AUTARQUIA ASSOCIADA À UNIVERSIDADE DE SÃO PAULO

**Deteccção de Contornos em Imagens de Padrões de Escoamento Bifásico com
Alta Fração de Vazio em Experimentos de Circulação Natural com o uso de
Processamento Inteligente**

REGIS CORTEZ BUENO

**Tese apresentada como parte dos
requisitos para obtenção do Grau de
Doutor em Ciências na Área
de Tecnologia Nuclear - Reatores**

Orientador:

Prof. Dr. Roberto Navarro de Mesquita

**São Paulo
2016**

INSTITUTO DE PESQUISAS ENERGÉTICAS E NUCLEARES
Autarquia associada à Universidade de São Paulo

**Deteccção de Contornos em Imagens de Padrões de Escoamento Bifásico com
Alta Fração de Vazio em Experimentos de Circulação Natural com o uso de
Processamento Inteligente**

REGIS CORTEZ BUENO

**Tese apresentada como parte dos
requisitos para obtenção do Grau de
Doutor em Ciências na Área
de Tecnologia Nuclear - Reatores**

Orientador:

Prof. Dr. Roberto Navarro de Mesquita

Versão Corrigida
Versão Original disponível no IPEN

São Paulo
2016

Dedico esse trabalho ao G.'A.'D.'U.', o Deus do meu coração e da minha compreensão, aos meus pais, Amador Bueno e Fátima de Lourdes Cortez Bueno pela imensa ajuda, carinho e amor que me deram todos esses anos, a minha amada esposa Luciane pelo carinho e auxílio para o término do doutorado e para a minha querida filha Yasmim que mora no meu coração. Todos vocês são os amores da minha vida!

Agradecimentos

À CAPES pelo financiamento da bolsa de estudos para o desenvolvimento desse projeto de pesquisa.

Ao meu orientador Dr. Roberto Navarro de Mesquita, pela sua flexibilidade, auxílio e pela confiança no desenvolvimento deste projeto.

Detecção de Contornos em Imagens de Padrões de Escoamento Bifásico com Alta Fração de Vazio em Experimentos de Circulação Natural com o uso de Processamento Inteligente

Regis Cortez Bueno

RESUMO

Este trabalho desenvolveu um novo método para a detecção de contornos em imagens digitais que apresentam objetos de interesse muito próximos e que contêm complexidades associadas ao fundo da imagem como variação abrupta de intensidade e oscilação de iluminação. O método desenvolvido utiliza lógica *fuzzy* e desvio padrão da declividade (Desvio padrão da declividade fuzzy - FuzDec) para o processamento de imagens e detecção de contorno. A detecção de contornos é uma tarefa importante para estimar características de escoamento bifásico através da segmentação da imagem das bolhas para obtenção de parâmetros como a fração de vazio e diâmetro de bolhas. FuzDec foi aplicado em imagens de instabilidades de circulação natural adquiridas experimentalmente. A aquisição das imagens foi feita utilizando o Circuito de Circulação Natural (CCN) do Instituto de Pesquisas Energéticas e Nucleares (IPEN). Este circuito é completamente constituído de tubos de vidro, o que permite a visualização e imageamento do escoamento monofásico e bifásico nos ciclos de circulação natural sob baixa pressão. Os resultados mostraram que o detector proposto conseguiu melhorar a identificação do contorno eficientemente em comparação aos detectores de contorno clássicos, sem a necessidade de fazer uso de algoritmos de suavização e sem intervenção humana.

Palavras-chaves: Escoamento Bifásico. Processamento de imagens. Detector de bordas. Circulação Natural. Inferência Fuzzy.

Edge detection in Images of two-phase flow patterns with high void fraction in natural circulation experiments with Intelligent Processing.

Regis Cortez Bueno

ABSTRACT

This work has developed a new method for digital image contour detection which can be successfully applied to images presenting objects of interest with high proximity and presenting complexities related with background abrupt intensity fluctuations. The developed method makes use of fuzzy logic and declivity standard deviation (Fuzzy Declivity Standard Deviation – FuzDec) to image processing and contour detection. Contour detection is an important task to estimate two-phase flow features through bubble segmentation in order to obtain parameters as void fraction and bubble diameter. FuzDec was applied to natural circulation instability images which were experimentally acquired. Image acquisition was done at the Natural Circulation Circuit (CCN) of the Instituto de Pesquisas Energéticas e Nucleares (IPEN) in Brazil. This facility is all made up with glass tubes allowing easy visualization and imaging of one-phase and two-phase flow patterns during natural circulation cycles under low pressures. Results confirm that the proposed detector can improve contour identification when compared to classical contour detector algorithms, without using smoothing algorithms or human intervention.

Keys-Words: Two-phase flow. Image processing. Edge detection. Natural circulation. Fuzzy inference.

LISTA DE TABELAS

Tabela 1: Máscaras dos operadores.....	35
Tabela 2: Classificação com diferentes valores de corte (limiares).....	52
Tabela 3: Matrizes de contingências para cada valor de corte.....	53
Tabela 4: Medidas de área associados a quantidades de n. de pontos.....	56
Tabela 5: Teoremas de Probabilidade.....	57
Tabela 6: Valores dos fluidos (líquido e gás) utilizados.....	66
Tabela 7: Regras de inferência.....	82
Tabela 8: Medidas de área sob a curva e seus respectivos pontos ROC da FIG.32.....	96
Tabela 9: Medidas de área sob a curva e seus respectivos pontos ROC da FIG.33.....	99
Tabela 10: Medidas de área sob a curva e seus respectivos pontos ROC da FIG.34.....	102
Tabela 11: Medidas dos volumes de líquido nos tubos.....	104
Tabela 12: Cálculo da fração de vazio obtida pelo experimento de 2013.....	105
Tabela 13: Cálculo da fração de vazio obtida pelo experimento de 2015.....	106
Tabela 14: Comparação dos métodos para as imagens obtidas em 2013.....	108
Tabela 15: Comparação dos métodos para as imagens obtidas em 2015 com caixa.....	109
Tabela 16: Comparação dos métodos para as imagens obtidas em 2015 sem caixa.....	110

LISTA DE FIGURAS

Figura 1: Imagens com alta fração de vazio de escoamento em escala de cinza	11
Figura 2: Padrões de escoamento gás-liquido em tubos verticais.....	22
Figura 3: Padrões de escoamento gás-liquido em tubos horizontais.....	23
Figura 4: Tarefas fundamentais para realizar o processamento de imagens....	25
Figura 5: Modelo físico de uma representação de imagens.....	28
Figura 6: Modelo Computacional.....	29
Figura 7: Equalização global do histograma.....	31
Figura 8: Modelos de Bordas.....	33
Figura 9: Representação Matricial de tamanho 3 x 3 pixels.....	35
Figura 10: Segmentação por Watershed.....	37
Figura 11: Sistema de Processamento Fuzzy.....	40
Figura 12: Curvas de Fuzzificação (Diagramas H-E) e suas respectivas funções de Pertinências para a variável linguística Temperatura....	42
Figura 13: Matriz de contingência.....	48
Figura 14: Gráfico ROC.....	50
Figura 15: Gráfico ROC.....	51
Figura 16: Curva ROC de um classificador.....	53
Figura 17: Área abaixo da Curva ROC da FIG.14.....	55
Figura 18: Arranjo experimental utilizado para a captura das imagens sob um aquecedor de 8000W.....	60
Figura 19: Arranjo experimental pelo método gravimétrico utilizado para a captura das imagens.....	62
Figura 20: Esquema experimental do escoamento bifásico em bolhas para medir a diferença de pressão (Δp).....	64
Figura 21: Imagem do escoamento bifásico.....	68

Figura 22: Diagrama de blocos da metodologia do processo do desvio padrão da declividade fuzzy para detectar o contorno das bolhas.....	71
Figura 23: Declividade da esquerda e direita.....	73
Figura 24: Imagem da bolha.....	73
Figura 25: Gráfico da declividade entre a distância (colunas) e os valores de cinza (0-255).....	74
Figura 26: Gráfico da declividade x Desvio padrão.....	78
Figura 27: Função membro dinâmica.....	81
Figura 28: Imagens Ground Truth (GT) que apresentam baixa fração de vazio com resolução de 1158 x 604 pixels.....	85
Figura 29: Imagens Ground Truth (GT) que apresentam alta fração de vazio com resolução de 432 x 165 pixels.....	86
Figura 30: Imagens Ground Truth (GT) que apresentam alta fração de vazio com resolução de 372 x 187 pixels.....	87
Figura 31: Resultado dos detectores de contornos para as imagens da FIG. 26.....	88
Figura 32: Resultado dos detectores de contornos para as imagens da fase de Refill da FIG. 27.....	89
Figura 33: Resultado dos detectores de contornos para as imagens da fase de Refill-incubation da FIG. 28.....	90
Figura 34: Análise ROC da FIG.29.....	93
Figura 35: Análise ROC da FIG.30.....	97
Figura 36: Análise ROC da FIG.31.....	101
Figura 37: Geometria dos tubos para o cálculo do volume de líquido.....	103
Figura 38: Resultado do FuzDec para medir a fração de vazio nas imagens do experimento feito 2013.....	107
Figura 39: Resultado do FuzDec para medir a fração de vazio nas imagens do experimento feito 2015 (com caixa anti-refração).....	108
Figura 40: Resultado do FuzDec para medir a fração de vazio nas imagens do experimento feito 2015 (com caixa anti-refração).....	110

SUMÁRIO

LISTA DE TABELAS.....	7
LISTA DE FIGURAS.....	8
1 INTRODUÇÃO.....	10
1.1 Objetivos.....	12
1.2 Revisão da Literatura.....	12
1.2.1. Referências Canônicas	18
2 FUNDAMENTAÇÃO TEÓRICA.....	21
2.1 Escoamento Bifásico.....	21
2.2 Processamento de Imagens.....	25
2.2.1 Modelos de Imagem.....	27
2.2.2 Aquisição de imagens.....	29
2.2.3 Equalização do Histograma.....	30
2.2.4 Abordagens Tradicionais para a Detecção de Bordas.....	32
2.3 Lógica Fuzzy.....	39
2.3.1 Fuzzificação.....	40
2.3.1.1 Principais operações Fuzzy.....	42
2.3.2 Mecanismo de Inferência.....	44
2.3.3 Defuzzificação.....	46
2.4 Análise ROC.....	47
2.4.1 Gráfico ROC.....	49
2.4.2 Curvas no espaço ROC.....	52
2.4.3 Área abaixo da Curva ROC.....	54
2.4.4 Método eficiente para a geração de Curvas ROC.....	55
3 METODOLOGIA.....	
3.1 Aquisição de imagens.....	59
3.1.1 CNN.....	60
3.1.2 Bancada Experimental do método gravimétrico.....	62
3.1.3 Medida da fração de vazio pelo método gravimétrico.....	64
3.2 Base de dados de imagens.....	66
3.2.1 Imagens de alta fração de vazio.....	66
3.2.2 Imagens de baixa fração de vazio.....	67
3.3 Pré-processamento das imagens.....	67
3.3.1 Base de imagens pré-processadas.....	68
3.3.2 Reconhecimento pela declividade fuzzy.....	69
3.3.2.1 Testes dos algoritmos de Reconhecimento de Padrões.....	69
3.4 Metodologia do Desvio Padrão da Declividade Fuzzy.....	70
3.4.1 Metodologia da Declividade.....	71
3.4.2 Detalhes de implementação.....	73
3.4.3 Método do desvio padrão da Declividade.....	77
3.4.4 Método do Desvio padrão da declividade Fuzzy.....	79

4 Resultados e Discussão.....	84
4.1 Aplicação do FuzDec em imagens de alta fração de vazio e comparação com os detectores de contornos clássicos.....	84
4.2 Aplicação do FuzDec em imagens de baixa fração de vazio.....	103
4.2.1 Cálculo do volume total de líquido presente nas imagens utilizadas.....	103
4.2.2 Comparação do método por imagem com a medida obtida pelo método gravimétrico.....	105
Conclusões.....	112
REFERÊNCIAS BIBLIOGRÁFICAS.....	114

1 INTRODUÇÃO

Atualmente existe uma ênfase especial no estudo da fenomenologia envolvida na refrigeração de reatores nucleares. Uma parcela significativa dos novos projetos de reatores utiliza sistemas de circulação natural para esse propósito. Como consequência a circulação natural tem sido um tema recente de publicação, apesar de 30 a 40 anos de estudo deste fenômeno. Uma área de pesquisa dentro deste contexto tem sido o estudo dos padrões e parâmetros de escoamento bifásico de diferentes tipos de refrigerantes, especialmente da água.

O Centro de Engenharia Nuclear (CEN) no IPEN possui um circuito experimental todo feito de vidro que possibilita a visualização e obtenção de imagens dos padrões de escoamento de ciclos de circulação natural sob baixa pressão. Este circuito (Circuito de Circulação Natural – CCN) é descrito em detalhes com estimativas do RELAP5 em (Andrade et al, 2000).

As transições de padrões de escoamento bifásico têm sido objeto de estudos através do processamento de imagens. Alguns métodos propostos (Abdallah, 2009; Crivelaro, 2002; De Mesquita, 2012; Mesquita, 2009; Sunde, 2005; Wu e Dong, 2006; Zhang e Huang, 2009) usam técnicas derivadas da inteligência artificial, tais como, Redes neurais artificiais, lógica *fuzzy*, *neuro-wavelet* e máquina de vetor de suporte (SVM) para identificar o regime de escoamento.

Muitos trabalhos (Shi et al., 2004; Shi, 2007; Dinh and Choi, 1996; Chan et al., 2005; Wenyin et al., 2008) descrevem métodos úteis para o reconhecimento de padrões através de parâmetros das bolhas. As bolhas são segmentadas para que sejam obtidas características tais como a área e o diâmetro. Entretanto, esses métodos restringem a detecção de contornos das bolhas para imagens de escoamento bifásicos onde as bolhas aparecem isoladas uma das outras. Bolhas muito próximas são difíceis de serem identificadas podendo ocasionar super-segmentação (Crivelaro et al., 2002; Sunde et al., 2005, Wu et al., 2006). Outros métodos de extração de características (Mishin and Hibiki, 1996; Sunde et al., 2005; Wang and Dong, 2009) usam contraste, entropia e energia para identificar padrões de escoamento sem levar em consideração o formato das bolhas.

Há poucos métodos capazes de identificar as bolhas sem interação humana em imagens de escoamento com alta fração de vazio (Wu et al., 2006; Shi, 2007; Wang and Dong, 2009; Lau et al., 2013, Do Amaral et al., 2013). Nesses trabalhos a detecção de contornos é uma tarefa importante para estimar parâmetros do escoamento. Diâmetros, volume, velocidade de massa, geometria da trajetória, distância entre as bolhas e seu tempo de vida são alguns exemplos de parâmetros obtidos através desses métodos. Em termos gerais, os métodos descritos são propostos para detectar objetos de interesse em imagens de escoamento, mas tem dificuldades em imagens, como ilustrado na Fig. 1, onde as mudanças das intensidades são consideradas abruptas ou onde os objetos são muito próximos. Além disso, diferenças e oscilações de iluminação são fatores importantes que torna o reconhecimento de objetos uma tarefa complexa.

Fonte: (Mesquita et al., 2009)

FIGURA 1 - Imagens com alta fração de vazio de escoamento em escala de cinza. (a) Fase de reenchimento. (b) Transição do reenchimento para a fase de incubação

1.1 Objetivos

Desenvolver um método para detectar contornos de objetos de interesse em imagens que apresentem objetos próximos e outras complexidades como mudanças abruptas de intensidade e oscilações de iluminação. Este método será utilizado para a detecção e segmentação, sem interação humana, da imagem do contorno das bolhas de vapor e gás em imagens digitais dos padrões de escoamento bifásico com alta fração de vazio. Estas imagens são obtidas em diferentes fases de instabilidades cíclicas do escoamento bifásico em circuitos de circulação natural. Este sistema utilizará regras *fuzzy* junto a um método probabilístico envolvendo técnicas oriundas de processamento de imagem,

A partir da detecção do contorno desenvolver métodos que possibilitem a segmentação das imagens das bolhas e obter outros parâmetros característicos do escoamento como diâmetro e volume das bolhas para a obtenção da medida da fração de vazio.

1.2 Revisão da Literatura

Zhang e Hung (2009) propõem em seu trabalho uma nova técnica para a identificação de imagens de bolhas de ar em um ambiente contendo gás - líquido tendo como base uma rede neural artificial com a finalidade de identificar as bolhas e realizar a sua contagem. As imagens são obtidas com o uso de três câmeras que fazem três ângulos preestabelecidos. A partir desta disposição de aquisição, as informações providas das câmeras são utilizadas como entrada para o aprendizado de uma rede neural. Segundo os autores, essa técnica pode substituir cálculos complexos de identificação melhorando a contagem de bolhas em um simples escoamento. Embora o aumento da eficiência do algoritmo no que se refere a identificação e contagem das bolhas, a técnica identifica poucas bolhas isoladas no escoamento bifásico, além de fazer uso de diversos equipamentos que elevam o custo deste método.

Outro trabalho publicado na mesma época (Wenyin et al., 2008) apresenta uma metodologia para a segmentação de imagens em escoamento multi-fásico com o intuito de realizar a detecção do tamanho das bolhas e sua escala de

distribuição. O método utiliza o operador de contornos de Canny e realiza a configuração de critérios (ruído do sinal, boa localização e resposta do contorno simples) de forma automática. Nesse sentido, o método estima os parâmetros de detecção de Canny tendo como base o filtro de suavização gaussiano, o operador diferencial de primeira ordem de Gauss e o uso da imagem de contorno, através do máximo local em uma janela 3x3 para efetivamente confirmar a localização do contorno, sendo útil para o processo de limiarização. Os resultados obtidos com o uso desta técnica, mostrou a detecção dos contornos da maioria das bolhas em imagens simples, desde que as bolhas encontrem-se separadas uma das outras.

O trabalho desenvolvido por Mesquita et al. (2009, 2012) refere-se à criação de um método para caracterizar fases diferentes de ciclos de instabilidade em escoamento bifásico de circulação natural, a saber, incubação (*incubation*), expulsão (*expulsion*) e reenchimento (*refill*), através de reconhecimento de padrões em imagens digitais. A proposta desse trabalho envolve estudar as transições das fases de escoamento pelo uso de técnicas oriundas da inteligência artificial e processamento de imagens selecionando as melhores características para compor parâmetros de cada padrão de escoamento. Utiliza-se um sistema *fuzzy* para classificar padrões nas diferentes fases de instabilidade do escoamento bifásico obtido em circuito experimental, baseado em parâmetros de características estatísticas de perfis simples da imagem em escala de cinza.

O método proposto por Wang e Dong (2009) faz uso de uma matriz de coocorrência em níveis de cinza (GLCM) com imagens capturadas através de uma câmera em alta velocidade. A proposta refere-se a extração das características das texturas nas imagens, tais como, contraste, entropia, energia, homogeneidade, correlação em imagens digitais e apresentar a relação existente entre as diversas características da textura com a razão de densidade gás - líquido. Essa técnica baseia-se na utilização de dois métodos para capturar as características da imagem. O primeiro método consiste em obter valores estatísticos de segunda ordem para os níveis de cinza. Já o segundo método envolve obter informações estatísticas do gradiente. Segundo os autores, todas as características foram extraídas com o método proposto, levando em consideração a imagem como um todo e não permitindo nenhum tipo de

identificação ou análise quanto a características das bolhas, mas apenas permitindo reconhecer o regime de escoamento.

Guo et al. (2010) propõem um algoritmo estatístico não linear para realizar a detecção de contornos em imagens *wavelet* de aplicações multi-fásicas. Uma imagem *wavelet* permite decompor e descrever características da imagem no domínio da frequência pelos quais podem ser feitas análises em diferentes escalas de frequência (análise de sinais) e tempo. O algoritmo adota um procedimento de análise de imagens por *wavelet* (análise de sinais) em imagens de escalas de cinza com filtro gaussiano para a eliminação de ruídos. Logo em seguida, a imagem é transformada para o domínio da frequência (*wavelet*). Neste instante, determina-se se um pixel pertence ao contorno ou não com um valor de limiar (*threshold*) específico através do cálculo do coeficiente e do ângulo de fase para encontrar o máximo local do gradiente de cinzas normalizado por um coeficiente máximo de todos os *pixels*. As imagens de escoamento originais utilizadas no experimento são simples por apresentarem bolhas distantes uma das outras em pouca quantidade e estrutura com contornos fechados. Os resultados obtidos demonstraram serem mais eficientes em comparação ao detector de Canny, pois o algoritmo proposto conseguiu detectar bolhas próximas, onde o operador de Canny detecta apenas uma única bolha.

Uma outra abordagem utilizada por Wu et al. (2004) faz menção a técnicas de processamento de imagens com o uso da transformada de *wavelet* e técnicas derivadas da inteligência artificial tal como a máquina de vetores de suporte (SVM) com o objetivo de extrair características. Uma análise multi-resolução de imagens e métodos estatísticos foram adotados para validar a viabilidade do método de extração dessas características. Os resultados obtidos, através de 30 imagens agrupadas para cada regime de escoamento, a saber, *slug* (pistonado), *churn* (turbulento) e *bubble* (borbulhado), localizou 73.3% de características para o regime *bubble*, 93,3% para o *slug* e 100% para o *churn*. As técnicas computacionais para o processamento de imagens são encontradas em Wang e Dong (2009) e Guo et al. (2010).

Zabulis et al. (2007) utilizam-se de uma aplicação de detecção das bordas das bolhas em imagens com alta fração de vazio com interação humana por

template-matching, com o intuito de melhorar a performance dos métodos existentes. A técnica de transformada de Hough é utilizada para reconhecer círculos e criar o *template* (modelo). A partir deste momento, diversas imagens são criadas em tamanhos diferentes (multi-escalas) e correlacionadas através da correlação cruzada normalizada que é invariante à iluminação da imagem original. O primeiro passo da transformada de Hough é feito primeiramente com o uso do operador de Canny. Logo após, é utilizada a transformada de Hough para reconhecer objetos circulares. Por fim, é realizada uma otimização dos mínimos quadrados com os pixels dos círculos identificados para encontrar círculos com estruturas melhores. O problema desta abordagem, refere-se a encontrar um número grande de modelos via interação humana. Um outro problema é que o método necessita de técnicas para rotacionar as imagens modelos com o intuito de melhorar a identificação das bolhas. Segundo os autores, a técnica implementada com a linguagem de programação C++ permitiu detectar os contornos de aproximadamente 80% das bolhas afastadas uma das outras.

O método proposto por Busciglio et al. (2009) visa medir a distribuição do tamanho das bolhas em um ambiente gás - líquido através da análise de imagens obtida por iluminação com faixas de laser de espessura arbitrária. Técnicas estatísticas são utilizadas, tais como, distribuição dos tamanhos das bolhas (BSD) e distribuição do tamanho da intercepção visível (VISD). Os resultados obtidos foram robustos o suficiente para determinar o tamanho das bolhas, mas somente aplicados em bolhas esféricas perfeitas.

Em Bhardwaj e Mittal (2012) foi apresentado um resumo das diversas técnicas para a detecção de contornos, tais como, Roberts, Sobel, Prewitt, Canny e principalmente a Declividade (*Declivity*). O operador de Declividade, primeiramente apresentado por Miché e Debie (1995), e utilizado em diversos outros trabalhos (Bensrhair, 1996; Miché e Debie, 1996; Ansari, Mousset e Bensrhair, 2010; Brisan, Vasiu e Munteanu, 2013). A declividade pode ser definida como um conjunto de pixels contínuos em uma linha da imagem, onde suas intensidades são representadas por uma função monotônica de suas posições. Uma das partes mais importantes do operador, é a sua habilidade para ter um valor de limiar alto adaptativo em uma imagem não filtrada. O valor de limiar leva em consideração o desvio padrão dos componentes de ruído branco (gaussiano)

multiplicado pela variação da amplitude do histograma do pixel em uma linha da imagem. Um dos problemas encontrados é a definição do valor de limiar sendo uma representação binária (sem levar em consideração um intervalo que permite capturar mais *pixels*) que pode representar contornos. Os resultados obtidos em poucas imagens foram conduzidos com o uso do MATLAB apresentando bons resultados, pois a técnica permite encontrar contornos verdadeiros em imagens de baixo contraste. Além disso, segundo os autores, a nova técnica demonstrou ter uma performance maior comparado ao operador de Canny.

O trabalho proposto Abdallah et al. (2009) sobre detecção de contornos com o uso da lógica *fuzzy*, refere-se ao um trabalho semelhante encontrado em Jayachandran et al. (2010) com a diferença de Abdallah descrever detalhadamente as regras de inferência *fuzzy* e apresentar as funções de pertinência. Neste sentido, o trabalho por ambos os artigos descreve um sistema fuzzy para detectar contornos, tendo como base duas propriedades principais das imagens, a intensidade e textura. As estratégias principais do novo algoritmo permite realizar a detecção na presença de ruídos, sem a necessidade de pré-processamento da imagem e sem fazer uso de limiares (*threshold*). Primeiramente, o algoritmo realiza a leitura de uma imagem *grayscale* com valores de 0-255. Logo após, fuzzifica a imagem de acordo com as variáveis linguísticas utilizadas, *Black*, *Edge*, *White* com o uso do método Mandani para a defuzzificação. As oito regras utilizadas levam em consideração uma máscara 3x3 para cada pixel da imagem. Os resultados obtidos com imagens de geometria simples foram comparados com o operador de Sobel e apresentaram contorno mais definidos nas redondezas para curvaturas, contornos retos nas linhas que apresentam pouco contraste (linhas suaves) e além de permitir identificar cantos nas imagens.

Uma outra abordagem *fuzzy* foi utilizada por Barkhoda et al. (2009) e Patel et al. (2011) que levam em consideração a outras duas características da imagem, Gradiente do pixel e valores de desvio padrão. No caso de Patel et al, o gradiente é o laplaciano de um gaussiano. Primeiramente, imagens de *grayscale* com valores entre 0-100, foram utilizadas como entrada do método que faz uso de uma máscara 3x3 para realizar o cálculo do desvio padrão e do gradiente do pixel central. Neste sentido, pixels com o desvio padrão maior do que o valor de limiar

são candidatos a contornos. Duas funções membro foram construídas, uma função para o desvio padrão e outra para o gradiente dos *pixels* tendo como inferência nove regras *fuzzy*. O problema dessa abordagem, é que a defuzzificação construída, tem como base uma equação que propõe fazer uso do pixel candidato a contorno com uma classe de valores pré-estabelecida, sem levar em consideração propriedades da imagem em análise. Segundo os autores, os resultados apresentaram mais contornos verdadeiros em imagens reais comparados aos operadores Sobel, Roberts e Prewitt.

Lau et al. (2013) descrevem um trabalho para medir o tamanho da distribuição das bolhas com o uso de técnicas de análise de imagens para medir baixa fração de vazio, no qual depende da conversão da imagem em binário. Neste sentido, é possível observar diversas bolhas que sobrepõem umas as outras, o que dificulta a detecção dos contornos. Para resolver esse problema, o método faz uso de uma técnica em processamento de imagens intitulada *watershedding* com o intuito de identificar as bolhas sobrepostas individualmente. Uma dos problemas neste caso, é o uso de imagens sintéticas, além do uso de apenas uma fase do escoamento. Os resultados obtidos, segundo os autores, permitiu identificar individualmente as bolhas e retirar totalmente o *background* da imagem com a técnica do *watershedding*. Nos experimentos realizados, as bolhas foram identificadas em dois grupos distintos. Foram encontrados bolhas com picos de até 2.1mm e o segundo bolhas largas com pico de aproximadamente 4.9mm.

Amaral et al. (2013) apresentam uma abordagem para estimar parâmetros das bolhas através de imagens obtidas por um *loop* horizontal de escoamento bifásico gás-liquido com o objetivo de comparar os valores obtidos pelo arranjo experimental com previsões teóricas. As imagens capturadas podem apresentar iluminação heterogênea e em alguns casos com um fundo escuro, tornado difícil a detecção de contornos. Para amenizar essas dificuldades, utilizaram uso do filtro morfológico com um elemento estruturante de três pixels chamado top-hat que permitiu melhorar os resultados. O algoritmo para a segmentação *watershed* foi selecionado, entretanto um dos problemas encontrados nessa abordagem faz menção a super segmentação que pode ocorrer com o uso desse algoritmo quando não há a seleção de técnicas de pré-processamento adequadas na

imagem original. Um outro problema está na identificação de níveis diferentes de H-mínimo como marcadores para fazer uso na segmentação, pois o marcador depende das características dos objetos, tais como, dimensão e intensidade de luz e, nesse caso, o H-mínimo foi escolhido empiricamente.

O reconhecimento de padrão em imagens utiliza diversas área do conhecimento humano para tornar possível a resolução de problemas complexos que envolvem a detecção de contornos e identificação de objetos de interesses. Com o avanço do desempenho dos computadores, diversas abordagens são desenvolvidas agregando um acumulado de técnicas. O desenvolvimento de hardwares cada vez mais rápidos permitiram o uso de técnicas inteligentes mais elaboradas para a detecção de objetos em imagens de difícil reconhecimento.

1.2.1. Referências Canônicas

Em concomitância com as etapas descritas acima, foi necessário fazer uso de um conjunto de referências canônicas para o aprofundamento do conhecimento relativo às técnicas de processamentos de imagens possibilitando uma análise abrangente da literatura vigente e aperfeiçoamento da revisão bibliográfica. Em Bender (1996), Luger (2008) e Russel e Norving (2010) foi possível encontrar material importante sobre a teoria dos algoritmos clássicos de inteligência artificial. Em Davies (2005), Forsyth (2002), Gonzalez e Woods (2007) e Parker (2011) encontra-se um importante material sobre visão computacional e material teórico de processamento de imagens. A base da teoria sobre algoritmos computacionais referente a estrutura de dados, matemática e estatística são encontrados em Drozdek (2008), Press (2007), Rosen (2007) e Wasserman (2004).

Em Bender (1996) encontra-se algumas das técnicas matemáticas mencionadas nos artigos estudados sobre o tema que são normalmente utilizadas em inteligência artificial, tais como, Teoria da probabilidade discreta e estatística para a construção de filtros estatísticos (pg: 257-297), Teoria dos conjuntos *fuzzy* que foi útil para o desenvolvimento de imagens *fuzzy* e de equações dinâmicas para a detecção automática de contorno nas imagens (pg.: 355-401) e Redes neurais artificiais (pg.: 425-494) para o reconhecimento de padrões das

características das bolhas. Em Russel e Norving (2010) encontra-se uma rede neural muito utilizada em reconhecimento de padrões intitulada *Perceptron* (pg.: 863-898).

Em Davies (2005) encontra-se a fundamentação teórica de algumas técnicas de processamento de imagens em aplicações diversas, tais como, operação sobre imagens e filtros (pg.: 19-44 ; 47-98) mais utilizados, técnicas clássicas de detecção de contornos com o uso de modelos (*templates*) (pg.: 131-157). Em visão computacional encontra-se detecção de círculos e cantos, bem como a teoria para reconhecimento de padrões estatísticos em imagens (pg.: 687-723) com o uso de redes neurais artificiais. Em Forsyth (2002) foi possível encontrar um ponto importante para o entendimento dos filtros derivativos para se construir contornos em imagens, ou seja, a teoria sobre as características geométricas da imagem, estudados na geometria do contorno, das curvas e de superfície (pg.: 96-118) bem como a apresentação dos filtros lineares e convolução entre imagens assim como filtros no domínio do espaço e da frequência (pg.: 182-212). Em Gonzalez e Woods (2007) o estudo da formação de uma imagem é apresentado (pg.: 34-71) bem como o fundamental clássico para segmentar imagens (pg.: 567-636) e o reconhecimento estatístico de objetos (pg.: 693-750). Gonzalez e Woods (2007) possuem um material teórico útil explicando matematicamente como transformar imagens coloridas em escalas de cinza, transformação para imagens negativas e equalização do histograma. Em Parker (2011) é apresentado a teoria e os algoritmos em linguagem C para processamento de imagens e visão computacional, importante para o desenvolvimento do algoritmo de captura das imagens. Detalha um projeto de reconhecimento de padrões com o uso de redes neurais artificiais com parâmetros da imagem com o objetivo de realizar o reconhecimento de caracteres ópticos.

Em Drozdek (2008) encontra-se as estruturas de dados em linguagem C/C++ para a construção de algoritmos com qualidade que serve de apoio a implementação do projeto mediante a linguagem de programação Python. Já em (Press, 2007) é apresentado uma breve teoria sobre os métodos matemáticos mais utilizados em computação científica e a sua implementação em Linguagem C++, como por exemplo, geometria computacional, equações diferenciais parciais

(para a construção de novos filtros em detecção de contornos), transformada rápida de Fourier (análise da imagem no domínio da frequência), correção linear e correlação, minimização e maximização de funções entre outros, que foi uma literatura útil dando suporte à codificação do projeto. Rosen (2007) e Wasserman (2004) apresentam a base da teoria da probabilidade, estatística e alguns pontos importantes para o reconhecimento de padrões que serviu como base matemática e para o entendimento das máquinas de aprendizagem supervisionada e não supervisionada.

Em Roberts (1965), Marr e Hildreth (1980) e Canny (1986) pode-se encontrar os artigos embrionários referente a detecção de contornos e segmentação de objetos que demonstram técnicas que podem ajudar no desenvolvimento de novos filtros para a resolução do problema proposto e outros artigos interessantes sobre desenvolvimento de filtros com o uso dos filtros já existentes (Jacobus e Chien, 1981; Haralik, 1984; Heijden, 1995; Vale e Poz, 2002; Galbanin, Vale e Poz, 2006; ZHAI, DONG e MA, 2008).

2 FUNDAMENTAÇÃO TEÓRICA

A detecção de contornos é uma tarefa importante para o cálculo da medida da fração de vazio por imagens. Envolve extrair o fundo e segmentar as bordas das bolhas (vapor ou gás) para efetuar o cálculo do volume. Para isso algumas técnicas de processamento de imagens, lógica *fuzzy* e um método estatístico de comparação são utilizados.

Nesse capítulo é apresentado a fundamentação teórica para o desenvolvimento desse trabalho. A seção 2.1 descreve uma introdução ao escoamento bifásico e seus regimes em tubulações verticais e horizontais. Na seção 2.2 é apresentado algumas técnicas de processamento, modelagem e aquisição das imagens. A seção 2.3 descreve uma introdução ao funcionamento da lógica *fuzzy*, suas principais operações e o mecanismo de inferência por meio de regras de produção. Na seção 2.4 a análise estatística por meio das curvas ROC é detalhada e apresenta uma técnica eficiente para gerar as curvas ROC utilizando poucos *pixels* da imagem.

2.1 Escoamento Bifásico

Em termodinâmica, uma fase pode ser definida como uma região do espaço com composição química homogênea da matéria e propriedades definíveis. A fase pode ocorrer nos estados sólidos, líquidos ou gasosos e sua mudança ocorre devido ao aumento ou redução da pressão e/ou temperatura (Çengel, Boles, 2008). Um gás, vapor, uma mistura deles, um líquido puro ou uma solução líquida são exemplos de fases. Quando ocorre uma mistura entre as fases, por exemplo água e óleo, água e vapor, água e gás entre outros, formam um sistema bifásico onde essas duas substâncias são separadas. Essa separação chama-se de interface e consiste em uma região de transição entre fases adjacentes. No escoamento bifásico ocorre a presença de dois fluidos diferentes ou de mesma natureza em fases diferentes (líquido e vapor), sendo comum encontrar alguns tipos muito utilizados tais como gás-líquido, gás-sólido, líquido-líquido e líquido-sólido (Borgnakke e Sonntag, 2013). Eles podem ser observados no líquido refrigerante do reator nuclear utilizado para a transferência de calor e em diversos processos industriais envolvendo ebulição de líquidos e

condensação de vapores. No escoamento bifásico podem ocorrer diferentes configurações que são designadas como regimes ou padrões de escoamento.

Os regimes de escoamento, segundo Whalley (1996), dependem das vazões (gás e líquido), das propriedades dos fluidos (massa, viscosidade e tensão superficial), das condições de operação (temperatura, pressão e outros) e da geometria do sistema (forma, diâmetro e inclinação). Esses regimes podem ter classificações diferentes para as tubulações horizontais e outras para as tubulações verticais.

Nos escoamentos bifásicos em tubulações verticais do tipo gás-líquido a mudança ocorre devido as vazões de cada fase. Os padrões para esse tipo de escoamento podem ser vistos na FIG.2. Eles são classificados como, bolhas dispersas (baixa vazão de gás), bolhas aglomeradas (vazões de gás mais altas), Pistonado (com tamanhos de bolhas na ordem de grandeza do diâmetro do tubo), Agitante (comportamento indefinido) e Anular (o gás ocupa toda a região do centro do tubo).

Fonte: (Ghiaasiaan, 2007)

FIGURA 2 – Padrões de escoamento gás-líquido em tubos verticais

Nos escoamentos bifásicos em tubulações horizontais do tipo gás-líquido a mudança de fase é caracterizada pela diferença da densidade das fases e pela

assimetria do escoamento devido à ação da gravidade. Os padrões observados nesse tipo de escoamento podem ser vistos na FIG.3 e classificados como, Borbulhado ou bolhas dispersas (*bubble flow*) com baixas vazões de gás, Tamponado ou bolhas alongadas (*plug flow*) com o aumento da vazão, Estratificado (*stratified flow*) com baixas velocidades em ambos os fluidos, Ondulado (*wavy flow*) onde é possível observar a separação das fases formando ondulações, Pistonado ou bolhas de Taylor (*slug flow*) onde o tamanho das bolhas podem assumir o diâmetro do tubo à medida que a velocidade do gás aumenta, Anular (*core flow*) ocorre a formação de uma película de líquido nas extremidades do tubo com um núcleo do gás na periferia.

FIGURA 3 – Padrões de escoamento gás-líquido em tubos horizontais

No estudo dos regimes de escoamento bifásico uma das medidas muito utilizadas é a fração de vazio denotada pela letra grega alpha (α) (EQ. 35, Seção 3.1.1). Essa medida consiste na razão entre o volume de gás (ou vapor) e o volume total da mistura em um comprimento finito da tubulação. Alguns métodos podem ser utilizados para a obtenção da fração de vazio. Entre eles podem-se destacar a fração de vazio volumétrica, que foi utilizada nesse trabalho, a local, a unidimensional, a bidimensional, a tridimensional e a com média espacial e temporal:

- A fração de vazio volumétrica, utilizada nesse trabalho, fornece a medida do valor médio da fração de vazio ao longo do tubo. O método utilizado para a obtenção experimental dessa medida utiliza o fechamento rápido de válvulas. Esse método consiste no aprisionamento da mistura (exemplo,

líquido-gás) da seção de testes do tubo através de um mecanismo para fechamento simultâneo das válvulas localizados na entrada e saída dessa seção;

- A fração de vazio local consiste na presença de gás em um ponto x qualquer do escoamento em uma determinada fração de tempo. Essa medida é obtida pela média temporal da função densidade de gás em um intervalo de tempo;
- Na fração de vazio unidimensional ou simplesmente fração de vazio corda, refere-se à fração de gás existente ao longo de um comprimento de uma linha. Essa medida é feita por métodos que utilizam feixes de emissão estreitos como por exemplo, os sensores de raio x ou ópticos que podem ser configurados para este fim;
- A fração de vazio bidimensional corresponde à média da função densidade de gás em uma área da seção transversal da tubulação;
- A fração de vazio tridimensional é medida pela fração volumétrica ocupada pelo gás em um determinado tempo;
- A fração de vazio com média temporal e espacial também intitulada de dupla média permite medir a média espacial e temporal da função densidade de gás simultaneamente. Ela corresponde a união entre a fração de vazio local e uma das outras frações de vazio, unidimensional ou bidimensional ou tridimensional.

Para a obtenção da medida da fração de vazio alguns métodos podem ser utilizados. Dentre eles podemos destacar, ultrassom, transdutores de impedâncias intrusivos e não-intrusivos, o método gravimétrico e o método das válvulas de acionamento rápido.

O cálculo da fração de vazio é utilizado para o entendimento da hidrodinâmica dos fluidos, para cálculo do carregamento correto do fluido refrigerante em um sistema frigorífico, para determinar os regimes de

escoamento, para avaliar a perda de pressão, para o controle de processos em plantas de produção química, em equipamentos de transferência de calor onde há mudança de fase entre outros. Em reatores nucleares, o estudo dos parâmetros (a fração de vazio, por exemplo) do escoamento bifásico no fenômeno de circulação natural é uma tarefa importante. Esse fenômeno é utilizado na planta de novos reatores nucleares, tal como o reator integrado IRIS (reator internacional inovador e seguro) (Macedo, Filho, 2006), e serve para remover o calor residual do núcleo no caso de perda da alimentação das bombas do circuito primário e em operações de baixa potência (Sabundjian et al., 2008).

2.2 Processamento de Imagens

O processamento de imagens consiste em um processo de manipulação das informações contidas em uma imagem digital através de algoritmos que geram como saída uma imagem modificada. Seu objetivo é melhorar o aspecto visual da imagem, sua transmissão, sua impressão, ou a obtenção de outros subsídios para a medição de suas características e estruturas visando uma melhor interpretação do analista (Russ, 2011). Um processo típico é ilustrado na FIG.4 através do diagrama de fluxo dos passos básicos realizados em processamento de imagens, desde a aquisição das imagens até a obtenção dos resultados.

FIGURA 4 - Tarefas fundamentais para realizar o processamento de imagens.

O processamento se inicia com a aquisição de imagens que possam ser representadas por duas ou mais dimensões. Essa é uma tarefa importante pois envolve o processo de digitalização no qual uma imagem deve ser representada de forma apropriada ao tratamento computacional. Após a captura, o pré-processamento é responsável por filtrar os ruídos introduzidos pelos sensores e pelo ambiente físico externo onde a imagem foi capturada. A partir desse momento, a imagem está pronta para ser particionada em unidades mais significativas, etapa conhecida como segmentação. A tarefa de segmentar uma imagem é identificar características similares e descontinuidades (bordas) em regiões de interesse. O próximo passo, é extrair as características ou propriedades dos objetos de interesse, que consiste na geração de descritores que caracterizam o objeto ou partes de uma imagem. Estes descritores podem ser representados através de um vetor de características, contendo por exemplo, formas geométricas, entropia, energia, que poderão ser úteis ao processo de reconhecimento e interpretação. O reconhecimento ou classificação de padrões é uma tarefa que envolve identificar objetos nas imagens em termos de padrões que as constituem e descobrir relações existentes entre grupos de objetos semelhantes baseados nas características provindas de seus descritores. Atualmente existem muitas técnicas para a obtenção do reconhecimento de padrões que é normalmente dividido em três abordagens:

- Estatística: métodos estatísticos são utilizados para separar as classes de objetos de interesse. Dentre os métodos utilizados, pode-se citar os classificadores Bayesianos, métodos probabilísticos e regras de decisão;
- Estrutural: os padrões são reconhecidos tendo como base o casamento de símbolos ou modelos que caracterizam e definem um padrão a ser reconhecido;
- Neural: o reconhecimento é obtido com o uso de redes neurais artificiais onde os padrões são obtidos pelo treinamento exaustivo da associação entre o padrão e a imagem analisada.

A interpretação envolve a fixação de um significado para um conjunto de objetos relacionados (Gonzales e Woods, 2007). Há três principais formalismos utilizados para interpretar uma imagem:

- Lógica formal: a lógica clássica que é expressa por meio de regras lógicas;
- Redes Semânticas: faz o uso de grafos direcionados que permitem relacionar os elementos de uma imagem;
- Sistemas baseado em conhecimento: Essa abordagem utiliza regras de produção para inferir o conhecimento. Outras abordagens podem ser agregadas a estas regras com o intuito de representar o conhecimento, tais como, lógica *fuzzy*, modal, epistêmica, e outras.

A base de conhecimento de um sistema de processamento de imagens contém o conhecimento relativo ao domínio de problemas que são dependentes da aplicação para a qual esta base foi projetada. Seu tamanho e complexidade varia e serve para realizar a comunicação entre os módulos do sistema de processamento de acordo com a complexidade da tarefa a ser realizada.

2.2.1 Modelos de Imagem

Uma imagem pode ser definida como uma função $f(x,y)$, onde f representa a intensidade (brilho) ou o nível de cinza em um ponto, denotado pelas coordenadas espaciais x e y (Gonzales e Woods, 2007). Seu modelo físico representado por (1) consiste na interação da luz em uma cena para produzir uma imagem, ilustrada na FIG.5, e pode ser expresso por dois componentes para a função $f(x,y)$ que representam a quantidade de luz incidente na imagem (iluminância) e a quantidade de luz refletida na imagem (reflectância) (Pedrini e Schwartz, 2008). A iluminância denotado por $i(x,y)$ é medida em lúmens/m² ou lux e a reflectância representado por $r(x,y)$ é medida no intervalo entre 0 e 1.

$$f(x, y) = i(x, y)r(x, y) \quad (1)$$

FIGURA 5 - Modelo físico de uma representação de imagens

Em seu modelo computacional, a imagem deve passar por uma conversão para um formato discreto denominada de digitalização, que envolve duas etapas, a amostragem e a quantização. A amostragem é o número de *pixels* em x e y da imagem que gera uma matriz bidimensional $M \times N$, conforme pode ser observado na FIG.6, sendo cada ponto da imagem ou elemento da matriz denominado de pixel (*picture element*). Um outro parâmetro associado à amostragem em imagens é a resolução espacial, que consiste no espaçamento físico (densidade de pixels) entre amostras. Ela precisa ser escolhida de modo a atender ao nível de detalhes que se deseja obter na análise da imagem. A quantização consiste em escolher o nível de cinza de cada pixel da imagem representado por um valor inteiro L em uma imagem monocromática. Normalmente esse valor é uma potência de 2, ou seja, $L = 2^p$, onde L é o número de níveis de cinza e p é a profundidade da imagem. A associação desse valor ao pixel respeita a escolha do intervalo $[L_{\min}, L_{\max}]$ denominado de escala de cinza. Dentre as diversas convenções que se deseja trabalhar, a mais comum é determinada por $L = 2^8$, que corresponde a atribuir ao pixel representado pela cor preta o nível de cinza mais escuro, o valor 0, e a cor branca o nível de cinza mais claro, o valor 255. O número 2 significa uma imagem binária com profundidade de 8 bits por pixel (1 byte por pixel), que corresponde ao armazenamento da imagem em formato digital. Considere, por exemplo, uma imagem $f(x,y)$ em formato digital com $x = 30$ cm e $y = 20$ cm cuja amostras estão espaçadas uniformemente a cada 1 mm em x e y . Neste caso, a imagem terá a resolução espacial de $M = 300$ por $N = 200$ amostras perfazendo 60.000 pixels. Para armazenar uma imagem, sem o uso de nenhum algoritmo de compressão, com 8 bits de profundidade, ou seja, $L = 2^8$ (256 níveis

de cinza), são necessário $300 \times 200 \times 8 = 480.000$ bits. Transformando tem-se $480.000 / 8 = 60.000$ bytes de memória, ou $60.000 / 1024 = 58,59$ kbytes de memória.

FIGURA 6 - Modelo Computacional. (a) Imagem (b) Níveis de Cinza no formato matricial

2.2.2 Aquisição de imagens

Normalmente a aquisição de imagens digitais é feita por meio de câmeras munidas por um dos dois tipos de sensores, CCD ou CMOS. A aquisição por esses sensores é utilizada na fotografia digital, no processamento de imagens de satélites, em equipamentos médico-hospitalares, na identificação de objetos em astronomia entre outros.

O dispositivo de carga acoplada ou CCD (*charge-coupled device*) foi patenteada em 1969 pela Bell Labs, é um sensor semicondutor formado por um circuito integrado que contém uma matriz de capacitores (fotodiodos) acoplados em fileira, intitulados de MOS, representados por pixels em processamento de imagens. Esses capacitores acumulam a carga elétrica proporcional a intensidade da luz incidente (fótons) naquela localização para que o circuito de controle (circuito externo) transfira o conteúdo de um capacitador para o seu vizinho. O último capacitador do conjunto envia a carga elétrica a um amplificador de carga para converter em voltagem. Essas voltagens são digitalizadas e armazenadas em uma memória (Russ, 2012).

O dispositivo intitulado de complementar metal-óxido ou CMOS (*Complementary metal-oxide semiconductor*) é um semicondutor cujo funcionamento é idêntico ao sensor CCD, com a diferença que o procedimento ocorre dentro do sensor e que o tratamento é realizado para cada *pixel* da imagem enviando tudo digitalizado para o processador da câmera. Com isso, ocorria a interferência de um componente com o outro dentro do sensor, provocando ruídos na imagem gerada. Entretanto, em 2011, uma nova geração CMOS foi desenvolvida para equipar câmeras para aplicações profissionais na indústria e na fotografia, resultando em imagens com qualidade semelhante às produzidas pelos sensores CCD a um custo mais baixo de fabricações e ainda gastando menos energia para produzir a imagem.

2.2.3 Equalização do Histograma

A percepção de informações contidas nas imagens é uma tarefa importante para o reconhecimento de padrões presentes nos objetos de interesse que faz distinção de outros elementos que compõe uma imagem. A equalização do histograma ou manipulação de contraste é uma das técnicas utilizadas para melhorar a qualidade das imagens com o intuito de facilitar essa percepção das informações sob critérios subjetivos ao sistema visual humano (Gonzalez e Woods, 2007; Pedrini e Schwartz, 2008). Além disso o uso da equalização permite contornar as limitações e variabilidades da iluminação presentes nas imagens pelo processo de aquisição, conforme pode ser observado na FIG.7.

FIGURA 7 - Equalização global do histograma. (a) imagem em níveis de cinza no intervalo de $[0, 255]$. (b) imagem após equalização.

A equalização do histograma para o intervalo de pixels $[0, L-1]$ realiza uma redistribuição dos valores dos *pixels* baseado no histograma da imagem. Há três técnicas distintas: a equalização global, regional por blocos e regional pontual. A equalização regional por blocos e pontual, utiliza-se para a análise dos níveis de cinza, uma janela de tamanho definido pelo usuário, distorcendo a imagem e realçando os detalhes. Um dos problemas encontrados com as técnicas regionais está no realce de todos os detalhes, até mesmo os ruídos presentes na imagem. A diferença entre essas duas técnicas é que a primeira realiza a equalização do bloco inteiro, enquanto a segunda equaliza somente o ponto central da janela. A equalização global utiliza todos os níveis de cinza presentes, preservando as características globais da imagem, aumentando o contraste. A expressão que fornece o histograma equalizado global da imagem é apresentada em (2):

$$eh(k) = \frac{(L - 1)}{MN} \sum_{i=0}^k n_i \quad (2)$$

onde $eh(k)$ é a função de distribuição acumulada de probabilidade, L é o valor máximo dos níveis de cinza, k são os valores para os níveis de cinza $k = 0, 1, \dots, L-1$, M e N é o número de *pixels* encontrados na imagem e n_i é o número de pixels com nível de cinza igual a i .

2.2.4 Abordagens Tradicionais para a Detecção de Bordas

Detecção de Bordas é uma parte do processo intitulado de segmentação e uma das operações em processamento de imagens mais utilizadas (Parker, 2011), pois envolve essencialmente localizar objetos de interesse. Há diversas definições possíveis para a borda. Uma das mais utilizadas é a ideia de limite ou fronteira, onde um conjunto de *pixels* são conectados para separar duas regiões com propriedades distintas de níveis de cinza (Pedrini e Schwartz, 2008). A dificuldade na detecção da borda envolve, na prática, imperfeições no processo de aquisição. Essas imperfeições podem ocorrer por ruídos e pelo processo de amostragem.

Um ruído pode ser definido como degradações na imagem caracterizado por um efeito randômico no nível de pixel para pixel, pela suavização em um conjunto de *pixels* e pelo aparecimento de borramento nas bordas. Pode ser ocasionado pelos limites óticos da lente, tipo de câmera, condições de iluminação, temperatura, efeitos atmosféricos, poeira e outros fatores. Seus tipos comumente modelados são o ruído Gaussiano, Exponencial, Impulsivo, Uniforme, Erlang, Poisson e Rayleigh.

No processo de amostragem um nível de cinza da borda se redistribui por mais pixels na imagem digital, resultando em bordas borradas. Esse problema ocorre devido a escolha da taxa de amostragem para a digitalização e por ser improvável que todas as bordas sejam realmente contornos em uma imagem real. A FIG. 8 mostra alguns exemplos de bordas do perfil de cinza unidimensional ao longo de uma linha com graus de borramento.

FIGURA 8 - Modelos de Bordas. (a) Mudança perfeita de níveis de cinza. (b) Borda com baixo grau de borramento. (c) Borda com um grau elevado de borramento.

Quanto maior é a mudança no nível de cinza (intensidade) ou quanto mais próximo estiver do caso ideal (FIG.8 (a)) mais fácil é a detecção da borda. No entanto, em casos reais, nenhuma mudança de níveis de cinza pode ser vista como uma tarefa fácil para a detecção da borda, devido às imperfeições na aquisição, resultando em uma imagem com diferentes graus de borramento (FIG. 8 (b)(c)).

A maioria das técnicas utilizadas para a detecção de bordas tenta resolver problemas que envolvem algum grau de borramento ou ruído com o intuito de identificar as bordas e obter a segmentação no que se refere ao reconhecimento

de objetos presentes nas imagens. Em sua maioria, elas são baseadas no mecanismo básico de definir um operador derivativo de primeira ou segunda ordem, associados a alguma técnica de suavização para reduzir os efeitos de ruídos.

Os operadores de Sobel, Prewitt e Roberts são métodos clássicos na detecção de bordas que utilizam a primeira derivada com o objetivo de identificar as mudanças locais significativas nos níveis de cinza. Esses operadores fazem uso da diferenciação de imagens chamado de gradiente, que refere-se a um vetor que indica os locais onde a maior variação dos níveis de cinza ocorre. A expressão abaixo mostra o vetor gradiente que pode ser calculado por derivadas parciais.

$$\nabla f(x, y) = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\delta f}{\delta x} \\ \frac{\delta f}{\delta y} \end{bmatrix} \quad (3)$$

Duas importantes medidas em detecção de bordas derivativas são a magnitude do vetor gradiente, que consiste na maior taxa de variação f por unidade de distância, e o ângulo de direção desse vetor. Elas são expressas respectivamente por:

$$\nabla f(x, y) = \text{mag}(\nabla f) = \sqrt{G_x^2 + G_y^2} \quad (4)$$

$$\theta = \text{arccotan} \left(\frac{\frac{\delta f}{\delta x}}{\frac{\delta f}{\delta y}} \right) \quad (5)$$

Devido ao custo computacional requerido pela equação (4), a magnitude do gradiente pode ser calculada por valores absolutos ou pelo valor máximo entre os gradientes na direção x e y .

Uma forma simples de calcular a magnitude do gradiente é fazer uso de diferenças em ambas as direções, onde G_x e G_y poderiam ser expressas por:

$$G_x = f(x, y) - f(x + 1, y) \quad (6)$$

$$G_y = f(x, y) - f(x, y + 1)$$

Desta forma, esses valores poderiam estar dispostos através de uma representação matricial de tamanho 3 x 3 que compõe uma região da imagem. Essa representação, conforme pode ser visto na FIG.9, é intitulada de máscara e pode ser utilizada para implementar a equação (4).

$f(x-1, y-1)$	$f(x, y-1)$	$f(x+1, y-1)$
$f(x-1, y)$	$f(x, y)$	$f(x+1, y)$
$f(x-1, y+1)$	$f(x, y+1)$	$f(x+1, y+1)$

FIGURA 9 - Representação Matricial de tamanho 3 x 3 pixels.

Sendo as máscaras uma aproximação da equação da magnitude do gradiente, os operadores de Sobel, Roberts e Prewitts podem ser definidos. A TAB.1 mostra as máscaras que implementam esses operadores.

TABELA 1 - Máscaras dos operadores.

Operador	Máscara G_x	Máscara G_y
Roberts	$\begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix}$	$\begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}$
Prewitt	$\begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}$	$\begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}$
Sobel	$\begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$	$\begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$

Em Roberts a detecção identifica bordas diagonais da esquerda e direita, enquanto em Prewitt e Sobel a preocupação está na obtenção de bordas horizontais e verticais. Em Sobel é possível observar a utilização do valor 2 na posição central da máscara, resultando na suavização da imagem nessa posição. De acordo com a necessidade, é possível modificar as máscaras desses operadores para obter a detecção das bordas diagonais, tal como ocorre com os

operadores de Roberts. Isso pode ser feito rotacionando seus valores no ângulo de 45 graus.

As máscaras encontradas na TAB.1 são utilizadas em conjunto com o método da convolução para encontrar as bordas. Esse método pode ser definido como uma operação linear local que dado duas funções, nesse caso, uma imagem e uma máscara, resulta em uma modificação do pixel correspondente na imagem resultante. Ela pode ser expressa por:

$$f * m(i, j) = \sum_m \sum_n f(m, n) * m(i - m, j - n) \quad (7)$$

onde f é a imagem, m e n é o tamanho da imagem, i e j é o tamanho da máscara de convolução.

Um outro método de detecção de bordas muito utilizado que faz uso de técnicas derivativas de primeira ordem é a detecção por Canny. Essa técnica envolve essencialmente uma lista de critérios para obter a identificação ótima da borda. O primeiro é a Taxa de Erro ou detecção que consiste na maximização da razão sinal ruído (SNR), ou seja, maior será a detecção de bordas verdadeiras quando menor for o SNR. O segundo critério é a Localização, que representa a distância entre os *pixels* encontrados por um detector de bordas derivativo de primeira ordem e sua respectiva posição verdadeira. Nesse caso, quanto maior for a Localização, os pontos detectados pelo filtro estarão mais próximos das posições verdadeiras. O terceiro e último critério é a Resposta mínima obtida pelo detector, isto é, onde existir somente bordas simples, o detector não deve identificar múltiplos pontos de borda. O algoritmo do detector de Canny envolve filtrar a imagem com o objetivo de tentar amenizar os ruídos, encontrar o gradiente, aplicar a supressão não máxima com o objetivo de remover pixels que não são considerados bordas, e finalmente fazer uso de dois *threshold*, um para aceitar um pixel como contorno e outro para rejeitar. Entretanto, caso o pixel estiver entre os dois *threshold*, o pixel somente será considerado se estiver conectado a um pixel que está acima do *threshold* mais alto (Canny, 1996).

Uma das técnicas mais utilizadas nas segmentações baseadas em regiões é a *watershed* também conhecida como linhas divisoras de água. Esse método encontra diferentes regiões da imagem onde cada região compartilha as mesmas características. Nesse caso, uma imagem pode ser interpretada como uma

superfície topográfica em que a intensidade dos pixels equivale a valores de altitude. O principal objetivo dessa segmentação refere-se a encontrar as linhas d'água, onde a inundação de baixo para cima, ou seja, dos mínimos locais para cima da topologia da imagem chegar a uma fase onde duas bacias vizinhas entram em contato. Esse processo continua até que a superfície esteja sob a água delimitando cada bacia de contenção, formando um conjunto de linhas d'água (*watershed*) com o intuito de evitar o transbordamento da água entre diferentes bacias. A FIG.10 ilustra o processo de imersão e formação das bacias d'água.

FIGURA 10 - Segmentação por Watershed.

Um dos problemas encontrados refere-se ao processo de inundação ser sensível ao ruído e pode ocorrer vazamentos resultando em super segmentação de borda. Isso significa que diversos pontos máximos ou mínimos são excedidos, resultando em um grande número de regiões que não correspondem a bordas verdadeiras de um objeto em uma imagem. Há diferentes técnicas que implementa um *watershed*, um dos algoritmos mais utilizados na literatura foi introduzido por Meyer (1992).

O operador Laplaciano é uma técnica utilizada para realçar uma imagem, apesar desse operador responder a transição de intensidades. Pode ser definido como uma função $f(x,y)$ pela derivada de segunda ordem expresso por:

$$\nabla f(x, y) = \frac{\delta^2 f}{\delta x^2} + \frac{\delta^2 f}{\delta y^2} \quad (8)$$

Assim como o gradiente foi definido, a equação (8) pode ser aproximada por uma máscara de convolução da seguinte forma:

$$\frac{\delta^2 f}{\delta x^2} = f(x-1, y) - 2f(x, y) + f(x+1, y) \quad (9)$$

$$\frac{\delta^2 f}{\delta y^2} = f(x, y-1) - 2f(x, y) + f(x, y+1) \quad (10)$$

$$L_x = \begin{array}{|c|c|c|} \hline 0 & 0 & 0 \\ \hline -1 & 2 & -1 \\ \hline 0 & 0 & 0 \\ \hline \end{array}$$

$$L_y = \begin{array}{|c|c|c|} \hline 0 & -1 & 0 \\ \hline 0 & 2 & 0 \\ \hline 0 & -1 & 0 \\ \hline \end{array}$$

(11)

Sendo L_x e L_y as máscaras das derivadas parciais em x e y representadas pelas expressões (9) e (10) respectivamente, a máscara de convolução do Laplaciano pode ser definida como:

$$Lp = L_x + L_y \quad (12)$$

$$Lp = \begin{array}{|c|c|c|} \hline 0 & -1 & 0 \\ \hline -1 & 4 & -1 \\ \hline 0 & -1 & 0 \\ \hline \end{array}$$

Outras derivações dessa máscara podem ser encontradas na literatura em (Gonzales e Woods, 2007) com o objetivo de detectar descontinuidades diagonais.

Por ser muito sensível ao ruído, esse operador não é utilizado para detectar bordas. Nesse sentido, o operador Laplaciano da Gaussiana (LOG) é utilizado para a detecção de bordas e há evidências que esse operador realiza operações muito semelhantes às realizadas pelo sistema visual humano (Berzins 1984). Conhecido também por chapéu mexicano, o operador LOG foi proposto por Marr e Hildreth (1980). A resposta desse operador pode ser vista pela equação (13), que inicialmente filtra os ruídos da imagem antes de efetuar a detecção por cruzamento de zeros da segunda derivada.

$$\nabla^2(G(x, y) * f(x, y)) \quad (13)$$

A filtragem dos ruídos pode ser feita em diferentes graus de suavização, controlado pelo desvio padrão σ da função Gaussiana $G(x,y)$ que é convolvida com uma imagem $f(x,y)$ expressa pela equação (14).

$$G(x, y) = \sigma^2 e^{\frac{-(x^2+y^2)}{\sigma^2}} \quad (14)$$

2.3 Lógica Fuzzy

A clássica teoria dos conjuntos pode ser considerada como um grupo de elementos distintos. Esses elementos podem ser descritos como números, nomes de objetos ou qualquer coisa que seja possível de ser categorizada em um universo definido, que estabelece apenas duas possibilidades, de um elemento pertencer ou não a um conjunto. Nesse sentido, a teoria dos conjuntos *fuzzy* estende a teoria clássica dos conjuntos para o tratamento de incertezas que envolve a maioria dos problemas no mundo real, pois é impossível representar o conhecimento incerto usando apenas sentenças que aditem valores verdadeiro ou falso.

O termo *fuzzy* significa nebuloso, vago, incerto, impreciso, subjetivo, difuso ou duvidoso e é utilizada para dar um tratamento matemático para as informações fornecidas pelos seres humanos que são carregadas de termos vagos vinculados

ao contexto do domínio do problema. A lógica *fuzzy* foi inicialmente definida por (Zadeh, 1965) no artigo intitulado *Fuzzy Set*. Ela defini graus de pertinências intermediários entre o grau de pertinência total e a não pertinência de elementos para um universo definido que permite a possibilidade de tratar conceitos imprecisos, tais como, “Baixo”, “Rápido” e “Inteligente”. Nesse contexto, um sistema lógico *fuzzy* ou um sistema de processamento *fuzzy* consiste em um conjunto de axiomas e regras de inferência com o intuito de representar formalmente um raciocínio válido. Pode ser dividido em três etapas básicas, a Fuzzificação, a Inferência *fuzzy* e a Defuzzificação, conforme ilustrado na FIG.11.

FIGURA 11 - Sistema de Processamento *Fuzzy*

2.3.1 Fuzzificação

A fuzzificação é a primeira etapa de um sistema de processamento *fuzzy* e consiste em transformar valores absolutos chamados de valores crisp, para valores nebulosos ou conjuntos nebulosos que pode ser definido por:

Um conjunto *fuzzy* é caracterizado por uma função de pertinência onde a transição de não-pertinência para pertinência é gradual, não abrupta dentro de um intervalo entre zero e um. A noção de união, intersecção, complementar, relação, convexidade, etc, é estendida para tais conjuntos, e várias propriedades dessas noções no contexto dos conjuntos *fuzzy* estão estabelecidos (Zadeh, 1965, p.338).

Seja o conjunto *fuzzy* A de um conjunto universo do discurso U mapeado através de uma função de pertinência $u_A: U \rightarrow [0,1]$ que associa cada número $x \in U$, sendo x o valor absoluto a um número real $u_A(x)$ em um intervalo $[0,1]$. Desta maneira, $u_A(x) = 0.3$ é o valor fuzzificado que consiste em x pertencer ao conjunto A com o grau de pertinência de 30%.

Cada conjunto nebuloso deve ser associado a uma variável linguística que representa o nome desses conjuntos. Por exemplo, a variável linguística “Temperatura” pode assumir os valores (conjuntos nebulosos) “baixa”, “média” e “alta”. Dessa forma essa variável pode possuir diversos conjuntos nebulosos que representam o universo do discurso associando cada conjunto a graus de pertinências. Assim, uma função de pertinência, também intitulada de função membro, pode ser representada pelo diagrama de Hassi-Euler (H-E) ilustrado na FIG.12.

FIGURA 12 - Curvas de Fuzzificação (Diagramas H-E) e suas respectivas funções de Pertinências para a variável linguística Temperatura.

Com o uso dessas funções, uma temperatura de 17° graus possui diferentes graus de pertinência para cada um dos três conjuntos nebulosos, a saber, $\mu_{Baixa}(x) = 0.3$, $\mu_{Média}(x) = 0.4$ e $\mu_{Alto}(x) = 0.0$.

2.3.1.1 Principais operações Fuzzy

As operações propostas por Zadeh são definidas de maneira similar às operações utilizadas pela lógica proposicional. Abaixo são apresentadas as principais funções com a intenção de prover um aspecto matemático para a teoria

da lógica *fuzzy*. Uma explicação mais detalhada pode ser encontrada em Zadeh, (1965), Zimmermann (2001).

- Complemento

Dado um conjunto A, o complemento desse conjunto pode ser interpretado como a sua negação:

$$\mu_{A^c}(x) = 1 - \mu_A(x) \quad (15)$$

- União

A união entre dois conjuntos pode ser interpretada como o conector lógico OU. Dado dois conjuntos A e B, a união é representada por:

$$\mu_{A \cup B}(x) = \text{máximo}(\mu_A(x), \mu_B(x)) \quad (16)$$

- Interseção

Dados dois conjuntos A e B, a interseção indicada pelo operador lógico E, pode ser representado por:

$$\mu_{A \cap B}(x) = \text{mínimo}(\mu_A(x), \mu_B(x)) \quad (17)$$

- Concentração

A concentração é um dos modificadores linguísticos capaz de reduzir a quadratura da função membro de um conjunto *fuzzy* (Chi, Yan, Pham, 1996), definida por:

$$\mu_A(x) = \mu_A^2(x) \quad (18)$$

- Dilatação

Sendo um dos modificadores linguísticos, a dilatação refere-se ao aumento do grau de crença para cada objeto em um conjunto *fuzzy* (Chi, Yan, Pham, 1996). A operação de dilatação é o inverso da concentração, definida pela equação (XX):

$$\mu_A(x) = 2\mu_A(x) - \mu_A^2(x) \quad (19)$$

- Soma delimitada

Seja dois conjuntos A e B, a soma delimitada consiste em obter o mínimo entre o valor absoluto 1 e a soma aritmética entre dois conjuntos *fuzzy*, podendo ser expressa por:

$$\mu_{A \oplus B}(x) = \text{mínimo}(1, \mu_A(x) + \mu_B(x)) \quad (20)$$

- Produto delimitado

Seja dois conjuntos A e B, o produto delimitado consiste em obter o máximo entre o valor absoluto 0 e a soma aritmética entre dois conjuntos *fuzzy* subtraído pelo valor 1.

$$\mu_{A \otimes B}(x) = \text{máximo}(0, (\mu_A(x) + \mu_B(x) - 1)) \quad (21)$$

- Produto Cartesiano

Semelhante a operação de interseção, o produto cartesiano permite encontrar o valor mínimo entre dois conjuntos, sendo que a única diferença está no fato de que cada conjunto pertence a universos diferentes, $A \in U_1$ e $B \in U_2$. Existem diversas definições para o produto cartesiano, a mais utilizada é definida pela expressão XX resultando em pares de valores.

$$\mu_{A \times B} = \text{mínimo}(\mu_A(x), \mu_B(y)) \quad (22)$$

2.3.2 Mecanismo de Inferência

A base de conhecimento do mecanismo de inferência *fuzzy* dispõe de regras de produção nas quais o antecedente e o consequente são conjuntos nebulosos. Armazenar o conhecimento por meio de regras é uma das formas mais comum (Rezende, 2005) e pode ser uma das melhores plataformas para explicar a inteligência humana no aprendizado e reconhecimento de objetos (Chi, Yan, Pham, 1996) que proporciona facilidade na manutenção e aquisição do conhecimento necessário à tomada de decisão. Elas são construídas mediante a ajuda dos especialistas da área do problema a ser resolvido. Normalmente, as regras são compostas de duas partes:

SE <antecedente> ENTÃO <consequente>

O antecedente da regra é formado por uma única ou um conjunto de condições. Quando essas condições são satisfeitas, a regra está pronta para o disparo no qual determina o processamento do consequente dessa regra. O consequente é composto por um conjunto de ações, tais como, resultados determinísticos, diagnósticos e pode dar suporte ao disparo de outras regras gerando um encadeamento de regras no processamento.

O processamento das regras depende da escolha do mecanismo de inferência que determina como serão processados os antecedentes, defini os indicadores de disparo das regras e quais os operadores utilizados. Muitas técnicas foram propostas para modelar as regras de inferência para gerir seu processamento. Existe alguns métodos que podem ser utilizados para o processamento dessas regras. O método Mamdani proposto por Wang e Mendel em 1974 é o método mais utilizado (Chi, Yan, Pham, 1996). Além dele, pode-se destacar o método de Tsukamoto que simplifica o método de Mamdani em que as funções de pertinência são monótonas, e o método TSK (Takagi e Sugeno, 1985; Sugeno e Kang, 1988) que é similar ao modelo Mamdani com a diferença que os consequentes das regras são formados de equações paramétricas relacionando as entradas e saídas do processo, em vez de fazer uso de relações *fuzzy*.

O modelo Mamdani, utilizado neste trabalho, possui algumas relações *fuzzy* definidas em ambos os lados da regra. Assim, uma regra pode ser definida para esse modelo da seguinte forma:

SE <Temperatura = Muito_Alta and Pressão = Muito_Alta>
ENTÃO <Perigo_de_Explosão = Alto>.

A regra acima possui duas variáveis linguísticas, Temperatura e Pressão, na qual o valor nebuloso “Muito Alto” é utilizado juntamente com operador *fuzzy* *and* (intersecção) para compor o antecedente dessa regra gerando como resultado um alto perigo de explosão.

Mamdani defini módulos de interface responsável por transformar as variáveis crisp em valores *fuzzy*, nos quais realiza a fuzzyficação. As regras

contidas na base de conhecimento são processadas pela máquina de inferência, a partir da composição de todas as regras disparadas, e logo após o modelo converte os valores *fuzzy* resultantes em variáveis *crisp*, no processo chamado de defuzzificação. A máquina de inferência processa essas regras tradicionalmente utilizando o modelo de inferência Max-Min. Essa inferência utiliza as operações de intersecção e união definidas em Zadeh, através de operadores de mínimo e máximo respectivamente.

2.3.3 Defuzzificação

Sendo o processo contrário à Fuzzificação, a conversão de um valor *fuzzy* em variáveis *crisp* é intitulada de Defuzzificação. Normalmente, os especialistas da área devem contribuir para o desenvolvimento das curvas de saída e escolher o melhor método para a solução do problema. A escolha do método depende do problema. Há problemas, por exemplo, que a resposta será um conjunto grande de valores associados a cada disparo de regra, ocasionando múltiplas saídas em tempos diferentes de processamento. Esse é o caso da transformação de uma imagem em escalas de cinza em um intervalo de $[0,255]$ em conjuntos *fuzzy*. A cada processamento de um pixel ou conjunto de pixels, seguindo determinados critérios, a resposta será um valor para cada pixel da imagem. Nesse caso, a defuzzificação não será necessária para esse tipo de problema, pois os valores gerados são *crisp* no intervalo em escalas de cinza. Para os problemas que necessitam de defuzzificação, os métodos do centro de massa e da média dos máximos são os mais utilizados (Rezende, 2005).

O método do critério de massa também intitulado centroide gera um valor de saída para um conjunto. O valor calculado corresponde a abscisa do ponto do centro de massa para ser usado como um valor de saída e determinar a solução do problema. Para isso, calcula-se a área da curva de todos os conjuntos *fuzzy* produzida pelo encadeamento de regras pela máquina de inferência e logo em seguida encontra o índice correspondente que divide esta área à metade. Esse método é normalmente utilizado em problemas que envolvem operações de controle, aproximação de funções e classificação binária. A EQ. 23 defini o método do critério de massa:

$$CG = \frac{\sum_{i=1}^n x_i \mu_{A(x_i)}}{\sum_{i=1}^n \mu_{A(x_i)}} \quad (23)$$

onde x_i representa o valor no universo correspondente ao centro de massa do conjunto *fuzzy* A e $\mu_{A(x_i)}$ é o grau de pertinência do conjunto A na posição x_i .

O método da média dos máximos propõe encontrar a classe de saída que determina o ponto médio entre os valores que tem o maior grau de pertinência, conforme a EQ. 24:

$$MM = \frac{\sum_{i=1}^n x_{Ai} \mu_{Ai}(x)}{\sum_{i=1}^n \mu_{Ai}(x)} \quad (24)$$

onde n é a quantidade de conjuntos *fuzzy* pertencente ao elemento, x_{Ai} é o i -ésimo conjunto *fuzzy* A a que o elemento pertence e μ_{Ai} é o grau de pertinência do i -ésimo conjunto *fuzzy*.

2.4 Análise ROC

Inicialmente proposto durante a segunda guerra mundial com o objetivo de quantizar a habilidade dos operadores de radares na distinção entre sinal e ruído, as Características de Operação do Receptor (ROC) é uma técnica estatística que permite validar os resultados de forma a quantizar seu poder discriminatório que envolvem diagnóstico ou previsão de resultados. A análise ROC possui uma extensa literatura (Zou, 2007) em diversas áreas do conhecimento em radiologia, comunicação e principalmente em medicina. Na área de processamento de imagens, a análise ROC vem ganhando bastante atenção da comunidade (Shui e Zhang, 2012), (Liu e Feng, 2014) devido à necessidade de obtenção de métricas mais apuradas para avaliar os algoritmos propostos.

Em análise ROC, um modelo de classificação usando duas classes ou um classificador binário consiste em mapear instâncias da classe verdadeira para a classe preditiva. Seja o conjunto binário da classe verdadeira rotulado por P e N, ou seja, número de instâncias positivas e negativas respectivamente, e o conjunto da classe preditiva (classificador) sendo representado por p, para instâncias positivas e n, para instâncias negativas. Quando um conjunto de instâncias é classificado, pode ocorrer quatro diferentes situações para compor uma matriz de contingência ilustrado na FIG.11, onde TP, FP, TN e FN representam:

- **Verdadeiros Positivos (TP):** refere-se aos valores positivos que o sistema julgou positivos (ACERTOS);
- **Falso Negativo (FN):** consiste em valores positivos que o sistema julgou negativos (ERROS);
- **Verdadeiros Negativos (TN):** são valores negativos que o sistema julgou como negativos (ACERTOS);
- **Falso Positivos (FP):** representa valores negativos que o sistema julgou como falso positivos (ERROS).

		Classe preditiva		
		p	n	
Classe Verdadeira	P	TP	FN	Pos
	N	FP	TN	Neg
		PPos	PNeg	Total

FIGURA 13 - Matriz de contingência

Pos e Neg são os totais de instâncias positivas e negativas da classe verdadeira e PPos e PNeg são os totais de instâncias positivas e negativas da classe preditiva respectivamente. Através desses valores é possível definir algumas medidas importantes, levando em consideração a estrutura da matriz de contingência. Essa matriz forma as medições básicas para algumas métricas comuns, tais como, TPR que representa a taxa de verdadeiros positivos, a FPR que se refere à taxa de falsos positivos, Acurácia, Taxa de acerto, e à Taxa de Erros que são representados abaixo:

$$TPR = \frac{TP}{Pos} \quad (25)$$

$$FPR = \frac{FP}{Neg} \quad (26)$$

$$TaxaAcerto = \frac{Pos \times TPR + Neg \times (1 - FPR)}{Total} \quad (27)$$

$$Acurácia = \frac{TP}{PPos} \quad (28)$$

$$TaxaErro = 1 - TaxaAcerto \quad (29)$$

Também conhecida como recall ou sensibilidade na literatura, TPR refere-se à habilidade do classificador em prever corretamente a condição positiva da classe verdadeira e TFP, conhecida como sensibilidade ou 1 - especialidade, é a habilidade do classificador em prever corretamente a ausência da condição negativa da classe verdadeira. A Acurácia expressa a proporção de exemplos positivos classificados corretamente e a soma da condição positiva da classe preditiva. A Taxa de Acerto, como sendo uma das medidas mais utilizadas na literatura, leva em consideração a variação da proporção de classes quando utilizada em classes desbalanceadas, pois pode ocorrer erro de predição da classe minoritária (Matsubara, 2008). Nesse caso, a Equação da taxa de acerto relaciona a TPR e FPR com total de positivos (Pos) e negativos (Neg), removendo essa quantidade do denominador que compõem o valor total das instâncias (Total).

2.4.1 Gráfico ROC

O gráfico ROC é um gráfico bidimensional, onde a medida de FPR é plotado no eixo x e a medida de TPR é plotado no eixo y correspondendo a um simples ponto no espaço ROC. A FIG.14 ilustra um gráfico ROC, onde é possível notar algumas regiões de interesse para a análise.

FIGURA 14 - Gráfico ROC

É possível localizar quatro regiões de interesse para a obtenção de uma análise classificatória em um espaço ROC. O ponto (0,1) representa uma classificação perfeita, no qual todas as instâncias positivas e negativas são rotuladas corretamente. Os pontos próximos ao ponto (1,0) correspondem a classificações com resultados ruins, onde não foi possível um classificador obter acertos (baixa TPR), somente erros (alto FPR). Os pontos próximos a linha da diagonal principal representam uma classificação aleatória, no qual o número de acertos (TPR) e erros (FPR) são semelhantes. A região próxima ao ponto (0,0) consiste em um classificador que mapeia instâncias onde o número de erros é baixo, o que é muito bom, entretanto o número de acertos também é baixo. Por outro lado, a região próxima ao ponto (1,1) representa uma classificação onde o número de acertos é alto, mas o número de erros é igualmente alto.

A análise do espaço ROC depende inicialmente do contexto do problema. Para um algoritmo de detecção de contornos, por exemplo, quanto mais próximo o ponto que representa o detector em análise estiver do ponto (0,1), melhores serão os resultados. No entanto, se o algoritmo for um classificador de mensagens de e-mail com filtros *spam*, a análise dos resultados pode mudar, ou

seja, o melhor classificador pode não ser aquele próximo ao ponto (0,1). Suponha um algoritmo que classifique mensagens de e-mails em *spam* (instâncias positivas) e não *spam* (instâncias negativas). Qual seria a melhor classificação, o algoritmo A ou B ilustrado na FIG.15?

FIGURA 15 - Gráfico ROC

Tendo em vista que o algoritmo B represente uma classificação ideal, seria interessante um algoritmo que não perca nenhuma instância positiva mesmo que o algoritmo classifique algumas mensagens *spam* como não *spam*. Nesse contexto, o melhor classificador é o A, pois classificar um e-mail importante como spam seria um erro grave, enquanto classificar um e-mail spam como não spam seria um erro com pouquíssima gravidade.

Em termos gerais, é importante levar em consideração o domínio da aplicação para a obtenção da análise ROC. Assim, quando é grave a classificação errônea de instâncias positivas, é interessante dar preferência aos pontos com altas taxas de TPR. Inversamente, quando é grave o erro de classificação das instâncias negativas, é importante dar atenção aos pontos com baixas taxas de FPR.

2.4.2 Curvas no espaço ROC

Uma análise ROC utiliza um modelo de classificação com duas classes gerando apenas um ponto determinado pela matriz de contingência, onde FPR e TPR são calculados e plotados nos eixos x e y respectivamente. Uma forma interessante de comparar e analisar classificadores é plotar pontos respectivos a cada classificador no gráfico ROC.

Considere um classificador probabilístico, tais como redes neurais ou um classificador Bayesiano com o objetivo de gerar *scores* para dez exemplos mostrados na TAB.2. A primeira linha da tabela refere-se aos pixels em uma imagem, onde cada um possui sua classe verdadeira (p) para cada exemplo de teste que estão dispostos na segunda linha, e logo em seguida os *scores* produzidos pelo classificador escolhido. Em um primeiro momento, os exemplos são ordenados de acordo com os *scores* em ordem decrescente.

TABELA 2 - Classificação com diferentes valores de corte (limiares).

Exemplos	p1	p2	p5	p4	p10	p6	p3	p8	p9	p7
classe	p	p	n	p	p	n	n	n	p	n
score	0.9	0.8	0.4	0.38	0.37	0.36	0.35	0.1	0.1	0.04
Limiar =0.9	p	n	n	n	n	n	n	n	n	n
Limiar =0.8	p	p	n	n	n	n	n	n	n	n
Limiar =0.4	p	p	p	n	n	n	n	n	n	n
Limiar =0.38	p	p	p	p	n	n	n	n	n	n
Limiar =0.37	p	p	p	p	p	n	n	n	n	n
Limiar =0.36	p	p	p	p	p	p	n	n	n	n
Limiar =0.35	p	p	p	p	p	p	p	n	n	n
Limiar =0.1	p	p	p	p	p	p	p	p	p	n
Limiar =0.04	p	p	p	p	p	p	p	p	p	p

A curva ROC pode ser definida pela adoção de diferentes valores de corte (limiar), que normalmente são valores de confiança dos exemplos classificados como positivos com a finalidade de construir para cada limiar uma matriz de contingência diferente, conforme mostrado na TAB.3.

TABELA 3 - Matrizes de Contingências para cada valor de corte.

	TP	FN	FP	TN	TPR	FPR
Limiar =0.9	1	4	0	5	0.2	0.0
Limiar =0.8	2	3	0	4	0.4	0.0
Limiar =0.4	2	3	1	4	0.4	0.2
Limiar =0.38	3	2	1	4	0.6	0.2
Limiar =0.37	4	1	1	4	0.8	0.2
Limiar =0.36	4	1	2	3	0.8	0.4
Limiar =0.35	4	1	3	2	0.8	0.6
Limiar =0.1	5	0	4	1	1.0	0.8
Limiar =0.04	5	0	5	0	1.0	1.0

Assim, para cada matriz de contingência são calculados valores de FPR e TPR que podem estar dispostos no gráfico para formar uma curva ROC desse classificador, conforme apresentado na FIG.16.

FIGURA 16 - Curva ROC de um classificador

2.4.3 Área abaixo da Curva ROC

Em muitos casos, comparar curvas ROC de classificadores diferentes é uma tarefa difícil, pois seria interessante quantizar com exatidão um teste diagnóstico que representa cada curva em vez de fazer comparações entre segmentos dessas curvas. Quando uma curva está muito próxima da outra, elas podem se cruzar, o que torna difícil a utilização de um método para a comparação. Nesse sentido, a área abaixo a curva ROC ou AUC é um método que permite medir a área para comparar diversos classificadores scores. Consiste em uma medida do desempenho de um teste, ou seja, uma grandeza escalar entre 0 e 1.0, sendo que 0 é o pior caso e 1.0 a classificação perfeita, ou seja, representa a probabilidade de um classificador ranquear uma instância positiva escolhida aleatoriamente para ser maior do que uma instância negativa escolhida aleatoriamente. A área abaixo da curva ROC pode ser calculada através de dois métodos, o método de resolução numérica, como, por exemplo, regra dos trapézios, ou através de métodos estatísticos, tais como, *Mann-Whitney* ou a estimativa de máxima verossimilhança. A FIG.17 mostra a área abaixo da curva ROC calculado através da regra dos trapézios da matriz de contingência ilustrado na TAB.3.

FIGURA 17 - Área abaixo da Curva ROC da FIG.14. Área calculada = 0.78 (78%)

2.4.4 Método eficiente para a geração de Curvas ROC

Seja n o número de pontos de um conjunto de teste, uma curva ROC é construída levando em consideração todos os pontos desse conjunto. Neste caso, o algoritmo executa lentamente por utilizar todos os pontos, pois requer uma complexidade $O(n \log n)$ para ordenar os dados e $O(n)$ para ler a lista dos pontos criados (Fawcett, 2006).

Um outro método pode ser utilizado para criar curvas no espaço ROC, sem precisar fazer uso de todos os pontos do conjunto de teste. Esse método utiliza inicialmente o ponto determinado pela TPR e FPR da matriz de contingência e

logo em seguida faz uso dos teoremas da probabilidade e Bayesiano para construir os outros pontos da curva.

O primeiro passo para iniciar o método é determinar o número de pontos da curva que serão apresentados no gráfico ROC. Em geral, não há necessidade de obter um grande número desses pontos, pois o cálculo faz uso dos valores de TPR e FPR obtidos para efetivamente criar outros pontos para formar a curva. Seja N o número de pontos criados para apresentar a curva com a finalidade de comparar dois classificadores que representam duas imagens diferentes de mesmo tamanho com resolução de 800x600 pixels. A TAB.4 abaixo mostra o número de pontos criados e suas respectivas áreas abaixo da curva ROC.

TABELA 4 - Medidas de área associados a quantidades de número de pontos.

Classificador_1		Classificador_2
N	Medida de Área	Medida de Área
50	0,053329	0,712217
100	0,052743	0,712292
1000	0,052541	0,712316
10000	0,052539	0,712317
100000	0,052539	0,712317

Levando em consideração que a medida de área encontra-se no intervalo [0,1] ou [0%, 100%], as diferenças de valores são insignificantes para as diversas quantidades dos números de pontos. Nesse caso, o classificador_1 possui uma medida de área de 5%, enquanto o classificador_2 de 71% para todos as N quantidades apresentadas na TAB.4.

A determinação do número N de pontos é um passo importante pois serão utilizados para a obtenção de cálculos, a partir dos valores (1 - FPR) e TPR encontrados para um classificador e seus fechos complementares. Conforme apresentado na TAB.5, a TPR representado por $P(+|Ct)$ consiste na probabilidade de ser positivo sabendo-se que o pixel é um contorno e a Especificidade (1 - FPR) denotado por $P(-|\hat{Ct})$ é a probabilidade de ser negativo sabendo-se que um pixel não é um contorno. Seus respectivos fechos complementares são denotados por $P(+|\hat{Ct})$ e $P(-|Ct)$ *respectivamente*.

TABELA 5 - Teoremas de Probabilidade.

Teorema da Probabilidade Condicional	
$A = Ct$ $P(\bar{A} B) = 1 - P(A B)$	$B = + \quad P(\bar{Ct} +) = 1 - P(Ct +)$ $B = - \quad P(Ct -) = \frac{P(- \bar{Ct}) \times P(\bar{Ct})}{P(-)}$
Teorema de Bayes	
$P(A B) = \frac{P(B A) \times P(A)}{P(B)}$	$B = + \quad P(Ct +) = \frac{P(+ Ct) \times P(Ct)}{P(+)}$ $A = Ct$
Teorema da Probabilidade Total	
$B = +$ $P(B) = P(B C_1)P(C_1) + P(B C_k)P(C_k)$	$\{C_i\}_{i=1} \quad C_1 = Ct$ $\{Ct, \bar{Ct}\} \quad C_2 = \bar{Ct}$ $P(+) = P(+ Ct)P(Ct) + P(+ \bar{Ct})P(\bar{Ct})$

O próximo passo é calcular as probabilidades, tendo como base a prevalência $P(Ct)$, ou seja, a proporção de pixels considerados contornos em um determinado conjunto. Assim, a primeira probabilidade refere-se a um pixel ser considerado contorno $P(+)$ e a outra de não ser um considerado contorno $P(-)$. O cálculo de $P(+)$ utiliza o teorema geral da probabilidade e $P(-)$ é o seu complemento. Em seguida calcula-se os valores para TP, FN, TN e FP que formam as diversas matrizes de contingências utilizando o teorema de Bayes, representados por $P(Ct|+)$, $1 - P(Ct|+)$, $P(Ct|-)$, $1 - P(Ct|-)$ respectivamente. Os algoritmos são mostrados nos Algoritmos 1 e 2.

Algoritmo 1: Método para a geração de números de prevalências

Entradas: N, um valor que representa a quantidade de prevalências a serem criadas.

Saídas: p, uma lista de números de prevalências em ordem crescente

1: adiciona (0) em p

2: $aux \leftarrow 0.0$

3: para $i \leftarrow 0$ até N faça

4: $aux = aux + (1.0 / N)$

5: adiciona (aux) em p
 6: fim para
 7: fim

Algoritmo 2: Método para a geração de curvas ROC

Entradas: p, uma lista das prevalências criadas em ordem crescente; sens, spec, valores da sensibilidade e especificidade

Saídas: tp, fp, listas ordenadas em ordem crescente

1: tp, fn, tn, fp = [], [], [], []
 2: $p(+), p(-) \leftarrow 0, 0$
 3: para $i \leftarrow 0$ até p faça
 4: $p(+) \leftarrow (\text{sens} * p[i]) + (1.0 - \text{spec}) * (1.0 - p[i])$
 5: $p(-) \leftarrow 1 - p(+)$
 6: adiciona $((\text{sens} * p[i]) / p(+))$ em tp
 7: adiciona $(1 - tp[i])$ em fn
 8: adiciona $(\text{spec} * (1.0 - p[i]) / p(-))$ em tn
 9: adiciona $(1 - tn[i])$ em fp
 10: fim para
 11: fim

3 METODOLOGIA

A metodologia deste trabalho consistiu nas seguintes etapas básicas:

- a aquisição de imagens das instabilidades do circuito de circulação natural;
- a preparação de uma base dados para os testes dos algoritmos de análise de imagens.
- o desenvolvimento de algoritmos de pré-processamento de imagens escritos através da linguagem Python versão 2.6.4, adequados às condições das aquisições feitas;
- a formação de nova base de dados contendo imagens preprocessadas e organizadas para uma segunda etapa de testes dos algoritmos de análise de imagens. As imagens capturadas possuem uma resolução alta de 21 MP (megapixels) e foram recordadas para o aumento de desempenho dos algoritmos;
- programação de um algoritmo escrito através da linguagem Python versão 2.6.4 para reconhecimento de padrões utilizando equações descritivas do método do desvio padrão da declividade através da criação de um sistema de processamento de regras *fuzzy*;
- teste do algoritmo desenvolvido através da base de dados organizada, e verificação de sua eficiência em termos estatísticos com a utilização da análise ROC na base de dados de alta fração de vazio obtida no Circuito de Circulação Natural;
- experimentos de medidas de fração de vazio pelo método gravimétrico para estabelecimento da base de dados de baixa fração de vazio (incluindo imagens e medidas diretas concomitantes);
- teste e aplicação na base de baixa fração de vazio para estimativa da eficiência do algoritmo para a obtenção da fração de vazio.

3.1 Aquisição de Imagens

A aquisição de imagens feita no circuito de circulação natural (CCN) gerou as imagens que apresentavam alta fração de vazio utilizadas neste trabalho e as imagens geradas no arranjo experimental utilizando o método gravimétrico de

medida de fração de vazio geraram as imagens que apresentavam baixa fração de vazio que foram utilizadas neste mesmo trabalho. Estes dois arranjos experimentais estão disponíveis no Centro de Engenharia Nuclear (CEN). Foram utilizados os equipamentos de aquisição existentes no CEN como uma câmera digital, acessórios de suporte, iluminação e sincronização descritos em Mesquita et al. (2009).

3.1.1 CCN

O CEN do IPEN possui um circuito experimental todo feito de vidro que possibilita a visualização e obtenção de imagens dos padrões de escoamento de ciclos de circulação natural sob baixa pressão. Este circuito é descrito em detalhes com estimativas de parâmetros físicos feitas com o modelagem do RELAP5 em (Andrade et al, 2000) e apresentado na FIG.18.

FIGURA 18 - Arranjo experimental utilizado para a captura das imagens sob um aquecedor.

O arranjo experimental de circulação natural utilizou um aquecedor elétrico de água com potência de 8000W. O CCN é formado por tubos de vidro com 2600 mm de altura por 850 mm de largura que permitem a visualização do escoamento, e sua fonte fria é um trocador de calor com espirais helicoidais. Seu tanque de expansão é localizado na parte superior do circuito e as medidas de temperatura são efetuadas em 16 pontos com termopares do tipo T.

O CCN tem possibilitado o desenvolvimento de métodos de modelagem e medidas experimentais de parâmetros de escoamento bifásico que tem sido publicado nos últimos anos (Andrade et. al. (2010); Rocha (2005); Mesquita et. al. (2009, 2012)). A medida de fração de vazio neste circuito através de sonda capacitiva e a comparação com os métodos por análise de imagem podem ser comparados às modelagens feitas com a utilização do RELAP5. Estes trabalhos estão sendo realizados no âmbito do IPEN e esta tese faz parte deste desenvolvimento.

(a) Parâmetros da aquisição da imagem

A captura das imagens foi feita por uma câmera fotográfica Canon EOS Rebel Xsi (Modelo 450D), com velocidade do obturador de 1/4000 segundos, ISO de 1600 e foco manual. Uma objetiva canon macro EF de 100mm, f/2.8L IS USM acoplada a câmera foi utilizada e a iluminação *backlight* foi feita através de um refletor com lâmpada de 1000W (220V) com *dimmer*. A distância entre a lente e o tubo cilíndrico foi de 34,7 cm com profundidade de campo estimada em 2 cm. A estimativa da profundidade de campo é baseada em uma escada manufaturada no IPEN que serve para calibração do foco utilizando as configurações da câmera que capta a imagem a uma distância de aproximadamente um metro do tubo de vidro. Essa escada é descrita na próxima seção (ver seção 3.1.2, item (b)). O tempo de aquisição de um experimento foi de um quadro por segundo durante 1000 – 1500s. O experimento referente às imagens utilizadas nesta tese levou quatro horas aproximadamente para a configuração das câmeras, iluminação e do arranjo experimental e seis horas para a aquisição das imagens.

A aquisição teve como meta a obtenção de imagens referentes aos diversos tipos de escoamento bifásicos observados nas instabilidades de

circulação natural obtidos no circuito experimental. A opção pela iluminação traseira (*backlight*) por se mostrar a mais apta a gerar imagens com alto contraste nas bordas das bolhas e padrões de interesse para medidas de fração de vazio.

3.1.2 Bancada Experimental do Método Gravimétrico

Foi desenvolvido no laboratório do IPEN uma bancada experimental para a calibração dos métodos experimentais sendo desenvolvidos para medidas feitas no CCN. Este experimento possibilita a medida da fração de vazio pelo método gravimétrico (ver FIG. 19) e a aquisição de imagens concomitantemente. Desta forma, podem ser comparados os resultados obtidos pelos métodos de análise de imagem com a medida direta.

(a)

(b)

FIGURA 19 - Arranjo experimental pelo método gravimétrico utilizado para a captura das imagens.

(a) Arranjo experimental (método gravimétrico) (b) Caixa anti-refração e escada de foco.

(a) Parâmetros da aquisição da imagem

Na FIG. 19a é apresentado um arranjo experimental do método gravimétrico com o uso de duas câmeras *full frame* EOS Canon 5D Mark II de alta resolução (22 megapixels). A câmera frontal foi configurada para a aquisição de imagens do escoamento com uma lente canon macro EF de 100mm, f/2.8L IS USM, ISO 3200, foco manual, velocidade de disparo de 1/8000s, estilo de

imagem padrão e o disparo remoto. A câmera traseira foi utilizada para captar as imagens dos manômetros de coluna com o objetivo de efetuar o cálculo da fração de vazio experimental. Essa câmera foi configurada com disparo remoto e utilizou uma lente canon zoom EF de 24-105mm, ISO 1600, foco manual, velocidade de disparo de 1/250s e a lente estava a uma distância de dois metros dos manômetros de coluna. Foi utilizado um refletor com lâmpada de 1000W (220V) com *dimmer*, dois tripés para suporte das câmeras, uma objetiva macro de 100 mm para capturar as imagens e uma caixa anti-refração.

A caixa anti-refração (FIG. 19b) é um equipamento de acrílico manufaturado na oficina do Ipen. Esta caixa contém água entre as paredes de acrílico e o tubo cilíndrico de vidro em que ocorre o escoamento bifásico, com dimensões de 200 mm de comprimento por 120 mm de largura (somente para o experimento feito em 2015). Seu efeito é gerar uma lente que compensa o efeito refrativo implícito nas imagens obtidas de objetos dentro dos tubos cilíndricos tanto no circuito de circulação natural quanto na bancada de medidas pelo método gravimétrico. O efeito refrativo em volumes cilíndricos gera distorções que podem alterar a posição, o formato e o tamanho das bolhas nas imagens e conseqüentemente altera a medida do volume para o cálculo da fração de vazio (Masotti et al, 2015).

O tempo de aquisição de uma imagem para outra considerou subjetivamente a estabilidade da distribuição do número de bolhas ao longo do tubo. O experimento levou três horas aproximadamente para a configuração das câmeras e do arranjo experimental e quatro horas para a aquisição das imagens. Um dos pontos importantes que vale ressaltar, foi o cuidado obtido em retirar todas as bolhas de ar dos manômetros de coluna. A existência dessas bolhas altera o resultado para o cálculo da medida experimental da fração de vazio. A distância entre a lente da câmera frontal e o tubo cilíndrico é de 34,7 cm com profundidade de campo estimada em 2 cm.

(b) Descrição da profundidade de campo

A estimativa da profundidade de campo é baseada na calibração da câmera frontal que capta a imagem da caixa anti-refração e de uma escada de calibração de foco (FIG. 19b) que é justaposta à caixa. Para cada degrau dessa escada foi etiquetada uma letra diferente com o intuito de servir de apoio à calibração manual do foco na câmera. A largura de cada degrau corresponde a exatamente 0.5 cm permitindo estimar a profundidade de campo para 2 cm.

3.1.3 Medida da fração de vazio pelo método gravimétrico

O método gravimétrico foi utilizado nesse trabalho por ser uma técnica para medida de fração de vazio bastante precisa em escoamento bifásico do tipo gás-líquido em tubos verticais (Rocha, 2005; Oksowski, 2007). Além disso, essa técnica pode ser utilizada para calibrar ou verificar medidas obtidas por outras técnicas. Essa técnica é aplicada somente a escoamentos verticais em regime de bolhas com velocidade de líquido muito baixas, quando os efeitos de atrito e aceleração forem desprezíveis e apresentar um regime de escoamento estacionário.

FIGURA 20 – Esquema experimental do escoamento bifásico em bolhas para medir a diferença de pressão (Δp).

O cálculo da fração de vazio volumétrica é obtido através do diferencial das densidades das fases líquida e gasosa em pontos diferentes do tubo. De acordo com o esquema experimental apresentado na FIG. 20, pode-se observar duas tomadas de pressão A e B a uma distância uma da outra de 1307 mm. Essas tomadas são conectadas a tubos que transportam a fase líquida até os manômetros de coluna que apresentam uma diferença de pressão (Δp) correspondente às alturas do líquido C e D. A EQ. 30 mostra a densidade da mistura (ρ_m):

$$\rho_m = \frac{\rho_L(d_{ab} - d_{bd})}{d_{ab}} \quad (30)$$

sendo ρ_L a densidade do líquido. A fração volumétrica das fases gasosa e líquida do escoamento bifásico pode ser definida como a relação entre o volume de gás (V_G) e o volume total da mistura analisada ($V_G + V_L$) representado pela EQ. 31 e a relação entre o volume de líquido (V_L) e o volume total da mistura representado na EQ. 32.

$$\alpha = \frac{V_G}{V_G + V_L} \quad (31)$$

$$\beta = \frac{V_L}{V_G + V_L} \quad (32)$$

Uma outra forma de escrever a EQ. 30, considerando que as bolhas são dispersas em um regime permanente (Rocha, 2005), leva em consideração a EQ. 31 e a EQ. 32 da seguinte forma:

$$\rho_m = \rho_L \frac{V_L}{V_L + V_G} + \rho_G \frac{V_G}{V_L + V_G} \quad (33)$$

sendo que ρ_G é a densidade média do gás. Por definição $\alpha + \beta = 1$ e consequentemente $\beta = 1 - \alpha$. Assim EQ. 33 pode ser escrita como,

$$\rho_m = \rho_L(1 - \alpha) + \rho_G \alpha \quad (34)$$

Então, a equação da fração de vazio volumétrica (EQ. 35) é obtida, igualando a EQ. 30 e EQ. 34.

$$\alpha = \frac{\rho_L}{\rho_L + \rho_G} \frac{d_{bd}}{d_{ab}} \quad (35)$$

Para o cálculo da fração de vazio, os valores utilizados neste trabalho para a densidade média do líquido (água), da densidade média do gás (ar) são apresentadas na TAB. 6, conforme (Borgnakke, 2013).

TABELA 6 - Valores dos fluidos (líquido e gás) utilizados

Variáveis	Valores
ρ_L	997,82 [kg/m ³]
ρ_G	1,2502 [kg/m ³]

3.2 Base de Dados de Imagens

Foi desenvolvido um banco de dados com as imagens digitais capturadas nos experimentos descritos acima. Este banco visou possibilitar testes dos algoritmos desenvolvidos nesse trabalho. As imagens foram categorizadas em subdiretórios distintos referente às fases de escoamento sob estudo.

3.2.1 Imagens de alta fração de vazio

Uma parte da base de dados foi organizada com as imagens obtidas em experimentos feitos no circuito de circulação natural que continham alta fração de vazio. Para esse trabalho, alta fração de vazio corresponde a um valor acima de 30%. A partir desse valor de fração de vazio, as imagens obtidas torna-se escuras pois a luz não conseguem chegar a lente da câmera. Além disso as bolhas estão aglomeradas e muito próximas umas das outras ao longo do tubo. Este experimento foi realizado no ano de 2009 como descrito em Mesquita et al. (2009), e organizados de acordo com os tipos de instabilidade. Essa base é composta de 1789 imagens com resolução espacial de 3888 x 2592. Nesse

trabalho foram selecionadas algumas imagens típicas para efeito de teste do método de detecção de bordas em imagens com alta fração de vazio.

3.2.2 Imagens de baixa fração de vazio

Outra base de dados foi organizada com as imagens obtidas na bancada (arranjo) experimental de medida de fração de vazio baseada no método gravimétrico. Essa base é composta de 737 imagens com resolução espacial de 3744 x 5616 relativas a dois experimentos principais, um realizado no ano de 2013 com 624 imagens e o outro em 2015 com 113 imagens, o primeiro sem caixa anti-refração e o segundo com caixa anti-refração.

3.3 Pré-processamento das imagens

O pré-processamento das imagens foi organizado de acordo com as seguintes subetapas:

- Transformação das imagens coloridas em escala de cinzas com o intuito de simplificar o processamento e identificação. Esta transformação foi feita utilizando-se da função *convert* da classe *Image.py*. Esta classe pertence a um repositório de funções da linguagem de programação Python da biblioteca PIL (Python Imaging Library) (PIL Library, 2006). Esta conversão usa o padrão ITU-R 601-2 ($L = R * 299/1000 + G * 587/1000 + B * 114/1000$);
- Geração de imagens negativas e equalização do histograma. A equalização é importante para tornar a imagem balanceada com relação a sua iluminação e contraste;
- Divisão de cada imagem em partes para permitir melhorar a análise dos dados provindas de cada pixel ou região de interesse da imagem.

As imagens utilizadas são originalmente capturadas no formato RGB, envolvendo três bandas de imagens, R(red), G(green), B(blue), referentes às cores vermelho, verde e azul respectivamente. Testes foram feitos nas bandas RGB e HSI (*Hue, Saturation and Intensity*) das imagem com o objetivo de verificar o resultado dos contornos nas imagens. O melhor resultado foi apresentado pela

Intensity da HSI no qual se assemelha ao padrão de conversão em tons de cinza utilizado pelo padrão (ITU-R601-2) da biblioteca PIL descrita acima. O negativo da imagem é utilizado nesse trabalho como base para associar níveis de cinza altos com os picos de borda. (FIG.21).

FIGURA 21 - imagem do escoamento bifásico. (a) imagem original colorida (b) imagem de nível de cinza (0-255)

A equalização global do histograma (Gonzalez, 2002) foi utilizado para melhorar a distribuição dos níveis de cinza melhorando o nível de contraste e consequente melhor visualização da borda. O algoritmo foi desenvolvido em Python para este trabalho utilizando a técnica do LUT (*Look-up Table*) para mapear os níveis de cinza da imagem e fazendo a sua redistribuição. Essa técnica tem como base a função de densidade de probabilidade dos níveis de cinza da imagem a ser equalizada. A equalização do histograma foi utilizada somente quando a imagem apresenta baixo nível de contraste.

3.3.1 Base de imagens Pré-processadas

As imagens preprocessadas foram armazenadas e organizadas em três subdiretórios, um para o período de 2013, que se refere a imagens sem fazer uso da caixa anti-refração e os outros dois para o período de 2015, que refere-se as imagens sem caixa anti-refração e com caixa. Após o pré-processamento, as imagens do experimento feito em 2013 foram armazenadas com uma resolução espacial de 1872 x 890 pixels. As imagens do experimento feito em 2015

possuem duas resoluções espaciais, uma com a caixa anti-refração com 2252 x 1052 pixels e a outra sem o uso da caixa com 1771 x 414 pixels.

3.3.2 Reconhecimento de Padrões pela declividade fuzzy

Por meio da análise e interpretação desses dados obtidos pelo pré-processamento das imagens, foi possível realizar o reconhecimento de padrões com a criação de equações descritivas para o método da declividade estatística em cada pixel da imagem. A criação de um sistema de processamento de regras *fuzzy* foi necessário junto a um método probabilístico capaz de compor as regras do sistema. Este sistema visa direcionar a resolução de conflitos entre o processamento de diversas regras que descrevem o conhecimento especialista dos contornos das bolhas. O algoritmo criado para a obtenção do reconhecimento do padrão dos contornos das bolhas possui uma complexidade computacional $O(n \log n)$ para o pior caso. Esse método da declividade *fuzzy*, desenvolvido para esse trabalho, será explicado na seção 3.4.

3.3.2.1 Testes dos algoritmos de Reconhecimento de Padrões

Foram realizados testes dos algoritmos de Reconhecimento de Padrões utilizando o maior número possível de aplicações sobre a base de dados organizada. Estes testes foram sistemáticos para permitir uma estimativa do erro de classificação com o uso da análise ROC. A estimativa desse erro de classificação é feita pela comparação dos detectores com as imagens Ground Truth (GT) de 2 bits. Todas as imagens das Gts e dos detectores utilizados precisam ter imagens com o mesmo número de bits para efetuar essa comparação. Os detectores FuzDec, *Watershed* e Canny geram uma imagem binária (2 bits), onde o valor 0 representa a cor preta e o valor 255 o contorno do objeto de interesse na cor branca. Por outro lado, os detectores Sobel e LOG geram imagens de 8 bits com tonalidades de cinza que variam de 0 até 255. Nesse caso, com o intuito de obter uma estimativa do erro de classificação, foram utilizados um conjunto de critérios preestabelecidos para transformar uma imagem em tons de cinza em uma imagem binária no momento de fazer uso da análise ROC. Esses critérios são utilizados na contagem de TP, FN, FP e TN da matriz de contingência da seguinte forma:

- TP é incrementado quando o pixel da imagem GT é igual ao valor 255 e o pixel da imagem gerada pelo detector é maior ou igual ao valor 50 do nível de cinza;
- Quando o pixel da imagem GT for igual ao valor 255 e o pixel da imagem gerada pelo detector for menor do que o valor 50, FN é incrementada;
- FP é incrementada, quando o pixel da imagem GT e o pixel da imagem gerada pelo detector for igual a zero e maior do que zero respectivamente;
- TN é incrementada, quando o pixel da imagem GT for igual a zero e o pixel da imagem gerada pelo detector for menor do que o valor 50.

3.4 Metodologia do Desvio Padrão da Declividade Fuzzy

O método proposto é baseado nas declividades estimadas sobre as imagens em escalas de cinza. No início, um conjunto de k declividades é quantizada no intervalo $[0.0, 1.0]$ através dos desvios padrões calculados localmente. Em seguida, as funções de pertinência *fuzzy* autoadaptativas são criadas com base na análise da imagem anterior relacionado ao cálculo do desvio padrão. Este sistema *fuzzy* é usado para inferir bordas onde as regras dependem das variáveis linguísticas. A FIG. 22 ilustra a metodologia do desvio padrão da declividade fuzzy.

FIGURA 22 – Diagrama de blocos da metodologia do processo do desvio padrão da declividade fuzzy para detectar o contorno das bolhas.

3.4.1 Metodologia da Declividade

O conceito de declividade utilizado nesse trabalho foi primeiramente definido pelos trabalhos de Miche e Debie (1995), Bensorhair, Miche e Debie, (1996), Bhardwaj e Mittal (2012) que enfatizam que essa característica da imagem tem vantagens importantes quando usadas para propósitos de segmentação.

Tendo como base uma linha da imagem, a declividade Dec desenvolvida nesse trabalho consiste em uma função não linear que mede a amplitude da intensidade dos níveis de cinza (grayscale) em um conjunto de pixels contíguo D_i . A função é limitada pelo intervalo $[x_{i-1}, x_{i+1}]$ que corresponde aos dois extremos

locais normalizados pela diferença entre a maior e a menor intensidade. É importante notar que o novo parâmetro $G(x)$ está associado a definição de Dec . Dec é definido como o quadrado do nível de cinza do pixel na posição x apresentado pela EQ.36.

$$Dec_{l,r} = \frac{\sqrt{\sum_{Di} |G(x)\delta x|}}{\max[I(x,y)] - \min[I(x,y)]} \quad (36)$$

$$0 < Dec_{l,r} < 1$$

$$Di = \{G(x)/x \in [x_i, x_{i+1}]\}$$

$$G(x) = I^2(x)$$

Em contraponto a declividade tradicional, a declividade Dec proposta tem duas propriedades importantes que faz a detecção do padrão ser mais fácil para a aplicação corrente. A primeira propriedade é que Dec pode apresentar dois lados opostos, esquerdo e direito, Dec_l e Dec_r (FIG.23). Dec pode apresentar apenas um valor se os níveis de cinza forem decrescentes ou crescentes através do comprimento da linha da imagem. A segunda propriedade refere-se a normalização do intervalo da declividade. Por definição é normalizada entre os valores 0 e 1. Quando Dec estiver muito próxima de 0, é considerado muito baixa e possivelmente irrelevante para a detecção do contorno na maioria dos casos. Por outro lado, quando é muito próxima de 1, significa dizer que a declividade é importante para a detecção do contorno. Uma outra característica interessante da Dec é que ela pode ser utilizada para segmentar qualquer objeto de interesse presente em uma imagem. Essa característica faz com que a Dec seja útil em outras aplicações para a detecção de contornos.

FIGURA 23 - Declividade da esquerda e direita

3.4.2 Detalhes de implementação da Declividade (Dec)

De acordo com a definição da declividade, a extração de características dos pontos de contorno é realizada tendo como base os picos detectados. As varreduras horizontal e vertical são feitas para estimar a Dec. Um exemplo é ilustrado na FIG. 24. Um perfil de linha com uma resolução de 1×62 de uma bolha isolada é ilustrado na FIG. 25.

FIGURA 24 - (a) imagem negativa de uma bolha. (b) perfil linear ampliado da bolha.

FIGURA 25 - Gráfico da declividade entre a distância (colunas) e os valores de cinza (0-255).

O primeiro pico de declividade (dec-1) encontrado é o menor de todos, entre as colunas 7 e 10 (FIG. 25). O segundo pico (dec-2) entre as colunas 15 e 28 e o terceiro (dec-3) entre 29 e 55. Um vetor de características (VCD), conforme pode ser visto abaixo, consiste em quatro elementos por linha que são implementados por esse método. Essas linhas dispostas no VCD apresentam os valores das declividades (dec-1, dec-2 e dec-3) da FIG. 25.

$$\text{VCD} = \begin{bmatrix} 0.099, 9, 0, 0.139 \\ 0.581, 20, 0, 0.61 \\ 0.877, 44, 0, 0.855 \end{bmatrix}$$

Nesse vetor os elementos representam respectivamente o valor da declividade da esquerda, a coluna do pixel com maior valor de intensidade, a linha do pixel com maior valor de intensidade e finalmente, o valor da declividade da direita.

Tendo como exemplo o pico da declividade dec-3 da FIG.25, a EQ. 36 pode ser utilizada para o cálculo da declividade. Uma outra equação para calcular a Declividade proposta nesse trabalho é utilizada com o objetivo de melhorar o desempenho computacional em comparação à utilização da EQ. 37. Ela permite calcular a declividade em ambos os sentidos de uma forma simples. Levando em consideração a FIG.24 e FIG. 25, o pico da intensidade de nível de cinza da imagem ocorre na coluna 44 com o nível de cinza associado a 214 (máximo) e seus respectivos mínimos, 103 (left) e 111 (right). Para esse exemplo, a declividade da esquerda calculada (dec_L) será 0.877 e a declividade direita (dec_R)

será 0.855. Conforme explicado anteriormente, essas informações compõem a estrutura do vetor de característica localizado na terceira linha do vetor VCD, [0.877, 44, 0, 0.855], que representa o pico dec-3 da FIG.25.

$$Dec_{l,r} = \frac{\sqrt{I^2(x_{i+1}) - I^2(x_i)}}{\max[I(x,y)] - \min[I(x,y)]} \quad (37)$$

O algoritmo 3 apresentado abaixo, descreve os passos fundamentais para a geração do vetor de características das declividades. Esse método foi utilizado para uma varredura da imagem em ambas as direções, horizontal e vertical. O código criado com a tecnologia orientada a objetos foi preparado para fazer uso de uma biblioteca intitulada *multiprocessing* ou outra equivalente. Essa biblioteca consiste em utilizar processamento multi núcleos do processador com o intuito de aumentar a performance computacional.

Algoritmo 3: Método para a geração do vetor de características da declividade

Entradas: img, uma imagem em escalas de cinza de 8 bits.

Saídas: microimg, vetor de características da declividade (esq e dir) da imagem analisada.

- 1: max ← valor máximo da escala de cinzas encontrado na imagem analisada
- 2: min ← valor mínimo da escala de cinzas encontrado na imagem analisada
- 3: microimg = [], dir = [], esq = []
- 4: nl = número de linhas da imagem
- 5: nc = número de colunas da imagem
- 6: para x ← 0 até p faça
- 7: se (img [y][x] >= img [y][x-1]) então
- 8: se dir <> [] então
- 9: adiciona (img [y][x-1]) em dir
- 10: v_dec ← sqrt(maxpoint² – minpoint²) / (max – min)
- 11: adiciona ([0, x-1, y, v_dec])

```
12         dir ← []
13:         adiciona (img [y][x-1]) em esq
14:     fim se
15:     se (img [y][x] < img [y][x-1]) então
16:         se (esq <> []) faça
17:             adiciona ( img [y][x-1] em esquerda
18:             v_dec ← sqrt(maxpoint2 – minpoint2) / (max – min)
19:             após capturar o último item da lista microimg.
20:             adiciona v_dec na posição da esquerda
21:             adiciona (img [y][x-1]) em dir
22:         fim se
23:     fim se
24: fim para
25: retorna (microimg)
26: fim
```

3.4.3 Método do desvio padrão da Declividade

Nessa fase, o método calcula o desvio padrão para cada par de declividade. Considere um vetor de características (VCD) de dimensão N e quantizada em K níveis de 0.0 a 1.0, onde esses níveis representam o intervalo das declividades. A primeira etapa é calcular o histograma normalizado da declividade como uma distribuição de probabilidade p , dada por:

$$\sum_{i=0}^{k-1} p_i$$

para $p_i \geq 0$

onde $p_i = \frac{n_i}{N}$, (38)

onde n_i representa cada declividade, para $i \in [0, N - 1]$.

A segunda etapa, o histograma é dividido em duas classes, um relacionado ao fundo w_0 (*background*) e a outra para as bolhas w_1 (*foreground*) para obter o desvio padrão da declividade em ambos os lados. Assim, as duas classes de probabilidades de ocorrências (w_0 e w_1) estão respectivamente nos intervalos $[0, j]$ e $[j+1, k-1]$ e as suas médias e desvios padrões são definidas por:

$$w_0(j) = \sum_{i=0}^j p_i \quad w_1(j) = \sum_{i=j+1}^{k-1} p_i = 1 - w_0(j) \quad (39)$$

$$\mu_1 = \sum_{i=j+1}^{k-1} \frac{i p_i}{w_1} \quad (40)$$

$$\sigma_1 = \sqrt{\sum_{i=j+1}^{k-1} \frac{(i - \mu_1)^2 p_i}{w_1}} \quad (41)$$

O resultado do cálculo dos desvios padrões (σ_1) pode ser observado abaixo e resulta em momentos acumulativos de terceira ordem, onde as declividades quantizadas em K foram mapeadas localmente. Para exemplificar, o primeiro valor do vetor 4.13338768e+00 representa a probabilidade do desvio padrão da declividade ocorrer no nível de declividade $K = 0.1$.

$$\text{Std} = \sigma_1 (\text{esquerda}) = [2.27585195\text{e}+00, 4.13338768\text{e}+00, 7.07744575\text{e}+00, \\ 8.48334270\text{e}+00, 8.70585992\text{e}+00, 9.00167802\text{e}+00, \\ 9.14904508\text{e}+00, 9.41055527\text{e}+00, 9.85520271\text{e}+00, \\ 5.21569525\text{e}+05]$$

$$\text{Std} = \sigma_1 (\text{direita}) = [7.88934811\text{e}-01, 3.60682225\text{e}+00, 6.45843714\text{e}+00, \\ 7.66032299\text{e}+00, 8.22647962\text{e}+00, 8.81874476\text{e}+00, \\ 9.07764375\text{e}+00, 9.46752718\text{e}+00, 9.94310408\text{e}+00, \\ 4.96816278\text{e}+05]$$

Apesar desses momentos estatísticos (σ_1) apresentarem valores próximos uns aos outros, uma mudança brusca do valor sempre ocorre nessa avaliação. No exemplo acima, essa mudança brusca ocorre no nível de declividade $K = 0.8$ para $K = 0.9$. Portanto, essa ruptura é intitulada nesse trabalho como Transição brusca (*abrupt transition* - at), refere-se ao início do intervalo de declividades onde os valores mais altos do desvio padrão são apresentados na imagem analisada (ver FIG. 26). Esse intervalo é relacionado aos maiores níveis de contraste.

FIGURA 26 - Gráfico da declividade x Desvio padrão – a transição brusca do desvio padrão ocorre em algum valor da declividade dependendo da imagem analisada. Nesse exemplo, ele ocorre no valor de declividade 0.7.

Assim, é possível realizar um mapeamento entre as K níveis de declividades e os seus respectivos desvios padrões que pode ser feito usando a relação de recorrência desenvolvida para esse trabalho, definida em (42).

$$\begin{aligned}
 s_0 &= \sum_{i=0}^{k-at} (\sigma)_i \\
 s_n &= \frac{s_{n-1} - (\sigma)_{j-1}}{s_0} \\
 \forall n, (1 \leq n \leq k-1) \\
 \forall j, j \in [k-at, 0]
 \end{aligned} \tag{42}$$

Um exemplo de um resultado típico é apresentado abaixo.

$$\begin{aligned}
 (\text{dec. da esquerda}) &= \begin{bmatrix} (0.9, 1.0), (0.8, 1.0), (0.7, 0.85), (0.6, 0.719), (0.5, 0.576), \\ (0.4, 0.45), (0.3, 0.32), (0.2, 0.20), (0.1, 0.08), (0.0, 0.029) \end{bmatrix} \\
 (\text{dec. da direita}) &= \begin{bmatrix} (0.9, 1.0), (0.8, 1.0), (0.7, 0.83), (0.6, 0.69), (0.5, 0.56), \\ (0.4, 0.42), (0.3, 0.28), (0.2, 0.17), (0.1, 0.07), (0.0, 0.01) \end{bmatrix}
 \end{aligned} \tag{43}$$

Embora a iluminação utilizada para a captura das imagens foi constante, houve oscilações de iluminação devido a vários ângulos de incidência de luz e consequentemente diferentes refrações causadas pelas bolhas deslocadas. Como resultado, as imagens capturadas apresentam variações de contraste relacionadas a falta de homogeneidade de iluminação. Isso significa que uma bolha em uma imagem pode conter uma diferença de iluminação em seu lado esquerdo comparado ao seu lado direito. Em consequência disso, essa técnica pode ser utilizada para encontrar os desvios padrões de cada lado da declividade devido a distribuição da iluminação.

3.4.4 Método do Desvio padrão da declividade Fuzzy

Embora cada linha da imagem tenha uma sequência de pares de declividade com valores diferentes, não é possível detectar as bolhas tendo como base somente esses pares. Diferenças de iluminação durante a aquisição, formas

irregulares, diferentes tamanhos de bolhas e espessuras não são completamente descritas por essa característica.

A lógica *fuzzy* pode ser útil para lidar com a incerteza dos diversos limiares que podem ser encontrados durante o processo de identificação do contorno das bolhas. A lógica *fuzzy* pode requerer um processamento pesado se aplicado em toda a imagem. Portanto esse método é inicialmente proposto nos vetores de características.

Após a fase de implementação do vetor de característica das propriedades de declividade, um sistema *fuzzy* é definido para transformar os desvios padrões da declividade (σ_1) em graus de pertinência obtida através de uma função de característica *fuzzy*. O desenvolvimento desse sistema de detecção de contornos tem como base alguns trabalhos (Abdallah et al., 2009; Jayachandran et al., 2010; Barkhoda et al., 2009; Patel et al., 2011) que destacam as vantagens da lógica *fuzzy*. As técnicas apresentadas em Barkhoda et al. (2009) e Patel et al. (2011) utilizam duas características da imagem, o gradiente e o desvio padrão dos níveis de cinza que fazem partes das duas funções de pertinência. Em Barkhoda et al. (2009), o gradiente foi obtido pelo operador de Sobel e o desvio padrão por uma máscara 3x3 dos níveis de cinza do *pixel*. Os valores obtidos por ambas as características da imagem são mapeadas para o intervalo de [0, 100]. Esse intervalo é dividido empiricamente para se obter valores de thresholds para classificar as classes, *low*, *medium* e *high* que fazem parte das duas funções membros utilizadas. O método faz uso de nove regras fuzzy e uma função de defuzzificação foi utilizada para classificar se o pixel analisado é um contorno.

O sistema *fuzzy* criado neste trabalho, utiliza uma abordagem estatística do desvio padrão da declividade em ambas as direções (esquerda e direita) que é intitulada como base de fuzzificação dinâmica (BFD), ao invés de utilizar um conjunto de valores empíricos de *threshold* para obter a classificação do pixel. O sistema BFD é um método auto adaptativo que analisa cada vetor de características das declividades de cada imagem, através de duas funções membros dinâmicas. Essas duas funções membros são necessárias para condições de foco variadas causado pelas propriedades ópticas das lentes e a refração devido ao tubo de vidro cilíndrico. As duas funções membro são definidas: uma para o lado esquerdo da declividade e a outra para o lado direito.

Um exemplo é ilustrado na FIG. 27 e suas respectivas funções membro são descritas na EQ. 44, EQ. 45 e EQ. 46.

FIGURA 27 - Função membro dinâmica

$$\mu_{Low}(\sigma_1) = \begin{cases} 0, & \sigma_1 < A \\ \frac{(C - \sigma_1)}{(C - A)}, & A < \sigma_1 \leq C \\ 1, & \sigma_1 \geq C \end{cases} \quad (44)$$

$$\mu_{Mean}(\sigma_1) = \begin{cases} 0, & \sigma_1 < B \\ \frac{(\sigma_1 - B)}{(C - B)}, & B < \sigma_1 \leq C \\ \frac{(D - \sigma_1)}{(D - C)}, & C < \sigma_1 \leq D \\ 0, & \sigma_1 > D \end{cases} \quad (45)$$

$$\mu_{High}(\sigma_1) = \begin{cases} 0, & \sigma_1 < C \\ \frac{(\sigma_1 - C)}{(E - C)}, & C \leq \sigma_1 < E \\ 1, & \sigma_1 \geq E \end{cases} \quad (46)$$

$(A, B, C, D, E) \in [0.0, 1.0]$

A partir dos desvios padrões encontrados para cada declividade (Dec_l and Dec_r), é possível estabelecer os valores do domínio das funções membro para cada declividade. Eles são encontrados analisando o resultado da equação (42), que constitui o método auto adaptativo. O processo inicia na determinação da variável C, que é encontrado pelo par ordenado do vetor da EQ. 43 que contem o valor do desvio padrão mais próximo de 0.5. Posteriormente, os valores das outras variáveis são definidos como segue:

1. E, refere-se ao desvio padrão da declividade mais alto encontrado na imagem, que pode ser visto na equação (43) sendo o valor 1.0, correspondendo a transição brusca;
2. B e D são os valores intermediários das variáveis A e C e das variáveis C e E respectivamente. Os valores B e D podem ser vistos na equação (43);
3. A se refere aos valores de desvio padrão da declividade mais baixos encontrado na imagem, que corresponde ao valor 0.1 como pode ser visto na equação (43) correspondendo aos valores 0.07 e 0.08.

Complementando o sistema *fuzzy*, a base de conhecimento do motor de inferência é apresentado na tabela 1, composto por oito regras de produção, onde há quatro regras simples (regras 1 até 4) e quatro com restrições adicionais para os valores de μ DSD_L e DSD_R (regras 5 até 8).

TABELA 7 – Regras de Inferência.

Variável Linguística: Desvio padrão da Declividade (DSD)	
Conjunto fuzzy: Low, Mean, High	
Número	Regras Simples
1	IF [DSD(left) is high] and [DSD(right) is high] then (pixel is white)
2	IF [DSD(left) is high] and [DSD(right) is mean] then (pixel is white)
3	IF [DSD(left) is mean] and [DSD(right) is high] then (pixel is white)
4	IF [DSD(left) is mean] and [DSD(right) is mean] then (pixel is white)
Número	Regras baseadas no grau de pertinência
5	IF [DSD(left) is mean] and [DSD(right) is low] then IF [GP(left) $\geq$ 0.5] and [GP(right) $\leq$ 0.5] then (pixel is white)
6	IF [DSD(left) is low] and [DSD(right) is mean] then IF [GP(left) $\leq$ 0.5] and [GP(right) $\geq$ 0.5] then (pixel is white)
7	IF [DSD(left) is low] and [DSD(right) is high] then IF [GP(left) $\leq$ 0.5] and [GP(right) $\geq$ 0.5] then (pixel is white)
8	IF [DSD(left) is high] and [DSD(right) is low] then IF [GP(left) = 1.0] then (pixel is white) IF [GP(left) $\geq$ 0.5] and [GP(right) $\leq$ 0.5] then (pixel is white) IF [GP(left) = 1.0] then (pixel is white)

Essas restrições foram necessárias para otimizar a detecção de contorno quando inclui os valores do desvio padrão da declividade incluídos foram classificadas como conjuntos *Low* dentro das regras *fuzzy* criadas.

4 Resultados e Discussão

Abaixo é apresentado a aplicação do algoritmo proposto, o FuzDec, no cálculo da medida de fração de vazio em imagens de escoamento bifásico dividido em duas seções. Na seção 4.1 é apresentado o FuzDec sendo aplicado em imagens com alta fração de vazio e na seção 4.2 a aplicação foi feita em imagens com baixa fração de vazio. Para esse trabalho, alta fração de vazio corresponde ao valor a partir de 30%.

4.1 Aplicação do FuzDec em imagens de alta fração de vazio e comparação com os detectores de contornos clássicos.

O algoritmo proposto FuzDec foi aplicado no banco de imagens criado para as imagens de escoamento de circulação natural adquirido nos circuitos experimentais sob condições de baixa pressão. Muitas imagens são relacionadas aos ciclos de incubação (*incubation*) e reenchimento (*refill*), que são as instabilidades dos padrões de escoamento de circulação natural, descrito no trabalho de Andrade et al (2010). As imagens foram obtidas por uma câmera Canon EOS 5D Mark II com uma objetiva EF 100mm f/2.8L Macro IS USM. As imagens analisadas apresentaram três resoluções básicas: 2316 x 1208, 864 x 330 e 744 x 374.

A atuação dos detectores de contornos pode ser avaliada com o uso de *receiver-operating characteristics* (ROC) em comparar o resultado com imagens produzidas manualmente por um ser humano. Essas imagens são intituladas de Ground Truth (GT) e indicam uma detecção ideal de observação (Heath, Sarkar, Bowuery, 1998). Mesmo com diferentes GTs produzidas por pessoas diferentes ou em ocasiões diferentes, o ranking relativo não muda, apenas a posição absoluta dos pontos ROCs variam, mas a ordem dos resultados é estável (Bowyer, Kraneburg, Doughrity, 2001).

A abordagem relativa à análise ROC envolve em determinar quatro métricas, *true positive* (TP), *false positive* (FP), *true negative* (TN), *false negative* (FN). Se um detector reportar um pixel de contorno onde a GT reportar também um pixel de contorno, então a TP é incrementada. Se um pixel é reportado em

uma região sem pixels da GT, então FP é incrementada. Onde não existir pixels de contornos na GT e no detector, TN é incrementada. Se existir pixels de contornos na GT, mas não existir no detector, FN é incrementada. Os quatro valores das métricas foram calculadas tendo como base a porcentagem total dos pixels da imagem GT. Valores altos de TP e TN associados a baixos valores de FP e FN serão requeridos para um detector ser considerado bom, quando a curva do gráfico estiver próximo do ponto (0,1). O método é considerado randômico quando estiver próximo do ponto (1,0). A FIG. 28 apresenta as imagens em tons de cinza das bolhas do banco de imagens e suas correspondentes imagens GT. Os contornos dos pixels são representados pelos valores 255 (branco) e zero (preto) que indica regiões sem interesse.

FIGURA 28 – Imagens que apresentam baixa fração de vazio com resolução de 1158 x 604. (a, c, e, g) imagens em tons de cinza e (b, d, f, h) imagens GT.

A FIG.27 mostra imagens das bolhas com resolução de 432 x 165 pixels no ciclo *refill* no escoamento com alta fração de vazio. Um critério para a identificação manual dessas bolhas foi detectar o contorno que estava com a intensidade maior daquele contorno apresentado pelo fundo (*background*).

FIGURA 29 – Imagens GT que apresentam alta fração de vazio com resolução de 432 x 165 pixels. (a, c, e, g) imagens em tons de cinza e (b, d, f, h) imagens GT.

A FIG.30 apresenta imagens das bolhas com resolução de 372 x 187 pixels no ciclo *refill-incubation* com alta fração de vazio e suas GT's. A produção das imagens GT's levou em consideração o mesmo critério utilizado para a produção das GT's da FIG.26.

FIGURA 30 – Imagens GT que apresentam alta fração de vazio com resolução de 372 x 187 pixels. (a, c, e, g) imagens em tons de cinza e (b, d, f, h) imagens GT.

O algoritmo de detecção criado foi implementado usando a linguagem de programação Python e foi aplicado a diversas imagens que foram comparadas aos detectores de contornos clássicos, o operador de Sobel, LOG, Canny e Watershed (Sobel, 1974; Marr e Hildreth, 1980; Canny, 1986; Meyer, 1992). Os resultados da detecção (FIG. 31) das bolhas no escoamento bifásico sob baixa pressão são discutidos nesta secção dos padrões. Os resultados da detecção relacionados a imagens com alta fração de vazio da fase de transição da instabilidade *refill-incubation* são ilustrados na FIG.32 e FIG.33. Essas últimas imagens apresentam muitas bolhas compactadas, que representam uma tarefa difícil para os algoritmos de detecção. O Algoritmo proposto obteve resultados satisfatórios para todos os tipos de imagens analisadas.

FIGURA 31 – Resultado dos detectores de contornos para as imagens da FIG. 28. (a) Imagem em tons de cinza. (b) Detector de Sobel. (c) Detector LoG. (d) Detector de Canny. (e) Detector de Watershed (f) Detector da Declividade Fuzzy.

FIGURA 32 – Resultado dos detectores de contornos para as imagens da fase de Refill da FIG. 29. (a) Imagem em tons de cinza. (b) Detector de Sobel. (c) Detector LoG. (d) Detector de Canny. (e) Detector de Watershed (f) Detector de Declividade Fuzzy

FIGURA 33 - Resultado dos detectores de contornos para as imagens da fase de Refill-incubation da FIG. 30. (a) Imagem em tons de cinza. (b) Detector de Sobel. (c) Detector LoG. (d) Detector de Canny. (e) Detector de Watershed (f) Detector da Declividade Fuzzy.

O Operador de Sobel destacou bolhas que podem ser identificadas através de pixels bem conectados apresentando intensidades diferentes. As intensidades mais fortes estão relacionadas as bordas principais, mas o detector de Sobel apresentou muitos detalhes mesmo em regiões da imagem onde as bolhas borradas estiveram presentes. Esse detector também tem como dificuldade identificar os contornos onde o baixo contraste está presente, como a utilização do valor 2 na posição central da máscara que resulta em uma imagem suavizada. Além disso, o operador obteve características da sombra interna das bolhas, produzindo uma aparência de duplo contorno (*double edge*).

A detecção de Canny faz uso de uma lista de critérios para a identificação: boa detecção, boa localização e resposta mínima. O detector de Canny realiza o filtro da imagem através do gradiente usando um operador de primeira ordem (tal como Sobel e Roberts) com o intuito de atenuar o ruído. Esse procedimento objetiva aplicar a supressão máxima para remover pixels, que não devam ser considerados como parte de contornos, e faz uso de dois limiares: um para aceitar um pixel como contorno e o outro para rejeitar. Entretanto, se o pixel apresentar um valor do gradiente de primeira ordem entre esses dois limiares, este pixel somente será considerado se ele está conectado ao pixel que está acima do limiar mais alto. Neste trabalho, seguindo as recomendações de Canny (1976), os valores para baixo limiar (*low threshold*) e alto limiar (*high threshold*) configurado foram 30 e 150 respectivamente. O algoritmo de Canny não permitiu contornar todas as bolhas, somente as bolhas na aplicação corrente àquelas que apresentam contornos em alto-contraste (FIG.32(d) e FIG.31(d)). Para a obtenção desses resultados o método de Canny foi configurado inicialmente para os valores de limiares recomendados, seguindo as suas recomendações. Entretanto, outros valores de limiares foram utilizados nos quais apresentaram resultados diferentes. Essas diferenças permitiram o método contornar outras bolhas e também partes do *background* das imagens com alta fração de vazio. O critério utilizado para a escolha manual desses valores foi feito em duas partes. A primeira foi escolher o valor de limiar que represente o *background*, e a segunda o valor de limiar que represente o contorno das bolhas. A dificuldade nessas escolhas foi em descobrir manualmente esses valores de limiares para cada imagem, pois há grandes variações de tons de cinza nas imagens.

No método de segmentação baseado em *watershed*, consiste em encontrar características da imagem intituladas linhas de água (*water lines*) que são definidas como os limites do processo de inundação onde a topologia da imagem de cima para baixo é preenchida até um estágio é obtido, onde somente topos das barragens são observados. Nesse ponto, as linhas de água define a técnica para a extração dos contornos conectados. O resultado de uma segmentação mais estável pode ser obtido através desse algoritmo onde os contornos de segmentação conectados são desejados, tal como na detecção de contorno das bolhas muito próximas umas das outras. Entretanto, quando essa técnica (Meyer, 1992) foi aplicada para as imagens desse trabalho, caminhos desconexos foram formados, ocorrendo super segmentação como ilustrado nas FIG.32(e) e FIG.33(e). Essa super segmentação foi devido as diversas variações de tonalidade no fundo da imagem (*background*), dentro das bolhas e nos contornos das bolhas.

O operador LOG realiza seu primeiro passo com o uso da suavização através do operador gaussiano devido à sensibilidade ao ruído e em seguida aplica o laplaciano nas imagens. Esse operador é governado pelo desvio padrão do filtro gaussiano, ou seja, quanto maior for o valor desse desvio padrão, mais amplo deve ser a matriz desse filtro. Isso resulta em uma imagem borrada, tornando a tarefa de detecção de contornos mais difícil em imagens com alta fração de vazio. Apesar de apresentar um bom resultado do operador LOG na FIG.31 (c), a suavização pode destruir o contorno de algumas bolhas, dificultando o trabalho do operador LOG em não detectar todo o contorno, conforme pode ser visto na FIG.32(c) e FIG.33(c). Esse resultado é devido a espessura da borda da bolha ser maior que a máscara do filtro utilizada (5x5).

Um dos pontos importantes na tarefa de segmentação está no fato de encontrar contornos mais finos ao invés dos detalhes de seus vizinhos mais próximos (Alshennawy et al, 2009), o algoritmo proposto, diferentemente dos métodos anteriores, leva em consideração o desvio padrão para cada declividade encontrada. FuzDec não faz uso da suavização, mesmo quando houver ruídos no fundo, ruídos no interior das bolhas e em regiões com diferentes níveis de contraste.

Como mostrado na FIG.35 e FIG.36, o detector proposto atinge melhores resultados (ver FIG. 31(b) e FIG.31(f)). Na FIG.29 encontra-se uma imagem

homogênea, onde não há grandes diferenças de iluminação. Nesse caso, o algoritmo proposto e o operador LOG possuem resultados próximos. Entretanto, quando a imagem é muito heterogênea, ou seja, imagem com alta fração de vazio presente no escoamento, é possível identificar ruídos, vários borrões dentro e próximo dos contornos das bolhas. Esse é o caso das imagens apresentadas nas FIG.32 e FIG.33, onde o algoritmo proposto (FuzDec) foi capaz de encontrar um número maior de bolhas simples, de bolhas aglomeradas e subtrair o *background* sem prejudicar o contorno contínuo da maioria das bolhas. Além disso, quanto mais o nível de ruído aumenta, o algoritmo proposto fornece melhorias mais significantes na detecção do contorno, devido a sua robustez ao ruído, conforme resultados apresentados através da análise ROC na FIG.35 e FIG. 36. A FIG.34 apresenta o gráfico das curvas ROC e a tabela 8 as medidas de área calculada sob a curva para cada detector.

(b)

(c)

FIGURA 34 - Análise ROC da FIG.31. (a) Curvas da FIG.31 (linha 1). (b) Curvas da FIG.31 (linha 2). (c) Curvas da FIG.31 (linha 3). (d) Curvas da FIG.31 (linha 4).

Nas imagens da FIG.31 (b), observa-se que o operador de Sobel detecta todos os contornos das imagens da FIG.31 (a) obtendo as maiores taxas de TP. Mesmo supondo um resultado ótimo para esse operador, entretanto, não é isso que ocorre. O operador de Sobel apresenta uma medida de área sob a curva muito pequena, devido à presença de duplo contorno na detecção, comprometendo o resultado por apresentar altas taxas de FP (TAB.8: FP = 0,99) para todas as imagens analisadas.

Os melhores resultados foram alcançados pelo detector de Canny (ver TAB.8) em todas as imagens, devido a obtenção das menores taxas de FP. No entanto, analisando a imagem da FIG.31 (1d), por exemplo, esse detector não obteve um bom resultado na identificação das bolhas (TAB.8: TP = 0,09; 0,16; 0,16 e 0,18), ou seja, apenas quatro bolhas de nove foram identificadas. Em contrapartida, o algoritmo proposto obteve uma área sob a curva ROC pouco

inferior a área da curva calculada para o detector de Canny, mas permitiu identificar as bolhas sem gerar duplo contorno com baixas taxas de FP (ver TAB. 8).

TABELA 8 - Medidas de área sob a curva e seus respectivos pontos ROC da FIG.34

Medidas de Área (a)								
Detectores	FIG.34 (1)		FIG.34 (2)		FIG.34 (3)		FIG.34 (4)	
Proposto	$a = 0,84$		$a = 0,75$		$a = 0,80$		$a = 0,86$	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,27	0,03	0,27	0,069	0,32	0,058	0,33	0,035
Sobel	$a = 0,033$		$a = 0,063$		$a = 0,054$		$a = 0,055$	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,47	0,99	0,68	0,99	0,63	0,99	0,62	0,99
LoG	$a = 0,75$		$a = 0,66$		$a = 0,70$		$a = 0,77$	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,16	0,04	0,22	0,095	0,24	0,08	0,27	0,055
Canny	$a = 0,85$		$a = 0,83$		$a = 0,84$		$a = 0,88$	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,09	0,008	0,16	0,017	0,16	0,016	0,18	0,013
Watershed	$a = 0,41$		$a = 0,42$		$a = 0,41$		$a = 0,40$	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,33	0,45	0,32	0,42	0,31	0,43	0,31	0,45

A FIG.35 ilustra o gráfico das curvas ROC para as imagens que apresentam alta fração de vazio presentes no escoamento para o ciclo de *refill* obtidas pelo arranjo experimental. Essas imagens são ilustradas na FIG. 33. A TAB.9 apresenta as medidas de área calculada sob a curva da FIG.35 para cada detector.

FIGURA 35 - Análise ROC da FIG.32. (a) Curvas da FIG.32 (1). (b) Curvas da FIG.32 (linha 2). (c) Curvas da FIG.32 (linha 3). (d) Curvas da FIG.32 (linha 4).

O algoritmo proposto alcançou os melhores resultados, conforme pode ser observado no cálculo de área e nas altas taxas de TP ilustrado na TAB.9 para esse conjunto de imagens. O Operador de Sobel considerou partes do *background* próximos as bolhas (ver FIG. 32 (b)) e gerou duplo contorno, no qual dificulta a tarefa de identificação das bolhas individualmente. LoG obteve bons resultados na identificação das bolhas, resultando em boas taxas de TP e baixas taxas de FP. O detector de Canny não alcançou resultados satisfatórios no contorno das bolhas. Nesse caso, esse detector pode funcionar para imagens que apresentam alta fração de vazio, mediante a escolha de outros valores de *threshold* daqueles recomendados por Canny (1986). O algoritmo de *watershed* obteve poucos acertos (baixa taxa de TP) com a geração de supersegmentação devido a grandes variações presentes no background.

TABELA 9 – Medidas de área sob a curva e seus respectivos pontos ROC da FIG.35

Medidas de Área (a)								
Detectores	FIG.35 (1)		FIG.35 (2)		FIG.35 (3)		FIG.35 (4)	
Proposto	<i>a</i> = 0,74		<i>a</i> = 0,71		<i>a</i> = 0,72		<i>a</i> = 0,74	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,62	0,27	0,54	0,23	0,61	0,28	0,58	0,23
Sobel	<i>a</i> = 0,004		<i>a</i> = 0,004		<i>a</i> = 0,003		<i>a</i> = 0,005	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,28	0,99	0,20	0,99	0,23	0,99	0,24	0,99
LoG	<i>a</i> = 0,58		<i>a</i> = 0,58		<i>a</i> = 0,56		<i>a</i> = 0,58	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,51	0,39	0,37	0,27	0,42	0,33	0,41	0,30
Canny	<i>a</i> = 0,69		<i>a</i> = 0,69		<i>a</i> = 0,52		<i>a</i> = 0,70	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,01	0,003	0,012	0,004	0,004	0,004	0,008	0,002
Watershed	<i>a</i> = 0,62		<i>a</i> = 0,60		<i>a</i> = 0,60		<i>a</i> = 0,61	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,35	0,21	0,32	0,004	0,35	0,25	0,33	0,21

A FIG.36 apresenta o gráfico das curvas ROC para as imagens que apresentam alta fração de vazio no escoamento no ciclo de *refill-incubation* obtidas pelo arranjo experimental ilustrado na FIG. 1. A TAB.10 apresenta as medidas de área calculadas sob a curva da FIG.36 para cada detector analisado.

(a)

(b)

(c)

(d)

FIGURA 36 - Análise ROC da FIG.33. (a) Curvas da FIG.33 (1). (b) Curvas da FIG.33 (linha 2). (c) Curvas da FIG.33 (linha 3). (d) Curvas da FIG.33 (linha 4).

O melhor resultado foi obtido pelo detector proposto (FIG.36 (b), FIG.36(c) e FIG.36(d) e pelo algoritmo de *watershed* (FIG. 36(a)). Esse último algoritmo gerou super segmentação em algumas regiões conforme os resultados apresentados nas FIG.36(b), FIG.36(c) e FIG.36(d). O detector de Sobel teve dificuldades em identificar as bolhas e detectou muitas regiões que pertencem ao *background* das imagens (ver FIG.36). A detecção obtida por Canny (ver FIG.33(d)) não atingiu resultados que permitiu diferenciar o contorno das bolhas do *background*. Como consequência, as áreas calculadas por esse detector foram todas iguais a zero conforme apresentado na TAB.10 (FIG.36(linha 2), FIG.36(linha 3) e FIG.36(linha 4)).

TABELA 10 - Medidas de área sob a curva e seus respectivos pontos ROC da FIG.36

Medidas de Área (a)								
Detectores	FIG.36 (1)		FIG.36 (2)		FIG.36 (3)		FIG.36 (4)	
Proposto	$a = 0,61$		$a = 0,64$		$a = 0,66$		$a = 0,67$	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,46	0,30	0,48	0,27	0,54	0,30	0,55	0,30
Sobel	$a = 0,001$		$a = 0,0009$		$a = 0,002$		$a = 0,002$	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,06	0,99	0,045	0,99	0,097	0,99	0,087	0,99
LoG	$a = 0,52$		$a = 0,53$		$a = 0,53$		$a = 0,0$	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,19	0,17	0,16	0,14	0,27	0,23	0,28	0,22
Canny	$a = 0,39$		$a = 0,0$		$a = 0,0$		$a = 0,70$	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,0004	0,0008	0,0	0,0	0,0	0,0	0,0	0,0
Watershed	$a = 0,62$		$a = 0,60$		$a = 0,61$		$a = 0,63$	
	TP	FP	TP	FP	TP	FP	TP	FP
	0,37	0,22	0,35	0,22	0,34	0,21	0,37	0,21

A precisão do FuzDec é fortemente afetada pela análise estatística de cada imagem gradiente. Consequentemente, quando as imagens incluem um grande número de bolhas conectadas (FIG.35 e FIG.36), o desempenho da identificação é melhorada: o número de bolhas detectadas (alta taxa de TP) com pouco erros (baixas taxas de FP).

4.2 Aplicação de FuzDec em imagens de baixa fração de vazio

4.2.1 Cálculo do volume total de líquido presente nas imagens utilizadas

A aquisição das imagens obtidas em 2013 e 2015 foram feitas pelo mesmo arranjo experimental, mas os diâmetros dos tubos foram diferentes. No experimento de 2013 e 2015, as medidas dos diâmetros externos foram de 4.44 cm e 4.56 cm respectivamente com a mesma espessura de 0.4 cm. Então, os raios internos medem 1.82 cm para o experimento de 2013, e 1.88 para o experimento de 2015 (FIG. 37 (b)) com uma profundidade de campo de 2.0 cm que implica em uma medida de 1.6 cm de profundidade para efeito do cálculo de volume da mistura bifásica para ambos os tubos, conforme pode ser visto na FIG. 37 (a):

FIGURA 37 – Geometria dos tubos para o cálculo do volume de líquido. (a) Profundidade de campo considerada. (b) Geometria para o experimento de 2013. (c) Geometria para o experimento de 2015.

sendo Θ o ângulo formado pela corda (w) e o centro do tubo interno de raio (r), f é a flecha (EQ. 47) e A (EQ. 48) e A_s (EQ. 49) as áreas do quadrado e do arco. Com a finalidade de medir o volume da mistura bifásica presente nas imagens, a área total (EQ. 50) deve ser calculada com o uso de algumas equações para o cálculo da geometria dos tubos, conforme pode ser visto nas equações abaixo.

$$f = r - \frac{1}{2} \sqrt{(4r^2 - w^2)} \quad (47)$$

$$A = (1.6 - flecha) \times altura \quad (48)$$

$$A_s = \frac{r^2}{2} \times \left(\frac{\pi \times \Theta}{180} - \text{sen}(\Theta) \right) \quad (49)$$

$$A_T = A + A_s \quad (50)$$

A medida do volume da seção transversal da A_T calculada pode ser obtida, tendo como base as imagens originais capturadas. Por exemplo, 4.44 cm de diâmetro externo do tubo equivale a 1978 pixels nas imagens. As medidas utilizadas nesse trabalho para os volumes da mistura bifásica são apresentadas na TAB. 11.

TABELA 11 - Medidas dos volumes de líquido nos tubos

Experimento	Medida
2013	12.05 [cm ³]
2015 (com caixa anti-refração)	37.29 [cm ³]
2015 (sem caixa)	18.75 [cm ³]

4.2.2 Comparação do método por imagem com a medida obtida pelo método gravimétrico

Nessa seção, é apresentado uma comparação entre as medidas realizadas pelo método FuzDec com as medidas obtidas pelo método gravimétrico para baixa fração de vazio nos experimentos realizados em 2013 e 2015. O método utilizou um ajuste das funções de pertinência para capturar as bolhas em foco nos experimentos 2013 e nos setores das imagens onde a caixa anti-refração não atua nos experimentos de 2015. As imagens adquiridas pelo experimento de 2013 foram divididas em três partes iguais com o objetivo de obter uma execução mais rápida do algoritmo FuzDec. A TAB. 12 apresenta as medidas de fração de vazio obtidas pelo experimento de 2013.

TABELA 12 – Cálculo da fração de vazio obtida pelo experimento de 2013

Medidas de Fração de Vazio (2013)			
Identificação das Imagens	ΔH	Medidas	%
77.tif	3 mm	0.002314	0.24%
81.tif	4 mm	0.003085	0.31%
86.tif	5 mm	0.003856	0.39%
89.tif	8 mm	0.006170	0.62%
96.tif	9 mm	0.006941	0.70%
102.tif	14 mm	0.010797	1.08%

O ΔH representa a medida obtida na observação dos manômetros de coluna da FIG. 20 para o cálculo da fração de vazio através da EQ. 35, explicado anteriormente na seção 2. A TAB 13 mostra as medidas das frações de vazio obtidas no experimento de 2015.

TABELA 13 – Cálculo da fração de vazio obtida pelo experimento de 2015

Medidas de Fração de Vazio (2015)			
Identificação das Imagens	ΔH	Medidas	%
84.tif	0 mm	0.00	0%
63.tif	0.3 mm	0.000229	0.023%
68.tif	0.7 mm	0.000535	0.054%
69.tif	3 mm	0.002292	0.23%
61.tif	4 mm	0.003057	0.31%
80.tif	4 mm	0.003057	0.31%

O método FuzDec obteve um conjunto de medidas para o experimento de 2013 das imagens ilustradas na FIG.38 e o cálculo é mostrado na TAB. 14.

77.tif	81.tif	86.tif	89.tif	96.tif	102.tif
1
2
3

FIGURA 38 – Resultado do FuzDec para medir a fração de vazio nas imagens do experimento feito 2013.

TABELA 14 – Comparação dos métodos para as imagens obtidas em 2013

Medidas de Fração de Vazio (2013)				
Identificação das Imagens	Medida por Imagens (FuzDec)	% (FuzDec)	% (Método Gravimétrico)	Erro (pontos percentuais)
77.tif	0.001152	0.12%	0.24%	0.12 pp
81.tif	0.001484	0.15%	0.31%	0.16 pp
86.tif	0.004239	0.42%	0.39%	0.03 pp
89.tif	0.005121	0.51%	0.62%	0.11 pp
96.tif	0.007978	0.80%	0.70%	0.10 pp
102.tif	0.015140	1.51%	1.08%	0.43 pp

No experimento de 2015, a FIG. 39 ilustra as imagens capturadas com o uso da caixa anti-refração. O calculo é apresentado na TAB. 15.

FIGURA 39 – Resultado do FuzDec para medir a fração de vazio nas imagens do experimento feito 2015 (com caixa anti-refração).

TABELA 15 – Comparação dos métodos para as imagens obtidas em 2015 com caixa

Medidas de Fração de Vazio (2015 – com caixa anti-refração)				
Identificação das Imagens	Medida por Imagens (FuzDec)	% (FuzDec)	% (Método Gravimétrico)	Erro (pontos percentuais)
84.tif	0.000062	0.0062%	0%	0.0062 pp
63.tif	0.000208	0.021%	0.023%	0.002 pp
68.tif	0.000179	0.018%	0.054%	0.03 pp
69.tif	0.002735	0.27%	0.23%	0.04 pp
61.tif	0.004303	0.43%	0.31%	0.12 pp
80.tif	0.002201	0.22%	0.31%	0.09 pp

A FIG. 40 apresenta as imagens capturadas sem o uso da caixa anti-refração. O cálculo da fração de vazio é apresentado na TAB. 16.

FIGURA 40 – Resultado do FuzDec para medir a fração de vazio nas imagens do experimento feito 2015 (com caixa anti-refração).

TABELA 17 – Comparação dos métodos para as imagens obtidas em 2015 sem caixa

Medidas de Fração de Vazio (2015 – sem caixa anti-refração)				
Identificação das Imagens	Medida por Imagens (FuzDec)	% (FuzDec)	% (Método Gravimétrico)	Erro (pontos percentuais)
84.tif	0.000031	0.0031%	0%	0.0031 pp
63.tif	0.000157	0.016%	0.023%	0.007 pp
68.tif	0.000109	0.011%	0.054%	0.043 pp
69.tif	0.000102	0.010%	0.23%	0.22 pp
61.tif	0.001433	0.14%	0.31%	0.17 pp
80.tif	0.002041	0.204%	0.31%	0.106 pp

As medidas feitas no experimento de 2015 com o uso caixa anti-refração obteve melhores resultados em comparação com os valores obtidos nos experimentos de 2013 e 2015 (sem caixa). Isso ocorre porque o experimento realizado com a caixa anti-refração permitiu considerar todas as bolhas da imagem para o cálculo do volume de gás. O que não ocorre nos experimentos sem a caixa anti-refração. Nesse caso, a região considerada para a captura das bolhas foi menor, ou seja, somente as bolhas em foco foram consideradas para o cálculo do volume do gás presente no tubo. Com isso, a diferença das porcentagens de fração de vazio foi maior nos experimentos sem caixa com diferenças de 0.1% 0.4% e 0.4% para os experimentos de 2015 (com caixa), 2015 (sem caixa) e 2013 respectivamente (ver TAB. 14, TAB. 15 e TAB. 16). Isso ocorre porque a distribuição das bolhas ao longo do tubo pode não ser homogênea (Rocha, 2005). Nesse sentido, capturar uma região maior garante uma medida com mais precisão no cálculo da fração de vazio.

Na imagem 84.tif (TAB. 16) é possível observar uma medida de 0% pelo método gravimétrico e 0.0031% no método por imagens sem caixa e 0.0065% com caixa. Assim, o método por imagens considerou corretamente três bolhas pequenas na imagem (ver FIG. 40 (84.tif) para a obtenção do cálculo do volume e consequentemente a medida da fração de vazio.

Um outro ponto que vale ressaltar é que os valores muito pequenos de ΔH (abaixo de 1 mm) são difíceis de observar a olho nu nos manômetros de coluna pelo método gravimétrico. Essa observação foi melhorada com a auxílio das fotografias dos manômetros de coluna no momento de realizar cada medição. Nesse caso, o método por imagens (FuzDec) alcançou bons resultados na medição de frações de vazio onde o ΔH apresentou valores abaixo de 1 mm, conforme a TAB. 15 (84.tif) e TAB. 16 (84.tif).

Conclusões

Este trabalho desenvolveu um método para detecção de contornos em imagens onde os objetos de interesse são muito próximos e que apresentem outras complexidades como fundo da imagem com mudanças abruptas de intensidade e oscilação de iluminação. Através de curvas ROC foi verificado um desempenho deste método (FuzDec) superior aos métodos clássicos de detecção de contorno (Sobel, LOG, Canny e Watershed).

Este método, além de apresentar melhores resultados, faz uma segmentação destas imagens complexas sem interação humana. FuzDec utiliza-se de funções membro fuzzy que dinamicamente se baseiam na estatística da declividade da imagem analisada. O cálculo do desvio padrão da declividade foi localmente mapeado para cada declividade tornado possível localizar uma transição brusca no vetor de características do desvio padrão que tornou o método auto adaptativo. A seleção do desvio padrão foi implementado através da lógica *fuzzy* usando duas funções membros dinâmicas para cada imagem analisada.

Este método foi aplicado a imagens de escoamento bifásico com adaptação das funções membro para filtrar os objetos das imagens adquiridas que estivessem fora de foco. Assim foi possível fazer estimativas da fração de vazio e compará-las com medidas diretas feitas pelo método gravimétrico. Esta aplicação se mostrou coerente para baixas frações de vazio (regime de bolhas dispersas). Os resultados foram apresentados em duas etapas. Na primeira etapa o algoritmo desenvolvido foi aplicado nas imagens de alta fração de vazio e foi feito uma comparação com os detectores de contornos clássicos. Na segunda etapa, o algoritmo foi aplicado em imagens para o cálculo de baixas frações de vazio em comparação ao método gravimétrico.

Os resultados mostraram que o detector proposto, sem a necessidade de fazer uso dos algoritmos de suavização e sem nenhuma intervenção humana, conseguiu melhorar a identificação do contorno em comparação aos detectores clássicos de Sobel, LOG, Canny e o método de watershed. Além disso, o detector proposto permitiu calcular frações de vazio muito baixas em imagens comparado ao método gravimétrico e conseguiu uma diferença de no máximo 0,12%

para um conjunto de imagens e 0,43 para os outros dois conjuntos de imagens utilizadas.

Estes resultados obtidos sugerem que a técnica desenvolvida será de muita utilidade no desenvolvimento da aplicação para estimativa da fração de vazio em imagens de escoamento em regimes com maior densidade de bolhas ou com altos valores de fração de vazio. Sugere-se assim que esta aplicação da técnica seja desenvolvida em comparação com outros métodos não invasivos de estimação de fração de vazio, tais como, a medição de impedância elétrica utilizando-se de sensores capacitivos e medidas feitas por ultrassom. Para outras aplicações, o método poderia ser utilizado para a calibração de sensores para estimativa da fração de vazio em escoamento bifásico de água-óleo, em sistemas frigoríferos para gerenciar o rendimento do trocador de calor, escoamento em micro canais, entre outros.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABDALLAH H. A., MOHIY, M., SHAALAN A., SVD-based watermarking scheme in complex wavelet domain for color video, *IEEE Int. Conf. Comput. Eng. Syst.* (2009) 455–460. doi:10.1109/ICCES.2009.5383220.
- ALSHENNAWY, A. A., & Aly, A. Edge Detection in Digital Images Using Fuzzy Logic Technique, 2009.
- AMARAL et al. Image Processing Techniques for high-speed videometry in horizontal two-phase slug flows. *Flow Measurement and Instrumentation*, 2013.
- ANDRADE, D., A. Belchior Jr., G. Sabundjian, J.L.F. Bastos, Two-Phase Instabilities in a Natural Circulation Rectangular Loop. *Proc. 8th International Conference on Nuclear Engineering*, Baltimore – Maryland, 2000.
- BARKHODA, W & Tab, F. A., & Shahryari, O. (2009). Fuzzy Edge Detection Based on Pixel's Gradient and Standard Deviation Values, 7–10.
- BENDER, Edward A. *Mathematical Methods in Artificial Intelligence*. IEEE Computer Society Press, 1996.
- BENSRHAIR, A., Mich, P., & Debie, R. (1996). Fast and automatic stereo vision matching algorithm based on dynamic programming method, 17, pp. 457–466.
- BERZINS.V. Accuracy of Laplacian Edge Detection. *Computer Vision, Graphics and Image Processing*. 27(2): 195-210, 1984.
- BORGNAKKE, C.; Sonntag, R.E. Fundamentos da Termodinâmica, São Paulo: *Edgard Blucher*, 2013.
- BHARDWAJ, S., & Mittal, A. (2012). A Survey on Various Edge Detector Techniques. *Procedia Technology*, 4, pp. 220–226. doi:10.1016/j.protcy.2012.05.033
- BOWYER, K, KRANENBURG, C., DOUGHERTY, S. *Edge Detector Evaluation Using Empirical ROC Curves*, (1999) 354–359.
- BRISAN, C., Vasiu, R.-V., & Munteanu, L. (2013). A modular road auto-generating algorithm for developing the road models for driving simulators. *Transportation Research Part C: Emerging Technologies*, 26, 269–284. doi:10.1016/j.trc.2012.09.008
- BUSCIGLIO, A.; GRISAFI, BRUCATO, A. *On the measurement of bubble size distribution in gas-liquid contactors via light sheet and image analysis*. *Chemical Engineering Science*, pp.: 2558-2568, 2010.
- CANNY, J. *A Computational Approach to Edge Detection*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. PAMI-8. No.6, 1986.
- CHAN, M. K., YOUN, K. K., LEE K. J., KO, Y. J., KIM, S. Electrical impedance imaging of phase boundary in two-phase systems with adaptive mesh regeneration technique, *Int. Commun. Heat Mass Transf.* 32 (2005) 954–963. doi:10.1016/j.icheatmasstransfer.2004.10.024.
- CRIVELARO, K.C.O.; SELEGHIM, P.; HERVIEU, E. *Detection Horizontal of two-phase flow patterns through a Neural Network Model*. *Journal of the Brazilian Society of Mechanical Sciences*, 2002.

- ÇENGEL, Y. A.; BOLES, M. A. *Thermodynamics: An Engineering Approach*. Seventh Edition. Mc Graw Hill, 2008.
- DE MESQUITA, R.N., MAZOTTI, P.H.F., PENHA, R.M.L., ANDRADE, D.A., SANUNDJIAN G., TORRES, W.M. et al., Classification of natural circulation two-phase flow patterns using fuzzy inference on image analysis, *Nucl. Eng. Des.* 250 (2012) 592–599. doi:10.1016/j.nucengdes.2012.06.014.
- DROZDEK, Adam. *Estrutura de Dados e Algoritmos em C++*. Tradução de Luiz Sergio de Castro Paiva. São Paulo: Cengage Learning, 2008.
- DINH, T. B.; CHOI, T.S. *Application of Image Processing Techniques in Air/Water Phase Flow*. Mechanics Research Communications, Vol.26, No. 4, pp. 463-468. Elsevier Science, 1999.
- DAVIES, E.R. *Machine Vision: Theory, Algorithms, Practicalities*. 3. Edition. Elsevier, 2005.
- EI ANSARI, M., Mousset, S., & Bensrhair, A. (2010). Temporal consistent real-time stereo for intelligent vehicles. *Pattern Recognition Letters*, 31(11), pp. 1226–1238. doi:10.1016/j.patrec.2010.03.023
- EI Ansari, M., Mousset, S., Bensrhair, A., & Bebis, G. (2010). Temporal consistent fast stereo matching for advanced driver assistance systems (ADAS). *2010 IEEE Intelligent Vehicles Symposium*, pp. 825–831. doi:10.1109/IVS.2010.5548054
- FAWCETT, T. An Introduction to ROC Analysis. *Pattern Recognition Letters*, 2006, pp. 861-874.
- FORSYTH, David A. *Computer Vision: A modern Approach*. Prentice Hall, 2002.
- GALVANIN, E.A.S.; VALE, G.M.; POZ, A.P.D. *The Canny Detector with Edge Region Focusing Using an Anisotropic Diffusion Process*. *Pattern Recognition and Image Analysis*, Vol. 16, No. 4, 2006.
- GHIAASIAAN, S. M. *Two-Phase Flow, Boiling and Condensation in Conventional and Miniture Systems*. Cambridge university Press, 2007.
- GONZALEZ, Rafael; WOODS, Richard. *Digital Image Processing*. 3. Edition. New Jersey: Prentice Hall, 2007.
- GUO, F.; YANG, Y.; CHEN, B.; GUO, L. *A novel multi-scale edge detection technique based on wavelet analysis with application in multiphase flows*. Powder Technology, 2010.
- HARALICK, R.M. *Digital Step Edge from Zero Crossing of Second Directional Derivatives*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. PAMI-6, No.1, 1984.
- HEATH, M.; SARKAR, S.; SANOCKI, T.; BOWYER, K. *Comparison of Edge Detectors*, 69 (1998) pp. 38–54.
- HEIJDEN, F.V.D. *Edge and Line Feature Extraction Based on Covariance Models*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 17, No.1, 1995.
- JACOBUS C. J.; CHIEN, R. T. *Two New Edge Detectors*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. PAMI-3, No.5, 1981.
- JAYACHANDRAN, A., Dhanashakeran, R., Anand, O. S., & Ajitha, J. H. M. (2010). Fuzzy information system based digital image segmentation by edge detection. *2010 IEEE International Conference on Computational Intelligence and Computing Research*, 1–5. doi:10.1109/ICCIC.2010.5705913

- KIM, Min Chan et ali. *Electrical impedance imaging of phase boundary in two-phase systems with adaptive mesh regeneration technique*. International Communications in Heat and Mass Transfer 32. pp. 954-963. Elsevier Science, 2005.
- LAU, Y. M., Deen, N. G., & Kuipers, J. a. M. (2013). Development of an image measurement technique for size distribution in dense bubbly flows. *Chemical Engineering Science*, 94, 20–29. doi:10.1016/j.ces.2013.02.043
- LI, Qiangwei. *Flow Pattern Identification of Two-Phase Flow Using Neural Network and Empirical Mode Decomposition*. IEEE Fourth International Conference on Natural Computation, 2007
- LIU, Jian-Lei; FENG, Da-Zheng. *Two-dimensional multi-pixel anisotropic Gaussian filter for edge-line segment (ELS) detection*. Journal of Image and Vision Computing, 2014.
- LUGER, G.F. *Artificial Intelligence: Structures and Strategies for Complex Problem Solving*. Fourth Edition. Addison Wesley, 2002.
- LUIZ, Leandro da Conceição. *VISUALIZAÇÃO DE ESCOAMENTOS BIFÁSICOS EM TUBULAÇÕES METÁLICAS POR NEUTRONGRAFIA EM TEMPO REAL*. Universidade Federal do Rio de Janeiro - COPPE. Dissertação de Mestrado, 2007.
- MACEDO, L. A.; FILHO, B. D. B. *Circuito experimental com escoamento bifásico e com alta concentração de não-condensáveis para pesquisa e desenvolvimento de sistemas de resfriamento de emergência de reatores nucleares avançados*. In: ENCIT Brazilian Congress of Thermal Sciences and Engineering, 2006, Curitiba.
- MARR, D.; HILDRETH, E. *Theory of Edge Detection*. Proceeding of Royal Society of London. Series. B, Biological Science, Vol. 207, No 1167, pp. 187-217, 1980.
- Masotti, Paulo Henrique Ferraz ; **DE MESQUITA, ROBERTO NAVARRO** . Paraconsistent Logic Study of Image Focus in Cylindrical Refraction Experiments. In: Jari Minoru Abe. (Org.). Intelligent Systems Reference Library. 1ed. Borna: Springer International Publishing, 2015, v. 94, p. 175-205.]
- MATSUBARA, E. T. UNIVERSIDADE DE SÃO PAULO. Tese de Doutorado. Instituto de Ciências Matemáticas e de Computação. Relações entre Ranking, Análise ROC e Calibração em Aprendizado de Máquina. São Carlos, 2008.
- MICHÉ, P., DEBRIE, R. *Fast and self-adaptive image segmentation using extended declivity*, Ann. Des Télécommunications. 50 (1995), pp. 401–410. doi:10.1007/BF02999740.
- MISHINA, k; HIBIKI, T. *SOME CHARACTERISTICS OF AIR-WATER TWO-PHASE FLOW IN SMALL DIAMETER VERTICAL TUBES*. Elsevier Science: *Int. J. Multiphase Flow* Vol. 22, No. 4, pp. 703-712, 1996.
- MESQUITA, Roberto Navarro et ali. *Two-phase Flow Patterns Recognition and Parameters Estimation Through Natural Circulation Test Loop Image Analysis*. In: ECI International Conference on Boiling Heat Transfer, 2009, Florianópolis.
- MESQUITA, Roberto Navarro et ali. *Análise Teórica Experimental do Fenômeno de Circulação Natural*. In: 1. Encontro Brasileiro sobre Ebulição, Condensação e Escoamento Multifásico líquido-gás, 2008, Florianópolis.
- MUNFORD, D., Shah J.; *Optimal Approximations by Piecewise Smooth Functions and Associated Variational Problems*, Comm. Pure Appl. Math., 1989.

- MITTELHAEUSSER, G., Kruggel F.; *Fast Segmenttition of Brain Magnetic Resonance Tomograms*. CVRMed'95: First International Conference on Computer Vision, Virtual Reality and Robotics in Medicine, Nizza, 1995.
- OLSZOWSKI, T. Pospolita, J. Conditions of dust sampling in pneumatic conveying through the horizontal pipeline. Powder Technology, 2007.
- PATEL, J. et ali. Fuzzy Inference Edge Detection System using Sobel and Laplacian of Gaussian Operators. 2011 International Conference and Workshop on Emerging Trends in Technology. Mumbai, India.
- PENG, Zhen-Rui; LIU, Shi-Zhong. *CONCENTRATION MEASUREMENT OF TWO-PHASE FLOW BY MEANS OF LS-SVM*. Proceedings of the Fifth International Conference on Machine Learning and Cybernetics. Dalian, 2006.
- PEDRINI, H.; SCHWARTZ, W. R.; *Análise de Imagens Digitais: Principios, Algoritmos e Aplicações*. São Paulo: Thomson Learning: 2008.
- PARKER, J.R. *Algorithms for Image Processing and Computer Vision*. Second Edition. USA: John Wiley & Sons, Inc, 2011.
- PIL Library. Python Imaging Library Source Kit 1.1.1.6. Disponível em <http://www.pythonware.com/products/pil/index.htm>, 2006. Acesso em 04 Fev 2012.
- PRESS, William et alii. *Numerical Recipes: The Art of Scientific Computing*. 3 edition. New York: Cambridge university Press, 2007.
- REZENDE, S. O.; *Sistemas Inteligentes: Fundamentos e Aplicações*. São Paulo: Editora Malone, 2005.
- CHI, Z.; YAN, H.; PHAM, T.; Fuzzy algorithms: with applications to image processing and pattern recognition. World Scientific Publishing Co, 1996.
- ROBERTS, L.G. *Machine Perception of Three-Dimensional Solids*. Massachusetts Instituted of Technology, 1965.
- ROSEN, K. H. Discrete Mathematics and its Applications. Sixth Edition. McGrawHill, 2007.
- RUSS, J.C. *The Image Processing Handbook*. 6 edition. CR Press, 2011
- RUSSEL Stuart; NORVIG Peter. *Artificial Intelligence: A Modern Approach*. 3 edition. New Jersey: Peason Education, 2010.
- SABUNDJIAN, Gaianês et ali. *Análise Teórico e Experimental do Fenômeno de Circulação Natural*. EBECM 2008. Florianópolis, 2008.
- SHI, Lilian; ZHOU, Zekui; REN, Shapu. *Parameter Measurements of Two-phase Bubly Flow Using Digital Image Processing*. IEEE Proceedings of the 5th World Congress on Intelligent Control and Automation. China, 2004.
- SHI, Z.; YAN, H; PHAM, T. Fuzzy Algorithms with Applications to Imagem Processing and Pattern Recognition. World Scientific, 1996.
- SHI, Lilian. *Fuzzy Recognition for Gas-liquid Two-phase Flow Pattern Based on Image Processing*. IEEE International Conference on Control and Automation. China, 2007.
- SHUI, Peng-Lang; Zhang, Wei-Chuan. Noise-robust edge detector combining isotropic and anisotropic Gaussian kernels. Patter Recognition, 2012.

- SUNDE, Carls; AVDIC, Senada; PAZSIT, Imre. *Classification of Two-Phase Flow Regimes via Image Analysis and a Neuro-Wavelet Approach*. Progress in Nuclear Energy, vol.46, No. 3-4, pp. 348-358, 2005.
- SMITH, Kevin; CARLETON, Alan; LEPETIT, Vincent. *Fast Ray Features for Learning Irregular Shapes*. In: IEEE International Conference in Computer Vision – ICCV, 2009, Kyoto.
- SOBEL, I. On calibrating computer controlled cameras for perceiving 3-D scenes, Artif. Intell. 4 (1974), pp. 185–198.
- ROCHA, Marcelo da Silva. UNIVERSIDADE DE SÃO PAULO. Escola Politécnica. *Projeto, Construção e Análise de um sensor de impedância de múltiplos aplicado à medição da fração de vazio em escoamentos bifásicos do tipo gás-líquido*, 2005.
- VALE, G.M.; POZ, A.P. *Processo de Detecção de Bordas de Canny*. Boletim de Ciência Geodésica, Vol.8, No.2, pp. 67-78, 2002.
- WANG H.; DONG, F.. *Image Features Extraction of Gas/Liquid Two-Phase Flow in Horizontal Pipeline By GLCM and GLGCM*. In: The Ninth International Conference on Electronic Measurement & Instruments, China, 2009.
- WASSERMAN, L. A.; *All of statistics: a concise course in statistical inference*. Springer, 2004.
- WU, M.M.; DONG, F. QI, G.H. *FEATURE EXTRACTION METHOD FOR GAS/ LIQUID TWO-PHASE FLOW BASED ON WAVELETS TRANSFORM*. IEEE Proceedings of the Fifth International Conference on Machine Learning and Cybernetics. China, 2006.
- Whalley, P.B, *Two-Phase Flow and Heat Transfer*, Oxford University Press, 1996.
- WOJTAN, Leszek; URSENBACHER, Thierry; THOME, John R. *Measurement of dynamic void fraction in stratified types of flow*. Experimental Thermal and Fluid Science 29 pp. 383-392, 2005.
- WENYIN, Z.; NINGDE, J.; XIA, L.; ZHIQIANG, N. *Bubble Image Segmentation of Gas/Liquid Two-Phase Flow Baseado n Improved Canny Operator*. Internation Conference on Computer Science and Software Engineering, 2008.
- ZADEH, L. A. Fuzzy Sets. Information and Control (1965). Volume 8-3, pp. 338-353.
- ZHAI, L.; DONG, S.; MA, H. *Recent Methods and Applications on Image Edge Detection*. International Workshop on Education Tecnology and Training and International Workshop on Geoscience and Remote Sensing, 2008.
- ZHANG, Z.; HUNG, Ting-lei. *A Novel Method for Bubble Identification Based on ANN*. Third International Conference on Genetic and Evolutionary Computing, 2009.
- ZABULIS, X.; PAPARA, M.; CHATZIARGYRIOU, A.; KARAPANTSIOS, T.D. *Detection of densely disperse spherical bubble in digital images based on a template matching technique Application to wet foams*. Colloids and Surfaces A: Physicochem. End. Aspects 309. Pp.: 96-106, 2007.
- ZIMMERMANN, H. J. *Fuzzy Set Theory and Its Applications*. Boston: Klumer, 2001.
- ZOU, K. H. (2007). *Receiver operating characteristic (ROC) literature research*. <http://www.spl.harvard.edu/archive/spl-pre2007/pages/ppl/zou/roc.html>, acessado em 06/2015.