



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
TRABALHO DE DIPLOMAÇÃO EM ENGENHARIA QUÍMICA



Desenvolvimento de Medidor de Vazão para escoamento Multifásico Água-Ar

Autor: Eduardo Pacheco e Silva

Orientador: Marcelo Farenzena

Porto Alegre, maio de 2021

Autor: Eduardo Pacheco e Silva

Desenvolvimento de Medidor de Vazão para Escoamento Multifásico Água-Ar

*Trabalho de Conclusão de Curso apresentado à
COMGRAD/ENQ da Universidade Federal do Rio
Grande do Sul como parte dos requisitos para a
obtenção do título de Bacharel em Engenharia
Química*

Orientador: Marcelo Farenzena

Banca Examinadora:

Prof. Dr., Jorge Otávio Trierweiler, DEQUI-UFRGS

MSc., Vinícius da Costa Avila, DEQUI-UFRGS

Porto Alegre,

2021

AGRADECIMENTOS

Primeiramente, eu gostaria de agradecer a minha família. Meus irmãos Igor e Fernanda pela companhia e inserção de felicidade na minha vida de diversas maneiras. Ao meu pai Fernando, pelos ensinamentos e ajuda incondicional. E especialmente para minha mãe Tatiana por toda dedicação, amor e exemplos ao longo da vida que me possibilitaram chegar até aqui.

À minha namorada Rafaela, por todo amor, paciência, suporte e incentivo dado não só para conclusão deste trabalho, mas também em todos os momentos que estamos juntos.

A todos os meus amigos pelos momentos memoráveis vividos ao longo dessa jornada na graduação. Aos meus amigos da UFRGS Nicholas, Braga, Angelo, Luis, Daniel, Andressa e Heloisa, com os quais passei a maior parte dessa caminhada vivenciando os mais diversos e maravilhosos momentos como um escorregão em uma festa ou um quase assalto de um picolé.

A meu orientador, Marcelo Farenzena, por toda dedicação, esclarecimentos, e esforços realizados para me ajudar neste trabalho e também pela paixão e entusiasmo cativante que apresenta em relação aos assuntos que aborda.

Por fim, mas não menos importante, a todos professores e funcionários da UFRGS que possibilitam o funcionamento dessa universidade maravilhosa que tanto produz e, ainda assim recebe tão pouco reconhecimento por suas atividades.

Vocês são incríveis, muito obrigado!

RESUMO

Escoamentos multifásicos ocorrem em diversos setores da indústria, e a capacidade de medir corretamente as vazões das fases neles presentes são cruciais para uma boa operação. Contudo, devido à complexidade das interações presentes nesses escoamentos não há a possibilidade de utilizar medidores de vazão convencionais para resolução dessa necessidade. Em vista disso, utilizam-se medidores de vazões multifásicos (MPFM) os quais empregam diversos sensores em sua estrutura, a fim de medir as variáveis necessárias para estimação das vazões ou inferi-las através de um reconhecimento de padrões das leituras. No entanto, os atuais MPFMs não são capazes de medir as vazões das fases com acuracidade para todo o espectro de composição da mistura. Além disso, a utilização de instrumentos baseados em princípios nucleares eleva o custo e a periculosidade desses medidores. No presente trabalho realizou-se o desenvolvimento de dois MPFMs (MPFM-1 e MPFM-2) para o escoamento multifásico ar e água em tubulação horizontal. O MPFM-1 refere-se as vazões das fases apenas para o escoamento estratificado e o MPFM-2 refere-se aos escoamentos estratificado, *plug* e golfada.. Os dados utilizados para desenvolvimento dos medidores foram obtidos através de experimentos utilizando um tubo de venturi com sensor de pressão diferencial, sensores de vibração, um acelerômetro e giroscópio, um sensor de condução e um sensor de vazão e um Arduino Nano como microcontrolador. Para o desenvolvimento dos MPFMs seguiu-se a mesma metodologia proposta por Kadlec et al. (2009) utilizada para construção de analisadores virtuais. Os dados adquiridos foram então inspecionados, a fim de verificar leituras congeladas ou com erros óbvios e processados, para remoção de leituras discrepantes. A seleção de variáveis foi feita através do método *Backward Elimination*. Os dados foram divididos em conjuntos de treinamento e validação e utilizados nos modelos de Regressão Linear Multivariável e Redes Neurais *Feedforward* (FANN). Empregou-se como métrica de validação para os modelos utilizados o coeficiente de correlação, sendo as FANNs o modelo selecionado para ambos os MPFMs. Os erros absolutos médios obtidos para vazão de ar e água foram, respectivamente, 0,27 e 0,02 L/min para o MPFM-1 e 0,42 e 0,02 L/min para o MPFM-2.

Palavras-chave: *Escoamento bifásico, Água e Ar, Fusão de dados, Medidores de vazão multifásico.*

ABSTRACT

Multiphase flows occur in several sectors of the industry, and the ability to correctly measure flow rate of the phases in it is crucial for a good operation. However, due to the complexity of the interactions present in these flows, there is no possibility of using conventional flow meters, thus, multiphase flow meters (MPFM) are used. These meters employ several sensors in their structure, in order to measure the necessary variables to determine the flow rates or infer them through a pattern recognition. However, the current MPFMs are not able to accurately measure the flow rates of the phases for the entire spectrum of the mix composition. In addition, the use of instruments based on nuclear principles increases the cost and hazard of these meters. In the present work, two MPFMs (MPFM-1 and MPFM-2) were developed for the multiphase flow of air and water in horizontal pipes. MPFM-1 refers to stratified flow only and MPFM-2 refers to stratified, plug and slug flow. The data used for the development of the meters were obtained through experiments using a Venturi tube with differential pressure sensor, vibration sensors, an accelerometer and gyroscope, a conduction sensor and a flow sensor and an Arduino Nano as a microcontroller. For the development of MPFMs, the same methodology proposed by Kadlec et al. (2009) used for the construction of soft sensors was implemented. The acquired data were inspected, in order to check for frozen readings or with obvious errors. Processed to remove outliers. The variables selection was done through the Backward Elimination method. The data were divided into training and validation sets. Finally, they were used in the models of Multivariable Linear Regression and Feedforward Neural Networks (FANN). The correlation coefficient was used as the validation metric for the models used, with FANNs being the model selected for both MPFMs. The mean absolute errors obtained for air and water flow were, respectively, 0.27 and 0.02 L / min for MPFM-1 and 0.42 and 0.02 L / min for MPFM-2.

Keywords: *Two-phase flow, Water and Air, Data fusion, Multiphase flow meters*

LISTA DE FIGURAS

Figura 2.1: Efeito do arraste sobre a fração de fase.	5
Figura 2.2: Padrões de escoamento para uma tubulação vertical.....	6
Figura 2.3: Padrões de escoamento para uma tubulação horizontal.	7
Figura 2.4: Mapa de escoamento para uma tubulação vertical.....	8
Figura 2.5: Mapa de escoamento para uma tubulação horizontal.	8
Figura 2.6: Padrões de escoamento para tubulações com inclinação 90° (horizontal), 91° (inclinada no sentido horário) e 89° (inclinada no sentido anti-horário).....	9
Figura 2.7: Padrões de escoamento para água e petróleo em uma tubulação vertical definidos pela velocidade superficial das fases.....	10
Figura 2.8: Padrões de escoamento para água e petróleo em uma tubulação horizontal definidos pela velocidade superficial das fases.....	10
Figura 2.9: Ilustrações de escoamentos trifásicos (água, petróleo e ar) em tubulação vertical.	11
Figura 2.10: Fluxograma das instalações de plataformas de petróleo que utilizam caracterização convencional para o poço.	14
Figura 2.11: Representação do funcionamento de um neurônio.	16
Figura 3.1: Representação conceitual da estrutura do sistema de experimentação.	17
Figura 3.2: Desenho detalhado do sistema de experimentação.....	18
Figura 3.3: Calibração realizada para sensores FT – 01 e FT – 02. Pontos pretos: medições realizadas; Linha vermelha: reta de ajuste linear aos pontos; Região em vermelho: região de 95% de confiança.....	19
Figura 3.4: Materiais utilizados para construção do sistema de experimentação.	20
Figura 3.5: Sistema experimental montado e operando.	20
Figura 3.6: Mapa de escoamentos para tubulação horizontal de 8mm de diâmetro interno (eixos em L/min) com pontos experimentais efetuados. Pontos verdes: experimentos realizados; Pontos laranjas: experimentos reclassificados como padrão golfada; Linhas azuis com círculos: fronteiras entre padrões de escoamento.	21
Figura 4.1: Percentual de <i>outliers</i> referente a todas leituras realizadas pelos sensores segundo metodologia MAD.....	25
Figura 4.2: Coeficientes de correlação em função do número de neurônios na camada oculta das Redes Neurais do MPFM-1 para variáveis de saída: vazão de ar e água.....	27
Figura 4.3: Coeficientes de correlação em função do número de neurônios na camada oculta das Redes Neurais do MPFM-2 para variáveis de saída: vazão de ar e água.....	28
Figura A.1: Etapas básicas para construção de um analisador virtual.	35

LISTA DE TABELAS

Tabela 3.1: Lista de variáveis criadas.....	23
Tabela 4.1: Variáveis selecionadas através do método <i>Backward Elimination</i>	25
Tabela 4.2: Coeficientes de correlação para modelo MLR.....	26
Tabela 4.3: Coeficientes de correlação para modelo MLR.....	27
Tabela 4.4: Comparação entre modelos matemáticos empregados.	28
Tabela B.1: Descrição dos equipamentos utilizados com <i>hyperlinks</i> para páginas de venda.	38

LISTA DE ABREVIATURAS E SIGLAS

ANN – Rede Neural Artificial

FANN – Rede Neural Artificial *Feedforward*

MAD – Desvio Absoluto da Mediana

MLR – Regressão Linear Multivariável

MPFM – Medidor de Vazão Multifásico

LISTA DE SÍMBOLOS

α_i – Fração de fase.

A_i – Área da secção transversal da tubulação ocupada por uma fase.

A_T – Área da secção transversal da tubulação.

F_{AR} – Vazão volumétrica de ar.

F_{H_2O} – Vazão volumétrica de água.

G_i – Fluxo mássico de uma fase.

G – Fluxo mássico de uma mistura.

J_i – Fluxo volumétrico de uma fase.

J – Fluxo volumétrico da mistura.

Q_i – Vazão volumétrica de uma fase.

R – Coeficiente de correlação/determinação.

x_i – Fração volumétrica de uma fase.

SUMÁRIO

1	Introdução	1
1.1	Objetivos	1
1.1.1	Objetivo Geral	1
1.1.2	Objetivos Específicos	2
1.2	Divisão do Trabalho	2
2	Revisão Bibliográfica	2
2.1	Conceitos Básicos de Escoamento Multifásico	2
2.2	Padrões de Escoamento	3
2.2.1	Parâmetros de Escoamento	4
2.2.2	Mapas de Escoamento	5
2.2.3	Gás-Líquido	5
2.2.4	Líquido-Líquido	9
2.2.5	Gás-Líquido-Líquido	11
2.3	Sensores Multifásicos	11
2.3.1	Categorias de MPFMs	12
2.3.2	Princípio de Medição dos Instrumentos Utilizados em MPFMs	12
2.4	Possíveis Utilizações para MPFMs	13
2.5	Técnicas de Modelagem e Construção de Analisadores Virtuais	14
2.6	Regressão Linear Multivariável (MLR)	14
2.7	Redes Neurais Artificiais (ANN)	15
3	Materiais e Métodos	16
3.1	Sistema de Experimentação	16
3.1.1	Sistema Conceitual	16
3.1.2	Sistema Construído	17
3.1.3	Especificação de Equipamentos	18
3.1.4	Planejamento de Experimentos	21
3.2	Aquisição de Dados	22
3.3	Processamento de Dados	22
3.4	Desenvolvimento do Modelo	23
4	Resultados	24
4.1	Aquisição de Dados	24
4.2	Processamento de Dados	24
4.3	Desenvolvimento do Modelo	26
4.3.1	Medidor de Vazão Multifásico – 1	26

4.3.2	Medidor de Vazão Multifásico – 2	27
4.4	Resumo dos Resultados	28
5	Conclusões e Trabalhos Futuros	29
	REFERÊNCIAS	31
	APÊNDICE A	34
6	Técnicas de Modelagem e Construção de Analisadores Virtuais	34
6.1	Conceitos básicos	34
6.2	Aquisição de Dados	35
6.3	Processamento de Dados	35
6.4	Desenvolvimento do Modelo	37
6.5	Adaptação	37
	APÊNDICE B	38

1 Introdução

Escoamentos multifásicos estão presentes em diversos setores da indústria, sendo de extrema importância, por exemplo, no transporte de componentes. Esses tipos de escoamento se caracterizam pela presença de duas ou mais fases fluindo juntamente por equipamentos ou tubulações. Diversos tipos desses escoamentos podem ser obtidos através da combinação de componentes em diferentes estados físicos (sólido, líquido ou gasoso) que são imiscíveis ou insolúveis, ou pelo equilíbrio entre duas fases para um componente (Falcone et al., 2009). Além disso, a distribuição interna das fases caracteriza o padrão de escoamento que pode ser obtido. Mapas de padrão de escoamento relacionam a distribuição observada com características do sistema como vazão, diâmetro e inclinação da tubulação (Govier e Aziz, 1972). Em tubulações horizontais os padrões de escoamento são classificados como: estratificado, ondulado, *plug*, golfada, anular e disperso (Mandhane et al., 1974).

A adição de novas fases ao escoamento aumenta a dificuldade de se obter medições com acuracidade das vazões. Atribui-se esse acréscimo de complexidade à inserção de novas variáveis a serem estimadas dificultando a obtenção das vazões individuais das fases (Falcone et al., 2001). Em vista disso, instrumentos chamados de medidores de vazão multifásico (MPFM, do inglês *Multiphase Flow Meter*) são utilizados. Esses instrumentos utilizam conjuntos de sensores, a fim de obter as informações necessárias para o cálculo das vazões individuais das fases (Barbariol et al., 2019). Os MPFMs podem ser classificados de três formas distintas de acordo com a metodologia utilizada para estimação da vazão (Corneliussen et al., 2005): em linha, com separação e fusão de dados. Os sensores predominantemente empregados em MPFMs baseiam-se em princípios tomográficos, dielétricos, mecânicos e sônicos (Dos Santos, 2015).

Um dos principais locais de utilização de MPFMs é na indústria de óleo e gás. A implementação desse tipo de instrumento para esse setor proporciona diversos ganhos, visto que fornece informações *online* sobre as vazões das fases (óleo, água e gás) possibilitando realização de otimizações no processo e diminuição de equipamentos para realização da caracterização da corrente (Falcone et al., 2001).

Embora tragam diversos benefícios os MPFMs não são majoritariamente utilizados devido às suas restrições de funcionamento a algumas condições operacionais. Além disso, a utilização de instrumentos baseados em princípios nucleares, como normalmente é o caso em MPFMs (Corneliussen et al., 2005), elevam o custo e periculosidade dos MPFMs e não viabilizam o aumento da gama de condições operacionais para emprego desses medidores (Meribout et al., 2009).

1.1 Objetivos

1.1.1 Objetivo Geral

O objetivo deste trabalho é o desenvolvimento de dois MPFMs baseados em fusão de dados os quais utilizarão sensores de pressão, vibração, acelerômetro e giroscópio, condução e vazão para realizar a predição das vazões volumétricas individuais das fases em um escoamento multifásico de ar e água em tubulações horizontais. Um dos medidores (MPFM-1) será construído com base em experimentos para o padrão de escoamento estratificado, ao

passo que o segundo MPFM (MPFM-2) será construído a partir de experimentos realizados para padrões de escoamentos estratificados, *plug* e *golpada*.

1.1.2 *Objetivos Específicos*

- Montagem do sistema em bancada.
- Planejamento de experimentos e coleta de dados.
- Análise de dados e ajuste de modelos matemáticos.

1.2 **Divisão do Trabalho**

O trabalho realizado está dividido da seguinte forma:

- Capítulo 2: revisão bibliográfica sobre escoamentos multifásicos, MPFMs, metodologias de construção de analisadores virtuais, Regressão Linear Multivariável e Redes Neurais.
- Capítulo 3: destinado aos materiais utilizados para realização dos experimentos e metodologia empregada para condução dos experimentos e criação do MPFM.
- Capítulo 4: apresentação dos resultados obtidos.
- Capítulo 5: conclusões acerca dos MPFMs desenvolvidos e recomendações para trabalhos futuros.

2 **Revisão Bibliográfica**

2.1 **Conceitos Básicos de Escoamento Multifásico**

Segundo Brennen (2005), escoamentos multifásicos são fenômenos de extrema importância para diversos setores da indústria. Esse tipo de escoamento é definido pela presença de duas ou mais fases imiscíveis com diferentes propriedades escoando simultaneamente em uma mesma direção em tubulações ou equipamentos. As indústrias alimentícia, nuclear, petroquímica e de tratamento de resíduos são apenas alguns exemplos de onde esses escoamentos podem ser encontrado (Dos Santos, 2015).

A presença de mais de um componente não é uma exigência para escoamentos multifásicos, visto que esse fenômeno pode ocorrer com apenas uma substância em diferentes estados físicos, por exemplo, água e vapor d'água (Dos Santos, 2015). Por conseguinte, uma forma de classificar escoamentos multifásicos é baseado no estado físico das fases nele presentes. Os possíveis estados físicos e suas características são:

- **Sólido:** presente tipicamente na forma de pequenas partículas não dissolvidas. É uma fase incompressível e que não sofre deformação pela interface existente com outras fases.
- **Líquido:** tipicamente incompressível, mas com algumas exceções. Deformável pela interface com outras fases.

- Gás: fase compressível.

Escoamentos multifásicos são formados pela combinação de diferentes estados físicos imiscíveis entre si. O tipo de escoamento mais usual é o bifásico no qual se tem como possibilidades de escoamentos (Dos Santos, 2015):

- Líquido–líquido: inclui escoamento de emulsões em tubulações, reatores, colunas recheadas agitadores e em extrações líquido-líquido.
- Gás-Sólido: partículas de sólido suspenso em gás. Relevante para indústria de combustão de combustíveis pulverizados, transporte pneumático e leitos fluidizados.
- Líquido-Sólido: encontrado largamente em transporte hidráulico de material sólido e em sistemas de cristalização.
- Gás-Líquido: possivelmente o mais importante dentre os escoamentos multifásicos. Encontrado frequentemente na indústria.

Escoamentos trifásicos também possuem significância prática. Alguns exemplos são:

- Gás-Líquido-Sólido: encontrado na flotação de espuma como meio de separar minerais e realização de reações gás-líquido na presença de um catalisador sólido (Wu e Tu, 2016).
- Gás-Líquido-Líquido: presente no setor de óleo e gás em escoamentos de água, gás natural e petróleo.
- Sólido-Líquido-Líquido: presente no setor de óleo e gás em escoamentos de água, óleo e areia.

Escoamentos com mais de três fases também são possíveis. Segundo Falcone et al. (2009), na exploração de petróleo, à medida em que o poço amadurece, a linha de produção, que inicialmente era constituída apenas por petróleo, pode atingir condições operacionais em que quatro fases ocorram sendo elas: água, petróleo, gás natural e areia.

2.2 Padrões de Escoamento

O comportamento e distribuição espacial da interface entre as fases presente nos escoamentos multifásicos é denominado padrão ou regime de escoamento. Nesse tipo de fenômeno, há a presença de forças atuando entre as fases e é o balanço dessas forças que determina o padrão de escoamento (Brennen, 2005).

Diversos fatores afetam o padrão de um escoamento multifásico. Alguns dos fatores que contribuem para definição do regime de escoamento são (Dos Santos, 2015):

- Temperatura e Pressão de operação.
- Propriedade dos componentes.

- Fração e velocidade das fases presentes no escoamento.
- *Design* da tubulação (diâmetro, válvulas e orientação).
- Estado do escoamento: estacionário, pseudo-estacionário ou transiente.

2.2.1 Parâmetros de Escoamento

Existem diversos parâmetros importantes para os escoamentos multifásicos (Brennen, 2005), sendo uma das principais a fração de fase (α_i), que é definida como:

$$\alpha_i = \frac{A_i}{A_T} \quad (2.1)$$

Sendo a razão entre a área transversal ocupada pela fase analisada (A_i) e área transversal total (A_T). Além disso, a velocidade superficial das fases (j_i), também chamado de fluxo volumétrico, é uma outra importante variável dada por:

$$j_i = \frac{Q_i}{A_T} \quad (2.2)$$

onde Q_i é a vazão volumétrica da fase i . A velocidade superficial da mistura é obtida através da soma das velocidades superficiais individuais das fases:

$$j = \sum_{i=1}^n j_i \quad (2.3)$$

Sendo n o número de fases presentes no escoamento. Analogamente, pode-se definir o fluxo mássico como o produto entre a velocidade superficial de uma fase e sua massa específica.

$$G_i = \rho_i j_i \quad (2.4)$$

Já o fluxo mássico da mistura é definido como a soma dos fluxos mássicos individuais.

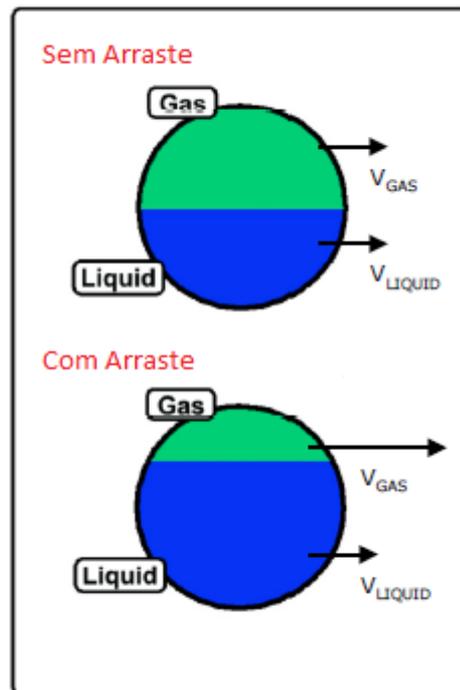
$$G = \sum_{i=1}^n G_n \quad (2.5)$$

A fração volumétrica de uma fase do escoamento multifásico pode ser obtido através da razão entre a sua velocidade superficial e a velocidade superficial total da mistura.

$$x_i = \frac{j_i}{j} \quad (2.6)$$

Os valores da fração de fases e fração volumétrica são iguais apenas quando não há diferença entre as velocidades das fases. Esse fato ocorre devido à diferença de velocidades que ocasiona um efeito de arraste, no qual a fase com velocidade mais elevada tem uma diminuição da sua área transversal, ao passo que a fase arrastada possui um incremento. Esse fenômeno é muito comum em escoamentos gás-líquido onde a fase gasosa consegue atingir velocidades mais elevadas quando comparada com a líquida, causando a diferença entre as propriedades de fração volumétrica e de fase. A Figura 2.1 ilustra o efeito causado pelo arraste.

Figura 2.1: Efeito do arraste sobre a fração de fase.



Fonte: Adaptado de Corneiliussen et al. (2005)

2.2.2 Mapas de Escoamento

A classificação de escoamentos multifásicos baseou-se originalmente em experimentos visuais bifásicos (Barnea et al., 1982). As observações são dispostas em um gráfico bidimensional possuindo contornos que indicam os padrões de escoamento. As coordenadas utilizadas nos mapas diferem entre autores (Barnea, 1987; Crawford et al., 1985), por exemplo, vazões mássicas, fluxos volumétricos ou fluxos mássicos. A utilização de diferentes coordenadas justifica-se pela necessidade de escolher uma variável independente do sistema de experimentação.

Os tipos de escoamento que apresentaram maior interesse de pesquisa foram escoamentos gás-líquido, líquido-líquido e gás-líquido-líquido (Barnea, 1987; Govier e Aziz, 1972; Hewitt, 2005) devido a suas relevâncias práticas. Logo, uma descrição sobre os padrões presentes nesses escoamentos e seus mapas de regime serão apresentados.

2.2.3 Gás-Líquido

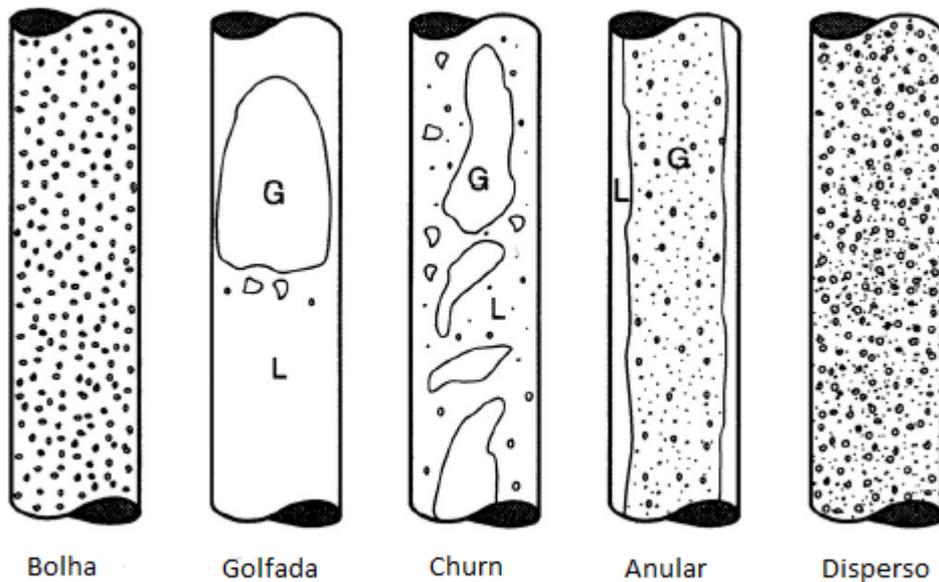
Os fatores que governam as distribuições espaciais das fases em um sistema gás-líquido são complexos. Incluem-se nesses fatores tensão superficial, coalescência, efeitos de troca térmica, entre outros. Não obstante, esse tipo de escoamento foi subclassificado em diversos padrões de escoamentos. As distribuições das fases variam gradualmente com condições de processo como vazão e diâmetro da tubulação e a transição entre regimes é normalmente suave (Dos Santos, 2015).

A separação entre mapas de escoamento é realizada com base na orientação da tubulação em que o escoamento ocorre. As possibilidades de orientações são vertical, horizontal e inclinado, sendo as duas primeiras as formas mais comumente utilizadas (Corneliussen et al.,

2005). A Figura 2.2 e 2.3 mostram os padrões de escoamento em uma tubulação vertical e horizontal respectivamente. Os regimes para tubulação vertical, em ordem crescente de vazão de gás, são definidos da seguinte maneira (Falcone et al., 2009):

- Bolha: nesse padrão de escoamento a fase líquida é contínua e a fase gasosa está presente de forma dispersa no líquido na forma de bolhas. As bolhas podem romper ou se juntar e geralmente possuem um tamanho não uniforme.
- Golfada: esse padrão ocorre quando o tamanho da bolha é próximo ao da tubulação adquirindo um formato similar ao de um cilindro.
- *Churn*: com aumento da velocidade da fase gasosa as bolhas se rompem levando para um regime instável com movimentação oscilatória.
- Anular: vazão da fase gasosa já é suficientemente elevada para permanecer em uma fase contínua no centro da tubulação, enquanto o líquido permanece nas paredes da tubulação.
- Disperso: versão similar ao escoamento tipo bolha, porém a fase contínua é a gasosa e a dispersa, na forma de gotas, é a líquida.

Figura 2.2: Padrões de escoamento para uma tubulação vertical.

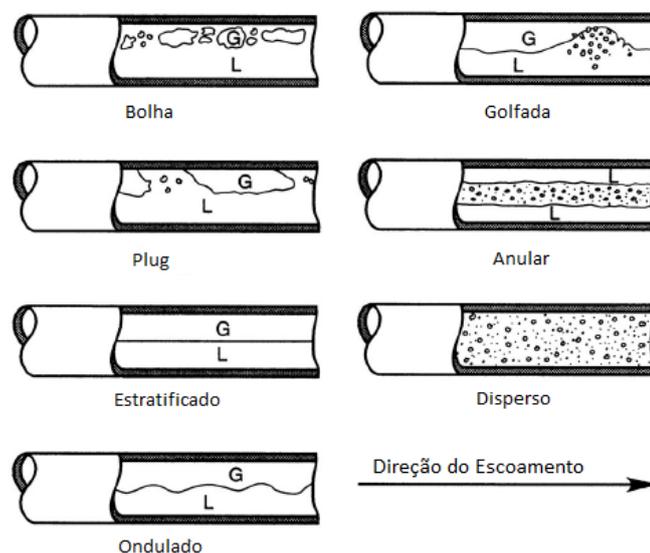


Fonte: Adaptado de Brennen (2005)

Diferentemente do escoamento dos regimes em tubulação vertical, a tubulação orientada horizontalmente é fortemente afetada pelo efeito gravitacional. Esse impacto causa a elevação da fase de menor massa específica do escoamento, nesse caso o gás, gerando padrões não vistos no caso vertical. Os regimes presentes em uma tubulação horizontal são (Dos Santos, 2015):

- Bolha: fase líquida constitui a fase contínua, ao passo que o gás em vazões mais baixas está presente na forma de bolhas dispersas. Devido a forças de empuxo, as bolhas de gás presente deslocam-se para a parte superior da tubulação.
- *Plug*: o incremento da vazão de gás coalesce as bolhas aumentando seus tamanhos. Nesse caso, as bolhas atingem tamanhos inferiores ao do diâmetro da tubulação.
- Estratificado: esse regime é atingido quando há a separação das fases ocasionado pelas forças gravitacionais. Dessa forma, o líquido fica presente em uma camada na parte inferior, enquanto o gás permanece na parte superior.
- Ondulado: incremento da vazão de gás forma ondas na fase líquida originadas pelo araste existente na fase líquida.
- Golfada: aumento da vazão de gás cria ondas de alta amplitude que ocupam, no seu pico, toda a secção transversal da tubulação. Esse fenômeno cria volumes de gás, que podem atingir elevada extensão, separados pela onda da fase líquida. Além disso, dada a elevada velocidade da fase gasosa pequenas bolhas podem estar presentes na fase líquida.
- Anular: efeito similar ao visto nas tubulações verticais. Todavia, devido aos efeitos gravitacionais o filme líquido presente na parte inferior da tubulação tende a ser mais espesso. Além disso, pode haver a presença de gotas da fase líquida sendo carregadas pelo escoamento de gás.
- Disperso: fase líquida permanece dispersa, na forma de gotas, no escoamento gasoso.

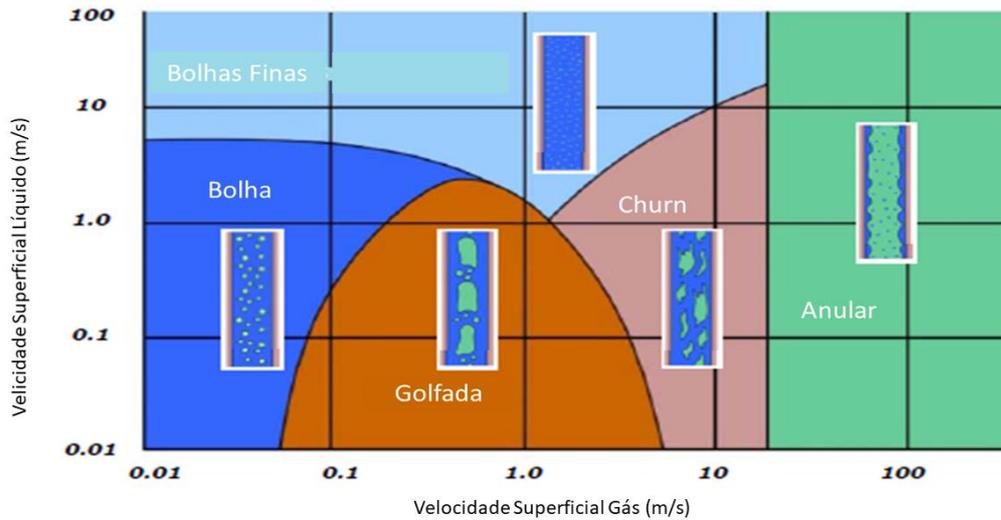
Figura 2.3: Padrões de escoamento para uma tubulação horizontal.



Fonte: Adaptado de Brennen (2005)

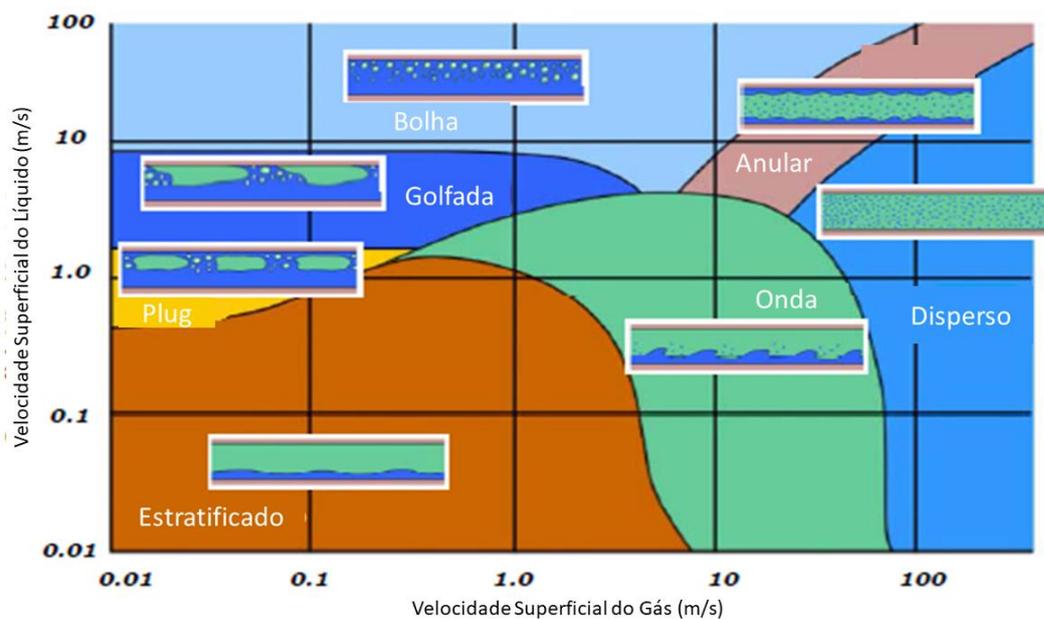
Do ponto de vista de engenharia, observações visuais nem sempre são possíveis e um método alternativo torna-se necessário para classificação de escoamentos. Esse método é chamado de mapa de padrão de escoamento no qual se utilizam coordenadas que se referam a propriedades do escoamento para classificá-lo quanto ao regime observado. As Figuras 2.4 e 2.5 mostram os mapas de escoamento para uma tubulação vertical e horizontal respectivamente.

Figura 2.4: Mapa de escoamento para uma tubulação vertical.



Fonte: Adaptado de Corneliusen et al. (2005).

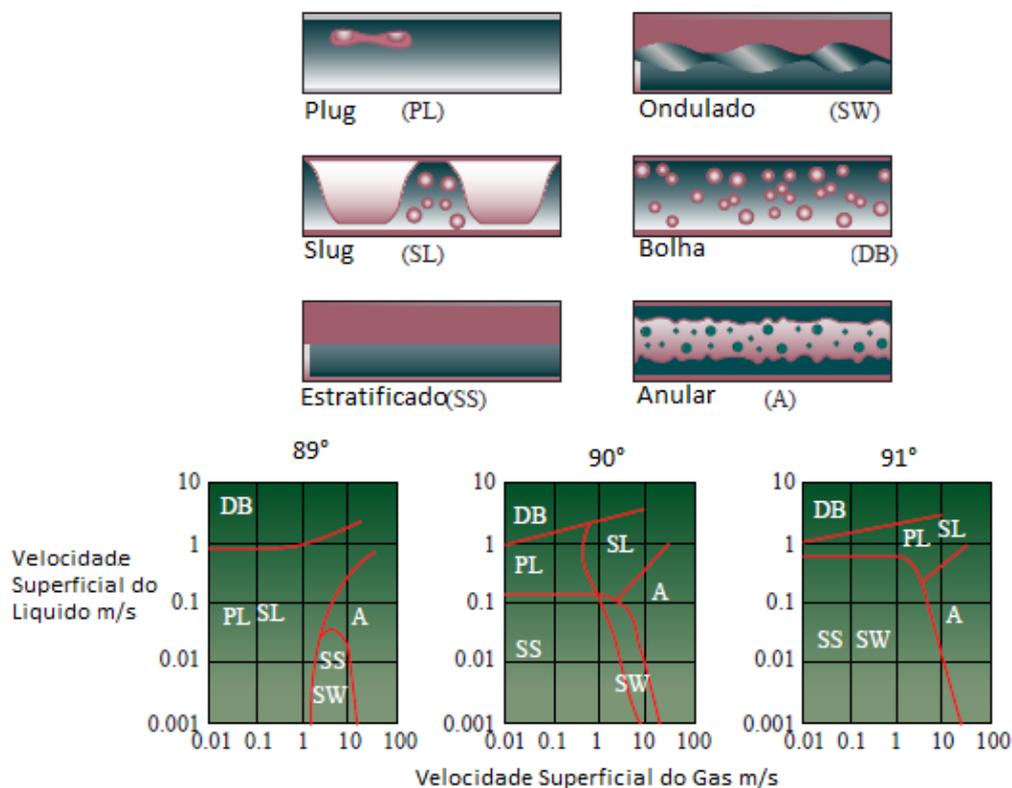
Figura 2.5: Mapa de escoamento para uma tubulação horizontal.



Fonte: Adaptado de Corneliusen et al. (2005).

Segundo Falcone et al. (2009), pequenas alterações no ângulo de inclinação das tubulações podem causar mudanças significativas nas fronteiras dos padrões de escoamento. A Figura 2.6 mostra como a alteração da inclinação em um grau modifica o mapa de regime de escoamentos.

Figura 2.6: Padrões de escoamento para tubulações com inclinação 90° (horizontal), 91° (inclinada no sentido horário) e 89° (inclinada no sentido anti-horário).



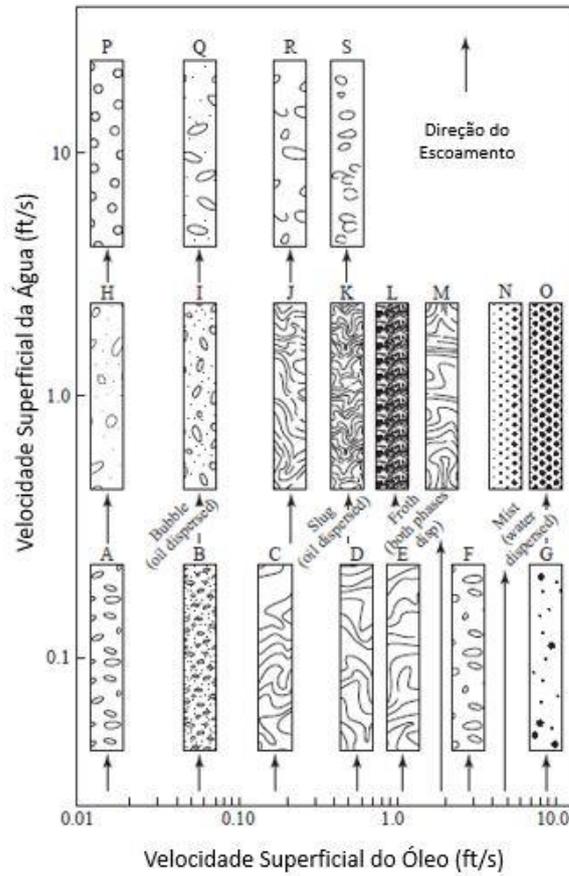
Fonte: Adaptado de Falcone et al. (2009)

2.2.4 Líquido-Líquido

Segundo Brauner e Moalem Maron (1992), escoamentos líquidos-líquidos não foram estudados extensivamente como no caso do tipo gás-líquido. Além disso, as conclusões e resultados originados pelo estudo do comportamento do escoamento gás-líquido não podem ser imediatamente traduzidas para o contexto líquido-líquido. A distribuição espacial das fases em um escoamento líquido-líquido é fortemente dependente das propriedades dos fluidos como massa específica, tensão superficial e viscosidade. Todavia, o baixo número de estudos não remete à falta de interesses práticos nesse tipo de escoamento, visto que está presente em diversos processos (Hasan e Kabir, 1988).

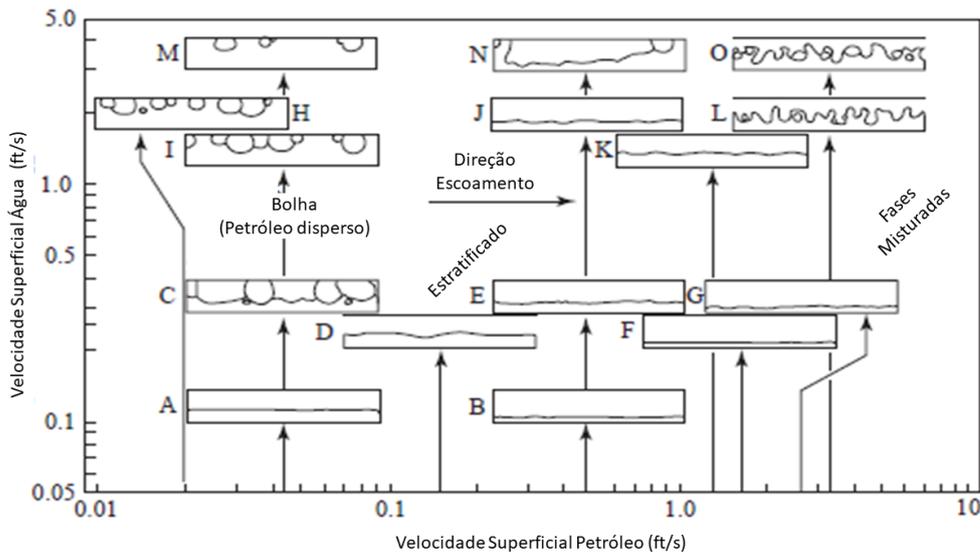
Uma discussão geral sobre escoamentos líquido-líquido é apresentada em Govier e Aziz (1972). As Figuras 2.7 e 2.8 apresentam os mapas de padrão de escoamento para tubulações verticais e horizontais, respectivamente, para água e petróleo. Nota-se que a característica de aumento da dispersão com aumento de velocidade é compartilhada entre os escoamentos líquido-líquido e gás-líquido. Contudo, a complexidade apresentada pelo primeiro tipo de escoamento é substancialmente maior.

Figura 2.7: Padrões de escoamento para água e petróleo em uma tubulação vertical definidos pela velocidade superficial das fases.



Fonte: Govier e Aziz (1972).

Figura 2.8: Padrões de escoamento para água e petróleo em uma tubulação horizontal definidos pela velocidade superficial das fases.



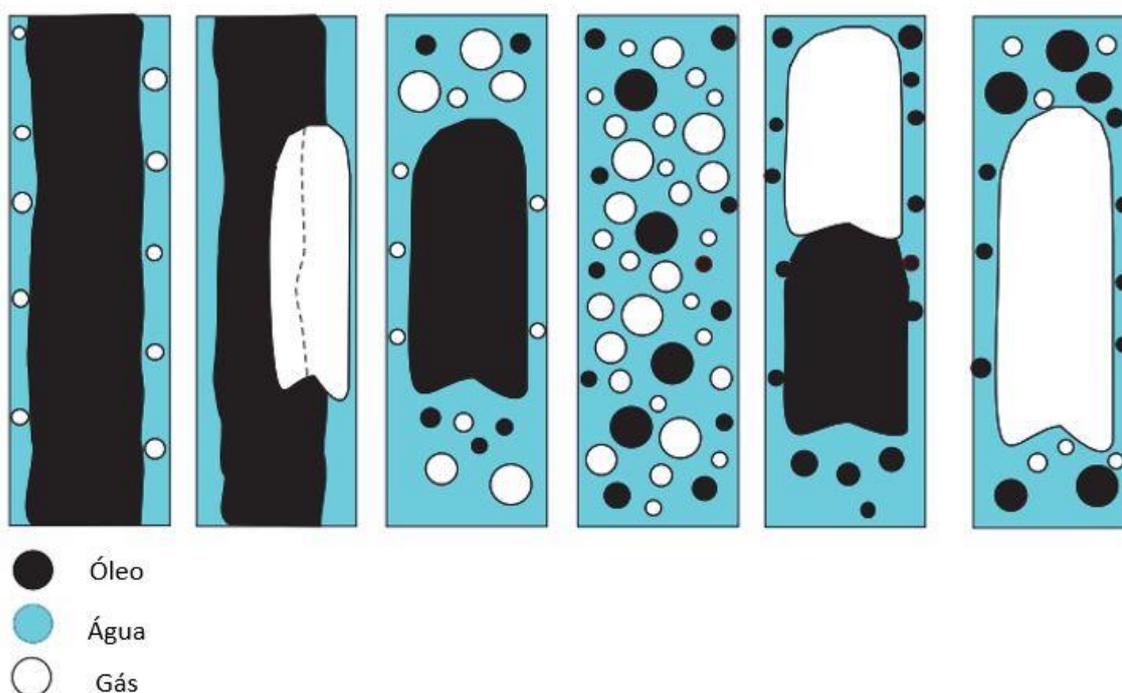
Fonte: Adaptado de Govier e Aziz (1972).

2.2.5 Gás-Líquido-Líquido

Escoamentos gás-líquido-líquido são encontrados frequentemente na exploração de poços de petróleo sendo composto por água, petróleo e gás natural. Diferentemente dos escoamentos bifásicos, a inclusão de uma terceira fase dificulta a classificação dos padrões de escoamentos de maneira visual. Além disso, não há consenso entre autores em relação à classificação dos padrões de escoamento (Serapião e Bannwart, 2013; Trevisan e Bannwart, 2006).

Segundo Serapião e Bannwart (2013), o estudo sobre escoamentos trifásicos é primordial para uma operação economicamente melhor em poços de petróleo. Essa conclusão é feita com base na dependência presente entre estratégias de gerenciamento, projetos de equipamentos em plataformas de petróleo e a composição da corrente extraída do poço. A Figura 2.9 apresenta ilustrações dos padrões de escoamento de uma corrente composta por água, petróleo e ar utilizadas como referência no estudo realizado por Serapião e Bannwart (2013).

Figura 2.9: Ilustrações de escoamentos trifásicos (água, petróleo e ar) em tubulação vertical.



Fonte: Adaptado de Serapião e Bannwart (2013).

2.3 Sensores Multifásicos

A existência dos mapas de padrão de escoamento por si só não é suficiente para aplicações práticas. Naturalmente, sua importância é grande, visto sua ajuda na classificação do escoamento e, conseqüentemente, na obtenção de informação sobre suas características. Ainda assim, para validação de modelos propostos para predição do comportamento de escoamentos multifásicos é necessário que haja uma maneira de adquirir dados. Por

consequente, há a necessidade de utilizar instrumentos que forneçam os parâmetros necessários do processo para classificação do regime (Dos Santos, 2015).

Segundo Meribout et al. (2010), o instrumento ideal seria aquele que determinasse a vazão para cada fase que compreende a mistura. Contudo, tal instrumento, teria de determinar as frações das fases e a vazão total do escoamento. Logo, a utilização de mais de um tipo de instrumento é indispensável.

2.3.1 *Categorias de MPFMs*

Os MPFMs podem possuir distintas categorias (Corneliussen et al., 2005; Falcone et al., 2001). As principais categorias são as seguintes:

- Em linha: as medições realizadas, para obtenção dos parâmetros de escoamento, são feitas diretamente na linha do escoamento multifásico sem separação prévia. Em certos casos tenta-se homogeneizar o escoamento antes de realizar leituras de vazão (Povey, 1997).
- Com separação: uma classe de MPFMs que se caracterizam pela utilização de separadores antes da realização das medições. O objetivo é transformar a complexa corrente de entrada em correntes mais simples com componentes puros de menor número de fases. A implementação desses separadores tornam essa alternativa mais cara, podendo torna-la inviável economicamente (Meribout et al., 2009).
- Processamento de sinais ou fusão de dados: como o nome indica, essa classe de MPFMs utiliza o processamento de sinais de diversos instrumentos conectados a linha para estimar as frações de fase e vazões.

2.3.2 *Princípio de Medição dos Instrumentos Utilizados em MPFMs*

A utilização de diferentes sensores é uma necessidade intrínseca aos MPFMs. Grande parte dos MPFMs recorrem as propriedades elétricas (capacitância e condutância) e/ou não elétricas (propagação de energia de ondas) das fases que compõem a mistura (Whitaker, 1996). Além disso, outros instrumentos de medição de vazão são utilizados em conjunto para completar a estrutura do MPFM. Utiliza-se os seguintes instrumentos para compor um MPFM:

- Tomografia de raios gama ou raios X: consiste na distribuição de fontes e receptores ao longo da circunferência da tubulação. O feixe transmitido pelo escoamento sofre atenuação e, como cada fase possui uma atenuação específica, pode-se recriar uma imagem da secção transversal da linha. Não possui limitação em relação à fração das fases, porém por se tratar de uma técnica que emprega fontes radioativas com custos consideráveis nem sempre é possível utilizá-la (Meribout et al., 2010).
- Capacitância e Condutância: baseia-se na medição das propriedades elétricas das fases do escoamento multifásico. Em ambos os casos, eletrodos são colocados em cada lado da tubulação, a fim de medir a capacitância ou condutância do meio. Essas medidas podem ser relacionadas com as fases que escoam na linha dado a

sua dependência das propriedades elétricas das fases. Em escoamentos trifásicos de água, petróleo e gás essa técnica não é satisfatória para frações de água entre 40% e 60%, visto que nesse intervalo a mistura não possui características de um condutor nem isolante (Corneliussen et al., 2005; Meribout et al., 2010).

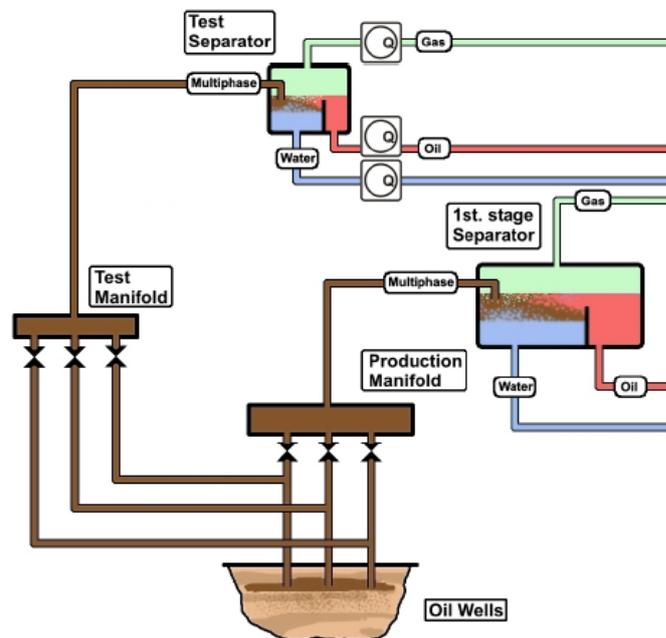
- **Ultrassônico:** distribuem emissores e receptores ao redor da circunferência da tubulação. A detecção de alteração na impedância acústica, causada pela interação da onda com as fases, é utilizada como medida para correlacionar as frações de fase presente no meio. Esse tipo de técnica possui limitações para fração de fase gasosa superior a 10% (Dos Santos, 2015; Povey, 1997).
- **Diferencial de Pressão:** mede a diferença de pressão entre dois pontos do escoamento. Utilizado em conjunto com venturis ou placas de orifício. Em alguns casos, agitadores são empregados para homogeneizar a mistura, a fim de considerar as fases com velocidade similares para reduzir o número de variáveis necessárias para caracterização do escoamento. Contudo, essa consideração não é plausível na presença de uma fase gasosa devido sua diferença de massa específica (Falcone et al., 2001).
- **Deslocamento positivo:** mede a vazão do escoamento. Discretiza o escoamento em volumes conhecidos e os conta para obter a vazão total. Esse tipo de técnica não apresenta bons resultados para frações da fase líquida inferiores a 10% (Meribout et al., 2010).
- **Malha de fios:** baseia-se na medição da condutância ou capacitância. Consiste na utilização de dois planos de fios, um de transmissores e o outro de receptores. Os fios são paralelos em cada plano e perpendiculares entre planos. Os pontos de cruzamento entre os fios são os locais onde a medição é realizada possibilitando a geração de uma imagem da seção transversal da linha. Seu efeito intrusivo no escoamento e a falta de certeza sobre faixas de viscosidade operacionais são algumas das suas desvantagens (Dos Santos, 2015; Velasco Peña e Rodriguez, 2015).

2.4 Possíveis Utilizações para MPFMs

Escoamentos multifásicos ocorrem em diversos setores da indústria. Alguns exemplos são em estações nucleares, plantas petroquímicas, indústria alimentícia e exploração de petróleo. A utilização de MPFMs agregam valor ao processo devido sua capacidade de fornecer medições em tempo real (Barbariol et al., 2019).

Segundo Corneliussen et al. (2005), os testes convencionais utilizados para avaliar a performance de poços de petróleo empregam um separador trifásico exclusivo para essa análise. A Figura 2.10 ilustra o funcionamento do procedimento de caracterização do poço. Após a separação das fases suas vazões podem ser medidas facilmente com um medidor monofásico. Logo, essa metodologia fornece uma ideia do estado do escoamento multifásico no momento do teste com acurácia entre 5% e 10% (Falcone et al., 2001; Mus et al., 2001).

Figura 2.10: Fluxograma das instalações de plataformas de petróleo que utilizam caracterização convencional para o poço.



Fonte: Corneliussen et al. (2005).

Segundo (Falcone et al., 2001), a aplicação de MPFMs podem levar a grandes benefícios na exploração de petróleo. Uma das vantagens citadas é a possibilidade de remoção do separador trifásico para caracterização do poço. Essa alteração diminui espaço ocupado, tempo gasto para estabilização dos escoamentos nos testes e perdas de produção causadas pelo teste. Além disso, outros benefícios citados são a melhoria do gerenciamento do reservatório, devido a medições em tempo real, e facilidade na alocação de produção pela caracterização do escoamento. Contudo, essa modificação demanda maior estudo sobre MPFMs devido sua restrição a algumas faixas de operação (Falcone et al., 2009).

2.5 Técnicas de Modelagem e Construção de Analisadores Virtuais

Este subcapítulo está presente no Apêndice A dada sua extensão. Nele são abordados os tipos de analisadores virtuais, as etapas e técnicas de modelagem utilizadas para construção de analisadores virtuais empíricos segundo Kadlec et al. (2009).

2.6 Regressão Linear Multivariável (MLR)

A Regressão Linear Multivariável (MLR) é uma das melhores técnicas para investigação de relações entre variáveis dependentes e independentes para amostras pequenas (Abyaneh, 2014). Geladi e Kowalski (1986) indicam a ocorrência de três situações que podem ser encontradas em problemas de regressão linear multivariável em função do número de variáveis ou colunas (m) e do número de amostras ou linhas (n):

- $m > n$: nesta situação, o problema apresenta um número de variáveis maior do que o número de amostras, o que não é desejado, pois indica um número infinito de soluções para o vetor dos parâmetros do modelo (b).

- $m = n$: situação em que o número de variáveis é igual ao número de amostras. Apesar de dificilmente ocorrer, este caso apresenta solução única para o vetor b .
- $m < n$: o problema possui mais amostras do que variáveis secundárias, o que indica a não existência de solução exata para o vetor b . A resolução do problema se dá através da minimização do vetor residual (Equação 2.7), que tem sua solução mais usual pela aplicação do método de mínimos quadrados.

$$e = y - X.b \quad (2.7)$$

onde e representa o vetor residual, y o vetor de resultados, X a matriz de dados e b o vetor associado aos coeficientes da regressão.

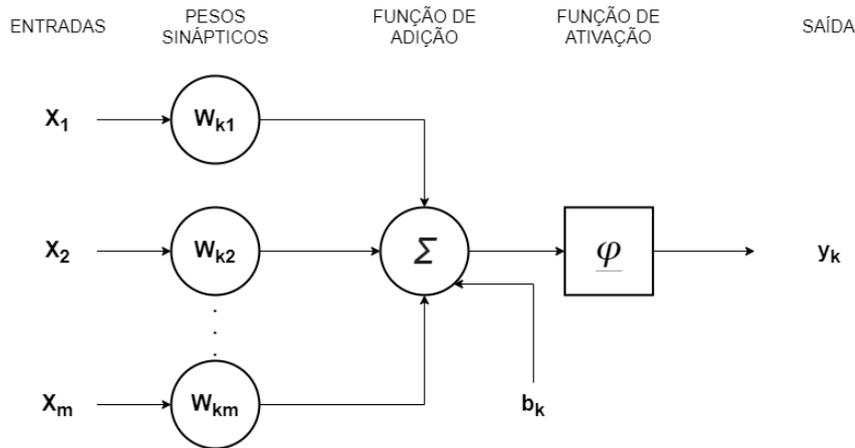
2.7 Redes Neurais Artificiais (ANN)

Diferentemente da técnica MLR, as Redes Neurais artificiais são modelos não-lineares de relativa complexidade, cuja estrutura tenta imitar a funcionalidade do cérebro humano. Qin (1997) destaca a grande utilidade de Redes Neurais para a modelagem de sistemas industriais e consequente aplicação para controle de processos, sendo amplamente aceitas na indústria de processos devido ao seu excelente custo-benefício, não-linearidade e o fato de serem desenvolvidas a partir de uma análise de dados.

As unidades de processamento de informação em redes neurais, denominadas de neurônios, têm papel fundamental no funcionamento das redes artificiais, sendo construídas com base em três elementos: o conjunto de sinapses, uma função aditiva e uma função de ativação (Haykin, 1994). A definição de Haykin (1994) para os três elementos está descrita a seguir, bem como representação de um neurônio (Figura 2.11).

- Sinapses: são as conexões entre as entradas (x_i) e o neurônio (k). Cada conexão sináptica possui um peso associado que multiplica o valor sináptico.
- Função de adição: realiza a soma do produto das conexões sinápticas com seus respectivos pesos.
- Função de ativação: é utilizada para restringir a amplitude de saída de um neurônio. Confere também, dependendo da função utilizada, as características não-lineares à Rede Neural.

Figura 2.11: Representação do funcionamento de um neurônio.



Fonte: Adaptado de Haykin (1994).

Willis et al. (1992) afirmam que, embora inúmeras arquiteturas de Redes Neurais tenham sido propostas, a Rede Neural artificial do tipo *feed-forward* (FANN) é a mais utilizada para a modelagem de processos. Hornik et al. (1989) mostraram que uma FANN é capaz de modelar qualquer função contínua de maneira satisfatória. A construção de uma FANN se dá através da disposição de neurônios, também chamados de nós, em uma única camada oculta (*single layer*) ou em múltiplas camadas ocultas (*multilayer*) entre as entradas e as saídas, que serão treinadas para representar um processo específico (Haykin, 1994).

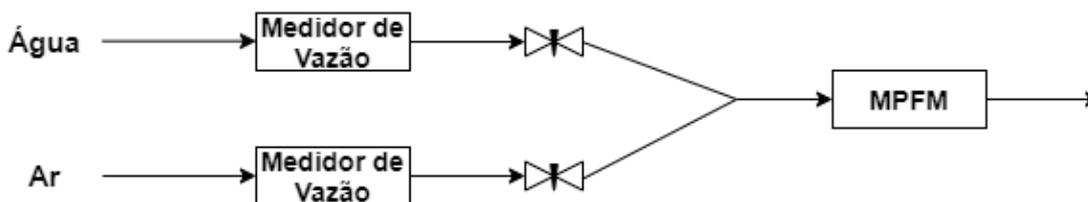
3 Materiais e Métodos

3.1 Sistema de Experimentação

3.1.1 Sistema Conceitual

Para realização do estudo do escoamento bifásico de água e ar necessitou-se construir uma planta, em pequena escala, a fim de conduzir experimentos para validação do MPFM desenvolvido. Conceitualmente, a estrutura construída deve proporcionar a geração de diferentes padrões de escoamento, assim como disponibilizar a informação sobre as vazões individuais de cada fase para serem utilizadas na calibração do MPFM. Logo, para acomodar ambas as necessidades, cada fase pura deve ser admitida individualmente por uma tubulação contendo medidor de vazão e válvula possibilitando a geração de diversas configurações experimentais. Posteriormente, as linhas contendo as fases puras são unidas gerando o escoamento bifásico que percorre horizontalmente o sistema contendo o MPFM. A Figura 3.1 representa a estrutura do sistema.

Figura 3.1: Representação conceitual da estrutura do sistema de experimentação.



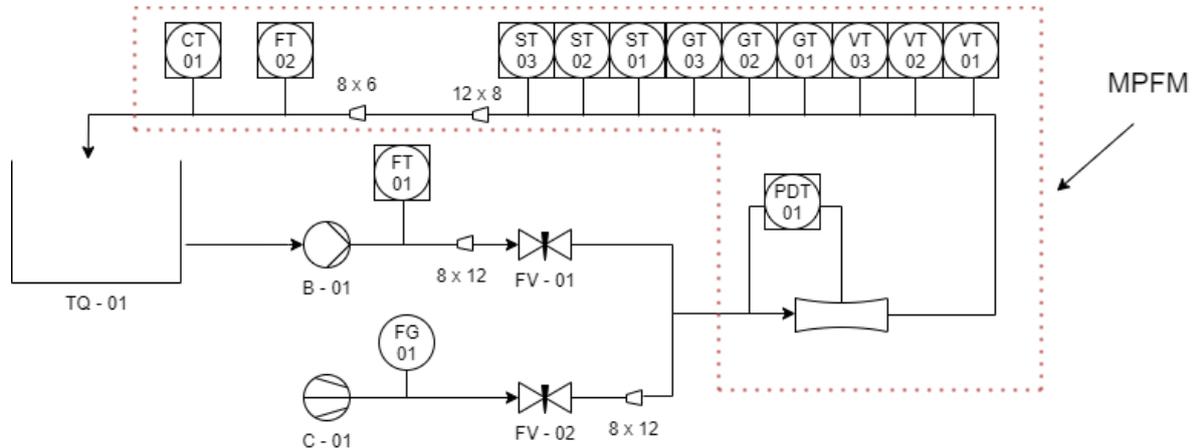
Fonte: Do autor

3.1.2 Sistema Construído

Com base na estrutura conceitual exposta na Figura 3.1, construiu-se o sistema final para utilização nos experimentos. A tubulação utilizada para o escoamento multifásico possui diâmetro externo de 12 mm e interno de 8mm. A Figura 3.2 mostra o desenho detalhado do sistema. Água presente no reservatório (TQ – 01) foi inserida no sistema através de uma bomba (B – 01), mediu-se sua vazão através de um sensor de vazão (FT – 01), passou-se por uma junta de expansão de 8mm para 12mm, uma válvula manual agulha (FV – 01) e uniu-se com a corrente de ar. Para admissão de ar no sistema, utilizou-se um compressor (C – 01) que utiliza ar atmosférico. Mediu-se, com um rotâmetro (FG – 01), a vazão da linha, passou-se por uma válvula manual agulha (FV – 02) e uma junta de expansão para, enfim, unir-se com a corrente de água, gerando o escoamento multifásico. Após a mistura das duas fases, a corrente encaminha-se para o sensor de vazão multifásico.

A primeira etapa do MPFM consiste na utilização de um venturi dotado de um sensor de pressão diferencial (PDT – 01) com tomadas de pressão na entrada e na garganta do venturi. Passado o venturi, mediu-se em três pontos distintos a vibração da tubulação através dos sensores VT – 01, VT – 02 e VT – 03. Além disso, realizou-se a medida das acelerações tangenciais e velocidades angulares nos três eixos espaciais por meio dos sensores GT e ST respectivamente. Por fim, a corrente passa por duas reduções de 12mm para 8mm e de 8mm para 6mm, a fim de possuir diâmetro de tubulação adequado para realização das medições finais de vazão (FT – 02) e condutividade (CT – 01). Finalizada a passagem pelo circuito de sensores que compreendem o MPFM, a corrente multifásica retorna para o TQ – 01 fechando o sistema de experimentação.

Figura 3.2: Desenho detalhado do sistema de experimentação.



Fonte: Do autor.

A ideia por trás da utilização dos sensores de vibração, velocidade angular e aceleração está nos efeitos causados pelos diferentes tipos de padrão de escoamento na tubulação. Logo, a utilização em conjunto desses sensores com os demais equipamentos, já comumente empregados em MPFMs, possibilitará uma maior quantidade de informações relevantes para caracterização do escoamento multifásico.

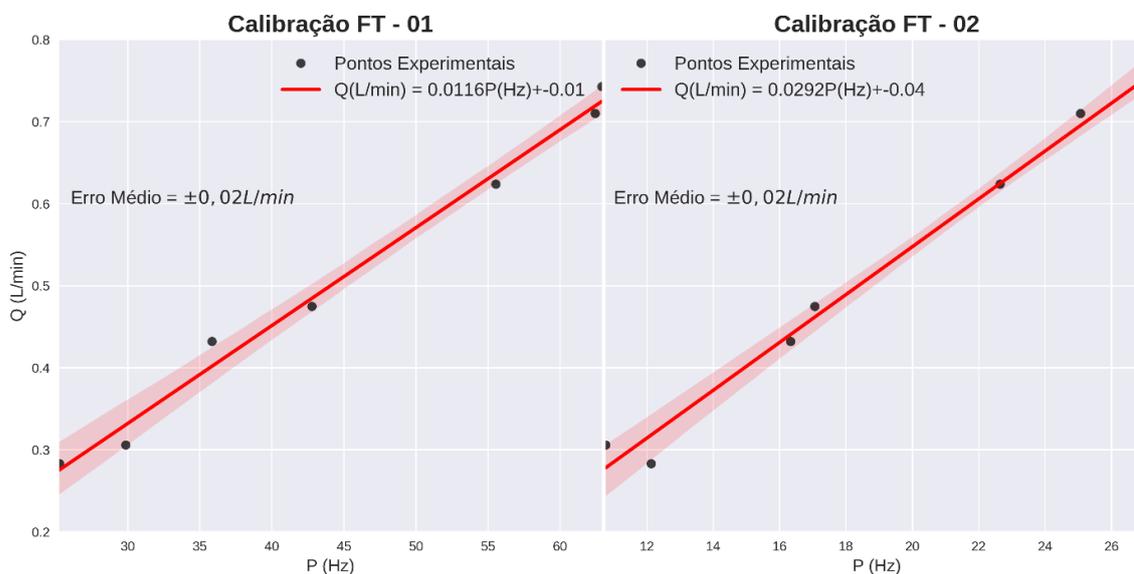
3.1.3 Especificação de Equipamentos

Para realizar a montagem do sistema de experimentação diversos equipamentos e sensores foram utilizados. Em vista disso, lista-se abaixo as características relevantes dos equipamentos empregados.

- TQ – 01: como reservatório de água utilizou-se um balde de 10 litros de volume, a fim de garantir nível adequado para bomba.
- B – 01: bomba submersível com vazão nominal de 400 L/h (6,7 L/min).
- C – 01: compressor de ar com vazão nominal de 2400 L/h (40 L/min).
- FG – 01 e FV – 02: rotâmetro provido de válvula agulha manual para regulagem da vazão de ar. Faixa de leitura do instrumento entre 0-10 L/min com resolução de 1 L/min.
- FT – 01 e FT – 02: sensor de vazão do tipo ventoinha. O princípio de medição baseia-se no efeito Hall no qual mede-se a diferença de potencial de um elemento condutor com passagem de corrente com um ímã permanente. A rotação da ventoinha causa alterações no campo magnético ao redor do elemento gerando um sinal de onda quadrada. Logo, pode-se relacionar a frequência do sinal com a vazão do fluido. Para efetuar a calibração dos sensores, mediu-se o tempo de enchimento de um volume conhecido para diversas vazões de água pura e obteve-se a frequência dos pulsos quadrados correspondentes. Dessa forma, uma relação entre vazão e frequência de pulsos foi obtida. A Figura 3.3 mostra a calibração dos

instrumentos para o intervalo de 0,2 à 0,7 L/min, no qual obteve-se um erro médio de 0,02 L/min para ambos sensores.

Figura 3.3: Calibração realizada para sensores FT – 01 e FT – 02. Pontos pretos: medições realizadas; Linha vermelha: reta de ajuste linear aos pontos; Região em vermelho: região de 95% de confiança.



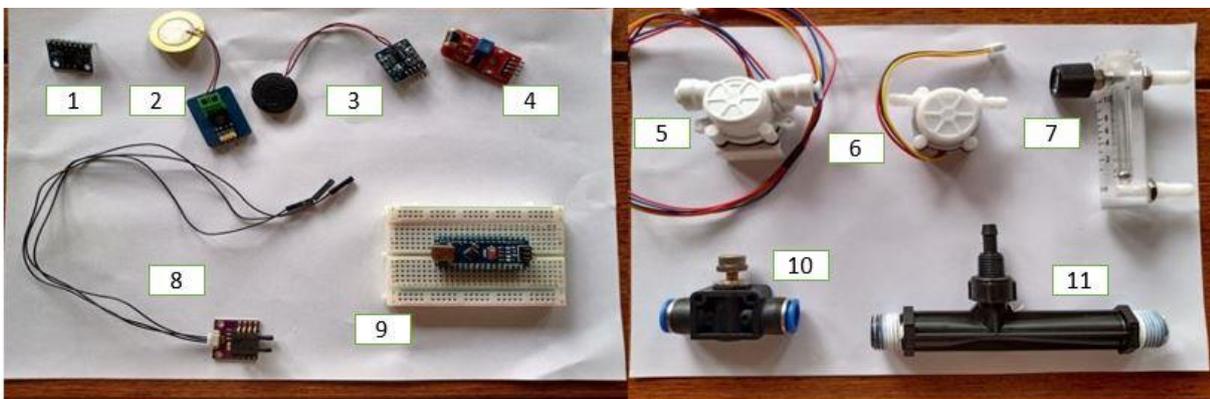
Fonte: Do autor.

- FV – 01: válvula agulha manual para realizar a regulagem da vazão de água para o sistema.
- PDT – 01 e Venturi: tubo de Venturi com diâmetro na entrada e na garganta 13 mm e 8 mm respectivamente. A queda de pressão provocada pela contração do venturi é medida através de um sensor diferencial de pressão com intervalo de medição entre -2 e 2 kPa com erro médio de 0,25 kPa. Esse sensor emprega materiais piezo-resistivos que quando submetidos à força resultante das duas tomadas de pressão sofre alteração na sua resistividade produzindo sinais elétricos diferentes de acordo com a diferença de pressão aplicada.
- VT – 01, VT – 02 e VT – 03: sensores de vibração piezoelétricos de diferentes fabricantes. A movimentação da estrutura em que são colocados causa alterações nas propriedades elétricas do instrumento que é relacionado com a vibração da estrutura. Devido à falta de informações dos fabricantes apenas os sinais brutos foram utilizados.
- GT – 01, GT – 02, GT – 03, ST – 01, ST – 02 e ST – 03: Essas leituras são realizadas a partir de um único sensor, acelerômetro e giroscópio. Fornece medições da aceleração (GTs) na escala $\pm 20 \text{ m/s}^2$ e velocidade angular (STs) no intervalo $\pm 250 \text{ }^\circ/\text{s}$, sendo que os números 01, 02 e 03 presentes nos nomes dos sensores representam, respectivamente, os eixos, X, Y e Z.

- CT – 01: sensor de condutância. Esse sensor é acoplado ao sensor de vazão FT – 02, compreendendo um único instrumento. Devido à falta de informações do fabricante apenas o sinal bruto desse sensor foi utilizado.
- Microcontrolador: escolheu-se o Arduino Nano como microcontrolador para realizar as leituras e processamento dos sinais obtidos pelos instrumentos.

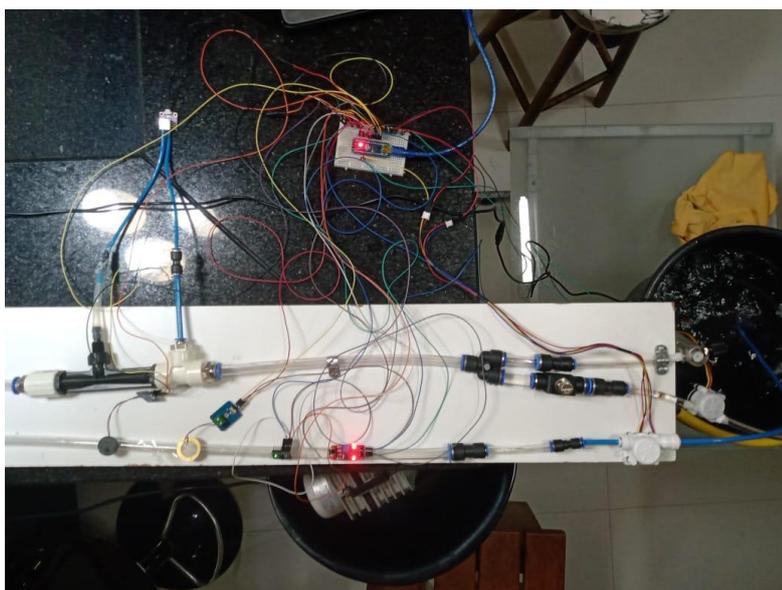
A Figura 3.4 e 3.5 mostram os equipamentos empregados para construção do sistema experimental e o sistema montado respectivamente. Os equipamentos apresentados na Figura 3.4 em ordem de aparição iniciando pelo canto superior esquerdo são: acelerômetro e giroscópio (GTs e STs na Figura 3.2), VT – 01, VT – 02, VT – 03, sensor de vazão e condução (FT – 02 e CT – 01), sensor de vazão (FT – 01), rotâmetro, sensor diferencial de pressão, microcontrolador (Arduino Nano), válvula agulha e tubo de Venturi.

Figura 3.4: Materiais utilizados para construção do sistema de experimentação.



Fonte: Do autor.

Figura 3.5: Sistema experimental montado e operando.

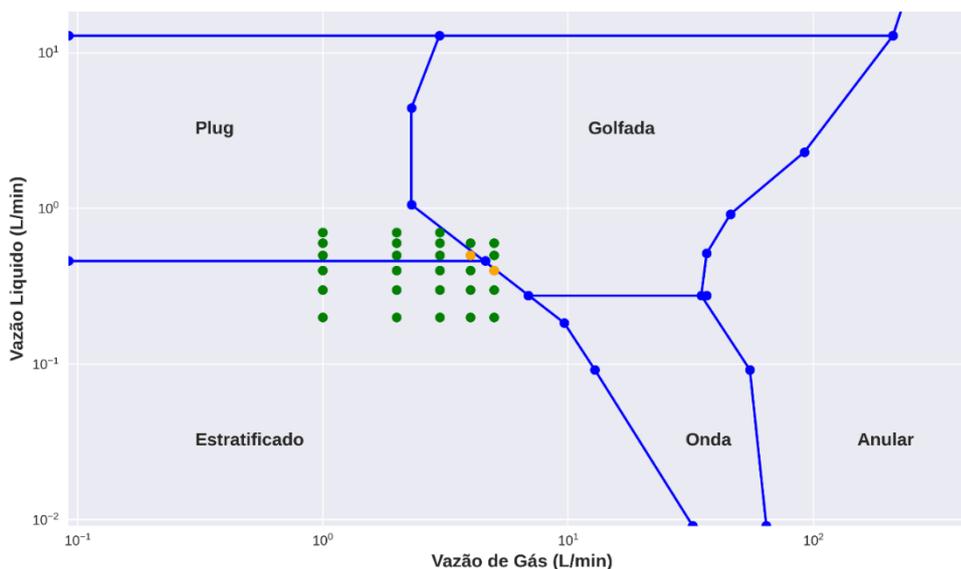


Fonte: Do autor.

3.1.4 Planejamento de Experimentos

Para efetuar o planejamento de experimento é necessário ter o conhecimento das possíveis condições operacionais do sistema que podem ser atingidas. Logo, com o sistema já montado, mediu-se as vazões máximas de água e ar atingidas por B – 01 e C – 01 respectivamente. No caso da água, a vazão máxima obtida foi de 1,6 L/min, ao passo que para o ar atingiu-se o fundo de escala do rotâmetro (10 L/min). No entanto, a presença de interação entre as vazões dos dois componentes reduziu consideravelmente a região experimental. Para vazões de água superiores a 0,7 L/min houve o bloqueio total da entrada de ar no sistema, impedindo, portanto, a geração do escoamento multifásico. Em vista disso, decidiu-se por empregar combinações de vazões de água dentro do intervalo 0,2 e 0,7 L/min com vazões de ar de 1 a 5 L/min, com exceção para vazão de água 0,7 L/min onde as vazões de ar utilizadas foram entre 1 e 3 L/min devido às interações entre as variáveis. Além disso, sabe-se que o diâmetro interno da tubulação utilizada para o escoamento multifásico é 8 mm, por conseguinte pode-se adicionar os pontos experimentais a um mapa de escoamentos para tubulação horizontal, a fim de classificar os escoamentos produzidos experimentalmente (Figura 3.6). Os experimentos referentes aos pontos (4; 0,5) e (5; 0,4) – sendo a primeira coordenada relativa à vazão volumétrica de ar e a segunda a de água – foram classificados como padrão golfada, visto suas proximidades às fronteiras de transição de escoamentos, conforme Figura 3.6, e a avaliação visual desempenhada.

Figura 3.6: Mapa de escoamentos para tubulação horizontal de 8mm de diâmetro interno (eixos em L/min) com pontos experimentais efetuados. Pontos verdes: experimentos realizados; Pontos laranjas: experimentos reclassificados como padrão golfada; Linhas azuis com círculos: fronteiras entre padrões de escoamento.



Fonte: Adaptado de Mandhane et al. (1974).

Os experimentos realizados dentro da área do padrão estratificado foram realizados em triplicata, ao passo que os demais experimentos foram efetuados apenas em duplicata. Essa ação deve-se ao fato da relevância dada ao escoamento estratificado para os projetos de

tubulações na indústria de óleo e gás (Taitel, 1986). Além disso, grande parte do espaço de experimentação está localizado nessa região.

3.2 Aquisição de Dados

Para realização dos experimentos fez-se um procedimento a ser seguido, a fim de diminuir erros de execução. Inicialmente, ligou-se o C – 01 e abriu-se toda a MV – 02, posteriormente ligou-se a B – 01 e ajustou-se a vazão de água através da MV – 01 para o valor desejado. Por fim, ajustou-se a vazão de ar, por meio da MV – 02, e esperou-se de 3 a 4 minutos para garantir a estacionaridade das séries de dados coletadas.

A aquisição dos dados foi feita com auxílio do Arduino modelo Nano e da linguagem de programação *Python* versão 3.7. Primeiramente, conectou-se, com a assistência de uma *protoboard*, todos os sensores ao Arduino já ligado ao computador. Utilizando o ambiente de desenvolvimento do Arduino, realizaram-se as leituras, com um tempo de amostragem de 3 segundos, e processamento dos sinais dos sensores que, por fim, foram disponibilizados no monitor serial. Então, por meio do emprego de *Python*, no ambiente de desenvolvimento *PyCharm*, fez-se uso da biblioteca *PySerial* para realizar a comunicação serial entre Arduino e *Python* possibilitando a obtenção dos valores disponibilizados pelo Arduino no monitor serial. Assim, os dados foram adquiridos por 3 minutos e salvos para futura inspeção.

Após o levantamento dos dados, realizou-se uma inspeção para buscar problemas óbvios nesse conjunto, por exemplo, a presença de valores negativos ou congelados e erros no sinal dos sensores. Essa inspeção foi realizada visualmente, imediatamente após o término de um experimento, através da observação dos valores máximos, médios, mínimos e desvio padrão para cada variável selecionada.

3.3 Processamento de Dados

Durante a etapa de processamento dos dados, realizou-se a identificação de *outliers* e seleção de variáveis com auxílio da linguagem de programação *Python* no ambiente de desenvolvimento *Google Colab*. A metodologia utilizada para identificação de outliers foi a baseada no desvio absoluto da mediana (MAD), onde os valores das variáveis para cada experimento que estivessem a mais de 3 MAD da sua mediana foram considerados outliers e substituídos pela sua mediana do experimento. Após realizado o tratamento dos outliers, calculou-se a média e o desvio padrão para as variáveis do sistema, a fim de utilizá-las nesse formato para modelagem (Tabela 3.1) e, por fim, transformou-se o conjunto dos dados para média zero e variância unitária via função *preprocessing.StandardScaler* da biblioteca *Scikit Learn* (Buitinck et al., 2013) disponível em *Python*. Para seleção de variáveis, a metodologia *Backward Elimination* foi adotada. Realizou-se essa técnica em *Python* com auxílio da biblioteca *Stats Models* (Seabold e Perfold, 2010).

Tabela 3.1: Lista de variáveis criadas

Sensores	Variável Média	Variável Desvio Padrão
VT – 01	μ_{VT-01}	σ_{VT-01}
VT – 02	μ_{VT-02}	σ_{VT-02}
VT – 03	μ_{VT-03}	σ_{VT-03}
GT – 01	μ_{GT-01}	σ_{GT-01}
GT – 02	μ_{GT-02}	σ_{GT-02}
GT – 03	μ_{GT-02}	σ_{GT-03}
ST – 01	μ_{ST-01}	σ_{ST-01}
ST – 02	μ_{ST-02}	σ_{ST-02}
ST – 03	μ_{ST-03}	σ_{ST-03}
PDT – 01	μ_{PDT-01}	σ_{PDT-01}
FT – 02	μ_{FT-02}	σ_{FT-02}

3.4 Desenvolvimento do Modelo

Para realização da escolha de modelos candidatos necessitou-se, inicialmente, elencar os diferentes tipos de analisadores virtuais que poderiam ser propostos baseados nas experimentações realizadas. Concluiu-se que dois MPFMs distintos com diferentes graus de complexidade poderiam ser concebidos. O objetivo desses dois analisadores é apresentado em ordem crescente de complexidade:

1. Predição da vazão individual das fases exclusivamente para o escoamento estratificado.
2. Predição da vazão individual das fases para padrões escoamentos experimentados (estratificado, plug e golfada).

O primeiro e o segundo analisador tiveram etapas de desenvolvimento idênticas. Após a seleção das variáveis realizou-se a divisão do conjunto de dados através da função *model_selection.train_test_split* da biblioteca *Scikit Learn*, onde 80% dos dados foram destinados para o treinamento e 20% para a validação do modelo. Dessa forma, os modelos escolhidos tiveram seus parâmetros ajustados através do conjunto de treinamento e então foram validados utilizando o conjunto de validação. A métrica de performance utilizada para validação dos modelos foi o coeficiente de determinação. As variáveis de saída utilizadas para ajuste dos modelos foram a vazão de ar (F_{AR}) e a vazão de água (F_{H_2O}). Utilizou-se o método de Regressão Linear Multivariável com o conjunto de variáveis selecionadas como primeiro

modelo devido à sua simplicidade. Em seguida, usou-se a biblioteca *Tensor Flow* (Abadi et al., 2016), disponível para *Python*, com a finalidade de construir uma FANN para cada uma das variáveis de saída. Utilizou-se como parâmetros para criação dos modelos FANN uma camada oculta, função de ativação tangente hiperbólica e função objetivo erro quadrado médio. O número de neurônios empregado na camada oculta foi variado entre 1 e 15, a fim de encontrar a estrutura adequada para modelagem dos dados. Para cada arquitetura treinaram-se 1000 Redes Neurais, a fim de tentar encontrar o mínimo global na etapa de estimação de parâmetros, já que a inicialização dos pesos sinápticos é realizada aleatoriamente. Além disso, utilizou-se como critério de parada do ajuste do modelo o momento em que a função objetivo não apresentasse mais variações significativas.

4 Resultados

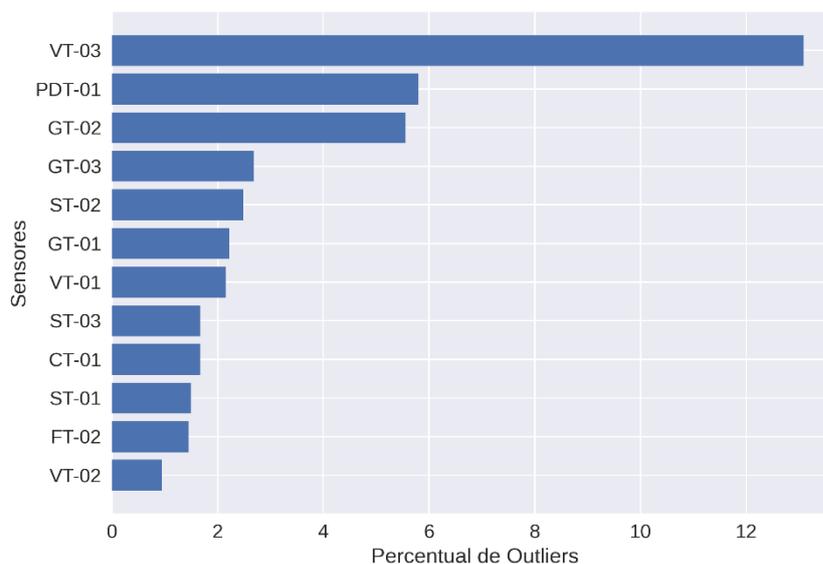
4.1 Aquisição de Dados

Tendo em vista que o tempo de coleta de dados para os experimentos foi de 3 minutos e o tempo de amostragem 3 segundos, obteve-se para cada experimento 60 observações. A inspeção dessas observações, após os experimentos, não identificou nenhum valor com algum problema claro. No entanto, nessa etapa verificou-se que as medidas realizadas pelo IT – 01 permaneceram congeladas na grande maioria dos experimentos realizados. Por conseguinte, os dados coletados referentes à essa variável foram removidos, a fim de não comprometer as etapas posteriores.

4.2 Processamento de Dados

A identificação dos *outliers* foi realizada através da metodologia baseada na mediana. Com a aplicação dessa metodologia no conjunto de dados de cada experimento pode-se identificar *outliers* presentes na leitura dos sensores. A Figura 4.1 mostra o percentual de outliers por sensor. Esses pontos foram substituídos por suas medianas do respectivo experimento.

Figura 4.1: Percentual de *outliers* referente a todas leituras realizadas pelos sensores segundo metodologia MAD.



Fonte: Do autor.

Necessitou-se realizar a etapa de seleção de variáveis para construção de cada modelo utilizado internamente em um analisador virtual. Logo, para cada um dos dois analisadores realizou-se a seleção de variáveis. Além disso, para cada analisadores necessitou-se realizar a seleção de variáveis duas vezes, visto que há a predição de duas variáveis distintas (F_{AR} e F_{H2O}). A Tabela 4.1 indica as variáveis selecionadas para cada caso.

Tabela 4.1: Variáveis selecionadas através do método *Backward Elimination*.

Analisador	Variável de Saída	Variáveis Selecionadas
1	F_{AR}	μ_{VT-01} , μ_{VT-03} , σ_{PDT-01} , σ_{FT-02} , μ_{GT-01} , μ_{GT-02} , σ_{GT-02} , μ_{GT-03} , σ_{GT-03}
	F_{H2O}	μ_{FT-02} , σ_{FT-02} , μ_{GT-02} , σ_{GT-02} , μ_{ST-01} , σ_{ST-01} , σ_{ST-03}
2	F_{AR}	σ_{PDT-01} , σ_{FT-02} , μ_{ST-01} , σ_{ST-01} , σ_{ST-02} , σ_{ST-03}
	F_{H2O}	μ_{FT-02} , σ_{FT-02} , μ_{GT-02} , σ_{GT-02} , μ_{GT-03} , μ_{ST-01} , σ_{ST-01} , σ_{ST-02} , σ_{ST-03}

4.3 Desenvolvimento do Modelo

4.3.1 Medidor de Vazão Multifásico – 1

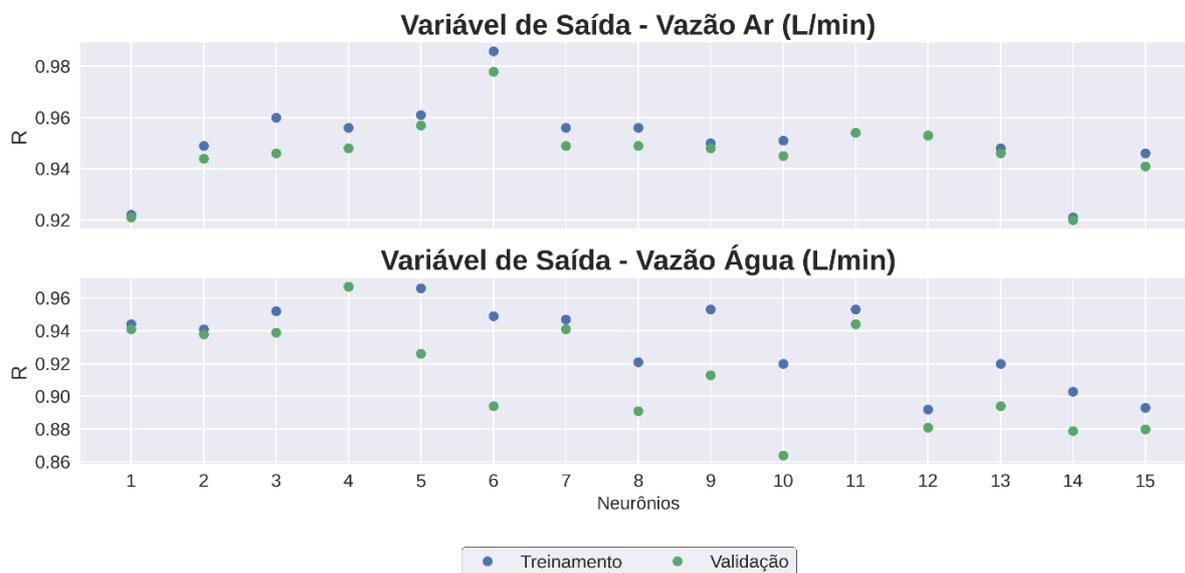
Com base na seleção de variáveis efetuada pelo método *Backward Elimination* realizou-se o ajuste dos dados para um modelo MLR. Os resultados do coeficiente de correlação para o conjunto de treinamento e validação são apresentados na Tabela 4.2. Nota-se que os valores de coeficiente de determinação para o conjunto de treino foram maiores do que aqueles do conjunto de validação, visto que o segundo grupo consiste de observações não utilizadas para o ajuste dos parâmetros do modelo. Além disso, a relação presente entre os valores preditos e as variáveis de saída revela que esses modelos conseguiram, com certo grau de qualidade, representar o sistema proposto.

Tabela 4.2: Coeficientes de correlação para modelo MLR.

Variável de Saída	R Treino	R Validação
Vazão de Ar	0,930	0,899
Vazão de Água	0,953	0,945

Para modelagem utilizando FANNs, realizou-se o treinamento do modelo no intervalo de 1 a 15 neurônios na camada oculta. A Figura 4.2 apresenta os valores do coeficiente de correlação para as melhores Redes Neurais dentro do intervalo de neurônios testados. Percebe-se que o maior valor para o coeficiente foi observado para o número de neurônios igual a 6, para variável de saída F_{AR} , com R igual 0,986 e 0,978 para treinamento e validação respectivamente, e 4, para variável F_{H_2O} , com R igual 0,967 e 0,965 para treinamento e validação respectivamente. Logo selecionaram-se esses modelos como os representantes finais das Redes Neurais. O erro médio absoluto e o erro relativo médio obtidos foram, respectivamente, 0,27 L/min e 11,41 % para F_{AR} e 0,02 L/min e 6,85 % para F_{H_2O} .

Figura 4.2: Coeficientes de correlação em função do número de neurônios na camada oculta das Redes Neurais do MPFM-1 para variáveis de saída: vazão de ar e água.



Fonte: Do autor.

4.3.2 Medidor de Vazão Multifásico – 2

Com base na seleção de variáveis realizada pelo método Backward Elimination, realizou-se o ajuste dos dados para um modelo MLR. Os resultados do coeficiente de correlação para o conjunto de treinamento e validação são apresentados na Tabela 4.3. Percebe-se, que houve uma redução nos valores dos coeficientes de correlação para os conjuntos de treinamento e validação no caso da vazão de ar, ao passo que essa métrica apresentou uma pequena melhora para vazão de água

Tabela 4.3: Coeficientes de correlação para modelo MLR.

Variável de Saída	R Treino	R Validação
Vazão de Ar	0,849	0,835
Vazão de Água	0,974	0,964

A modelagem das FANNs utilizadas para esse modelo seguiu os mesmos passos realizados para o MPFM anterior. A Figura 4.3 mostra os resultados obtidos para as diversas configurações da camada oculta. Os melhores resultados foram obtidos pelas FANNs com 8 neurônios na camada oculta, para variável de saída vazão de ar, com R de 0,926 e 0,901 para treinamento e validação respectivamente, e 6 neurônios na camada oculta, para variável vazão de água, com R de 0,991 e 0,989 para treinamento e validação respectivamente. O erro médio absoluto e o erro relativo médio obtidos foram, respectivamente, 0,42 L/min e 18,40 % para F_{AR} e 0,02 L/min e 6,13 % para F_{H_2O} . O aumento dos erros observados para vazão de ar pode ser entendido pela intensificação da interação entre as variáveis de saída presente nos experimentos com maiores vazões de água

Figura 4.3: Coeficientes de correlação em função do número de neurônios na camada oculta das Redes Neurais do MPFM-2 para variáveis de saída: vazão de ar e água.



Fonte: Do autor.

4.4 Resumo dos Resultados

A utilização das técnicas de Regressão Linear Multivariável e de Redes Neurais *feedforward* para construção dos MPFMs mostrou-se satisfatória. Os modelos FANN, no entanto, obtiveram performances superiores àquelas apresentadas pelos modelos MLR para correlacionar os dados de entrada com as variáveis de saída, conforme indica a Tabela 5.1. Além disso, os coeficientes de correlação obtidos pelas FANNs estão de acordo àqueles encontrados no trabalho de Shaikhina e Khovanova (2017) onde obtiveram valores de R para o conjunto de validação entre 0,92 e 0,935 para aplicações medicinais.

Tabela 4.4: Comparação entre modelos matemáticos empregados.

MPFM	Variáveis de Saída	Modelo	R Treinamento	R Validação
1	F_{ar} e F_{H_2O}	MLR	0,930 e 0,953	0,899 e 0,945
1	F_{ar} e F_{H_2O}	FANN	0,986 e 0,967	0,978 e 0,965
2	F_{ar} e F_{H_2O}	MLR	0,849 e 0,974	0,835 e 0,964
2	F_{ar} e F_{H_2O}	FANN	0,926 e 0,991	0,901 e 0,989

Meng et al. (2010) obtiveram erros relativos médios entre 5 e 10 % para predição das vazões mássicas de um escoamento ar e água utilizando um tubo de Venturi e leituras da resistência da mistura em diversos pontos. Nota-se que os resultados obtidos neste trabalho para predição da vazão de água estão de acordo com o trabalho de Meng et al. (2010)

apresentando erros relativos médios de 6,85 % e 6,11 %, respectivamente, para o MPFM 1 e 2. Contudo, o mesmo não pode ser dito sobre a vazão de ar onde os erros relativos médios foram de 11,41 % e 18,42 %, respectivamente, para MPFM 1 e 2. Atribui-se a esse fato, a medição da vazão de entrada de ar ser realizada via rotâmetro, ou seja, sem sinal de saída. Logo, a interação existente entre as vazões pode ter ocasionados desvios nos valores médios assumidos para F_{AR} . Além disso, o conjunto de sensores utilizados neste trabalho são mais simples do que o utilizado por Meng et al. (2010).

A partir dos resultados obtidos na etapa de seleção de variáveis pode-se constatar que todos os instrumentos utilizados tiveram alguma medida participando do conjunto de variáveis selecionadas para cada MPFM. Logo, a utilização de um tubo de venturi com sensor de pressão diferencial, acelerômetro e giroscópio, medidor de vazão do tipo ventoinha e sensores de vibração mostraram-se capazes de realizar a predição das vazões individuais das fases para um escoamento multifásico ar e água.

5 Conclusões e Trabalhos Futuros

O presente trabalho teve por objetivo a construção de medidores de vazão multifásico capazes de medir as vazões volumétricas de ar e água em um escoamento multifásico. Em vista disso, utilizou-se na estrutura dos MPFMs sensores de vibração, acelerômetro e giroscópio, vazão do tipo ventoinha e um tubo de Venturi com sensor de pressão diferencial.

Os MPFMs desenvolvidos apresentaram bons resultados. Os erros relativos médios obtidos para vazão volumétrica de ar e água foram, respectivamente, 11,41 % e 6,85 %, para o MPFM-1, e 6,11 % e 18,42 % para o MPFM-2. Quando comparado com os resultados obtidos no trabalho de Meng et al. (2010), percebe-se uma diferença nos erros relativos médios obtidos para vazão de ar. Contudo, a implementação de um conjunto de sensores mais simples associada com a utilização de um rotâmetro para medição de referência da vazão de ar justifica as diferenças observadas. Logo, nota-se que o grupo de sensores utilizado é promissor para caracterização de escoamentos multifásicos.

A construção do sistema em bancada possibilitou a fácil execução e reprodutibilidade dos experimentos. Todavia, a utilização de um rotâmetro para medição da vazão de ar de referência mostrou-se prejudicial dada a baixa resolução do instrumento, ausência de sinal de saída e interação entre variáveis do sistema. Com a estrutura pronta pode-se realizar o planejamento dos experimentos baseados nas condições operacionais atingíveis pelo sistema e a coleta de dados através da utilização de um Arduino Nano e da linguagem de programação *Python*. Os dados obtidos foram analisados e com isso removeu-se as observações do sensor de condução, visto que apresentou valores congelados para grande parte dos experimentos, além disso, tratou-se dos *outliers*, garantindo a qualidade dos dados utilizados nas etapas posteriores. As variáveis utilizadas nos modelos para predição da vazão de ar e água foram selecionadas através do método *Backward Elimination*. Posteriormente, testou-se os modelos MLR e FANN para correlacionar as variáveis selecionadas às variáveis de saída (F_{AR} e F_{H_2O}) utilizando conjuntos de treinamento e validação. O modelo de FANNs foi selecionado dada a melhor performance no treinamento e validação, possibilitando o desenvolvimento e bons resultados obtidos para os medidores de vazão multifásicos.

Como considerações futuras estão a aplicação do conjunto de sensores utilizados para o desenvolvimento dos MPFMs apresentados neste trabalho em escoamentos multifásicos com diferentes fases envolvidas, por exemplo, água e óleo, óleo e ar ou água, óleo e ar. Além disso, a adição de instrumentos baseados em imagem, como malha de fios (Velasco Peña e Rodriguez, 2015), e a utilização de outros modelos matemáticos para construção dos analisadores são outras atividades que podem ser estudadas.

REFERÊNCIAS

ABADI, M.; BARHAM, P.; CHEN, J.; et al. TensorFlow : A System for Large-Scale Machine Learning This paper is included in the Proceedings of the TensorFlow : A system for large-scale machine learning. 2016.

ABEYKOON, C. **Design and Applications of Soft Sensors in Polymer Processing: A Review**IEEE Sensors JournalInstitute of Electrical and Electronics Engineers Inc., , 15 abr. 2019.

ABYANEH, H. Z. Evaluation of multivariate linear regression and artificial neural networks in prediction of water quality parameters. **Journal of Environmental Health Science and Engineering**, v. 12, n. 1, 2014.

BARBARIOL, T.; FELTRESI, E.; SUSTO, G. A. **Machine Learning approaches for Anomaly Detection in Multiphase Flow Meters**. IFAC-PapersOnLine. **Anais...Elsevier B.V.**, 1 jan. 2019

BARNEA, D. A unified model for predicting flow-pattern transitions for the whole range of pipe inclinations. **International Journal of Multiphase Flow**, v. 13, n. 1, p. 1–12, 1 jan. 1987.

BARNEA, D.; SHOHAM, O.; TAITEL, Y. Flow pattern transition for downward inclined two phase flow; horizontal to vertical. **Chemical Engineering Science**, v. 37, n. 5, p. 735–740, 1 jan. 1982.

BRAUNER, N.; MOALEM MARON, D. Flow pattern transitions in two-phase liquid-liquid flow in horizontal tubes. **International Journal of Multiphase Flow**, v. 18, n. 1, p. 123–140, 1 jan. 1992.

BRENNEN, C. E. **Fundamentals of Multiphase Flows**. 2005.

BUITINCK, L.; LOUPPE, G.; BLONDEL, M.; et al. API design for machine learning software: experiences from the scikit-learn project. 1 set. 2013.

CORNELIUSSEN, S.; COUPUT, J.-P.; DAHL, E.; et al. **Handbook of Multiphase Flow Metering**. [s.l.: s.n.].

CRAWFORD, T. J.; WEINBERGER, C. B.; WEISMAN, J. Two-phase flow patterns and void fractions in downward flow Part I: Steady-state flow patterns. **International Journal of Multiphase Flow**, v. 11, n. 6, p. 761–782, 1 nov. 1985.

DOS SANTOS, E. N. Development and application of wire-mesh sensors for high-speed multiphase flow imaging. n. August, p. 205, 2015.

FACCHIN, S. **Técnicas de análise multivariável aplicadas ao desenvolvimento de analisadores virtuais**. [s.l.] Universidade Federal do Rio Grande do Sul, 2005.

FALCONE, G.; HEWITT, G. F.; ALIMONTI, C.; et al. Multiphase Flow Metering: Current Trends and Future Developments. **Proceedings - SPE Annual Technical Conference and Exhibition**, n. October 2014, p. 1291–1303, 2001.

FALCONE, G.; HEWITT, G. F.; ALIMONTI, C. **Multiphase Flow Metering: Principles and Applications** *Annals of Physics*, 2009.

FORTUNA, L.; GRAZINI, S.; RIZZO, A.; et al. **Soft Sensors for Monitoring and Control of Industrial Processes**. [s.l.] Springer London, 2007.

GELADI, P.; KOWALSKI, B. R. Partial least-squares regression: a tutorial. **Analytica Chimica Acta**, v. 185, n. C, p. 1–17, 1 jan. 1986.

GOVIER, G. .; AZIZ, K. **The Flow of Complex Mixtures in Pipes**. [s.l.] van Nostrand Reinhold Company, 1972.

HASAN, A. R.; KABIR, C. S. **New model for two-phase oil/water flow: production log interpretation and tubular calculations**. Society of Petroleum Engineers of AIME, (Paper) SPE. **Anais...** Publ by Soc of Petroleum Engineers of AIME, 1 maio 1988

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. [s.l.] Macmillan, 1994.

HEWITT, G. F. Three-phase gas-liquid-liquid flows in the steady and transient states. **Nuclear Engineering and Design**, v. 235, n. 10–12, p. 1303–1316, maio 2005.

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. **Neural Networks**, v. 2, n. 5, p. 359–366, 1 jan. 1989.

KADLEC, P.; GABRYS, B.; STRANDT, S. **Data-driven Soft Sensors in the process industry** *Computers and Chemical Engineering* Pergamon, , 21 abr. 2009.

MANDHANE, J. M.; GREGORY, G. A.; AZIZ, K. A flow pattern map for gas-liquid flow in horizontal pipes. **International Journal of Multiphase Flow**, v. 1, n. 4, p. 537–553, 30 out. 1974.

MENG, Z.; HUANG, Z.; WANG, B.; et al. Air-water two-phase flow measurement using a Venturi meter and an electrical resistance tomography sensor. **Flow Measurement and Instrumentation**, v. 21, n. 3, p. 268–276, 1 set. 2010.

MERIBOUT, M.; AL-RAWAHI, N. Z.; AL-NAAMANY, A. 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.

MERIBOUT, M.; AL-NAAMANY, A. M.; AL BUSAIDI, K. An industrial-prototype acoustic array for real-time emulsion layer detection in oil storage tanks. **IEEE Sensors Journal**, v. 9, n. 12, p. 1838–1846, 2009.

MUS, E. A.; TOSKEY, E. D.; BASCOUL, S. J. F.; et al. **Added Value of a Multiphase Flow Meter in Exploration Well Testing**. Society of Petroleum Engineers (SPE), 30 abr. 2001

PEARSON, R. K. Outliers in process modeling and identification. **IEEE Transactions on Control Systems Technology**, v. 10, n. 1, p. 55–63, jan. 2002.

PISA, I.; SANTÍN, I.; VICARIO, J. L.; et al. ANN-based soft sensor to predict effluent violations in wastewater treatment plants. **Sensors (Switzerland)**, v. 19, n. 6, p. 1280, 2 mar. 2019.

POVEY, M. J. W. **Ultrasonic Techniques for Fluids Characterization**. [s.l.] Elsevier, 1997.

QIN, S. J. Neural Networks for Intelligent Sensors and Control — Practical Issues and Some Solutions. In: **Neural Systems for Control**. [s.l.] Elsevier, 1997. p. 213–234.

SEABOLD, S.; PERKFOLD, J. **Statsmodels: Econometric and Statistical Modeling with Python**. 2010.

SERAPIÃO, A. B. S.; BANNWART, A. C. Knowledge Discovery for Classification of Three-Phase Vertical Flow Patterns of Heavy Oil from Pressure Drop and Flow Rate Data. **Journal of Petroleum Engineering**, v. 2013, p. 1–8, 19 dez. 2013.

SHAIKHINA, T.; KHOVANOVA, N. A. Handling limited datasets with neural networks in medical applications: A small-data approach. **Artificial Intelligence in Medicine**, v. 75, p. 51–63, 1 jan. 2017.

TAITEL, Y. Stability of severe slugging. **International Journal of Multiphase Flow**, v. 12, n. 2, p. 203–217, 1 mar. 1986.

TAYLOR, R. Interpretation of the Correlation Coefficient: A Basic Review. **Journal of Diagnostic Medical Sonography**, v. 6, n. 1, p. 35–39, 1 jul. 1990.

TREVISAN, F.; BANNWART, A. C. **THREE-PHASE FLOW PATTERNS AND PRESSURE DROP FOR HEAVY CRUDE OIL-WATER-GAS HORIZONTAL FLOW**. Begell House, 2006

VELASCO PEÑA, H. F.; RODRIGUEZ, O. M. H. Applications of wire-mesh sensors in multiphase flows. **Flow Measurement and Instrumentation**, v. 45, p. 255–273, 2015.

WANG, G.; HAO, J.; MAB, J.; et al. A new approach to intrusion detection using Artificial Neural Networks and fuzzy clustering. **Expert Systems with Applications**, v. 37, n. 9, p. 6225–6232, 1 set. 2010.

WHITAKER, T. S. **Multiphase flow measurement: current and future developments**. IEE Colloquium on Advances in Sensors for Fluid Flow Measurement. **Anais...IEE**, 1996 Disponível em: <https://digital-library.theiet.org/content/conferences/10.1049/ic_19960569>. Acesso em: 12 abr. 2021

WILLIS, M. J.; MONTAGUE, G. A.; DI MASSIMO, C.; et al. Artificial neural networks in process estimation and control. **Automatica**, v. 28, n. 6, p. 1181–1187, 1 nov. 1992.

WU, C.; TU, X. Biological and fermentative conversion of syngas. In: **Handbook of Biofuels Production: Processes and Technologies: Second Edition**. [s.l.] Elsevier Inc., 2016. p. 335–357.

ZAMPROGNA, E.; BAROLO, M.; SEBORG, D. E. Optimal selection of soft sensor inputs for batch distillation columns using principal component analysis. **Journal of Process Control**, v. 15, n. 1, p. 39–52, 1 fev. 2005.

APÊNDICE A

6 Técnicas de Modelagem e Construção de Analisadores Virtuais

6.1 Conceitos básicos

Analisadores virtuais são sensores não físicos que utilizam modelos matemáticos baseados em dados. Esses modelos são capazes de descrever processos com diferentes níveis de complexidade, relacionando parâmetros de processo, com medição disponível, àqueles sem medição ou de difícil análise (Pisa et al., 2019).

Os analisadores virtuais são classificados em dois grupos, os analisadores orientados ao modelo (do inglês, *model-driven*) e os analisadores orientados aos dados (do inglês, *data-driven*). Enquanto os sensores orientados ao modelo buscam representar estados estacionários, os sensores voltados aos dados possuem maior potencial na representação de processos dinâmicos (Abeykoon, 2019).

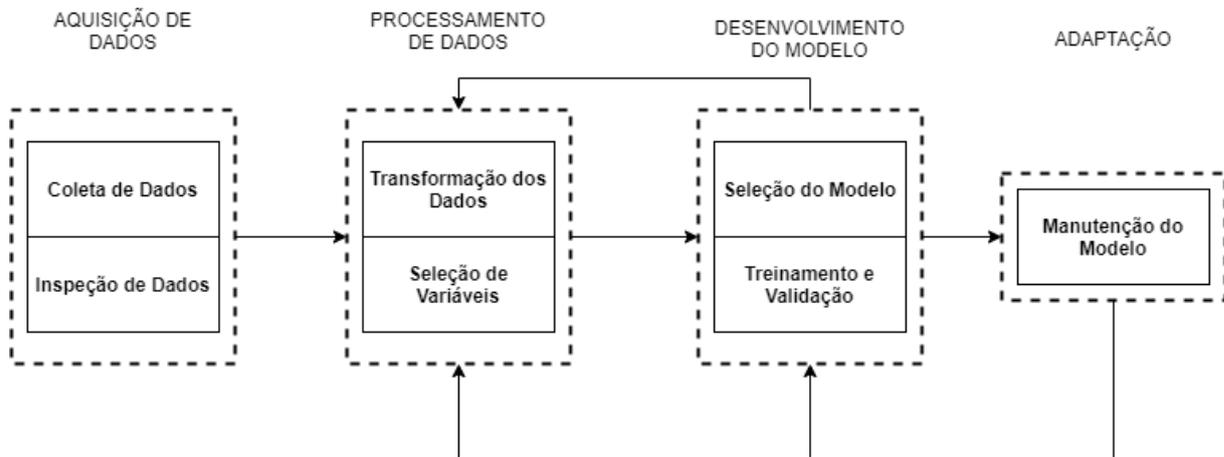
Segundo Facchin (2005), o desenvolvimento dos analisadores virtuais é baseado em três principais características: o modelo matemático utilizado, as variáveis desse modelo e o método de correção empregado pelo modelo. Além disso, Facchin (2005) destaca a capacidade de adaptação dos analisadores virtuais frente às variações nos processos. Assim, com base nos dados analíticos e nas variáveis secundárias de processo, o sensor é capaz de otimizar o modelo matemático corrigindo as flutuações sem afetar a variável de saída inferida.

O modelo matemático é um sistema de equações que possui a função de estabelecer a relação entre as variáveis de processo presentes no conjunto de entrada e a variável que se deseja inferir. Segundo Facchin (2005), as três principais classes de modelos são definidas da seguinte forma:

- Fenomenológicos: utilizam princípios científicos e levam em consideração balanços de energia, momento e massa para representação do sistema. Possuem alta capacidade extrapolativa, porém demandam elevado esforço para modelar o sistema.
- Empíricos: modelos empíricos aplicam métodos matemáticos às observações de experimentos, com a finalidade de representa-los. A capacidade extrapolativa é comprometida, visto que apenas os dados são modelados, não o processo completo, relacionando as variáveis de entrada e saída.
- Semi-empíricos: resultam da utilização concomitante de modelos empíricos e fenomenológicos, onde o fenômeno é conhecido, porém há dados desconhecidos que são obtidos experimentalmente que podem ser tratados com o uso de modelos matemáticos.

Segundo Kadlec et al. (2009) e Abeykoon (2019), as etapas básicas para construção de analisadores virtuais baseados em modelagem empírica envolvem a aquisição de dados, processamento dos dados, desenvolvimento do modelo e manutenção do modelo (Figura A.1). Cada uma das etapas citadas será descrita a seguir.

Figura A.1: Etapas básicas para construção de um analisador virtual.



Fonte: Adaptado de Kadlec et al. (2009).

6.2 Aquisição de Dados

Para iniciar-se com a construção de um analisador virtual faz-se a coleta e inspeção dos dados a serem utilizados. O objetivo dessa etapa é fazer a identificação de estados estacionários e de possíveis inconsistências nos dados, que comprometeriam a análise. A inspeção foca na observação e eliminação de distúrbios claros presentes nos dados de processo (Kadlec et al., 2009).

6.3 Processamento de Dados

O propósito dessa etapa é realizar transformações nos dados para que sua utilização na modelagem matemática seja a mais eficiente possível (Kadlec et al., 2009). Kadlec et al. (2009) cita como principais atividades desse estágio o tratamento de dados faltantes, a detecção e tratamento de pontos discrepantes, também chamados de *outliers*, e a seleção de variáveis para modelagem matemática.

A explicação para dados faltantes tem relação com falhas de registro dos bancos de dados e até mesmo de funcionamento de sensores. Sua correção pode ser realizada através de técnicas para representar o valor correspondente ao dado faltante, como por exemplo, a interpolação dentro de um intervalo ou através da exclusão de todo aquele conjunto relativo aos dados inexistentes quando o intervalo for muito significativo (Wang et al., 2010).

Os outliers podem ser classificados com base na sua facilidade de identificação. Os fácil identificação e representam situações fisicamente impossíveis, como por exemplo, vazões negativas ou temperaturas excessivamente altas. Os de difícil identificação são representados por valores possíveis de serem alcançados, mas excedem restrições físicas e são identificados pela correlação dos dados, como por exemplo, flutuações elevadas nas variáveis de um sistema de dinâmica estável (Qin, 1997).

Pearson (2002) cita como modo de identificação de *outliers* métodos baseados no desvio padrão e desvio absoluto da mediana (MAD, do inglês *Median Absolute Deviation*). No caso baseado no desvio padrão, classifica-se as observações distantes por mais de 3 desvios padrões da média como *outliers*. Contudo, essa metodologia tende a subestimar o número de *outliers* devido a inflação originada por esses pontos na variância estimada. O segundo método é equivalente ao primeiro, porém utiliza-se a mediana, como valor de referência, e o MAD, como valor de distância, para realizar a identificação do ponto, sendo esse modo mais robusto à presença de *outliers*. A equação A.1 expõe o método de cálculo do MAD, onde x é o conjunto de dados de uma variável, M é o operador que retorna a mediana do conjunto e 1,4826 é uma constante que assume a normalidade do conjunto sem *outliers*.

$$\text{MAD}=1,4826.M(|x-M(x)|) \quad (\text{A.1})$$

Segundo Qin (1997), a correção aplicada aos outliers, tanto aos óbvios quanto aos não óbvios, pode ser realizada de três formas. A primeira consiste na substituição do valor pela média ou mediana da variável no intervalo analisado. Como segunda opção, pode-se realizar a substituição por valores máximos ou mínimos do intervalo ou realizar o tratamento do ponto como um dado faltante.

Segundo Fortuna et al. (2007) a seleção de variáveis é um momento crucial no desenvolvimento de analisadores virtuais, uma vez que a seleção de variáveis não sensíveis afeta diretamente a eficiência do modelo matemático utilizado. A escolha inadequada das variáveis podem causar problemas numéricos de singularidade e de performance do modelo proposto ressaltando a importância dessa etapa (Zamprognia et al., 2005).

Para execução da seleção das variáveis há diversos mecanismos que podem ser empregados. Facchin (2005) cita como possíveis métodos de escolha as metodologias de busca exaustiva, sequenciais ou *stepwise* e genética. A metodologia de busca exaustiva, embora garanta a seleção da melhor seleção do subconjunto de variáveis para o modelo apresenta um elevado custo computacional à medida que o número de variáveis candidatas aumenta, visto que o número de modelos a serem testados é 2^k , onde k é o número de variáveis. Os algoritmos genéticos emulam o comportamento evolutivo, esse método é muito utilizado em problemas de otimização, entretanto não garantem que a solução encontrada seja a melhor possível. Por fim, os algoritmos sequenciais fundamentam-se na adição ou remoção de variáveis por etapas de acordo com a melhora significativa do modelo. Essa metodologia possui três variantes:

- Método de adição (*Forward Selection*): inicia-se com um modelo sem variáveis e cria-se modelos com uma das variáveis selecionáveis e, posteriormente modelos com combinações dessas variáveis. Avalia-se, através de um teste F, por exemplo, se a adição da variável ocasionou melhoria significativa para o modelo. O procedimento é repetido até que se atinja uma etapa onde a adição das variáveis não ocasiona melhoria significativa.
- Método de eliminação (*Backward Elimination*): inicia-se com um modelo contendo todas as variáveis selecionáveis e a cada etapa remove-se as uma das variáveis do modelo e verifica-se, através de um teste F, por exemplo, se houve melhora

significativa no modelo. O procedimento é repetido até que a remoção das variáveis não produza melhora significativa no modelo.

- Regressão *stepwise*: funciona como uma combinação dos dois métodos citados anteriormente. O procedimento inicia-se com um *Forward Selection* e, a partir da segunda etapa, é realizado o procedimento de *Backward Elimination* após a adição de novas variáveis, a fim de verificar se a variável adicionada não é redundante a alguma outra previamente adicionada.

6.4 Desenvolvimento do Modelo

A etapa de desenvolvimento do modelo é de suma importância para o correto funcionamento de analisadores virtuais, visto que o modelo identificará a relação entre as variáveis selecionadas e a variável de saída. O desenvolvimento é realizado através da seleção do tipo de modelo, treinamento e validação do modelo selecionado (Kadlec et al., 2009).

Segundo Kadlec et al. (2009), não há consenso sobre algum procedimento para seleção de modelos, contudo recomenda partir de modelos mais simples e então evoluir a complexidade, avaliando o desempenho de cada modelo testado. Além disso, descreve o procedimento de treinamento e validação do modelo através da divisão do grupo de dados em dois blocos, um que será destinado ao treinamento do modelo e o outro, destinado a validá-lo.

Existem diversas técnicas de modelagem aplicadas aos dados que podem ser utilizadas para o desenvolvimento do modelo. Em seu trabalho, Facchin (2005) destaca e exemplifica as técnicas de Regressão Linear Multivariável (MLR, do inglês *Multi-Linear Regression*), Regressão de Componentes Principais e Mínimos Quadrados Parciais. Kadlec et al. (2009) e Wang et al. (2010) destacam uma crescente aplicabilidade das Redes Neurais Artificiais (ANN, do inglês *Artificial Neural Network*), Máquinas de Suporte Vetorial (SVM, do inglês *Support Vector Machine*), Sistemas de Lógica Fuzzy e modelos híbridos, como os Sistemas Neuro-Fuzzy.

A validação do modelo é, na sua grande maioria, realizada em função do coeficiente de correlação (R) (Equação A.2), que avalia o grau de linearidade entre duas variáveis, indicando qual modelo melhor se ajusta aos dados (Fortuna et al., 2007; Taylor, 1990). Onde x_i e y_i ($i = 1, \dots, n$) são os valores pontuais das variáveis x e y respectivamente, e \bar{x} e \bar{y} os respectivos valores médios para as variáveis

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (\text{A.2})$$

6.5 Adaptação

O desempenho da estimação dos analisadores virtuais é um ponto bastante sensível pelo fato de serem diretamente afetados por variações nas características do processo. Esse fato pode ser facilmente observado através da comparação da variável predita pelo modelo e da variável real. A fim de superar as variações do processo, Facchin (2005) cita como possibilidades a aplicação do filtro de Kalman estendido e a correção bias, que consiste em somar ao modelo um termo relacionado à diferença entre valor predito e valor real em um intervalo de referência.

APÊNDICE B

Este capítulo tem o intuito de compartilhar *links* que direcionam para páginas de venda dos equipamentos utilizados neste trabalho (Tabela B.1) e para um [repositório](#) que contém todos os dados levantados nos experimentos realizados.

Tabela B.1: Descrição dos equipamentos utilizados com *hyperlinks* para páginas de venda

TAG	Descrição
FT - 01	Sensor de vazão tipo ventoinha utilizado para obtenção da vazão de água pura.
FT - 02/CT - 01	Sensor de vazão tipo ventoinha com sensor de condutividade embutido utilizado no MPFM
ST - 01/02/03 GT - 01/02/03	Acelerômetro e giroscópio utilizado no MPFM
VT - 01	Sensor de vibração piezoelétrico utilizado no MPFM
VT - 02	Sensor de vibração piezoelétrico utilizado no MPFM
VT - 03	Sensor de vibração piezoelétrico utilizado no MPFM
B - 01	Bomba submersível utilizada para inserção de água no sistema
C - 01	Compressor utilizado para inserção de ar no sistema
FV - 01	Válvula agulha manual com conexão de 12 mm. Utilizada para controle da vazão de água no sistema.