamento, atingia-se um valor de SSE (calculado com o conjunto de teste de validação) menor que o anterior;
4. Teste de validação: apresentação à melhor rede neural treinada os 25% do banco de dados previamente separados para teste, salvando-se a resposta (saída da RNA) para cada vetor apresentado;
5. Comparação por um gráfico de dispersão os valores previstos pela rede (output) com os valores verdadeiros (target). Gera-se também um coeficiente de correlação R^2 , que deve ser o mais próximo de 1.

4.5. COMBINAÇÃO FINAL DAS REDES NEURAIIS

Para cada variável a ser predita (FVG e IPDE), os dois modelos neurais desenvolvidos deverão ser combinados em paralelo de modo que o sistema seja robusto. Assim, mesmo se algum dos dados de entrada (seja ultrassom ou números adimensionais) estejam em falta, é possível obter uma predição confiável. A Figura 17 mostra um esquema da predição final de FVG e de IPDE:

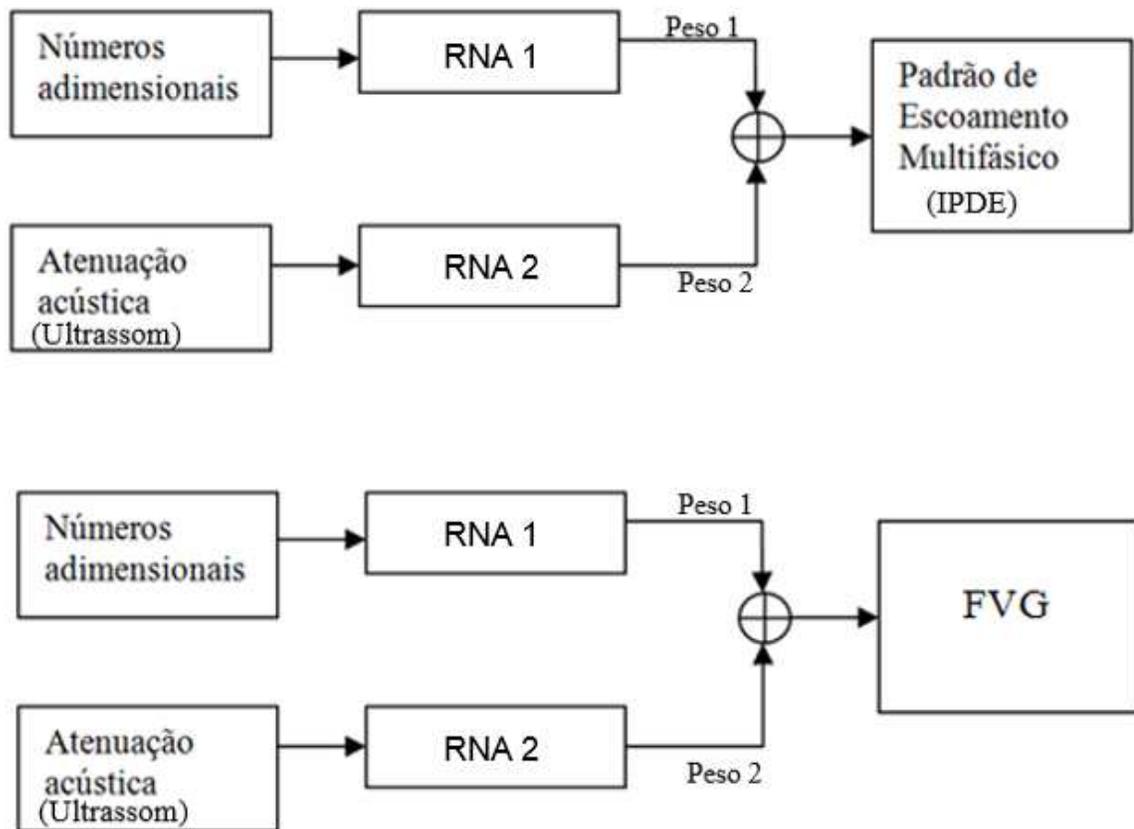


Figura 17. Esquema do sistema da predição final de FVG e de IPDE.

O resultado final para cada variável de saída (IPDE ou FVG) deverá ser uma média ponderada das previsões das redes RNA1 e RNA2. Os pesos 1 e 2 da Figura 17 dependerão da confiabilidade instantânea da medição das variáveis de entrada das redes neurais. Por exemplo, se por algum motivo operacional as medições provenientes do ultrassom estiverem indisponíveis, o peso 1 deverá ser 100% e o peso 2 ser 0%.

É proposto, porém, um valor padrão de peso, que foi determinado de acordo com o desempenho de cada RNA. Primeiramente, analisa-se qual rede neural (grupos adimensionais ou ultrassom) fornece o melhor desempenho, avaliado em termos de SSE e erro médio. Esta rede neural terá o maior peso e é chamado de peso 1. Variam-se então os pesos de acordo com a Tabela 13, verificando assim a melhor configuração, que será considerada padrão.

Tabela 13 Combinação de pesos para avaliação de pesos padrão do sistema neural

Peso 1	Peso 2
0.5	0.5
0.6	0.4
0.7	0.3
0.8	0.2
0.9	0.1

Por fim, o desempenho do sistema neural é avaliado tanto visualmente por meio de gráficos como por comparações entre o SSE e erro médio do sistema neural com as redes neurais separadamente. Os dados usados foram os de Gonçalves (2013) e os extraídos com o protótipo ultrassônico, pois são os únicos dados ultrassônicos disponíveis.

5.RESULTADOS E DISCUSSÃO

5.1. RNA ULTRASSOM

As Tabelas 14 e 15 mostram a relação de testes preliminares realizados para se determinar a melhor combinação de neurônios para a arquitetura final da RNA. Foram usados no banco de dados todos os escoamentos na tubulação de 1 e 2 polegadas. As tabelas contemplam as diferentes combinações do número de neurônios das camadas intermediárias. Constam também seus respectivos coeficientes de correlação do gráfico de dispersão (real versus predito) e valores de SSE e erro médio calculados com o conjunto de validação (não vistos durante o treinamento) e que foram separados pelo algoritmo de separação de 25% do banco de dados.

Para a arquitetura da rede, verificou-se que o menor valor de SSE e erro médio obtidos dentre todas as combinações realizadas foi de cinco neurônios na primeira camada intermediária e dois neurônios na segunda camada intermediária, tanto para a rede neural que prevê FVG como para a que prevê IPDE. Portanto, foi essa a arquitetura final da rede neural que foi utilizada para o treinamento final das redes neurais. Estes resultados também confirmaram que um número excessivo de neurônios não beneficia a rede neural. O sistema torna-se mais complexo, o que pode aumentar o gasto computacional para os cálculos. Além disso, pode-se piorar a resposta da rede, correndo-se o risco de sobre-ajuste.

Tabela 14. Treinamentos para determinação da melhor arquitetura da rede neural com dados ultrassônicos para resposta em fração de vazio

Número do treinamento	Neurônios camada oculta 1	Neurônios camada oculta 2	R ²	SSE	Erro médio
1	1	1	0,8525	1,31E+04	0,9791
2	2	1	0,9065	8,58E+03	0,7916
3	3	1	0,9409	5,52E+03	0,6349
4	4	1	0,9545	4,29E+03	0,5601
5	5	1	0,9703	2,92E+03	0,462
6	6	1	0,9785	2,07E+03	0,3886
7	1	2	0,8541	1,30E+04	0,9755
8	2	2	0,9434	5,28E+03	0,6208
9	3	2	0,9572	4,03E+03	0,5423
10	4	2	0,9734	2,57E+03	0,4333
11	5	2	0,9829	1,69E+03	0,3518
12	6	2	0,979	2,08E+03	0,3900
13	1	3	0,8523	1,31E+04	0,9794
14	2	3	0,9468	5,00E+03	0,6046
15	3	3	0,9617	3,78E+03	0,5252
16	4	3	0,9693	2,92E+03	0,4615
17	5	3	0,9811	1,81E+03	0,3632
18	6	3	0,978	2,20E+03	0,4007

Tabela 15. Treinamentos para determinação da melhor arquitetura da rede neural com dados ultrassônicos para resposta em padrão de escoamento

Número do teste	Neurônios camada oculta 1	Neurônios camada oculta 2	R ²	SSE	Erro médio
1	1	1	0,8178	1,23E+00	0,0095
2	2	1	0,8868	7,29E-01	0,0073
3	3	1	0,9159	6,02E-01	0,0066
4	4	1	0,9304	5,05E-01	0,0061
5	5	1	0,9542	3,34E-01	0,0049
6	6	1	0,9562	3,18E-01	0,0048
7	1	2	0,8189	1,22E+00	0,0095
8	2	2	0,9216	5,60E-01	0,0064
9	3	2	0,9502	3,65E-01	0,0052
10	4	2	0,9562	3,19E-01	0,0048
11	5	2	0,972	2,05E-01	0,0039
12	6	2	0,9651	2,55E-01	0,0043
13	1	3	0,8541	1,01E+00	0,0086
14	2	3	0,9322	4,87E-01	0,006
15	3	3	0,9573	3,11E-01	0,0048
16	4	3	0,965	2,58E-01	0,0043
17	5	3	0,9699	2,22E-01	0,004
18	6	3	0,9714	2,11E-01	0,0039

A Figura 18 ilustra a arquitetura das redes neurais construídas e a Tabela 16 mostra a relação de número de dados obtidos nestes experimentos com ultrassom para o treinamento das redes neurais.

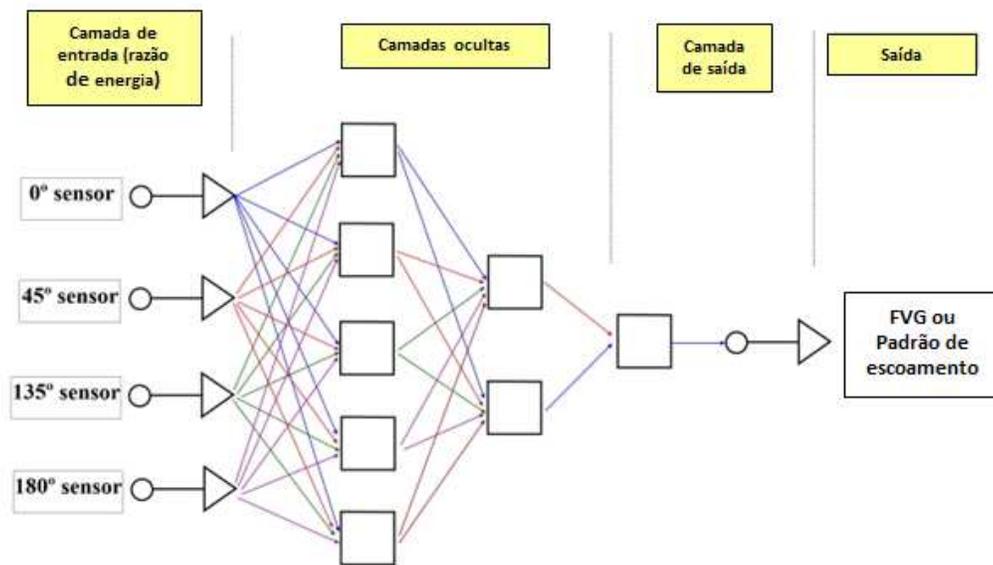


Figura 18 - Arquitetura das redes neurais desenvolvidas tanto para FVG quanto para Padrão de escoamento.

Tabela 16. Número de dados disponíveis para cada tipo de padrão de escoamento (montagem experimental item 4.2.1).

Diâmetro interno [polegadas]	Composição do escoamento	Número de dados (padrões verticais)			
		Bolhas dispersas	Intermitente	Agitado	Anular
1	O-A	22	24	36	6
	O-A-P	10	5	10	5
	O-A-P-S	25	16	32	6
	O-A-P-S-W	27	15	32	6
2	O-A	29	35	0	0
	O-A-W	25	35	0	0
	O-A-W-S	28	34	0	0
	TOTAL	166	164	110	23

O-A: Óleo-Ar

O-A-P: Óleo-Ar-Poliamida

O-A-P-S: Óleo-Ar-Poliamida-Areia

O-A-P-S-W: Óleo-Ar-Poliamida-Areia-Água

O-A-W-S: Óleo-Ar-Água-Areia

O-A-W: Óleo-Ar-Água

A Figura 19 mostra o resultado da RNA para a identificação do padrão de escoamento. Como se pode observar, previsões incorretas para os padrões ocorreram para os regimes intermitente e anular. Um ponto de padrão intermitente foi

incorretamente previsto como bolhas dispersas, o que possivelmente se deve às dificuldades em visualmente avaliar o padrão de escoamento na medida em que as bolhas crescem para bolhas de Taylor. Uma hipótese é que o que foi avaliado como intermitente pode ainda ser bolhas dispersas. Além disso, os desvios padrões nas razões de energia dos regimes intermitente e agitado tendem a ser maiores devido a variações aleatórias causadas pelos pistões durante o escoamento, o que altera o padrão de leitura dos sinais ultrassônicos (as reflexões causadas pelas estruturas desses dois escoamentos, caracterizados por bolhas de Taylor e calotas causam essas grandes variações). Isso pode também ter contribuído para a previsão incorreta. Sobre a predição incorreta para o caso do ponto de padrão anular, previsto como agitado, deve-se ao fato de esse ponto estar muito perto da transição entre os dois regimes, sendo difícil sua determinação visual.

A Figura 20 compara os valores experimentais com as respostas previstas pela RNA, ponto a ponto, de cada vetor que compõe o banco de dados de validação. Com ela é possível verificar qual ponto dentro do banco de dados está fora do intervalo correto estabelecido pela observação experimental. Cada vetor representa no banco de dados o conjunto das razões de energia de cada sensor ultrassônico e seu padrão de escoamento verificado visualmente. Os intervalos de vetores com maiores variações foram de 40 a 60 e de 90 a 116. Os vetores de 40 a 60 tratam do padrão agitado em tubulação de uma polegada. A evolução dos padrões em uma polegada é mais difícil de determinar visualmente. Além disso, o padrão agitado faz parte também do padrão intermitente e a separação apenas foi feita para melhorar o desempenho da rede neural, pois ajudou a rede a ter maiores acertos no padrão anular. Portanto, as variações nesse intervalo são aceitáveis. Para o intervalo de 90 a 116 trata-se do padrão intermitente para escoamento em duas polegadas. Apesar de uma maior variação, todos os pontos foram corretamente classificados, com exceção de um. Foram verificadas as razões de energia desse vetor, porém não foi possível detectar nenhum problema.

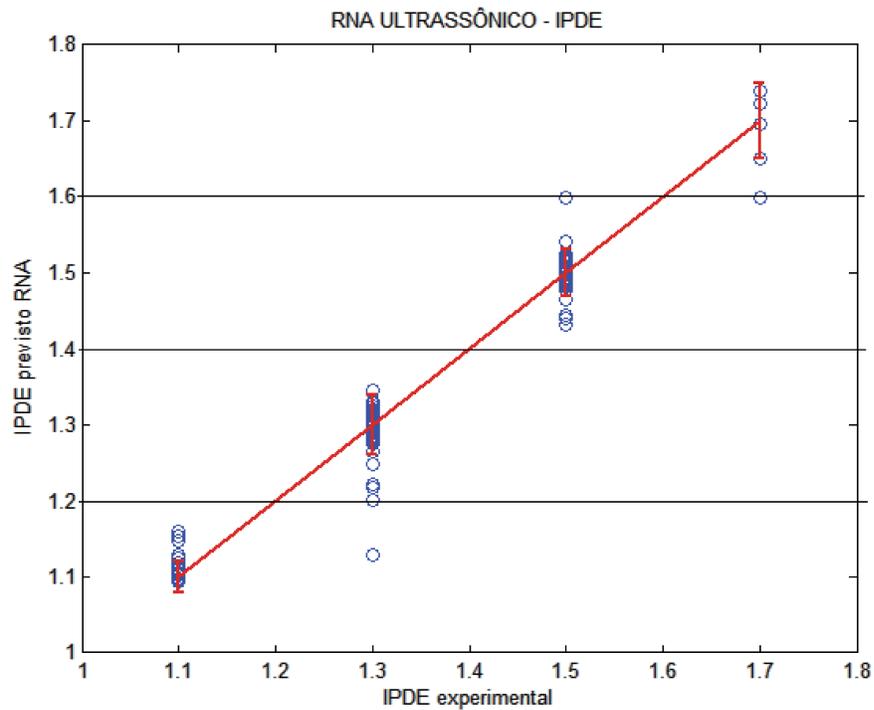


Figura 19. Desempenho da RNA para a identificação de padrão de escoamento para as tubulações de 1 e 2 polegadas com banco de dados de validação.

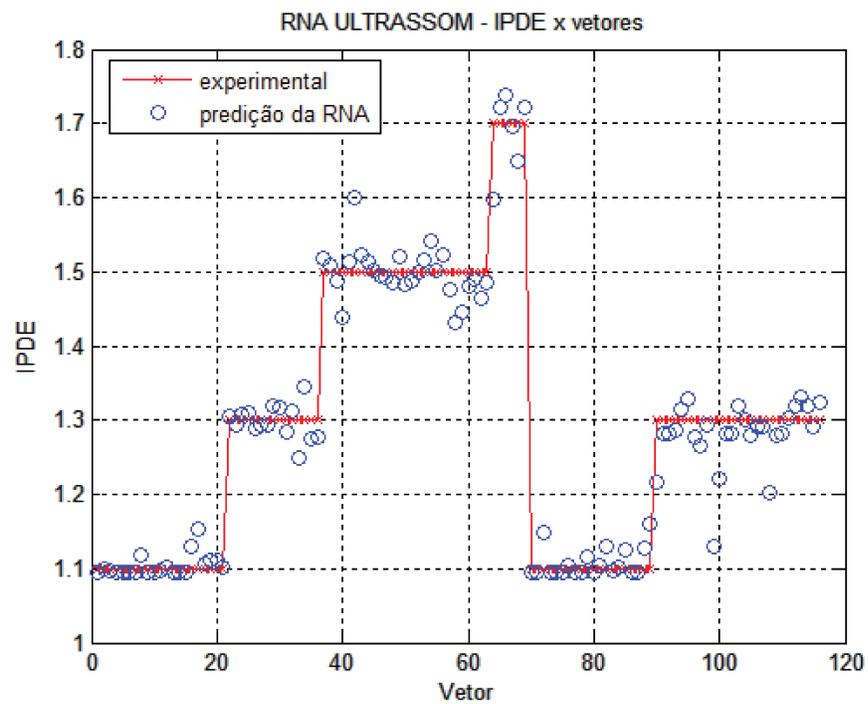


Figura 20. Comparação entre os valores de IPDE (padrões de escoamento) previstos pela rede e os valores experimentais versus vetores.

A Figura 21 mostra os resultados da RNA para a previsão da FVG. Os limites aproximados para cada padrão de escoamento correspondente à FVG foram colocados de acordo com observações visuais. Sobre as previsões de FVG, a Figura 21 mostra que os valores previstos estão próximos aos valores corretos (os pontos estão próximos da linha diagonal). A Figura 22 compara os valores alvo com as respostas da RNA ponto a ponto de cada vetor que compõe o banco de dados de validação. Com ela é possível verificar qual ponto dentro do banco de dados está muito discrepante do valor de FVG estabelecido pelo alvo. A vetorização de 0 a 69 são os dados para a tubulação de uma polegada e de 70 a 116 são para a tubulação de duas polegadas. Os resultados da RNA para duas polegadas são mais próximos dos medidos experimentalmente e com menos variações do que para uma polegada. Este resultado é coerente, pois a tubulação de duas polegadas tem maior turbulência. Esta turbulência causa uma uniformização maior dos padrões, ou seja, menos variações na topologia do escoamento para um mesmo padrão. Portanto, há menos aleatoriedades na FVG para duas polegadas.

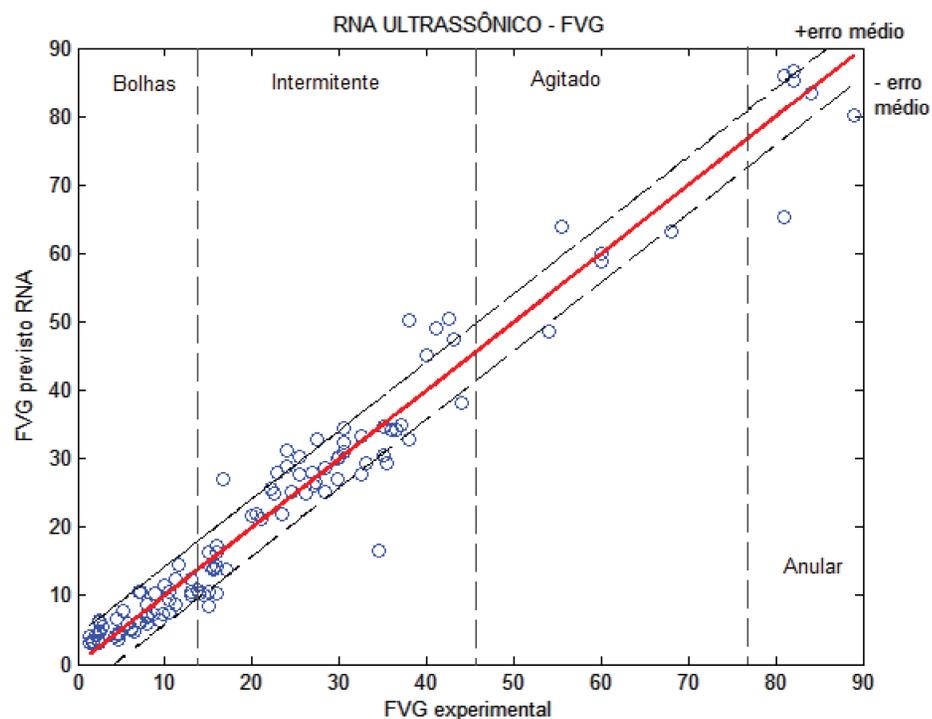


Figura 21. Resultado da RNA para previsão de FVG para as tubulações de 1 e 2 polegadas mostrando erro médio do resultado total de 4,2%.

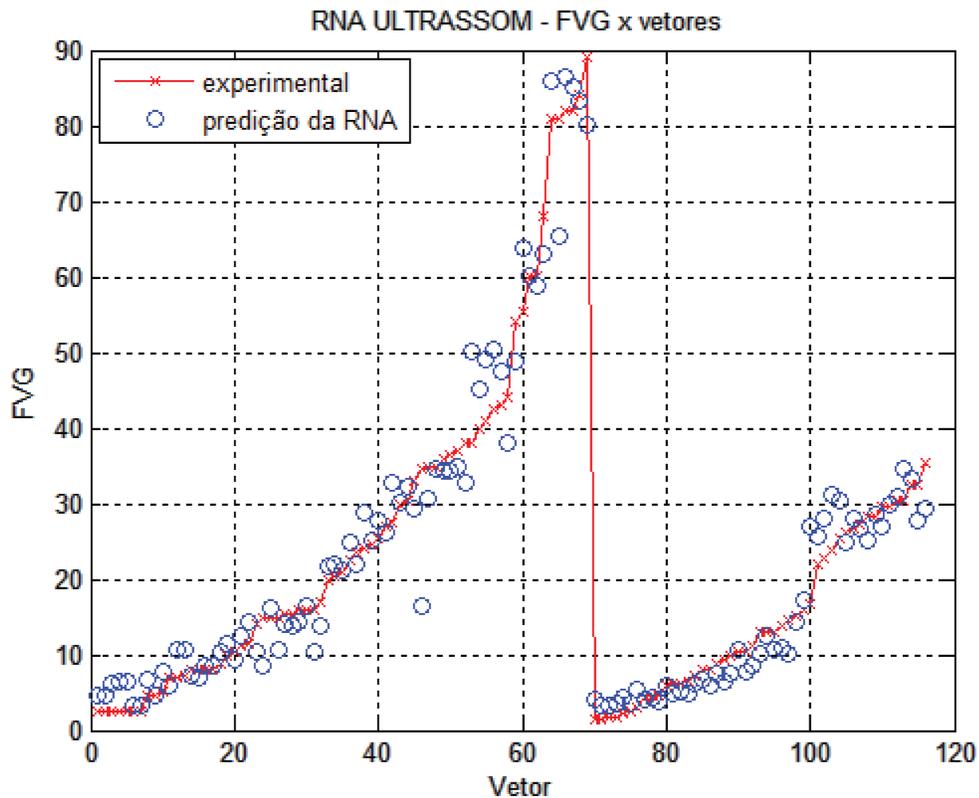


Figura 22. Comparação entre os valores de FVG previstos pela rede, os valores experimentais versus vetores.

A Tabela 17 resume os resultados obtidos. Ela mostra os resultados de SSE e seu correspondente erro médio em termos de IPDE e FVG. O erro médio em termos de FVG continuamente cresce à medida em que o padrão de escoamento progride de bolhas dispersas para anular. Este comportamento é coerente com o fato de que os padrões vão se tornando mais complexos e com maiores variações à medida que evoluem e, portanto, mais difícil a previsão correta. Além disso deve-se levar em conta uma menor disponibilidade de pontos para treinamento nos padrões de FVG mais elevados, havendo muito menos pontos para treinamento do padrão anular do que para o padrão bolhas dispersas (Tabela 16).

Os resultados gerais mostram um acerto de 98,3% para as predições dos padrões de escoamento. Conclui-se que as RNAs puderam prever adequadamente os padrões de escoamento e a FVG mesmo tendo apenas como dados de entrada os valores de razão de energia acústicos.

Tabela 17. Avaliação dos resultados das RNAs usando-se o conjunto de validação

Padrão de escoamento	Predição dos Padrões pela RNA			Predições FVG pela RNA	
	% Correto	SSE	±Erro médio	SSE	±Erro médio
Bolhas Dispersas	100,0	0,013	0,02	179,4	2,0
Intermitente	97,6	0,068	0,04	496,8	3,6
Agitado	100,0	0,029	0,03	944,2	5,7
Anular	83,0	0,015	0,05	377,7	7,9
Resultado total	98,3	0,125	0,03	1998,0	4,2

5.2. RNA NÚMEROS ADIMENSIONAIS

Para a construção do banco de dados da literatura, foram usados 11 estudos, totalizando 1355 vetores de dados (KOUBA, 1986; FELIZOLA, 1992; FRANÇA; LAHEY JR, 1992; MENG, 1999; MANABE, 2001; OMEBERE-IYARI; AZZOPARDI, 2007; GOKCAL *et al.*, 2008; ROSA *et al.*, 2010; BRITO, 2012; GHAJAR; TANG, 2012; GONÇALVES, 2013). Como nem todos os estudos tinham dados disponíveis de FVG e padrões de escoamento, alguns dados utilizados foram dados sintéticos, conforme explicado na Seção 4.3.3. A Tabela 18 mostram quais estudos utilizaram dados sintéticos. As porcentagens de dados sintéticos nos conjuntos de dados de FVG e IPDE são 25,5% e 26,3%, respectivamente.

Tabela 18 Relação de estudos da literatura completados com dados sintéticos

Estudo	Informação sintética
Manabe (2001)	FVG
Omebere-Iyari e Azzopardi (2007)	FVG
Gokcal <i>et al.</i> (2008)	IPDE

Durante as primeiras tentativas de treinamento, percebeu-se que à medida que se aumentavam os neurônios das camadas ocultas, melhorava-se o SSE e o erro médio que a rede fornecia para o conjunto de validação previamente selecionado. Porém, ao expô-la a um banco de dados com estudos nunca vistos pela rede, a resposta em termos de SSE e erro médio pioravam com o aumento de neurônios. Portanto, quanto maior o número de neurônios mais chances de ocorrer sobre-ajuste na rede. Com esta constatação, resolveu-se fazer os testes preliminares para a melhor

combinação de neurônios nas camadas ocultas utilizando o parâmetro SSE e erro médio para um banco de dados não vistos no treinamento. Foram separados dois estudos para essa finalidade: Gonçalves (2013) em tubulação de 2 polegadas e França e Lahey Jr (1992), totalizando 163 vetores de dados. Procurou-se retirar do treinamento o mínimo possível de dados, mas que ao mesmo tempo fossem bem representativos de toda a extensão possível das variáveis de saída FVG e IPDE, ou seja, respectivamente de 0 a 100% e 0,1 a 1,7. Variou-se a primeira camada oculta de 1 a 8 neurônios e a segunda camada oculta de 1 a 3 neurônios. Os resultados para FVG e IPDE estão nas Tabelas 19 e 20.

Tabela 19. Treinamentos para determinação da melhor arquitetura da rede neural com números adimensionais e resposta FVG

Número treinamento	Neurônios camada oculta 1	Neurônios camada oculta 2	R ²	SSE	Erro médio
1	1	1	0,8247	6,98	13%
2	2	1	0,8606	5,79	12%
3	3	1	0,8946	4,57	11%
4	4	1	0,8858	4,71	11%
5	5	1	0,8499	7,21	13%
6	6	1	0,7141	11,55	17%
7	7	1	0,815	8,79	15%
8	8	1	0,7915	8,63	15%
9	1	2	0,8395	6,44	13%
10	2	2	0,8754	5,98	12%
11	3	2	0,8494	6,99	13%
12	4	2	0,8497	6,74	13%
13	5	2	0,8849	4,89	11%
14	6	2	0,8578	5,97	12%
15	7	2	0,895	6,01	12%
16	8	2	0,8884	4,63	11%
17	1	3	0,8488	5,99	12%
18	2	3	0,8709	5,78	12%
19	3	3	0,8689	6,2	12%
20	4	3	0,8931	4,47	10%
21	5	3	0,796	8,18	14%
22	6	3	0,8551	6,42	13%
23	7	3	0,8309	7,2	13%
24	8	3	0,8077	8,51	14%

Tabela 20. Treinamentos para determinação da melhor arquitetura da rede neural com números adimensionais e resposta IPDE

Número treinamento	Neurônios camada oculta 1	Neurônios camada oculta 2	R ²	SSE	Erro médio
1	1	1	0,76	23,80	0,24
2	2	1	0,79	24,10	0,24
3	3	1	0,78	23,30	0,24
4	4	1	0,68	33,10	0,28
5	5	1	0,63	38,40	0,31
6	6	1	0,78	27,70	0,26
7	7	1	0,77	23,83	0,24
8	8	1	0,76	25,60	0,25
9	1	2	0,78	21,83	0,23
10	2	2	0,77	26,07	0,25
11	3	2	0,82	19,13	0,22
12	4	2	0,81	19,87	0,22
13	5	2	0,80	24,87	0,25
14	6	2	0,78	25,21	0,25
15	7	2	0,33	63,57	0,39
16	8	2	0,74	28,11	0,26
17	1	3	0,77	22,79	0,24
18	2	3	0,79	22,57	0,23
19	3	3	0,80	23,54	0,24
20	4	3	0,82	21,76	0,23
21	5	3	0,75	29,10	0,27
22	6	3	0,76	28,27	0,26
23	7	3	0,68	34,25	0,29
24	8	3	0,77	27,04	0,26

Conclui-se que a melhor configuração para as redes neurais com números adimensionais foram: 3 e 1 neurônios nas camadas intermediárias para a RNA FVG e 3 e 2 neurônios para a RNA IPDE. Por fim, ao se realizar a análise de pesos e bias de todas as entradas da rede neural, pôde-se concluir que não seria possível, *a priori*, retirar nenhum grupo adimensional.

Essas configurações foram usadas para treinar as redes neurais com o banco de dados completo com os 11 estudos. As Figuras 23 e 24 comparam os

resultados previstos pelas RNAs (para o grupo de validação, separado com os 25% do banco de dados completo conforme Seção 4.4.2) frente aos valores fornecidos pelos estudos da literatura para o caso FVG. Elas mostram que os valores previstos estão próximos aos valores corretos, pois encontram-se próximos da linha diagonal e a maioria dos pontos dentro do intervalo de \pm erro médio (7%) na Figura 23. A Figura 24 compara os valores alvo com as respostas da RNA ponto a ponto de cada vetor que compõe o banco de dados de validação. Com ela é possível verificar quais pontos dentro do banco de dados estão muito discrepantes do valor de FVG correto. Os pontos discrepantes ocorrem em toda a faixa testada, o que pode significar que a rede foi treinada de maneira mais uniforme. Isto foi possível pela utilização de dados sintéticos.

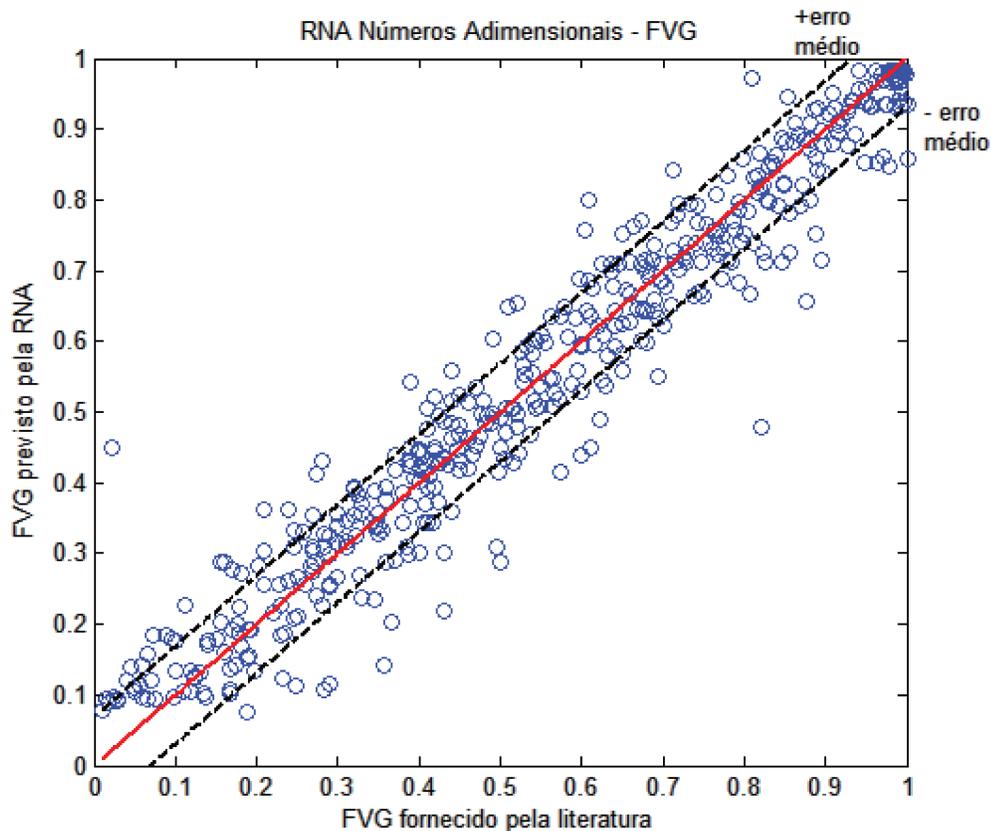


Figura 23. Resultado para o grupo de validação da RNA de previsão de FVG com números adimensionais e erro médio de $\pm 7\%$

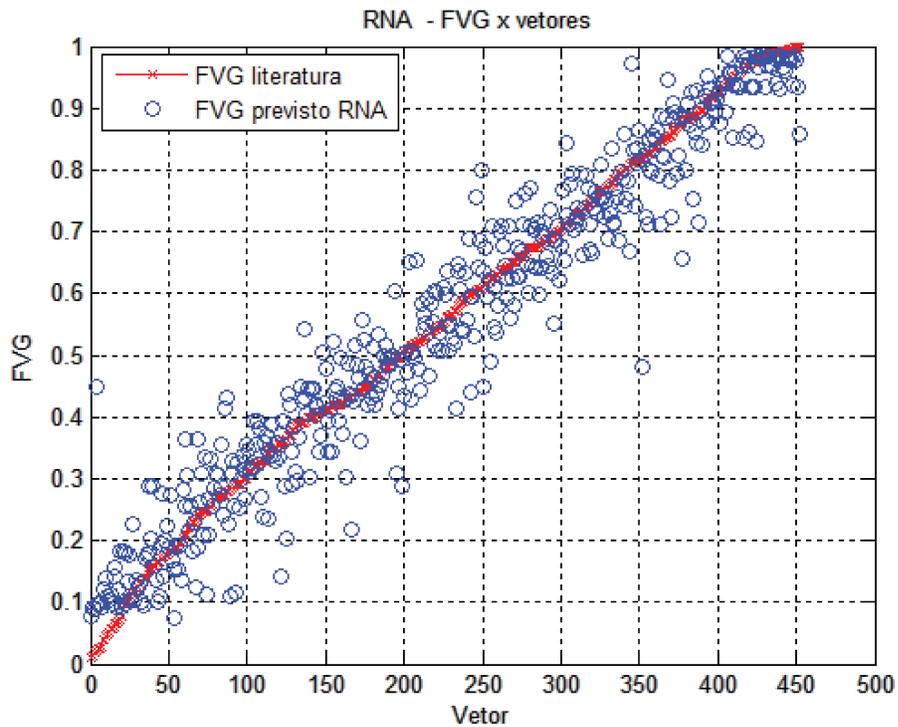


Figura 24. Comparação de resposta da RNA para FVG e da literatura para cada vetor do banco de dados de validação

A Tabela 21 separa os resultados da RNA para cada estudo que compõe o banco de dados. Com ela, pode-se avaliar o desempenho da RNA em cada estudo. Avaliando-se os erros médios, percebe-se que, de modo geral, a rede tem um bom desempenho, nunca ultrapassando os 15%. Considerando todo o banco de dados o erro médio foi de 7%. Destaca-se aqui o excelente desempenho que o sistema neural teve em prever a FVG para o experimento de Manabe (2001), cujo erro médio foi de apenas 3%. Como já mencionado, este estudo é importante por se tratar de escoamento tendo como fase contínua petróleo. Além disso, os experimentos foram conduzidos a pressões mais elevadas (15 e 30 bar). Conclui-se que essa RNA mostra-se promissora para prever FVG em escoamentos da indústria petrolífera, pois apenas seis pontos tiveram um desvio maior que 20%. Dentre eles, dois pontos referem-se a valores de FVG acima de 80% e apenas um ponto tinha originalmente um valor de FVG abaixo dos 10%, em que um desvio de 20% é mais significativo.

Como o banco de dados foi composto por estudos em que o escoamento bifásico tinha como fase contínua diversos fluidos como petróleo, água, óleo mineral, querosene, etc., pode-se concluir também que a rede neural foi universal, conseguindo ter bom desempenho independentemente do tipo de fluido usado. O fato das entradas da RNA serem números adimensionais que relacionavam as forças atuantes no escoamento bifásico (uma abordagem fenomenológica) pode ser uma razão para este comportamento mais universal da rede.

A Tabela 22 mostra o desempenho da RNA em prever a FVG para cada padrão de escoamento. Nessa situação, no geral, a rede teve bom desempenho nas previsões independentemente do padrão de escoamento, pois o erro médio nunca ultrapassou os 9%. O padrão anular horizontal teve o melhor desempenho, com erro médio de apenas 3%. Todavia, ainda são necessários mais dados para se comprovar e corroborar este bom desempenho da rede neural. O padrão pistonado teve o segundo melhor desempenho (6%), possivelmente por ser o padrão com o maior número de pontos, logo a rede esteve mais exposta a esse padrão. Portanto, espera-se que a expansão do banco de dados melhore ainda mais o desempenho do sistema.

Tabela 21 Avaliação do desempenho da RNA dos números adimensionais para previsão de FVG para cada estudo da literatura.

Estudo	Nº pontos	SSE	Erro médio	Nº de pontos desvio >10%	Nº de pontos desvio >20%
Brito, 2012	85	0,76	9%	15	2
Felizola, 1992	4	0,10	15%	2	2
França e Lahey Jr, 1992	25	0,15	8%	4	0
Ghajar e Tang, 2012	43	0,05	4%	0	0
Gokcal et al., 2008	89	0,19	5%	3	0
Gonçalves 2013 1"	22	0,30	12%	8	1
Gonçalves 2013 2"	16	0,10	8%	3	0
Kouba, 1986	14	0,04	5%	1	0
Manabe, 2001	62	0,05	3%	0	0
Meng, 1999	50	0,11	5%	4	0
Omebere-Iyari e Azzopardi, 2007	24	0,16	8%	5	1
Rosa et al., 2010	18	0,15	9%	6	0
Total	452	2,16	7%	51	6

Tabela 22 Avaliação do desempenho da RNA dos números adimensionais para previsão de FVG para cada padrão de escoamento

Padrão de escoamento	IPDE	n° pontos	SSE	Erro médio
Horizontal				
Bolhas Dispersas	0,1	6	0,03	7%
Estratificado	0,3	94	0,52	7%
Estratificado Rugoso	0,5	16	0,07	7%
Pistonado	0,7	185	0,71	6%
Anular	0,9	20	0,02	3%
Vertical				
Bolhas Dispersas	1,1	27	0,14	7%
Intermitente	1,3	53	0,30	8%
Agitado	1,5	18	0,10	8%
Anular	1,7	33	0,27	9%

As Figuras 25 e 26 comparam os resultados previstos pelas RNAs (para o grupo de validação, separado com os 25% do banco de dados completo conforme Seção 4.4.2, totalizando 452 vetores de dados) frente aos valores fornecidos pelos estudos da literatura para o caso IPDE. Elas mostram que, embora tenham pontos que a rede neural não previu corretamente, há claramente uma tendência. Além disso, a determinação do padrão de escoamento tem um fator subjetivo e uma imprecisão em casos de transição de padrão, portanto esses fatores podem ter influenciado nos erros de previsão da rede neural. Por fim, a Figura 26 compara os valores alvo com as respostas da RNA ponto a ponto de cada vetor que compõe o banco de dados de validação. Com ela é possível verificar quais pontos dentro do banco de dados estão muito discrepantes do valor de IPDE correto. Percebe-se que, apesar de uma maior dispersão nos resultados (Figura 25), olhando vetor a vetor nota-se uma grande tendência de previsões corretas, com alguns pontos discrepantes. Percebe-se também que o padrão pistonado (IPDE 0,7) teve grande quantidade de acertos, enquanto que os padrões verticais dispersam mais, o que é mais um indício de que é possível melhorar o desempenho da rede neural com o aumento de dados para treinamento.

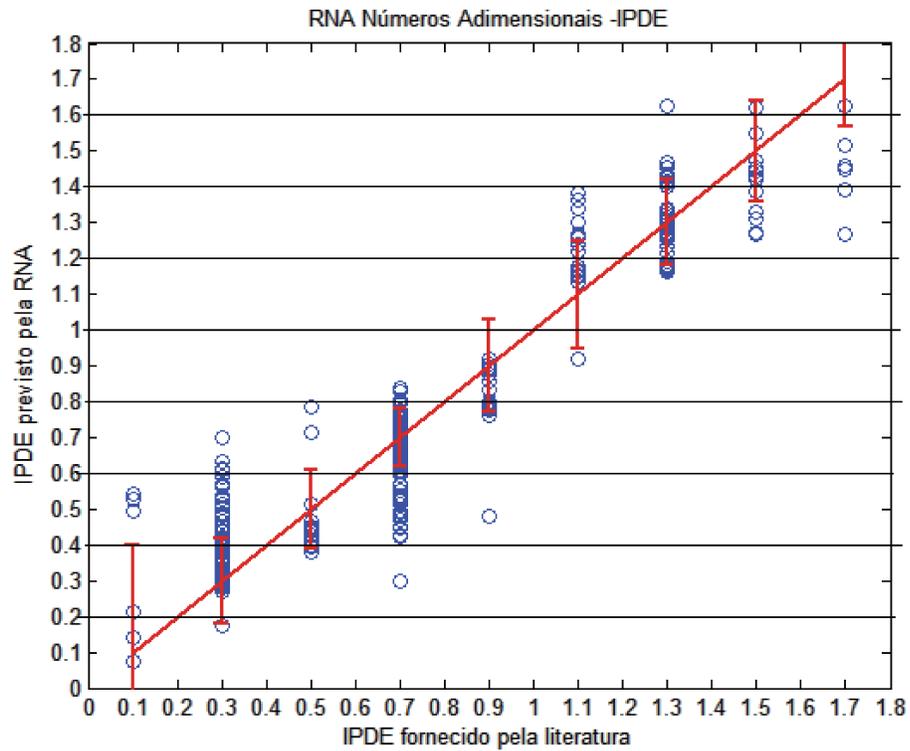


Figura 25 Resultado para o grupo de validação da RNA de previsão de IPDE com números adimensionais

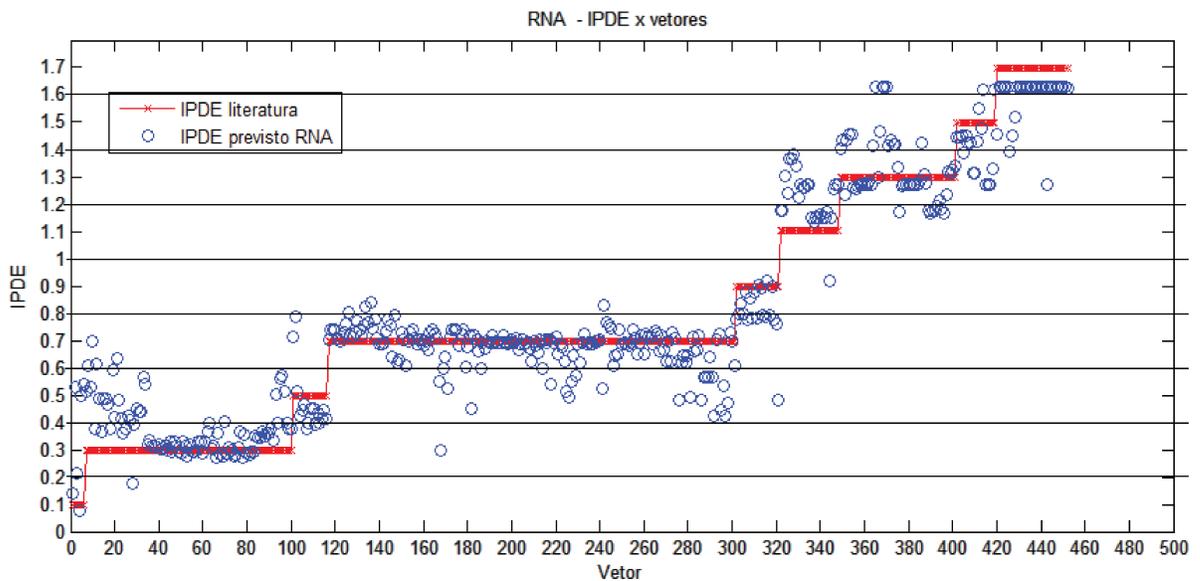


Figura 26 Comparação de resposta da RNA para IPDE e da literatura para cada vetor do banco de dados de validação

A Tabela 23 separa os resultados da RNA para cada estudo que compõe o banco de dados. Nela há a quantidade de dados de cada estudo, a porcentagem de acertos, o SSE e o erro médio. Com ela, pode-se avaliar o desempenho da RNA em cada estudo. Avaliando-se a porcentagem de acertos, percebe-se que, de modo geral, a rede tem um bom desempenho (71% de acertos no geral), porém há estudos com desempenho bem melhor do que outros. Considerando todo o banco de dados o erro médio foi de 0,12. Como cada padrão de escoamento fica em um intervalo de $\pm 0,1$ em termos de IPDE, 0,12 ultrapassa esse limite, porém ainda aceitável.

A Tabela 24 mostra o desempenho da RNA em prever o IPDE para cada padrão de escoamento. Nela, fica claro quais padrões foram previstos com maior precisão pela rede. O pior desempenho foi para bolhas dispersas em escoamentos horizontais. Porém, trata-se também do padrão com o menor número de pontos para treinamento e validação. Possivelmente, a medida em que o sistema neural for sendo treinado com mais dados nesse padrão de escoamento, será possível verificar uma melhora na previsão. O padrão pistonado teve uma boa taxa de acerto (84,3%), também refletindo o fato de ser o padrão de escoamento com o maior número de pontos no banco de dados.

Tabela 23 Avaliação do desempenho da RNA dos números adimensionais para previsão de IPDE para cada estudo da literatura.

Estudo	n° pontos	%acertos	SSE	Erro médio
Brito, 2012	85	68%	1,71	0,14
Felizola, 1992	4	100%	0,01	0,05
França e Lahey Jr, 1992	25	96%	0,06	0,05
Ghajar e Tang, 2012	43	72%	0,55	0,11
Gokcal et al., 2008	89	64%	1,56	0,13
Gonçalves 2013 1"	22	36%	0,48	0,15
Gonçalves 2013 2"	16	56%	0,14	0,09
Kouba, 1986	14	93%	0,03	0,05
Manabe, 2001	62	68%	0,84	0,12
Meng, 1999	50	98%	0,05	0,03
Omebere-Iyari e Azzopardi, 2007	24	63%	0,41	0,13
Rosa et al., 2010	18	50%	0,34	0,14
Total	452	71%	6,17	0,12

Tabela 24 Avaliação do desempenho da RNA dos números adimensionais para previsão de IPDE para cada padrão de escoamento

Padrão de escoamento	IPDE	n° pontos	% Acertos	SSE	Erro médio
Bolhas Dispersas	0,1	6	33,3%	0,547	0,30
Estratificado	0,3	94	71,3%	1,440	0,12
Estratificado Rugoso	0,5	16	62,5%	0,211	0,11
Pistonado	0,7	185	84,3%	1,291	0,08
Anular	0,9	20	40,0%	0,335	0,13
Bolhas Dispersas	1,1	27	40,7%	0,641	0,15
Intermitente	1,3	53	54,7%	0,797	0,12
Churn	1,5	18	50,0%	0,330	0,14
Anular	1,7	33	84,8%	0,582	0,13

A partir dessas informações, é possível fazer hipóteses sobre os piores desempenhos da rede neural. Deve-se destacar que há um desempenho sensivelmente melhor para os padrões horizontais, principalmente devido aos padrões estratificado e pistonado por terem a maior quantidade de pontos experimentais. O critério utilizado para destacar os estudos com piores desempenhos foi aqueles com desempenhos menores que 70% de acerto.

Brito (2012) teve 27 pontos incorretos, dos quais 14 foram do padrão pistonado (IPDE 0,7). Entretanto, a maior parte dos dados desse estudo eram desse padrão, logo a porcentagem de erro foi de apenas 23%. Para os demais padrões, os erros aumentaram inversamente ao número de dados disponíveis. Conclui-se, nesse estudo, que as maiores quantidades de erros proporcionalmente falando, encontram-se nos padrões com menor número de dados, enquanto que o melhor desempenho foi o padrão pistonado, que teve uma grande quantidade de dados disponíveis para treinamento.

O trabalho de Gokcal *et al.* (2008) é o único caso em que o IPDE foi obtido através de simulação; logo, esse caso deve ser visto com ressalvas. No entanto, as simulações estão sendo aperfeiçoadas e uma nova avaliação deverá ser feita. Além disso, considera-se que 64% de acerto é um resultado promissor.

O estudo em uma polegada conduzido em Gonçalves (2013) teve erros em todos os padrões verticais. Havia menos pontos para treinamento nos padrões verticais, portanto o banco de dados ainda não é grande o suficiente para uma boa generalização. Além disso, a evolução dos padrões em tubulação de uma polegada é mais difícil de ser avaliada visualmente. Como foi usado um método visual para determinar o padrão de escoamento, é possível que haja erros e imprecisões intrínsecas, o que pode explicar um mau desempenho. Já para o caso da tubulação de duas polegadas, todos os erros se referem ao padrão intermitente (IPDE 1,3), que foram previstos como bolhas dispersas (IPDE 1,1). A explicação mais provável é a má generalização da rede neural nos casos de escoamento vertical. O mesmo vale para o estudo de Omebere-Iyari e Azzopardi (2007) que também se refere a escoamentos verticais.

Em Manabe (2001), metade dos erros se referem ao padrão anular horizontal (IPDE 0,9). Como houve poucos pontos para treinamento neste padrão, um banco de dados maior provavelmente melhorará o desempenho da RNA.

Finalmente, em Rosa *et al.* (2010), cinco dos nove pontos previstos errados são de padrão agitado (IPDE 1,5) previstos como intermitente (IPDE 1,3). Contudo, a separação do padrão agitado do padrão intermitente foi apenas feita por conveniência, tratando-se efetivamente do mesmo padrão.

5.3. Protótipo Ultrassônico

Após desenvolvidas as redes neurais, tanto com números adimensionais como com o uso da razão de energia ultrassônica, o experimento realizado com o protótipo ultrassônico conforme descrito na Seção 4.2.2 foi avaliado.

5.3.1. Ultrassom

As Figuras 27 a 30, a seguir, comparam as tendências da razão de energia de cada sensor para as fases contínuas óleo mineral e as diversas amostras de petróleo. É possível verificar uma mudança de comportamento devido à viscosidade dos fluidos, mais nitidamente com o óleo mineral, que tem um comportamento muito

diferente em todos os sensores exceto o de 0° . Para o sensor de 0° , apesar do comportamento do óleo mineral ser numericamente parecido com as outras amostras, percebe-se claramente entre as amostras de petróleo uma mudança gradativa de comportamento à medida que se aumenta a viscosidade. No sensor de 45° , todas as amostras de petróleo tiveram comportamento similar descendente, por outro lado o óleo mineral teve um comportamento ascendente. O mesmo acontece para o comportamento do óleo mineral para o sensor de 135° . Para as amostras de petróleo neste sensor, há uma mudança gradual conforme a sua viscosidade, no entanto o comportamento é totalmente diferente do óleo mineral, pois inicialmente é ascendente com um ponto de máximo e descendente a seguir. Por fim, no sensor de 180° todos os fluidos têm comportamento descendente, porém enquanto as amostras de petróleo tem um comportamento exponencial descendente, o óleo mineral tem valores de razão de energia mais altos para as mesmas FVG e com um decaimento mais suave. Por essas constatações, a rede neural treinada apenas com dados do óleo mineral (fluido menos viscoso) não poderia fornecer bons resultados para o petróleo. Devido a estes fatos, não se testou a RNA com os dados obtidos com o experimento com o protótipo. Portanto, apenas os dados ultrassônicos se mostram insuficientes para uma universalização da rede neural, pois é necessário abarcar a influência viscosa do fluido da fase contínua. Uma possível solução deve ser a associação entre as redes neurais ultrassônica e dos grupos adimensionais. Também é necessário obter mais dados ultrassônicos com fluidos viscosos para treinamento da rede.

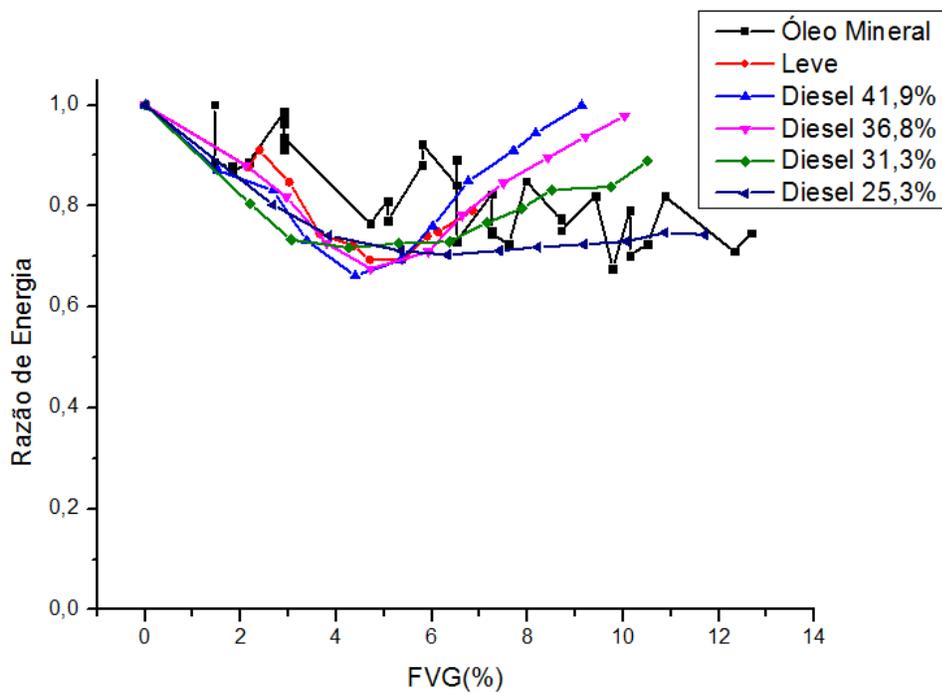


Figura 27 Tendências no sensor 0°

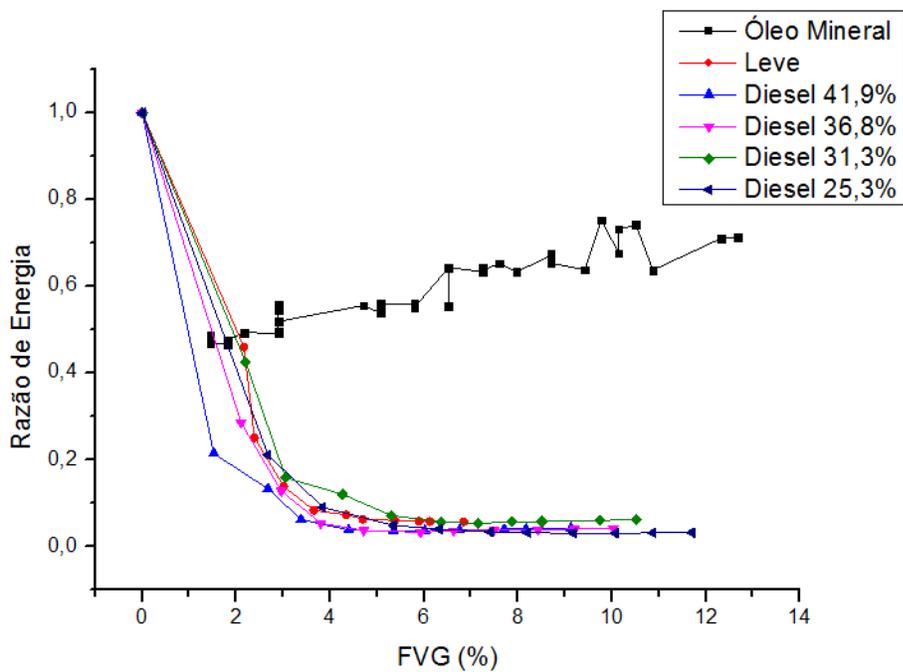


Figura 28 Tendências no sensor de 45°

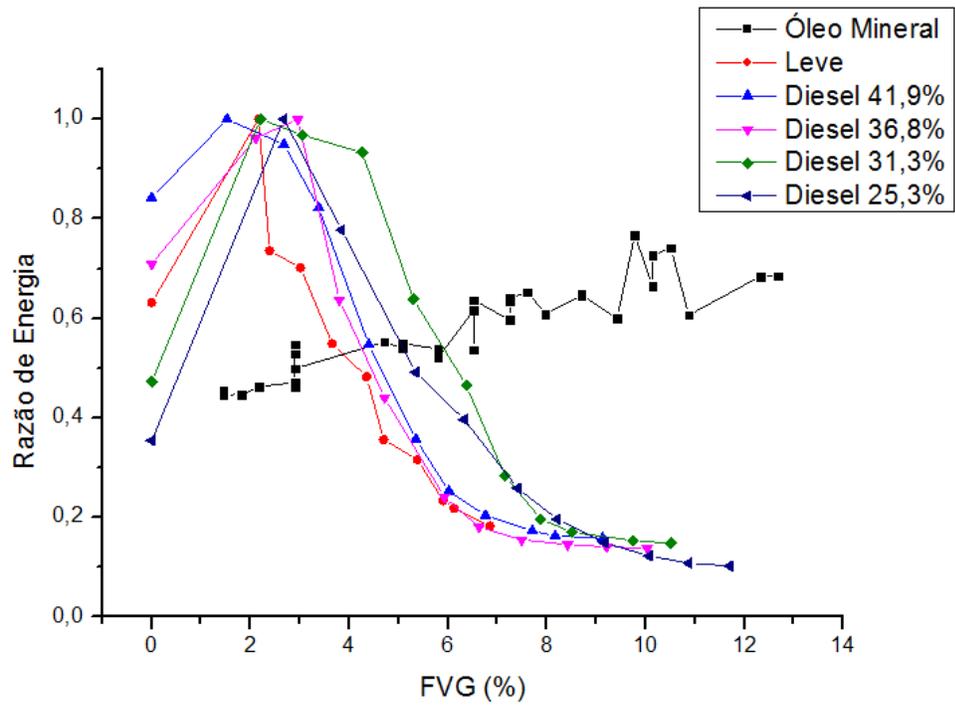


Figura 29 Tendências no sensor de 135°

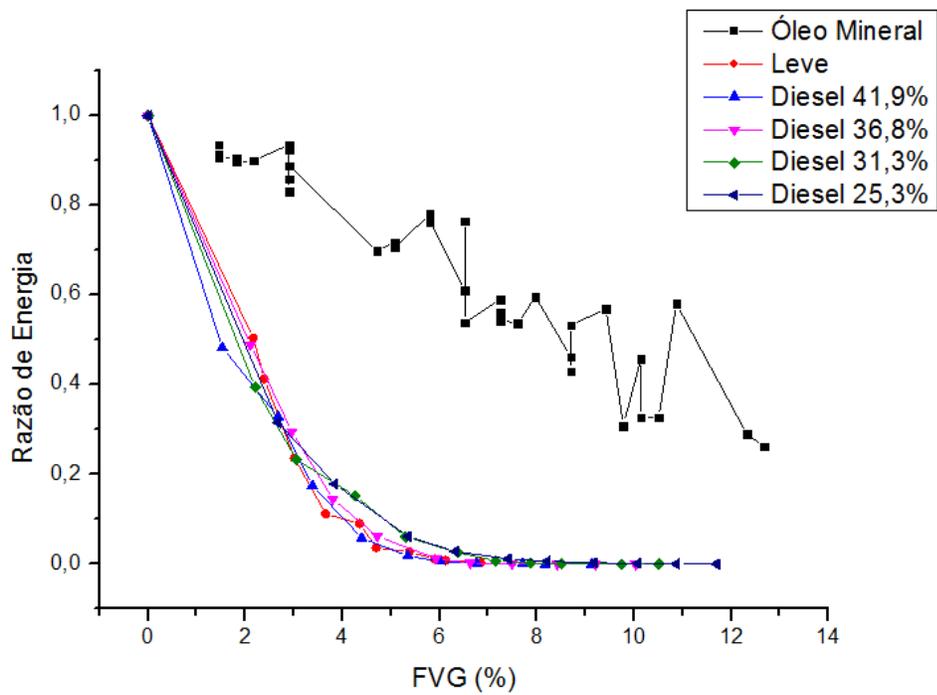


Figura 30 Tendências no sensor de 180°

Devem-se ressaltar também as dificuldades enfrentadas durante o experimento e a leitura das frações de vazio. As amostras de petróleo foram de difícil manipulação devido à alta viscosidade dos fluidos. Isto, primeiramente, dificultou a diluição das amostras em diesel. Além disso, houve uma dificuldade de leitura do inchamento da coluna, pois sua altura oscilava. Quanto maior a vazão de gás, portanto maior FVG, maior era a oscilação, o que acarretava em maior erro de leitura. A Tabela 25 mostra o desvio padrão da FVG (calculado com as alturas máximas e mínimas da coluna de líquido) de cada medida conforme o aumento em FVG.

Tabela 25 Desvio padrão da leitura da FVG para cada amostra de petróleo.

FVG	σ_{FVG} Leve	σ_{FVG} Diesel 41,9%	σ_{FVG} Diesel 36,8%	σ_{FVG} Diesel 31,3%	σ_{FVG} Diesel 25,3%
0%	0,00%	0,00%	0,00%	0,00%	0,00%
2%	0,14%	0,21%	0,34%	0,20%	-
2%	0,13%	-	-	-	0,33%
3%	-	0,33%	0,33%	0,33%	-
3%	0,13%	0,26%	-	-	-
4%	0,26%	0,26%	0,33%	0,32%	0,33%
4%	0,32%	-	-	-	-
5%	0,39%	0,19%	0,32%	0,38%	0,32%
5%	0,76%	-	-	-	-
6%	0,63%	0,25%	0,38%	0,37%	0,31%
6%	0,69%	-	-	-	-
7%	0,43%	0,31%	0,37%	0,37%	0,30%
7%	-	-	0,36%	-	-
8%	-	0,30%	0,36%	0,42%	0,30%
8%	-	0,24%	-	-	-
9%	-	0,41%	0,29%	0,36%	0,35%
10%	-	-	0,29%	0,46%	0,34%
11%	-	-	-	0,40%	0,34%
12%	-	-	-	-	0,28%

Por fim, as medidas da FVG pelo inchamento da coluna de líquido são medidas volumétricas, isto é, uma média em todo o volume de líquido na tubulação. Por outro lado, as medidas com o ultrassom são uma aproximação da medida em uma dada

seção transversal. Se as variações de FVG de uma seção a outra forem grandes, o que é o mais provável quando se trata de fluidos viscosos, poderia ser imprecisa a comparação direta entre as medidas de fração de vazio obtidas pela média em todo o volume da coluna de líquido e as FVGs obtidas pelas medições ultrassônicas.

Para melhores resultados seria necessário fazer medidas ultrassônicas em várias posições na coluna para se fazer uma média. Esta média seria então comparada com o resultado do inchamento da coluna. Todavia, isto seria um procedimento experimental inviável do ponto de vista prático neste experimento simplificado.

5.3.2. Números Adimensionais

Calcularam-se os números adimensionais para os experimentos com o protótipo. Foram cinco grupos de experimentos conforme Tabela 9.

A vazão de líquido no experimento era zero, ou seja, encontrava-se em repouso. Conseqüentemente, alguns grupos adimensionais tornaram-se zero (Re_i , We_i , λ_i). Como em nenhum experimento do banco de dados da literatura havia essa situação, todos os experimentos com o protótipo se caracterizaram como extrapolações das faixas de treinamento da rede neural. Portanto, não foi possível testar a rede neural dos grupos adimensionais com os dados deste experimento com o protótipo.

5.4. Combinação das RNAs dos grupos adimensionais e o ultrassônico

Ao combinar duas redes neurais com entradas bem distintas (razão de energia e grupos adimensionais) espera-se que a resposta obtida contenha as informações dos grupos adimensionais (abordagem fenomenológica) e razão de energia ultrassônica (abordagem empírica por uma técnica não intrusiva de medição). Assim, espera-se obter um sistema que seja flexível, abrangente e cujos resultados estejam próximos da realidade.

A combinação das duas redes neurais é feita através de uma média ponderada feita com as saídas fornecidas por cada uma delas. A determinação do peso a ser aplicado à média ponderada entre as duas abordagens levou em conta o desempenho que cada RNA teve individualmente. As discussões dos itens 5.1, 5.2 e

5.3 levam a crer que a rede neural ultrassônica é mais precisa e confiável, dando respostas plausíveis, embora inexatas, mesmo para um banco de dados não visto no treinamento. Estabeleceu-se que o peso variaria de 0 a 1 para a composição da média ponderada entre as redes neurais. Assim, após várias tentativas, resumidas nas Tabelas 26 e 27, estabeleceu-se que a melhor combinação de pesos seria de 0,1 para a RNA dos grupos adimensionais e 0,9 para a RNA ultrassônica. Estes pesos serão revistos à medida que mais dados ultrassônicos e da literatura se tornem disponíveis. Esta primeira tentativa teve o objetivo principalmente de estabelecer e testar um método para combinação dos dois tipos de rede neurais. Portanto, com esta primeira combinação de pesos espera-se uma resposta com ênfase nas medições ultrassônicas, porém contendo algumas informações fenomenológicas.

Os testes de escolha de pesos desse sistema para fração de vazão e padrão de escoamento se referem ao conjunto composto pelo experimento de Gonçalves (2013) (descrito na Seção 4.2.1), pois é o único que possui dados ultrassônicos para as duas variáveis de saída.

Tabela 26 Teste de pesos para previsão de FVG

Peso RNA Adimensional	Peso RNA ultrassom	SSE	Erro médio (%)
0,5	0,5	6044,2	6,3
0,4	0,6	4486,2	5,4
0,3	0,7	3329,8	4,7
0,2	0,8	2575,0	4,1
0,1	0,9	2221,9	3,8

Tabela 27 Teste de pesos para previsão de IPDE

Peso RNA Adimensional	Peso RNA ultrassom	SSE	Erro médio
0,5	0,5	0,614	0,064
0,4	0,6	0,410	0,052
0,3	0,7	0,255	0,041
0,2	0,8	0,150	0,032
0,1	0,9	0,096	0,025

As Figuras 31 e 32 mostram o resultado para FVG na melhor combinação de pesos. Mesmo tendo a RNA dos grupos adimensionais um erro médio maior do que a rede neural ultrassônica, através da Tabela 28 é possível notar uma ligeira melhora de resultado em termo de erro médio para o sistema combinado. Isto é um indício de que a combinação das redes pode realmente melhorar o sistema. Espera-se que a expansão do banco de dados e, conseqüentemente, a melhora da performance da RNA dos grupos adimensionais, será possível aumentar o peso relativo dessa rede e melhorar o resultado do sistema combinado. Portanto, resultados mais conclusivos só serão possíveis quando mais dados estiverem disponíveis.

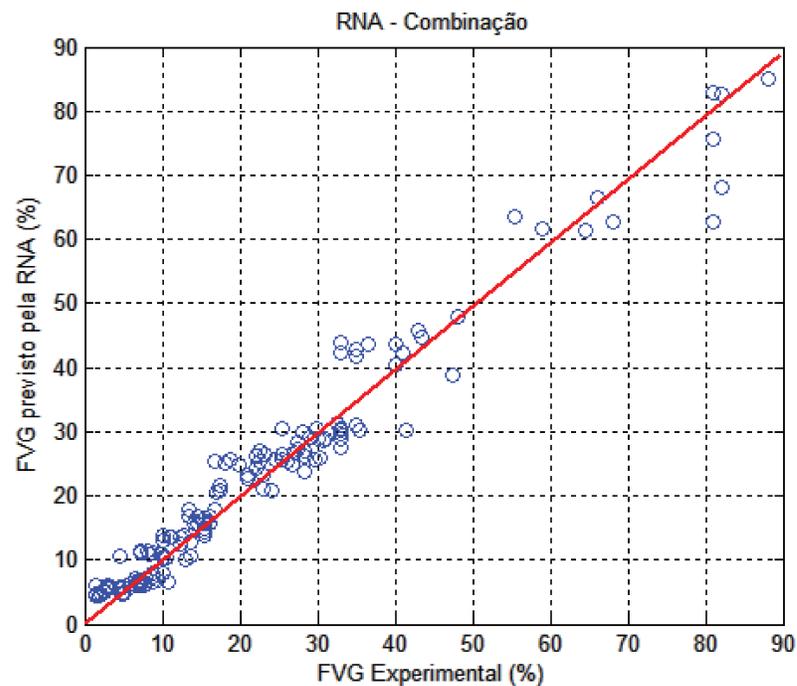


Figura 31 Resultado para o sistema neural combinado para previsão de FVG

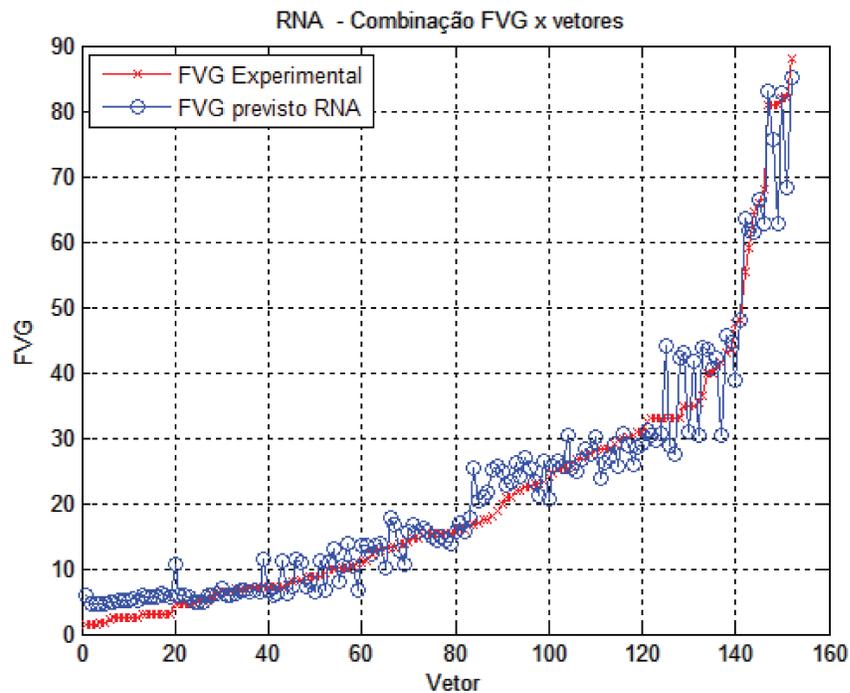


Figura 32 Comparação de resposta para FVG experimental e do sistema neural combinado para cada vetor do banco de dados

As Figuras 33 e 34 mostram o resultado para IPDE. Mesmo tendo a RNA dos grupos adimensionais um erro médio maior do que a rede neural ultrassônica, através da Tabela 28 é possível notar que ficou inalterado o resultado em termo de erro médio para o sistema combinado, se comparado com o melhor resultado, que foi o da rede neural ultrassônica. O baixo peso usado na RNA dos grupos adimensionais explica esse resultado. Novamente, resultados mais conclusivos só serão possíveis quando mais dados estiverem disponíveis.

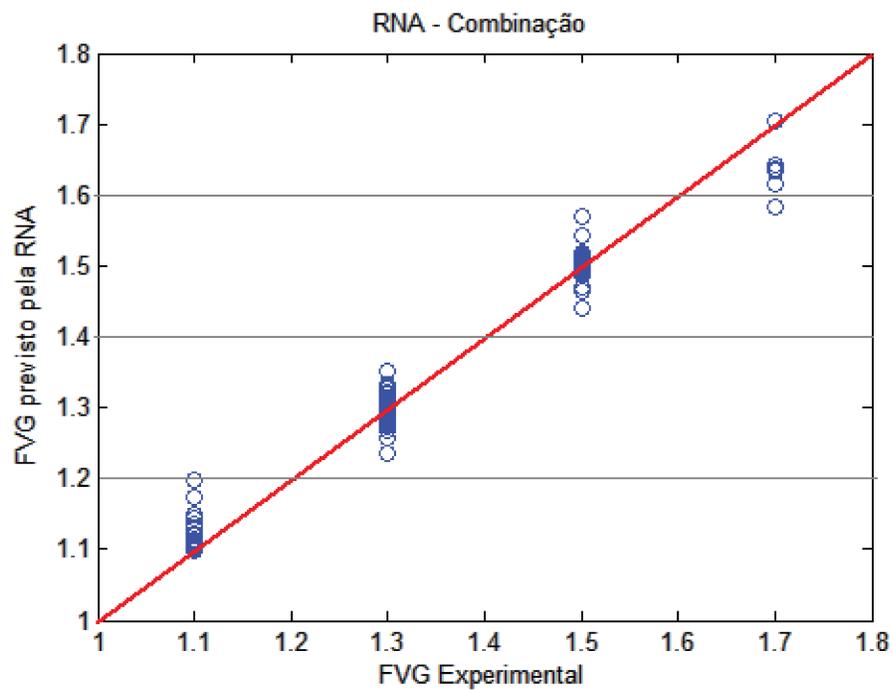


Figura 33 Resultado para o sistema neural combinado para previsão de IPDE

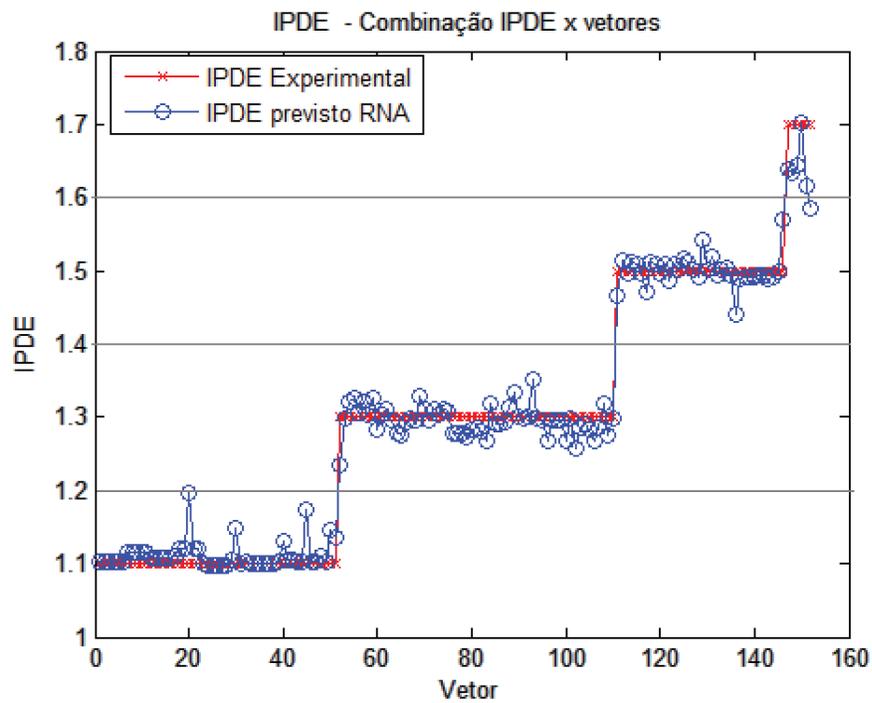


Figura 34 Comparação de resposta para IPDE experimental e do sistema neural combinado para cada vetor do banco de dados

Tabela 28 Comparação do erros médios calculados das previsões das redes neurais dos grupos adimensionais, ultrassônica e sistema combinado para os sistemas que preveem FVG e IPDE

	Erro médio grupos adimensionais	Erro médio ultrassom	Erro médio combinação
FVG	11,4%	3,9%	3,8%
IPDE	0,125	0,025	0,025

6. CONCLUSÃO

Espera-se com este trabalho ter contribuído para o desenvolvimento de uma técnica de medição multifásica de aplicação prática na indústria de petróleo e gás natural utilizando medidas ultrassônicas e redes neurais. O uso de redes neurais mostra-se promissor para tal, pois é versátil e fornece respostas rápidas para problemas com alta complexidade e não lineares. Além disso, esta técnica tem a característica de se aperfeiçoar cada vez mais à medida que novos dados são adicionados para treinamento e aprendizado, o que pode ser um desdobramento natural deste trabalho à medida que novas unidades do medidor multifásico forem implantadas em aplicações diversas.

Para o desenvolvimento da RNA ultrassônica, dados de atenuação acústica para escoamentos multifásicos verticais, usando óleo mineral como fase contínua, foram apresentados e analisados. Os modelos neurais desenvolvidos forneceram excelentes resultados, identificando satisfatoriamente os padrões de escoamento e FVG para todos os tipos de escoamentos multifásicos testados com óleo mineral. A rede neural desenvolvida conseguiu um acerto de 98,3% na predição do padrão de escoamento, enquanto o modelo desenvolvido para previsão de FVG obteve um erro médio de 4,2%, ou seja, em média as previsões variaram dentro de uma média de $\pm 4,2\%$ do valor experimental, muito aceitável para aplicações práticas.

Para o desenvolvimento da rede neural com os números adimensionais, foi criado um banco de dados que conta atualmente com 1807 vetores, com 11 estudos em condições variadas, o que é essencial para um bom aprendizado e generalização do modelo neural proposto. Ao analisar os resultados gerados com o grupo de validação, percebeu-se que para FVG o modelo apresentou boa generalização, pois no total o erro médio foi de 7%. Já para a rede neural de previsão do IPDE, o desempenho foi menor (71% de acerto) se comparado com a rede neural ultrassônica. Ainda assim é um bom resultado, pois espera-se um desempenho melhor da técnica ultrassônica, cujos resultados estão diretamente ligados à configuração do escoamento e à distribuição das fases no meio medido. Também deve-se levar em conta o fato de os diferentes estudos usarem diferentes classificações para os padrões de escoamento, portanto a padronização para os padrões usados neste estudo pode ter certa

imprecisão. Ainda assim, os resultados seguiram, no geral, uma tendência dentro dos valores corretos, conseguindo distinguir eficazmente os vários padrões verticais e horizontais.

Comparando-se o desempenho de cada padrão de escoamento, o pior foi para bolhas dispersas em escoamentos horizontais. Porém, trata-se também do padrão com o menor número de pontos para treinamento e validação. O padrão pistonado, por sua vez, teve uma boa taxa de acerto (84,3%), refletindo o fato de ser o padrão de escoamento com o maior número de pontos no banco de dados. Conclui-se, portanto, que mesmo a RNA tendo fornecido bons resultados, há a expectativa de seus resultados serem ainda melhores à medida em que mais dados forem sendo fornecidos à rede neural.

Os dados ultrassônicos obtidos experimentalmente com o protótipo foram analisados. As redes neurais desenvolvidas não foram testadas com os dados do protótipo devido aos seguintes fatores:

1. A viscosidade do petróleo é muito maior que a do óleo mineral usado para treinar a RNA ultrassônica. Foi demonstrado que o comportamento detectado pelos sensores ultrassônicos é muito diferente entre os experimentos com óleo mineral e aqueles com petróleo. Portanto, a forte dissipação viscosa na fase contínua pode alterar o comportamento dos sinais ultrassônicos e é a razão principal para as diferenças de comportamento;
2. A própria medição experimental pode ter sido imprecisa, pois o petróleo é um fluido de difícil manuseio e a medição da FVG através da expansão da coluna de líquido era prejudicada pelas grandes oscilações na coluna de fluido. Além disso, a FVG local de uma seção a outra do tubo pode ser diferente da FVG média medida através da expansão da coluna de fluido (o que é mais provável de ocorrer em altas viscosidades). Como o protótipo é capaz de medir apenas a FVG da seção transversal onde está localizado, é possível que esta medição em uma única seção transversal não seja representativa da FVG medida experimentalmente pelo inchamento da coluna.

Também não se testou a RNA com os grupos adimensionais para os dados experimentais com o protótipo. Era previsível que a RNA não iria prever resultados

confiáveis, pois a velocidade superficial da fase líquida era zero, portanto zerando alguns grupos adimensionais. Como em nenhum estudo do banco de dados havia a condição de fase líquida parada, tratou-se de uma extrapolação do modelo. Portanto, preferiu-se esperar que mais dados nessas condições estejam disponíveis, de modo a realizar um novo treinamento e, assim, avaliar o desempenho da RNA para os dados do protótipo.

Em seguida, testou-se o desempenho da combinação das duas redes neurais desenvolvidas (grupos adimensionais e razão de energia) em um sistema neural. Usou-se um peso de 0,1 para a RNA grupos adimensionais e 0,9 para a RNA ultrassônica. Portanto, enfatizou-se a tecnologia ultrassônica, pois ela demonstrou ter um desempenho melhor do que o modelo neural com grupos adimensionais. Este sistema mostrou uma ligeira melhora em termos de erro médio comparado ao modelo neural ultrassônico isoladamente. Isto é um indício de que a combinação pode melhorar o sistema, pois combina um modelo fenomenológico com a tecnologia ultrassônica. Além disso, ela é mais robusta para aplicações práticas da indústria do petróleo, pois caso alguma informação esteja em falta (seja algum dado para os grupos adimensionais, sejam dados ultrassônicos), é possível extrair uma resposta confiável de apenas uma das redes neurais em paralelo.

A partir dos resultados deste trabalho, pode-se sugerir como próximos passos:

- Obtenção de mais dados ultrassônicos, com o protótipo desenvolvido, em escoamentos multifásicos tendo petróleo como fase contínua em uma condição experimental mais próxima das condições reais da indústria e com um método mais confiável de medição de FVG. Testar o desempenho da RNA desenvolvida neste trabalho e, posteriormente, treiná-la novamente com esses novos dados;
- Testar o desempenho da rede neural dos números adimensionais com os dados dos experimentos com o protótipo em uma condição mais próxima do que é observado na indústria. Reavaliar o desempenho da RNA;

- Comparar a predição de IPDE obtida pelo sistema neural desenvolvido com escoamentos reais da indústria do petróleo, em que se conheça o padrão de escoamento. Alimentar, então, o sistema com esses novos dados;
- Expandir o banco de dados da literatura para mais condições, incluindo-se dados para baixos valores das velocidades superficiais da fase líquida;
- Extensão deste trabalho incluindo outras geometrias além da tubular. Por exemplo, uma seção transversal anular que compõe a entrada de bombas centrífugas submersas;
- Estudo sistemático da mudança no comportamento dos vários sensores ultrassônicos em função de variações nas viscosidades da fase líquida.

Por fim, espera-se que a tecnologia de medição da atenuação acústica na forma de razão de energia, aliada à rede neural artificial continue se desenvolvendo, pois os resultados se mostraram promissores para um equipamento de aplicação prática na indústria do petróleo.

7.REFERÊNCIAS

ÅBRO, E. et al. Determination of void fraction and flow regime using a neural network trained on simulated data based on gamma-ray densitometry. **Meas. Sci. Technol.**, v. 10, p. 619-630, 1999.

ACKLEY, D. H.; HINTON, G. E.; SEJNOWSKI, T. J. A Learning Algorithm for Boltzmann Machines. **Cognitive Science**, v. 9, p. 147-169, 1985.

ARMIN, G. Continues crude oil characterization by radio frequency resonator. **Oldenburg Wisseenschaftsverlag GmbH**, v. 71, n. 9/2004, p. 486-491, 2004.

ARORA, R. **Production Well Testing Using Non-radioactive Multiphase Flow Meters**. Exploration & Production Touch Oil and Gas. 7: 86-89 p. 2009.

BHAT, N.; MCAVOY, T. J. Use of Neural Nets for Dynamic Modeling and Control of Chemical Process Systems. . **Comput. Chem. Eng**, v. 14, n. n. 4-5, p. 573-583, 1990.

BISHOP, C. M.; JAMES, G. D. Analysis of multiphase flows using dual-energy gamma densitometry and neural networks. **Nuclear Instruments and Methods in Physics Research**, v. A327, p. 580-593, 1993.

BO, O. L.; NYFORS, E. Application of microwave spectroscopy for the detection of water fraction and water salinity in water/oil/gas pipe flow. **Journal of Non-Crystalline Solids**, v. 305, p. 345-353, 2002.

BRITO, R. M. **Effect of medium oil viscosity on two-phase oil-gas flow behavior in horizontal pipes**. 2012. 311 (Master of Science). University of Tulsa

CAREY, V. P. **Liquid-Vapor Phase-Change Phenomena**. Taylor & Francis, 1992. ISBN 1-56032-074-5.

CARVALHO, R. D. M. D. et al. Application of the ultrasonic technique and high-speed filming for the study of the structure of air–water bubbly flows. **Experimental Thermal and Fluid Science**, v. 33, p. 1065-1086, 2009.

CARVALHO, R. D. M. D.; BANNWART, A. C. **The Use of the Ultrasonic Technique for the Study and Online Monitoring of Multiphase Flows**. Advances in Multiphase Flow and Heat Transfer. CHENG, L. e MEWES, D.: Bentham Science Publishers. 4: 144-177 p. 2010.

CORNELIUSSEN, S. et al. **Handbook Multiphase Flow Metering**. Norwegian Society for Oil and Gas Measurement (NFOGM) and The Norwegian Society o Chartered Technical and Scientific Professionals (Tekna), 2005. ISBN 82-91341-89-3.

DUKLER, A. E.; WICKS, M.; CLEVELAND, R. G. Frictional Pressure Drop in Two-Phase Flow: B. An Approach through Similarity Analysis. **AIChE Journal**, v. 10, n. 1, p. 44-51, 1964.

DUNS, H. J.; ROS, N. C. J. Vertical Flow of Gas and Liquid Mixtures in Wells. World Petroleum Congress, 1963, Frankfurt, Germany. p.451-465 (Paper 22-PD6).

DYKESTEEN, E. et al. Non-intrusive three-component ratio measurement using an impedance sensor. **J. Phys. E: Sci. Instrum.**, v. 18, p. 540-544, 1985.

FALCONE, G.; HEWITT, G. F.; ALIMONTI, C. **Multiphase Flow Metering, Principles and Applications**. First Elsevier, 2010. ISBN 978-0-444-52991-6.

FELIZOLA, H. **Slug Flow in Extended Reach Directional Wells**. 1992. (Master of Science). Department of Petroleum Engineering, University of Tulsa

FRANÇA, F.; LAHEY JR, R. T. The use of drift-flux techniques for the analysis of horizontal two-phase flows. **Int. J. Multiphase Flow**, v. 18, n. 6, p. 787-801, 1992.

FRANCA, F. A. et al. Mechanistic Modeling of the Convective Heat Transfer Coefficient in Gas-Liquid Intermittent Flows. **Heat Transfer Engineering**, v. 29 n. 12, p. 984–998, 2008.

GHAJAR, A. J.; TANG, C. C. Void Fraction and Flow Patterns of Two-Phase Flow in Upward and Downward Vertical and Horizontal Pipes. **Advances in Multiphase Flow and Heat Transfer**, v. 4, p. 175-201, 2012.

GODBOLE, P. V.; TANG, C. C.; GHAJAR, A. J. Comparison of Void Fraction Correlations for Different Flow Patterns in Upward Vertical Two-Phase Flow. **Heat Transfer Engineering**, v. 32, n. 10, p. 843-860, 2011.

GOKCAL, B. et al. **Effects of High Oil Viscosity on Oil/Gas Flow Behavior in Horizontal Pipes**. Annual Technical Conference and Exhibition San Antonio, Texas: 1-11 p. 2008.

GONÇALVES, J. L. **Desenvolvimento de um a técnica ultrassônica para medição da concentração das fases dispersas em escoamentos multifásicos representativos da indústria de petróleo e gás natural**. . 2013. 161p. (Doutorado em Conversão de Energia). Instituto de Engenharia Mecânica, Universidade Federal de Itajubá, Itajubá.

GRANGEIRO, F. A. **Caracterização do Escoamento Intermitente Horizontal Água-Ar através de Ultrassom Auxiliado por Filmagem Ultrarrápida**. 2010. (Mestre em Ciências e Engenharia de Petróleo). Faculdade de Engenharia Mecânica, UNICAMP, Campinas.

GRESKOVICH, E. J.; SHRIER, A. L. Slug Frequency in Horizontal Gas-Liquid Slug Flow. **Industrial Engineering Chemistry Process Design and Development**, v. 11, n. 2, p. 317-318, 1972.

GUZHOV, A. L.; MAMAYEV, V. A.; ODISHARIYA, G. E. **A Study of Transportation in Gas-Liquid Systems**. 10th International Gas Union Conference. Hamburg, Germany 1967.

HAGAN, M. T.; MENHAJ, M. Training feedforward networks with the Marquardt algorithm. **IEEE Trans. Neural Networks**, v. 5, p. 989–993, 1994.

HARTLEY, P. E. et al. Trial of a gamma-ray multiphase flow meter on the West Kingfish oil platform. **Nuclear Geophysics**, v. 9, n. 6, p. 533-552, 1995.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2. Porto Alegre: Bookman, 2001.

HETSRONI, G. **Handbook of Multiphase Systems**. Washington, D.C. ; New York, NY Hemisphere : McGraw-Hill, 1982.

HIRSCHEN, K.; SCHÄFER, M. Bayesian regularization neural networks for optimizing fluid flow processes. **Comput. Methods Appl. Mech. Engrg.**, v. 195, p. 481-500, 2006.

INOUE, E. H. et al. **DEVELOPMENT OF A NEURAL NETWORK FOR THE IDENTIFICATION OF MULTIPHASE FLOW PATTERNS**. Intelligent Systems and Control: 305-312 p. 2013.

JAWORSKI, A. J.; DYAKOWSKI, T. Measurements of oil-water separation dynamics in primary separation systems using distributed capacitance sensors. **Flow Measurement and Instrumentation**, v. 16, p. 113-127, 2005.

JONES, S. W.; AMBLARD, A.; FAVREAU, C. Interaction of an ultrasonic wave with a bubbly mixture. **Experiments in Fluids**, v. 4, p. 341–349, 1986.

KINSLER, L. E. et al. **Fundamentals of Acoustics**. Fourth Edition. John Wiley & Sons, 2000. ISBN 978-81-265-2199-9.

KOUBA, G. **Horizontal Slug Flow Modeling and Metering**. 1986. 152 (Doctor of Philosophy). Department of Petroleum Engineering University of Tulsa

LAMPINEN, J.; VEHTARI, A. Bayesian approach for neural networks: a review and case studies. **Networks**, v. 14, p. 257-274, 2001.

MALAYERI, M. R.; MÜLLER-STEINHAGEN, H.; SMITH, J. M. Neural network analysis of void fraction in air/water two-phase flows at elevated temperatures. **Chemical Engineering and Processing**, v. 42, p. 587-597, 2003.

MANABE, R. **A Comprehensive Mechanistic Heat Transfer Model for Two-Phase Flow with High-Pressure Flow Pattern Validation**. 2001. (Ph.D. in Petroleum Engineering). Department of Petroleum Engineering, The University of Tulsa

MANABE, R. et al. **Crude Oil - Natural Gas Two-Phase Flow Pattern Transition Boundaries at High Pressure Conditions**. SPE Annual Technical Conference and Exhibition. New Orleans: SPE 2001.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.

MENG, W. **Low Liquid Loading Gas-Liquid Two-Phase Flow in Near Horizontal Pipes**. 1999. 170 (Doctor of Philosophy). University of Tulsa

MERIBOUT, M. et al. A Multisensor Intelligent Device for Real-Time Multiphase Flow Metering in Oil Fields. **IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT**, v. 59, n. 6, p. 1507-1519, 2010.

MI, Y.; TSOUKALAS, L. H.; ISHII, M. Application of multiple self-organizing neural networks: flow pattern classification. **Trans. Am. Nucl. Soc.**, v. 77, p. 114-116, 1997.

MI, Y.; ISHII, M.; TSOUKALAS, L. H. Vertical Two-Phase Flow Identification Using Advanced Instrumentation and Neural Networks. **Nuclear Engineering and Design**, v. 184, p. 409-420, 1998.

MI, Y.; ISHII, M.; TSOUKALAS, L. H. Flow regime identification methodology with neural networks and two-phase flow models. **Nuclear Engineering and Design**, v. 204, p. 87-100, 2001.

MINSKY, M. L.; PAPERT, S. A. **Perceptrons**. Cambridge, MA: MIT Press, 1969.

OMEBERE-IYARI, N. K.; AZZOPARDI, B. J. Two-Phase Flow Patterns in Large Diameter Vertical Pipes at High Pressures. **AIChE J**, v. 53, p. 2493-2504, 2007.

POWELL, R. L. Experimental Techniques for Multiphase Flows. **Physics of Fluids**, v. 20, p. 1-20, 2008.

ROACH, G. J. et al. Field trial of gamma-ray multiphase flow meter on Thevenard Island. **Nuclear Geophysics**, v. 9, n. 1, p. 1-17, 1995.

ROSA, E. S. et al. Performance Comparison of Artificial Neural Networks and Expert Systems Applied to Flow Pattern Identification in Vertical Ascendant Gas-Liquid Flows. **International Journal of Multiphase Flow**, 2010.

ROSENBLATT, F. The Perceptron: A probabilistic model for information storage and organization in the brain. **The Perceptron: A probabilistic model for information storage and organization in the brain**, v. 65, p. 386-408, 1958.

ROSHANI, G. H. et al. Precise volume fraction prediction in oil–water–gas multiphase flows by means of gamma-ray attenuation and artificial neural networks using one detector. **Measurement**, v. 51, p. 34-41, 2014.

RUMELHART, D. E.; MCCLELLAND, J. L. **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**. Cambridge: MA: MIT Press, 1986.

SALGADO, C. M. **Identificação de regimes de fluxo e predição de fração de volume em sistemas multifásicos usando técnica nuclear e rede neural artificial** 2010. 162 (Doutorado). COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro.

SHAIKH, A.; ALDAHAN, M. Development of an artificial neural network correlation for prediction of overall gas holdup in bubble column reactors. **Chemical Engineering and Processing**, v. 42, n. 8-9, p. 599-610, 2003. ISSN 02552701.

SHOHAN, O. **Mechanistic Modeling of Gas-Liquid Two-Phase Flow in Pipes**. Society of Petroleum Engineers, 2006. 396 ISBN 155563107X.

STRANEO, H. P. **Models for Time Series Prediction Based on Neural Networks. Case Study: GLP Sales Prediction from ANCAP**. 2013. (Magíster en Ingeniería Matemática). Instituto de Investigación: LPE/IMERL- Facultad de Ingeniería, Universidad de la República

TAITEL, Y.; DUKLER, A. E. A Model for Predicting Flow Regime Transitions in Horizontal and Near Horizontal Gas-liquid Flow. **AIChE Journal**, v. 22, n. 1, p. 47-55, 1976.

TANAHASHI, E. I. **Desenvolvimento da Técnica de Ultrassom para Medição da Fração de Vazio e Detecção do Padrão de Escoamentos Água-Ar**. 2010. (Dissertação de Mestrado). Instituto de Engenharia Mecânica, Universidade Federal de Itajubá (UNIFEI), Itajubá, MG.

TANAHASHI, E. I. et al. Application of the Ultrasonic Technique for Monitoring Intermittent Liquid-Gas Flows and Liquid-Solid Flows. In: SMITH, S. P., 7th North American Conference on Multiphase Technology (MPNA 2010), 2010, Banff, Canada. BHR Group. p.125-139.

THOMAS, J. E., Ed. **Fundamentos de Engenharia de Petróleo**. Rio de Janeiro: Editora Interciênciaed. 2004.

TSOUKALAS, L. H.; ISHII, M.; MI, Y. A Neurofuzzy Methodology for Impedance-based Multiphase Flow Identification. **Engng Applic. Artif. Intell.**, v. 10, n. 6, p. 545-555, 1997.

VATANAKUL, M.; ZHENG, Y.; COUTURIER, M. Application of ultrasonic technique in multiphase flow. **Industrial and Engineering Chemistry Research**, v. 43, p. 5681-5691, 2004.

WHITE, F. M. **Fluid Mechanics**. 7. New York: Mcgraw-Hill, 2011.

ZHENG, Y.; ZHANG, Q. Simultaneous measurement of gas and solid holdups in multiphase systems using ultrasonic technique **Chemical Engineering Science**, v. 59, p. 3505-3514, 2004.

ANEXO A

Programa MATLAB® para treinamento da RNA ultrassônica.

```
%PROGRAMA PARA SEPARAR 25% E 75% DE UMA MATRIZ EM DUAS MATRIZES TRAIN (25%)
%TEST(75%) ASSUMINDO QUE CADA LINHA É UM CONJUNTO DE DADOS E ASSUMINDO QUE OS
DADOS FORAM COLOCADOS EM ORDEM CRESCENTE.
clc
clear all
close all

%Separa o banco de dados para os escoamentos de 1 pol
D=xlsread('TESTE.xlsm','TESTE1POL');
S=size(D);
passo = round(S(1) / (round(0.25 * S(1))));
n = 1;
m = 1;
linha = 1;
while linha <= S(1)
    if linha == (2 + (passo) * (n - 1))
        TEST(n, :) = D(linha, :);
        n = n + 1;
    else
        TRAIN(m, :) = D(linha, :);
        m = m + 1;
    end
    linha = linha + 1;
end
clear passo n m linha
M1=TRAIN;
N1=TEST;
clear TRAIN TEST S

% %Separa o banco de dados para os escoamentos de 2 pol
D=xlsread('TESTE.xlsm','TESTE2POL');
S=size(D);
passo = round(S(1) / (round(0.25 * S(1))));
n = 1;
m = 1;
linha = 1;
while linha <= S(1)
    if linha == (2 + (passo) * (n - 1))
        TEST(n, :) = D(linha, :);
        n = n + 1;
    else
        TRAIN(m, :) = D(linha, :);
        m = m + 1;
    end
    linha = linha + 1;
end
clear passo n m linha
M2=TRAIN;
N2=TEST;
clear TRAIN TEST S
```

```

%comando que salva o conjunto de dados de 1 pol e 2 pol usados para o teste de
validação.
save('conj_test1pol','N1')
save('conj_test2pol','N2')
save('conj_train1pol','M1')
save('conj_train2pol','M2')

%Programa que inicia o treinamento e validação da rede neural.
m1=size(M1);
n1=size(N1);
m2=size(M2);
n2=size(N2);
erro(1)=1e9;

entrada = M1(:,1:m1(2)-1);
entrada(m1(1)+1:m1(1)+m2(1),:)=M2(:,1:m2(2)-1);

entradateste=N1(:,1:n1(2)-1);
entradateste(n1(1)+1:n1(1)+n2(1),:)=N2(:,1:n2(2)-1);

saida = M1(:,m1(2));
saida(m1(1)+1:m1(1)+m2(1),:)=M2(:,m2(2));

saidateste= N1(:,n1(2));
saidateste(n1(1)+1:n1(1)+n2(1),:)=N2(:,n2(2));

entrada = entrada';
saida = saida';
entradateste = entradateste';
saidateste = saidateste';
N1=N1';
N2=N2';

net=newff(minmax(entrada),[5,2,1],{'logsig','logsig','purelin'},'trainbr');
net.trainParam.showWindow=false;
net.trainParam.epochs=1000;
net.trainParam.show=50;
net.trainParam.goal=1e-0;
net.initFcn='initlay';
net.performFcn='sse';
net.trainParam.min_grad=1e-100;
net.trainParam.mu_max=1e+100;
c=1;

% looping que faz Tentativas de treino e guarda os pesos e bias com o menor
% sse.
for a=1:1:100
net=init(net);
[net,tr]=train(net,entrada,saida);
Y=sim(net,entradateste);%simula com os dados de entrada do arquivo de
teste normalizado
e_nor = saidateste-Y;
sse_teste = sse(e_nor);
if sse_teste<min(erro)
save le2pol_FVGrna_ultrassom_TOTAL_v6 net;

```

```

        et(c)=sse_teste;
        c=c+1;
        min(et)
    end
    erro(a+1)= vpa(sse_teste,4);
    a
end
clear a c

%Comandos que permitem ao usuário escolher os pesos e bias salvos para a
%simulação e teste de validação.
[fileName,filePath] = uigetfile('*', 'Select data file', '.');
if filePath==0, error('None selected!'); end
load( fullfile(filePath,fileName) );

Y=sim(net,entradateste);
errol=Y-saidateste;
sse=sse(errol)
q=numel(saidateste);
erromedio=(sse^0.5)/q

figure(1);
plot(Y,saidateste,'o')
xlabel('saida rede neural')
ylabel('Target')
title('RNA - IPDE ULTRASSOM TOTAL de 1" e 2"')
grid on

figure(2);
[mbr]=postreg(Y,saidateste);

```

Programa MATLAB® para treinamento da RNA dos grupos adimensionais.

```
clc
clear all
close all

D=xlsread('TEST.xlsx','TESTE');
S=size(D);
simull=xlsread('TEST.xlsx','simulacao');
save('FVG_conj_simul_literatura_8','simull')

%PROGRAMA PARA SEPARAR 25% E 75% DE UMA MATRIZ EM DUAS MATRIZES TRAIN (25%)
%TEST(75%) ASSUMINDO QUE CADA LINHA É UM CONJUNTO DE DADOS E ASSUMINDO QUE OS
DADOS FORAM COLOCADOS EM ORDEM CRESCENTE
passo = round(S(1) / (round(0.25 * S(1))));
n = 1;
m = 1;
linha = 1;
while linha <= S(1)
    if linha == (2 + (passo) * (n - 1))
        TEST(n, :) = D(linha, :);
        n = n + 1;
    else
        TRAIN(m, :) = D(linha, :);
        m = m + 1;
    end
    linha = linha + 1;
end
clear passo n m linha
M1=TRAIN;
N1=TEST;
save('FVG_conj_test_literatura_8','N1')

m1=size(M1);
n1=size(N1);
erro(1)=1e9;
inputTRAIN = M1(:,2:m1(2));
targetTRAIN = M1(:,1);
inputTRAIN=inputTRAIN';
targetTRAIN=targetTRAIN';

[INPUTn,INs] = mapminmax(inputTRAIN); %Coloca os inputs numa escala entre
[-1,1]
[TARGETn,Ts] = mapminmax(targetTRAIN);%Coloca os targets numa escala entre
[-1,1]

inputTEST= N1(:,2:n1(2));
targetTEST=N1(:,1);
inputTEST=inputTEST';
targetTEST=targetTEST';
inTESTn=mapminmax('apply',inputTEST,INs);
tTESTn=mapminmax('apply',targetTEST,Ts);

net=newff(minmax(INPUTn),[3,1,1],{'logsig','logsig','purelin'},'trainbr');
net.trainParam.showWindow=false;
net.trainParam.epochs=1000;
```

```

net.trainParam.show=50;
net.trainParam.goal=1e-1;
net.initFcn='initlay';
net.performFcn='sse';
net.trainParam.min_grad=1e-100;
net.trainParam.mu_max=1e+100;
c=1;

% looping que faz Tentativas de treino e guarda os pesos e bias com o menor
% sse.
for a=1:1:100
net=init(net);
[net,tr]=train(net,INPUTn,TARGETn);
Y=sim(net,inTESTn); %simula com os dados de entrada do arquivo de teste
normalizado
e_nor = tTESTn-Y;
sse_teste_nor = sse(e_nor);
if sse_teste_nor<min(erro)
save FVG_rna_NumAdim_Lit_v8 net INs Ts;
et(c)=sse_teste_nor;
c=c+1;

min(et)
end
erro(a+1)= vpa(sse_teste_nor,4);
a
end
clear a c

[fileName,filePath] = uigetfile('*', 'Select data file', '.');
if filePath==0, error('None selected!'); end
load( fullfile(filePath,fileName) );

Y=sim(net,inTESTn);
X=mapminmax('reverse',Y,Ts); %desnormaliza dados de saída
errol=targetTEST-X;
sse=sse(errol);

figure(1);
plot(X,targetTEST,'o')
xlabel('saida rede neural')
ylabel('Target')
title('RNA Números Adimensionais')
grid on

figure(2);
[mbr]=postreg(X,targetTEST);

```