

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E  
INFORMÁTICA INDUSTRIAL

MAUREN LOUISE SGUARIO

**Uma nova abordagem do método *Level Set* baseada em conhecimento a priori da forma**

TESE

CURITIBA

2015

MAUREN LOUISE SGUARIO

**Uma nova abordagem do método *Level Set* baseada em conhecimento a priori da forma**

Tese apresentada como requisito parcial para obtenção do título de Doutor em Ciências, do Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná. Área de Concentração: Engenharia de Automação e Sistemas.

Orientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Lúcia Valéria Ramos de Arruda

**CURITIBA**

**2015**

---

**Dados Internacionais de Catalogação na Publicação**

---

A553n     Andrade, Mauren Louise Sguario Coelho de  
2015        Uma nova abordagem do método *Level Set* baseada em  
             conhecimento a priori da forma / Mauren Louise Sguario  
             .-- 2015.  
             129 f.: il.; 30 cm

             Texto em português, com resumo em inglês.  
             Tese (Doutorado) - Universidade Tecnológica Federal  
do Paraná. Programa de Pós-Graduação em Engenharia  
Elétrica e Informática Industrial, Curitiba, 2015.  
             Bibliografia: f. 117-124.

             1. Teoria do conhecimento. 2. Escoamento bifásico.  
3. Gás - Escoamento. 4. Segmentação de imagens. 5.  
Processamento de imagens. 6. Reconhecimento de padrões.  
7. Métodos de simulação. 8. Engenharia elétrica -  
Teses. I. Arruda, Lúcia Valéria Ramos de, orient. II.  
Universidade Tecnológica Federal do Paraná. Programa  
de Pós-Graduação em Engenharia Elétrica e Informática  
Industrial. III. Título.

CDD: Ed. 22 -- 621.3

---

**Biblioteca Central da UTFPR, Câmpus Curitiba**

Título da Tese Nº. \_\_\_\_\_

## **Uma Nova Abordagem do Método Level Set Baseada em Conhecimento a Priori da Forma**

por

### **Mauren Louise Sguario Coelho de Andrade**

**Orientadora: Profa. Dra. Lúcia Valéria Ramos de Arruda**

Esta tese foi apresentada como requisito parcial à obtenção do grau de DOUTOR EM CIÊNCIAS – Área de Concentração: **Engenharia de Automação e Sistemas**, pelo Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial – CPGEI – da Universidade Tecnológica Federal do Paraná – UTFPR, às **14:00h** do dia **12 de novembro de 2015**. O trabalho foi aprovado pela Banca Examinadora, composta pelos doutores:

---

Profa. Dra. Lúcia Valéria Ramos de Arruda  
(Presidente – UTFPR)

---

Prof. Dr. Luiz Eduardo Soares de Oliveira  
(UFPR)

---

Profa. Dra. Giselle Lopes Ferrari Ronque  
(UFPR)

---

Prof. Dr. Daniel Rodrigues Pipa  
(UTFPR)

---

Profa. Dra. Leyza Elmeri Baldo Dorini  
(UTFPR)

Visto da Coordenação:

---

Prof. Dr. Emilio Carlos Gomes Wille  
(Coordenador do CPGEI)

## **AGRADECIMENTOS**

### **Sonhos (Chris Durán)**

“Há um lugar

Pra chegar

Há uma ponte

Que te levará

Pro outro lado

Há um sonho, uma voz

Dizendo: “os teus sonhos também são meus”

Vou te levar, te conduzir

E quando você alcançar

Saberás que em todo tempo

Eu estive ao teu lado.”

“Àquele que está assentado no trono e ao Cordeiro sejam o louvor, a honra, a glória e o poder, para todo o sempre!” (Apocalipse 5, 13)

Ao meu marido Kleber pelo apoio, paciência, incentivo, conselhos e principalmente pelo seu amor e exemplo de fé em Deus.

Aos meus filhos Isabella, Juliana e Pedro pela paciência, por serem filhos maravilhosos e por seu amor, vocês são a minha maior motivação.

Aos meus pais que sempre me ensinaram a agir com respeito, simplicidade, dignidade, honestidade e amor ao próximo. Obrigada por me guiar e me fazer acreditar que sempre, tudo vai dar certo. Mãe você é minha maior inspiração sei que estou realizando um sonho que também era seu.

Aos meus sogros Altair e Sueli, obrigada por cuidarem dos meus filhos com tanto amor e dedicação, este sonho só foi possível com o apoio de vocês.

A orientadora Prof<sup>a</sup>. Dr<sup>a</sup>. Lúcia Valéria Ramos de Arruda, por me deixar caminhar sozinha e ao mesmo tempo sempre disponível quando precisei. Principalmente por me dar uma chance e confiar em mim. Agradeço pela amizade, conselhos e paciência. Professora você é um exemplo de simplicidade, compreensão e competência. Que eu possa sempre contar com o

privilégio da sua amizade.

A Prof<sup>a</sup>. Dr<sup>a</sup>. Leyza Dorini, sempre disponível para trocar ideias e mostrar que o caminho pode ser simples, que não é preciso complicar para chegar ao final, obrigada.

A Universidade Tecnológica Federal do Paraná, pela estrutura e ambiente.

Aos colegas professores do Departamento de Informática da UTFPR - Ponta Grossa, pelos conselhos, pelo apoio e por assumir minhas aulas nos 6 meses em que estive afastada para concluir esta tese, especialmente aos amigos e colegas Prof. Dr. Richard Duarte Ribeiro e Prof<sup>a</sup>. Dr<sup>a</sup>. Adriane Marie Salm Coelho.

Aos colegas do LACIT/Laboratório de escoamento de Fluidos da Universidade Tecnológica Federal do Paraná, sempre dispostos aos novos experimentos e desafios.

A CAPES pelo suporte financeiro.

## RESUMO

ANDRADE, Mauren. Uma nova abordagem do método *Level Set* baseada em conhecimento a priori da forma. 129 f. Tese – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2015.

A análise do comportamento dos fluidos em escoamentos multifásicos possui grande relevância para garantia de segurança em instalações industriais. O uso de equipamentos para monitorar tal comportamento fica sujeito a fatores tais como, alto investimento e mão de obra especializada. Neste contexto, a aplicação de técnicas de processamento de imagens na análise do escoamento seria de grande auxílio, no entanto, poucas pesquisas foram desenvolvidas. Nesta tese, uma nova abordagem para segmentação de imagens baseada no método *Level Set* que une contornos ativos e conhecimento a priori é desenvolvida. Para tanto, um modelo da forma do objeto alvo é treinado e definido por meio do modelo de distribuição de pontos e então inserido como uma função de velocidade de extensão para evolução da curva de nível zero do método *Level Set*. A abordagem proposta cria um *framework* que consiste em três termos de energia e uma função de velocidade de extensão ( $\lambda L_g(\phi) + \nu A_g(\phi) + \mu P(\phi) + \phi_f$ ). Os três primeiros termos desta equação são os mesmo introduzidos em (LI CHENYANG XU; FOX, 2005) e a última parcela  $\phi_f$  é baseada na representação da forma do objeto proposta nesta tese. Duas variações do método são utilizadas: uma com restrição (*Restrict Level Set - RLS*) e outra sem restrição (*Free Level Set - FLS*). A primeira será utilizada na segmentação de imagens que contém alvos com pouca variação na forma e pose. A segunda deve ser utilizada para a identificação correta da forma de bolhas de gás no escoamento bifásico gás-líquido. A robustez e eficiência da abordagem RLS e FLS são apresentados em imagens do escoamento bifásico gás-líquido e na base de dados HTZ (FERRARI et al., 2009). Os resultados promissores confirmam o bom desempenho do algoritmo proposto (RLS e FLS) e indicam que a abordagem pode ser utilizada como um método eficiente para validação e/ou calibração de diversos equipamentos utilizados como medidores das propriedades do escoamento bifásico, bem como, em outros problemas de segmentação de imagens.

**Palavras-chave:** Conhecimento a priori, *Level Set*, Velocidade de Extensão, *Active Shape Model*, Escoamento bifásico, Reconhecimento de padrões

## ABSTRACT

ANDRADE, Mauren. A new approach to the Level Set Method based on a priori knowledge of the shape. 129 f. Tese – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2015.

The analysis of fluid behavior in multiphase flow is very relevant to guarantee system safety. The use of equipment to describe such behavior is subjected to factors such as the high level of investments and of specialized labor. The application of image processing techniques to flow analysis can be a good alternative, however, very little research has been developed. In this subject, this study aims at developing a new approach to image segmentation based on Level Set method that connects the active contours and prior knowledge. In order to do that, a model shape of the targeted object is trained and defined through a model of point distribution and later this model is inserted as one of the extension velocity functions for the curve evolution at zero level of Level Set Method. The proposed approach creates a framework that consists in three terms of energy and an extension velocity function ( $\lambda L_g(\phi) + vA_g(\phi) + \mu P(\phi) + \phi_f$ ). The first three terms of the equation are the same ones introduced in (LI CHENYANG XU; FOX, 2005) and the last part of the equation  $\phi_f$  is based on the representation of object shape proposed in this work. Two method variations are used: one restricted (*Restrict Level Set - RLS*) and the other with no restriction (*Free Level Set - FLS*). The first one is used in image segmentation that contains targets with little variation in shape and pose. The second will be used to correctly identify the shape of the bubbles in the liquid gas two phase flows. The efficiency and robustness of the approach RLS and FLS are presented in the images of the liquid gas two phase flows and in the image dataset HTZ (FERRARI et al., 2009). The results confirm the good performance of the proposed algorithm (RLS and FLS) and indicate that the approach may be used as an efficient method to validate and/or calibrate the various existing equipment used as meters for two phase flow properties, as well as in other image segmentation problems.

**Keywords:** Prior knowledge, Level Set Method, Extension velocity, Active Shape Model, Two-phase flow, Pattern recognition



## LISTA DE FIGURAS

FIGURA 1 – Padrões de escoamento bifásico gás-líquido horizontal .....	20
FIGURA 2 – Mapa de escoamento .....	21
FIGURA 3 – Representação de uma célula unitária no padrão golfada gás-líquido ....	22
FIGURA 4 – Cálculo da área transversal do gás com $\delta_{ff} < r$ .....	25
FIGURA 5 – Cálculo da área transversal do gás com $\delta_{ff} > r$ .....	26
FIGURA 6 – Representação de uma imagem utilizando diferentes níveis de quantização	33
FIGURA 7 – Exemplo de segmentação por limiarização .....	37
FIGURA 8 – Corte de Wu e Leahy para grafos .....	38
FIGURA 9 – Resultado da segmentação por NCuts .....	40
FIGURA 10 – Autovetores obtidos por NCut .....	40
FIGURA 11 – Função implícita .....	41
FIGURA 12 – Curvatura indicando movimento de uma curva .....	42
FIGURA 13 – Princípio do método <i>Level Set</i> .....	44
FIGURA 14 – Propagação com velocidade $F$ .....	45
FIGURA 15 – Segmentação do núcleo celular .....	49
FIGURA 16 – Ilustração da Segmentação por método <i>Level Set</i> .....	49
FIGURA 17 – Ilustração de pontos chaves .....	51
FIGURA 18 – Segmentação por ASM .....	53
FIGURA 19 – Diferenças no formato da cauda .....	64
FIGURA 20 – Fluxogram segmentação .....	67
FIGURA 21 – Construção da velocidade de extensão .....	69
FIGURA 22 – Momento de chegada $T(x,y)$ da frente para velocidade $F > 0$ .....	70
FIGURA 23 – Configuração para a formulação do valor limite .....	70
FIGURA 24 – Transformação do movimento da frente .....	71
FIGURA 25 – Segmentação por <i>Restrict Level Set</i> .....	75
FIGURA 26 – Resultado da segmentação .....	76
FIGURA 27 – Resultado da segmentação .....	76
FIGURA 28 – Resultado da segmentação por <i>Free Level Set</i> .....	77

FIGURA 29 – Segmentação de imagem sintética .....	81
FIGURA 30 – Segmentação de objetos sobrepostos .....	82
FIGURA 31 – Segmentação objeto incompleto .....	83
FIGURA 32 – Segmentação base HTZ .....	84
FIGURA 33 – Ilustração da curva ROC .....	87
FIGURA 34 – Curva ROC, símbolo da <i>Apple</i> .....	89
FIGURA 35 – Curva ROC, canecas .....	90
FIGURA 36 – Curva ROC, garrafas .....	91
FIGURA 37 – Representação da base de dados do escoamento .....	94
FIGURA 38 – Desprendimento de gotículas de gás em meio líquido .....	94
FIGURA 39 – Ilustração da aquisição para o padrão golfada (célula unitária) .....	95
FIGURA 40 – Construção do vetor de característica SURF .....	96
FIGURA 41 – Resultados da segmentação do escoamento .....	99
FIGURA 42 – Resultados da segmentação do nariz das bolhas de gás .....	101
FIGURA 43 – Resultados da segmentação da cauda das bolhas de gás .....	101
FIGURA 44 – Curva ROC, nariz das bolhas de gás .....	103
FIGURA 45 – Curva ROC, corpo das bolhas de gás .....	105
FIGURA 46 – Curva ROC, cauda das bolhas de gás .....	106
FIGURA 47 – Representação dos pontos inicial ( <i>X</i> ) e final ( <i>Y</i> ) .....	107
FIGURA 48 – Gráfico do aumento da velocidade da bolha .....	109
FIGURA 49 – Gráfico comparativo da velocidade da mistura <i>J</i> .....	110
FIGURA 50 – Gráfico comparativo do comprimento da bolha de gás .....	110
FIGURA 51 – Gráfico comparativo da velocidade da bolha de gás .....	111
FIGURA 52 – Circuito experimental de escoamentos bifásicos .....	126

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>12</b>
1.1	OBJETIVOS	14
1.2	PRINCIPAIS CONTRIBUIÇÕES	15
1.3	ORGANIZAÇÃO DA TESE	17
<b>2</b>	<b>ESCOAMENTO BIFÁSICO: FUNDAMENTAÇÃO TEÓRICA</b>	<b>19</b>
2.1	ESCOAMENTO BIFÁSICO	19
2.2	PADRÃO GOLFADA	21
2.3	TRABALHOS RELACIONADOS	27
2.4	CONSIDERAÇÕES FINAIS	31
<b>3</b>	<b>PROCESSAMENTO DE IMAGENS: FUNDAMENTAÇÃO TEÓRICA</b>	<b>32</b>
3.1	CONCEITOS BÁSICOS	32
3.2	SEGMENTAÇÃO	33
3.2.1	Segmentação por Limiarização	36
3.2.2	Segmentação por corte em grafos	36
3.2.2.1	Corte Normalizado - <i>NCut</i>	38
3.2.2.2	Algoritmo para segmentação	39
3.2.3	Segmentação por contornos ativos	41
3.2.3.1	Método Level Set	43
3.2.3.2	Método <i>Level Set</i> - Formulação Variacional	46
3.2.3.3	Segmentação de imagens utilizando métodos <i>Level Set</i> : uma visão intuitiva	48
3.2.3.4	Modelo de forma ativa ( <i>Active Shape Model</i> - ASM)	50
3.2.3.5	Modelo de Distribuição de Pontos - PDM	50
3.3	TRABALHOS RELACIONADOS	54
3.3.1	Propriedades locais	55
3.3.2	Conhecimento a priori da forma	56
3.3.2.1	Métodos baseados em modelos estatísticos	56
3.3.2.2	Métodos por funções de base radial	58
3.3.2.3	Métodos para segmentar múltiplos objetos	60
3.3.2.4	Métodos com inclusão de funções de energia	61
3.4	CONSIDERAÇÕES FINAIS	63
<b>4</b>	<b>RESTRICT LEVEL SET - RLS E FREE LEVEL SET - FLS</b>	<b>65</b>
4.1	ALGORITMO PARA SEGMENTAÇÃO	66
4.2	DEFINIÇÃO DA FORMA A PRIORI	66
4.3	<i>RESTRICT LEVEL SET</i> - RLS	68
4.3.1	Formulação fundamental do método RLS	69
4.4	<i>FREE LEVEL SET</i> - FLS	77
4.5	CONSIDERAÇÕES FINAIS	78
<b>5</b>	<b>VALIDAÇÃO EXPERIMENTAL EM BASE DE DADOS <i>BENCHMARK</i></b>	<b>79</b>
5.1	IMAGENS SINTÉTICAS	80
5.2	IMAGENS HTZ	81
5.3	AVALIAÇÃO DAS SEGMENTAÇÕES	85

5.4	BASE COM 150 IMAGENS DO LABORATÓRIO <i>COMPUTER VISION LABORATORY, ETH ZURICH</i> - SÍMBOLO <i>APPLE</i> , CANECAS E GARRAFAS .....	88
5.5	CONSIDERAÇÕES FINAIS .....	91
<b>6</b>	<b>APLICAÇÃO DA TÉCNICA EM ESCOAMENTO BIFÁSICO .....</b>	<b>92</b>
6.1	DESCRIÇÃO DA BASE DE IMAGENS .....	92
6.2	DESENVOLVIMENTO DO CLASSIFICADOR .....	95
6.3	VALIDAÇÃO EXPERIMENTAL IMAGENS ESCOAMENTO .....	98
6.4	AVALIAÇÃO QUANTITATIVA .....	101
6.4.1	Base com imagens representando o nariz da bolha .....	102
6.4.2	Base com imagens representando o corpo da bolha .....	104
6.4.3	Base com imagens representando a cauda da bolha .....	104
6.4.4	Base com imagens do escoamento para diferentes velocidades das bolhas de gás ...	106
6.4.5	Cálculo das propriedades relevantes do padrão golfada .....	107
6.5	CONSIDERAÇÕES FINAIS .....	109
<b>7</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS .....</b>	<b>112</b>
7.1	CONCLUSÕES .....	112
7.2	LIMITAÇÕES DO PRESENTE ESTUDO .....	115
7.3	TRABALHOS FUTUROS .....	115
	<b>REFERÊNCIAS .....</b>	<b>117</b>
	<b>Apêndice A – CIRCUITO PARA AQUISIÇÃO DAS IMAGENS DA BASE DE TES-</b>	
	<b>TES .....</b>	<b>125</b>
	<b>Apêndice B – CÁLCULO DA DERIVADA GÂTEAUX E FUNÇÃO DIRAC .....</b>	<b>127</b>
	<b>Apêndice C – LISTA DE PUBLICAÇÕES .....</b>	<b>129</b>

## 1 INTRODUÇÃO

Os escoamentos multifásicos possuem grande importância nas indústrias química, nuclear e petrolífera, pois ocorrem durante o transporte de diversos materiais, como, por exemplo, líquidos, gases, óleos, materiais pastosos ou combinação destes em várias instalações. Para essas indústrias, a correta representação e compreensão dos fenômenos que descrevem o comportamento dos fluidos no escoamento, assegura o funcionamento eficiente dos processos e equipamentos envolvidos.

Em se tratando de fluxo bifásico em dutos, foco deste trabalho, a combinação gás-líquido ocorre mais provavelmente do que qualquer outra combinação de fases (AZZOPARDI, 2006). Em tal caso, ocorrem variações nas taxas de fluxo de massa, pressão e velocidade. Para análise e compreensão do comportamento das fases são desenvolvidos modelos matemáticos que são validados por meio de diversos instrumentos, tais como equipamentos de raios-X e *gamma*, sondas ópticas, ultrassonografias, sensores de impedância, entre outros. Por outro lado, os modelos matemáticos buscam representar as diversas propriedades dos escoamentos, dentre elas vazões e velocidades dos fluidos, a fim de prever a evolução do escoamento no tempo e no espaço. A partir do comportamento do escoamento, de seus valores de vazão e velocidades dos fluidos, são definidos padrões (ou regimes) de escoamento, em função do posicionamento e geometria do duto.

Os instrumentos empregados como medidores das propriedades relevantes acima citados, são considerados robustos e eficazes se puderem ser validados e/ou calibrados por outro mecanismo ou sistema independente das grandezas utilizadas para a medição. O processamento de imagens é uma técnica eficiente que pode prover um mecanismo de validação/calibração de instrumentos que tem como principais vantagens a avaliação visual, a não intrusão e o baixo custo, além de ser relativamente simples de implementar e projetar.

Neste sentido, este trabalho propõe o desenvolvimento de um sistema computacional baseado em processamento de imagens que seja capaz de identificar as bolhas de gás presentes nas imagens do escoamento bifásico gás-líquido horizontal, mais especificamente para o regime

denominado golfada que se caracteriza pelo descolamento de grandes bolhas de gás seguidas por pistão de líquido. A partir da sequência de imagens de bolhas (série temporal) obtidas em um escoamento, o sistema deve ser capaz de calcular os valores médios de variáveis de interesse do escoamento estudado. Algumas dessas variáveis são as velocidades dos fluidos, vazão das fases e fração de vazio. Essas variáveis podem ser utilizadas em modelos matemáticos ou de simulação para caracterizar o comportamento das bolhas de gás e, por conseguinte o comportamento do escoamento.

Para a análise computacional das bolhas de gás em imagens, faz-se necessário inicialmente a segmentação dessas bolhas, a qual separa o objeto de interesse (bolhas de gás) do fundo (líquido). Esta tarefa de segmentação se torna mais complexa à medida que se aumenta a velocidade das bolhas de gás. Quando isto ocorre, diversas bolhas dispersas desprendem-se da bolha alongada (vide Capítulo 2 para definição de bolha alongada) formando um emaranhado de pequenas bolhas, que se movimenta no rastro da bolha alongada, e que são difíceis de separar e identificar.

No trabalho (DORINI et al., 2011), os autores aplicaram o método *Level Set* no processo de segmentação de imagens de escoamento a fim de identificar bolhas alongadas. Tal abordagem mostrou-se promissora, entretanto, com resultados imprecisos na presença de bolhas dispersas. Tais resultados indicaram a necessidade da criação de um algoritmo mais eficiente, a fim de minimizar as imperfeições observadas na segmentação do método *Level Set* tradicional. Nos últimos anos, o método *Level Set* vem sendo adaptado para incluir a informação da forma do objeto que se pretende localizar como um conhecimento previamente adquirido (QIN et al., 2014; TOMOSHIGE et al., 2014; ROUSSON; PARAGIOS, 2002; CHEN et al., 2001; LEVENTON et al., 2000). O conhecimento da forma é adicionado a evolução da curva do *Level Set*, a fim de guiar a segmentação de objetos, contribuindo para se atingir uma segmentação satisfatória.

De forma semelhante, este trabalho propõe uma nova abordagem baseada em conhecimento a priori da forma e representações *Level Set* a fim de segmentar as bolhas de gás de imagens do escoamento bifásico do tipo golfadas. A ideia básica é segmentar o objeto por meio de uma extensão da abordagem *Level Set* que inclui a informação da forma previamente treinada (formato em golfada das bolhas de gás), a qual influenciará a evolução da curva inicial. Neste caso, a abordagem usa uma função composta por três termos de energia e uma função de velocidade de extensão. Os termos de energia são os mesmos introduzidos por Li e colaboradores, em 2005 (LI CHENYANG XU; FOX, 2005), cujo trabalho utiliza o método *Level Set* sem conhecimento a priori, e a função de velocidade proposta desta tese é baseada na representação

do modelo da forma do objeto. O modelo da forma do objeto será obtido a partir de um conjunto de imagens de treinamento, em que a forma é definida por meio do modelo de distribuição de pontos (*Point Distribution Model* - PDM (COOTES et al., 1995)).

Em suma o método proposto nesta tese define uma função de velocidade de extensão baseada no modelo de forma, limitando a curvatura da função *Level Set* a fim de segmentar o objeto na nova imagem que represente a forma treinada. Com esta função de extensão adicional há uma contribuição para a evolução do formato médio, ou seja, a evolução da curva se dá em função do formato e do gradiente da imagem, entretanto, respeitando as características de cada objeto em diferentes imagens.

## 1.1 OBJETIVOS

O objetivo deste trabalho é o desenvolvimento de um sistema computacional de segmentação de imagens do escoamento bifásico gás-líquido a fim de definir o formato médio das bolhas de gás para posterior medição das propriedades relevantes que descrevem as condições de evolução do escoamento no tempo e no espaço, utilizando para tal as técnicas de processamento e análise de imagens. A segmentação será realizada através de uma extensão do método *Level Set* que será adaptado para inclusão de informações a priori sobre o formato das bolhas.

A partir do objetivo principal, foram estabelecidos os seguintes objetivos específicos:

- desenvolver um método de segmentação eficiente que leve em consideração a forma do objeto a ser segmentado.
- testar e validar o método proposto em imagens de bases consolidadas, ressaltando a sua eficiência em casos críticos tais como oclusões e partes do objeto alvo faltante.
- aplicar o método validado no escoamento bifásico e calcular as propriedades relevantes ao escoamento.
- validar o método em imagens de escoamento nas situações críticas acima citadas.
- consolidar a base de imagens para que possa ser utilizada em outros desenvolvimentos relacionados à análise do escoamento.

Para tanto, o modelo da forma do objeto, obtido a partir do modelo de distribuição de pontos, dará velocidade a evolução do contorno ativo pelo método *Level Set*. As abordagens de base foram escolhidas pela facilidade de implementação e pelos bons resultados obtidos em imagens com objeto e pose bem conhecidos, como por exemplo, na segmentação de

mãos humanas (COOTES et al., 1995), cavalos (ROUSSON; PARAGIOS, 2002) e imagens médicas (DIOP; BURDIN, 2013) uma vez que as bolhas de gás em escoamentos bifásicos, também possuem formato e pose previamente conhecidos.

## 1.2 PRINCIPAIS CONTRIBUIÇÕES

Como resultado dos objetivos especificados acima, a principal contribuição deste trabalho no que se refere à segmentação de imagens é a representação de uma nova função de velocidade de extensão incorporada como um conhecimento a priori sobre o formato da curva inicial para a evolução do método *Level Set*. A abordagem permite a utilização da nova função de velocidade de duas formas: livre ou restrita. No primeiro caso, a evolução da curva inicial se dará livremente a partir do modelo de forma definido e no segundo caso, a evolução sofrerá uma restrição imposta pela forma, sendo neste caso, útil para segmentar objeto com problemas de oclusão ou partes faltantes. Também é apresentado um estudo quantitativo e comparativo da qualidade da segmentação entre a abordagem aqui proposta e quatro importantes métodos de segmentação de imagens. Uma segunda contribuição se dá no estudo de escoamentos bifásicos através do desenvolvimento de uma técnica automática para identificar o formato das bolhas de gás em escoamentos gás líquido de tal maneira que se possam calcular algumas de suas propriedades relevantes, a fim de contribuir para a modelagem precisa dos sistemas envolvidos.

A partir dessas duas contribuições no sentido mais amplo, destacam-se as seguintes contribuições específicas deste trabalho:

- Uma nova função de velocidade de extensão capaz de guiar a evolução da função  $\phi$  do *Level Set* ao objeto de interesse respeitando as características da imagem mas principalmente mantendo a evolução em função da forma previamente conhecida e definida. Desse modo, é possível a definição mais precisa do objeto que se deseja segmentar melhorando os resultados de segmentação.
- Desenvolvimento de uma nova abordagem para segmentação de imagens do fluxo bifásico gás-líquido: as imagens capturadas são divididas em três tipos (nariz, corpo e cauda). Para cada um deles é obtido um formato médio por meio do modelo de distribuição de pontos - PDM (COOTES et al., 1995). O formato médio é utilizado como informação prévia para a segmentação de novas imagens do escoamento por meio do método proposto nesta tese.
- Utilização da nova função de velocidade de extensão gerando duas novas técnicas de segmentação baseada no método *Level Set*: livre (*Free Level Set - FLS*) ou restrita (*Restrict Level Set - RLS*). No primeiro caso, a evolução da curva inicial se dará livremente a



partir do modelo de forma definido e no segundo caso, a evolução sofrerá uma restrição imposta pela forma.

- Desenvolvimento de um sistema de reconhecimento de padrões para identificar a qual parte da bolha de gás uma determinada imagem pertence, dentre três padrões: nariz (parte inicial da bolha de gás), corpo (parte central da bolha de gás) e cauda (parte traseira da bolha de gás). Sendo identificada a parte da bolha em golfada, o sistema utiliza esta informação para a escolha de uma das três formas previamente treinada. Então, a forma é inserida para segmentar a mesma parte em novas imagens do escoamento.
- Método baseado em análise de imagens para o cálculo das propriedades associadas ao escoamento bifásico em golfada, cruciais para a modelagem precisa dos sistemas envolvidos, bem como para validação de outros equipamentos de medição. As propriedades consideradas foram: velocidade da bolha alongada; comprimento, volume e área da bolha alongada; e fração de gás;
- Desenvolvimento de uma plataforma de ensaio para o processamento e análise de imagens, visando o acompanhamento e a validação dos instrumentos de medição de fração de líquido e gás utilizados pelo Laboratório de Ciências Térmicas - LACIT na UTFPR em Curitiba, de modo que o operador do sistema tenha acesso às informações das características do padrão em golfadas;
- Elaboração de uma base de imagens com informações de validação que servirão para novas pesquisas na área de escoamento multifásico (as imagens para realização dos experimentos foram adquiridas utilizando-se um aparato experimental construído no LACIT e estarão restritas ao uso pelo laboratório). Partes destas imagens foram manipuladas manualmente por um especialista de forma a permitir a extração dos valores exatos das propriedades em análise. Desta forma, os resultados obtidos através da abordagem proposta puderam ser corretamente validados.
- Desenvolvimento de uma abordagem de segmentação genérica que pode ser utilizada na segmentação de outros objetos que possuam forma e pose previamente conhecidos.

Além da formalização da abordagem aqui proposta, também são discutidos diversos exemplos de como a informação prévia sobre o objeto a ser segmentado pode ser fundamental para obtenção de resultados mais precisos.

### 1.3 ORGANIZAÇÃO DA TESE

O texto desta tese está organizado de modo a apresentar tanto os principais resultados da pesquisa realizada quanto à fundamentação teórica básica necessária ao entendimento do trabalho.

#### **Capítulo 2: Conceitos básicos do escoamento bifásico**

Este capítulo introduz os conceitos básicos necessários ao entendimento do escoamento bifásico gás-líquido em golfadas. Esses conceitos são apresentados a fim de esclarecer a importância na obtenção dos valores de algumas propriedades do escoamento.

A ideia principal está relacionada ao cálculo dos valores da velocidade das bolhas de gás a partir da qual outras propriedades importantes podem ser derivadas. Sua teoria aplicada ao estudo dos escoamentos bifásicos permite a correta compreensão da evolução do escoamento no tempo e no espaço. Com isso, os sistemas e equipamentos que envolvem a utilização de escoamentos podem ser desenvolvidos com maior segurança (SHOHAM, 2006).

#### **Capítulo 3: Fundamentação teórica sobre segmentação e conhecimento a priori**

O Capítulo 3 apresenta a fundamentação teórica básica sobre segmentação de imagens bem como a utilização do conhecimento a priori da forma do objeto no processo de segmentação. As técnicas de segmentação utilizadas no desenvolvimento da proposta são descritas em detalhes, visando dar o embasamento necessário ao leitor para compreensão dos resultados obtidos e no desenvolvimento da abordagem proposta.

#### **Capítulo 4: Nova abordagem para o método *Level Set* com conhecimento a priori**

Este capítulo desenvolve a abordagem proposta para o método *Level Set* com conhecimento a priori da forma, com duas variações denominadas: *Restrict Level Set - RLS* e *Free Level Set - FLS*.

A ideia básica é a inserção de uma função de velocidade de extensão capaz de manter a evolução da curva inicial baseada na forma previamente treinada, de tal maneira que seja também suavizada para que sua evolução não seja penalizada computacionalmente.

A formulação da evolução da curva pela abordagem proposta é definida então pela inserção da função de velocidade de extensão  $\phi_f$ :

$$\phi_f = \frac{\phi_i - \phi(t)}{\lambda_2}$$

em que  $\phi_i$  é a imagem binária com a forma previamente treinada (curva inicial) e  $\phi(t)$  é a curva

em evolução no tempo. O valor para  $\lambda_2$  é obtido empiricamente e reflete o peso a ser definido para a suavização da função de velocidade da forma: quanto maior for o seu peso menor será a restrição imposta pela forma previamente treinada. A função de velocidade inserida é projetada de modo a não interferir na função de distância sinalizada desenvolvido por Li e colaboradores (LI CHENYANG XU; FOX, 2005), o que é necessário para garantir uma boa evolução da curva inicial, uma vez que tal função é calculada pelos termos de energia.

### **Capítulo 5: Validação experimental em base de dados *benchmark***

Os resultados qualitativos e quantitativos são apresentados neste capítulo para duas bases de imagens diferentes: imagens sintéticas e imagens da base do laboratório *Computer Vision Laboratory, ETH Zurich* (FERRARI et al., 2006).

Também são discutidos e analisados os resultados por meio de seis métricas distintas: distância de Hausdorff, coeficientes de Jaccard e Dice, taxa falso positivo, taxa falso negativo e F-measure. Todas as métricas são calculadas a partir de valores de segmentação ideal definidos manualmente por um especialista. Adicionalmente, utiliza-se da curva ROC para validar todos os exemplos testados. Este capítulo ilustra ainda alguns exemplos em que a utilização da função de velocidade de extensão  $\phi_f$  conduz a evolução da curva inicial  $\phi$  do zero *Level Set* mais próxima a segmentação final ideal para imagens que apresentam boa definição sobre o objeto a ser segmentado.

### **Capítulo 6: Aplicação da técnica em escoamento bifásico**

Os resultados qualitativos e quantitativos são apresentados neste capítulo para a base de imagens do escoamento bifásico gás-líquido. Uma vez que a forma previamente definida é fundamental para condução da curva inicial, neste capítulo será discutido os resultados do processo de classificação das imagens do escoamento, de acordo com as três partes que compõem as bolhas de gás do escoamento bifásico: nariz, corpo e cauda.

Por meio do classificador, o sistema irá decidir qual a forma a ser utilizada para o processo de segmentação, baseada no critério acima informado.

### **Capítulo 7: Conclusões**

Finalmente, no último capítulo serão apresentadas as conclusões deste trabalho e as perspectivas de trabalhos futuros.

## 2 ESCOAMENTO BIFÁSICO: FUNDAMENTAÇÃO TEÓRICA


Este capítulo introduz os conceitos necessários ao entendimento do escoamento bifásico horizontal gás-líquido em golfadas. Na Seção 2.1, são apresentados os conceitos básicos sobre escoamento bifásico. A Seção 2.2 discute o padrão de escoamento em golfadas bem como algumas das propriedades relevantes associadas ao escoamento bifásico. Na Seção 2.3 é apresentada uma revisão da literatura sobre os diversos equipamentos usados para medir as propriedades do escoamento, bem como, as abordagens de processamento de imagens já empregadas para extrair tais propriedades. Concluindo este capítulo, na Seção 2.4 um resumo será apresentado.

### 2.1 ESCOAMENTO BIFÁSICO

O fluxo bifásico gás-líquido pode ser caracterizado de forma horizontal ou vertical, com padrões distintos de escoamento estabelecidos para cada um deles. Por exemplo, em escoamento horizontal a observação de padrões distintos além de estar relacionada com as diferenças de velocidades entre as fases, também sofre a ação da gravidade que atua perpendicularmente ao eixo do tubo, ocasionando inclusive a separação das fases em alguns casos (e, assim, o aumento do número possível de padrões no fluxo). Essas características, bem como a assimetria entre as fases, podem ser observadas na Figura 1 que ilustra os padrões de escoamento para um escoamento horizontal.

Os padrões que podem ser estabelecidos em escoamentos horizontais são descritos por Azzopardi (AZZOPARDI, 2006) da seguinte forma:

- Borbulhado/Bolhas dispersas (*Bubble Flow*): nesse tipo de regime, as bolhas estão dispersas no líquido e a sua maior concentração ocorre na parte superior do tubo (devido à sua flutuabilidade). O padrão é ilustrado na Figura 1 (a).
- Estratificado (*Stratified Flow*): ocorre quando há uma completa separação das fases devido às baixas velocidades do gás e do líquido. A interface que separa as fases é rela-



**Figura 1: Padrões de escoamento bifásico gás-líquido horizontal**

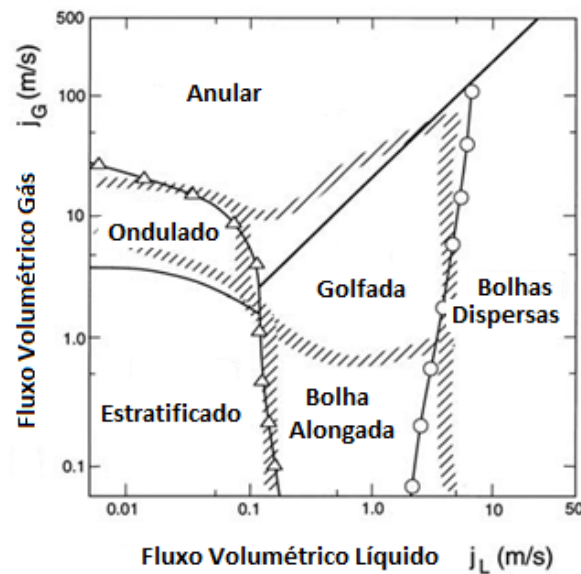
Fonte: Adaptado de (SHOHAM, 2006)

tivamente lisa e não apresenta perturbações, sendo que o gás fica na parte superior. A Figura 1 (b) ilustra um exemplo.

- Pistonado ou golfada (*Slug Flow*): este padrão tem como característica principal a alternância entre bolhas e uma região de líquido, denominada pistão de líquido. Tal regime intermitente possui bolhas grandes ou bolhas alongadas, denominadas bolhas de Taylor. A Figura 1 (c) ilustra um exemplo. Este padrão é considerado neste trabalho para extração do formato das bolhas de gás e posterior levantamento das propriedades do escoamento.
- Anular (*Annular Flow*): padrão que ocorre para elevadas vazões de líquido e gás. O gás escoa no centro da tubulação, podendo conter gotículas de líquido, e o líquido escoa próximo à parede da tubulação, formando uma espécie de filme. A gravidade faz com que o filme seja mais espesso na parte inferior do tubo. A Figura 1 (d) ilustra um exemplo.

Diversos autores apresentam discussões detalhadas sobre tais padrões (HEWITT, 1982; TAITEL; DUKLER, 1976; MANDHANE et al., 1974). Nesses trabalhos são apresentados mapeamentos gráficos dos padrões de escoamento obtidos a partir de ensaios experimentais, em que os dados são mapeados em gráficos relacionando-se as velocidades superficiais do líquido e do gás. A Figura 2 apresenta o mapeamento obtido por Mandhane, Gregory e Aziz (MANDHANE et al., 1974).

Vários outros pesquisadores utilizam-se desses mapeamentos, devido à maior facili-



**Figura 2: Mapa de escoamento obtido por Mandhane, Gregory e Aziz**


**Fonte: Adaptado de (MANDHANE et al., 1974)**

dade de visualização e correlação entre os padrões de escoamento e suas velocidades superficiais (TAITEL; BARNEA, 1990) (AZZOPARDI, 2006). É importante mencionar que, em alguns casos, para as mesmas condições operacionais de vazão e diâmetro da tubulação, por exemplo, mapas de diferentes autores podem mostrar diferenças na região de transição de um padrão para outro, pois é difícil detectar com precisão a transição entre algumas regiões.

## 2.2 PADRÃO GOLFADA

Dentre os padrões de escoamento horizontal, o padrão em golfadas vem sendo estudado individualmente desde 1969 (WALLIS, 1969), sendo um dos padrões de maior ocorrência em aplicações industriais. É um escoamento intermitente cujas características variam no espaço e no tempo, e que é caracterizado pela sucessão de pistões de líquido seguidos por uma grande bolha alongada, podendo apresentar bolhas dispersas ou não dependendo da velocidade das fases. Wallis, 1969 introduz o conceito de célula unitária como ilustrado na Figura 3, o qual pode ser usado para representar graficamente o modelo de escoamento em golfada (WALLIS, 1969). Observa-se na ilustração o pistão de líquido e sua bolha alongada adjacente e diversas bolhas dispersas com o respectivo filme líquido. Com a descrição e análise do comportamento de uma célula unitária, todas as propriedades do escoamento em padrão golfadas ao longo de um duto podem ser previstas (AZZOPARDI, 2006; SHOHAM, 2006). Este padrão é considerado neste trabalho para extração do formato médio da bolha alongada, a qual possibilitará o estudo das

propriedades do escoamento.



**Figura 3: Representação de uma célula unitária no padrão golfada gás-líquido na horizontal, bem como o filme líquido, a bolha alongada e o pistão líquido**

Fonte: Adaptado de (SHOHAM, 2006)

Um estudo sobre os parâmetros mais relevantes associados ao escoamento bifásico em golfadas foi realizado por (RODRIGUES, 2009). Na sequência, são definidos aqueles considerados neste trabalho.

O comprimento de uma célula unitária, denotado aqui por  $L_U$ , é dado pela soma dos comprimentos da bolha alongada,  $L_B$ , e do pistão de líquido,  $L_S$ . A diferenciação entre as velocidades é um fator fundamental para obtenção de diversos outros parâmetros. As velocidades locais das fases de líquido,  $U_L$  e de gás,  $U_G$  são expressas, respectivamente, por:

$$U_L = \frac{Q_L}{A_L} \quad \text{e} \quad U_G = \frac{Q_G}{A_G}, \quad (1)$$

em que  $A_L$  e  $A_G$  denotam, respectivamente, a área ocupada pelo líquido e pelo gás (em uma seção transversal genérica do escoamento bifásico); e  $Q_L$  e  $Q_G$  são as vazões volumétricas de líquido e gás na seção transversal analisada. Pode-se definir a fração de uma fase ( $R_L$  para líquido e  $R_G$  para gás) como a razão entre a área ocupada por esta e a área da seção transversal, isto é:

$$R_L = \frac{A_L}{A_T} \quad \text{e} \quad R_G = \frac{A_G}{A_T}, \quad (2)$$

em que  $A_T$  denota a área da seção transversal do duto. Dada essa informação, as velocidades de cada fase também podem ser escritas como:

$$U_L = \frac{Q_L}{R_L A_T} \quad \text{e} \quad U_G = \frac{Q_G}{R_G A_T}. \quad (3)$$

Entretanto, é mais comum a utilização das velocidades superficiais das fases, denotadas por  $J_L$  (líquido) e  $J_G$  (gás). Estas representam a velocidade obtida caso a fase escoasse sozinha na

tubulação, e são definidas por:

$$J_L = \frac{Q_L}{A_T} \quad \text{e} \quad J_G = \frac{Q_G}{A_T}. \quad (4)$$

A velocidade média da mistura (ou velocidade da mistura) é dada por:

$$J = \frac{Q}{A_T} = \frac{Q_L + Q_G}{A_T}, \quad (5)$$

em que  $Q$  denota a vazão volumétrica total,  $Q = Q_L + Q_G$ . A partir das equações em 4, pode-se concluir que a velocidade da mistura é a soma das velocidades superficiais de cada fase, ou seja:

$$J = J_L + J_G. \quad (6)$$

segundo (RODRIGUES, 2009), as velocidades superficiais de líquido e gás (aqui denotadas por  $J_L$  e  $J_G$ ) são variáveis de grande utilização em escoamentos bifásicos devido ao fato de serem facilmente relacionadas à vazão volumétrica das fases. Considera ainda que no escoamento bifásico gás-líquido, o líquido é tipicamente tratado como incompressível e o gás como compressível. Dessa forma, a vazão volumétrica do líquido (e, conseqüentemente, a velocidade superficial) é constante ao longo de todo o escoamento. Por outro lado, a vazão volumétrica do gás varia ao longo do escoamento, de acordo com a pressão.

Outro parâmetro importante para a modelagem do escoamento é a frequência  $f$  da célula unitária em golfadas, a qual é definida como o inverso do tempo de passagem de uma célula em um determinado ponto da tubulação. Essa frequência pode ser utilizada para relacionar a velocidade de translação da bolha e comprimentos de pistão de líquido e é expressa por:

$$f = \frac{1}{\Delta t_U}, \quad (7)$$

em que  $\Delta t_U$  é o tempo de passagem da célula unitária.

Por fim, é possível calcular também o volume de cada fase. O volume total de gás é calculado multiplicando-se o valor da área do gás,  $A_G$ , por seu comprimento,  $L_B$ . Logo, o volume total de gás em cada aquisição é igual ao somatório dos volumes de cada bolha alongada, dado por:

$$V_G = \sum A_G \times L_B. \quad (8)$$

Para obter o volume de líquido, deve-se subtrair o volume de gás  $V_G$  do volume total da aquisição, ou seja, da célula unitária. Esse volume total é igual à área interna da tubulação multiplicada pelo somatório dos comprimentos das células unitárias obtidas durante a aquisição,



isto é:

$$V_L = \pi r^2 \times (\sum(L_U - V_G)). \quad (9)$$

O volume das bolhas de gás é calculado por meio de uma aproximação da forma. Uma bolha de gás é formada por um conjunto de imagens (frames) bastante variável, de acordo com o comprimento da bolha bem como da taxa de aquisição por segundo das imagens. Deste modo, inicialmente é determinada a altura média do filme de líquido  $\delta_{ff}$  para o conjunto de frames que o compõe. Dependendo do seu valor, igual, menor ou maior que o raio interno da tubulação, o procedimento de cálculo é diferente (GRANGEIRO, 2010):

Caso 1:  $\delta_{ff} = r$

É definido quando a área transversal ocupada pelo gás é exatamente igual à metade da área do círculo com diâmetro igual ao diâmetro interno da tubulação. Caso de ocorrência rara. Logo:

$$A_g = \frac{\pi r^2}{2} \quad (10)$$

Caso 2:  $\delta_{ff} < r$

Neste caso, a espessura do filme de líquido é menor que o raio interno da tubulação, portanto, a área a ser calculada é a área ocupada pelo gás, indicada na Figura 4 pela cor branca. O triângulo AOC, ilustrado pela Figura 4, define o segmento da interface gás-líquido. A área ocupada pelo gás, por conseguinte, é igual à área do triângulo AOC somada à área do arco ACD. Então, para o triângulo AOC, o lado AB é determinado por:


$$x = \sqrt{r^2 - (r - \delta_{ff})^2} \quad (11)$$

Sendo os triângulos OAB e OBC semelhantes, o comprimento do segmento AC é dado por:

$$AC = 2 \cdot \sqrt{r^2 - (r - \delta_{ff})^2} \quad (12)$$

A área do triângulo AOC é expressa por:

$$A_{\Delta} = \sqrt{r^2 - (r - \delta_{ff})^2} \cdot (r - \delta_{ff}) \quad (13)$$



**Figura 4: Cálculo da área transversal do gás com  $\delta_{ff} < r$**

**Fonte: Adaptado de (GRANGEIRO, 2010)**

A área do arco AOCD é expressa por:

$$A_A = \frac{\pi r^2 \theta_2}{360} \quad (14)$$

Enfim, a área ocupada pelo gás é:

$$A_g = A_{\Delta} + A_A \quad (15)$$

Caso 3:  $\delta_{ff} > r$


Neste caso, a espessura do filme de líquido é maior que o raio interno da tubulação, conforme ilustra a Figura 5. A área transversal ocupada pelo gás é igual à área transversal da tubulação subtraída da área do triângulo AOC e do arco ACD. O comprimento do segmento AC é determinado a partir do valor de x:

$$x = \sqrt{r^2 - (\delta_{ff} - r)^2} \quad (16)$$

O comprimento do arco AC é, portanto:

$$AC = 2 \cdot \sqrt{r^2 - (\delta_{ff} - r)^2} \quad (17)$$

Sendo os triângulos AOB e BOC semelhantes, então a área do triângulo AOC é:



**Figura 5: Cálculo da área transversal do gás com  $\delta_{ff} > r$**

**Fonte: Adaptado de (GRANGEIRO, 2010)**

$$A_{\Delta} = \sqrt{r^2 - (\delta_{ff} - r)^2} \cdot (\delta_{ff} - r) \quad (18)$$

A área do arco ACD é expressa por:

$$A_A = \frac{\pi r^2 \theta_2}{360} \quad (19)$$

Enfim, a área ocupada pelo gás é:

$$A_g = A_i - A_{\Delta} - A_A \quad (20)$$

em que  $A_i$  é a área interna da tubulação, ou seja,  $\pi r^2$ .

Em 1984, Bendiksen apresenta o seguinte modelo de fluxo horizontal (BENDIKSEN, 1984):

$$U_t = \left( C_0 J + C_{\infty} \sqrt{gD} \right) \quad (21)$$

em que  $g$  é a gravidade,  $D$  é o diâmetro interno do tubo e  $J$  é a velocidade de mistura ( $J = J_L + J_G$ ). O coeficiente de distribuição de fluxo ( $C_0$ ) e o coeficiente de inclinação do tubo ( $C_{\infty}$ ) são parâmetros com base nas características do tubo e do número de Reynolds. Tal modelo vem sendo amplamente aceito na literatura da área e, portanto, será base de comparação com os resultados obtidos pela abordagem proposta.

### 2.3 TRABALHOS RELACIONADOS

A importância de medidas precisas para o escoamento bifásico pode ser observada pelo número de pesquisadores que tem se dedicado nos últimos anos ao estudo de técnicas e equipamentos capazes de fornecer informações precisas e confiáveis, tanto sobre o comportamento dos fluidos no fluxo quanto dos padrões associados. Algumas técnicas, apesar de promissoras, não possuem uso disseminado tipicamente devido ao alto custo associado, à necessidade de profissionais especializados para a operação dos equipamentos ou, ainda, pela falta de exatidão nos resultados obtidos. Várias abordagens têm sido propostas, variando desde equipamentos de raios-X e ressonância magnética até a aplicação de técnicas de processamento de imagens, sendo este último caso o foco deste trabalho.

Enquanto Jones e Zuber (JONES; ZUBER, 1975) utilizaram um sistema de raios-X para determinar os padrões de escoamento, Kumar e colaboradores (KUMAR et al., 1997) fizeram uso de raios gama. Ambas as técnicas necessitam de apoio de profissional especializado para a correta utilização dos equipamentos, principalmente devido às normas de segurança restritas para uso de tais equipamentos.

Warsito e colaboradores (WARSITO, 1999) elaboraram uma breve revisão das técnicas não invasivas para monitoramento de plantas de escoamentos multifásicos. Os autores optaram pela utilização da tomografia computadorizada ultrassônica para medir a distribuição de fases ao longo da seção transversal do duto. Em (TSOUKALAS et al., 1997), foram utilizados sensores de impedância não intrusivos, sendo cada sensor formado por um conjunto de eletrodos e um circuito de medidores de impedâncias. Oito eletrodos foram simetricamente dispostos e embutidos na tubulação. Cada par de eletrodos fornece uma medida de impedância. Portanto, uma combinação de medições de impedâncias é realizada em uma seção transversal da tubulação. As múltiplas combinações se destinam a resolver os problemas associados com a distribuição não uniforme das fases.

Recentemente, (POWELL, 2008) faz uma revisão das técnicas experimentais que fornecem boa resolução espacial e temporal usadas para descrever escoamentos multifásicos. Cinco métodos são discutidos: radiografia de ressonância magnética, ultrassom *doppler* pulsado, tomografia de impedância elétrica, radiografia de raios-X e de nêutrons. O autor aponta a técnica que utiliza ressonância magnética como sendo a mais versátil, por ser capaz de fornecer medidas para uma ampla faixa de concentração, velocidade, constituintes químicos e difusão das fases. Contudo, é preciso considerar o custo elevado desses equipamentos, além da necessidade de mão de obra especializada para sua efetiva utilização.

Também como uma revisão Wahab e colaboradores (WAHAB et al., 2015) fazem uma descrição dos principais tipos de processos tomográficos não invasivos. A revisão compreende o período de 2004 até a data da sua publicação. Os autores dividem a discussão em duas partes: tomografia não invasiva do tipo *hard field* e tomografia não invasiva do tipo *soft field*. Dentre as diversas técnicas listadas destacam-se: tomografia de raios-X, tomografia óptica e tomografia ultrassônica. Segundo os autores a combinação de raios-X e tomografia de sensor *Wire-Mesh* produziu uma melhor imagem reconstruída em comparação com uma única modalidade de tomografia de raios-X. Entretanto, como principais desvantagens estão à necessidade de um especialista para operar o sistema, o alto custo e precauções de segurança relacionadas com questões de radiação. Na tomografia óptica a limitação refere-se à sua superfície óptica; os sensores não podem ser colocados muito próximos uns dos outros a fim de evitar a reflexão, e pode apenas detectar a imagem entre a área dos sensores ópticos. A tomografia ultrassônica tem melhores resultados, entretanto, um alto custo é necessário devido ao número de sensores (acima de 32 pares) para a reconstrução de imagens em alta resolução.

A combinação de sensores de capacitância com técnicas de processamento de imagens também vem sendo utilizada. O sensor *Wire-Mesh* (sensor de malha de eletrodos) foi inicialmente proposto por Prasser et. al. em 1998 (PRASSER et al., 1998). Seu princípio de funcionamento consiste em captar diferenças de permissividade elétrica e/ou a condutividade elétrica existentes em cada substância (SILVA et al., 2007). Apesar dos resultados promissores em representar a fenomenologia do escoamento, a abordagem possui a desvantagem de ser intrusiva.

Por outro lado, alguns pesquisadores tem buscado a identificação do formato das bolhas em escoamentos, especificamente a definição da célula unitária. Netto e colaboradores, 1999, apresentam um estudo teórico e experimental da forma das bolhas alongadas semelhantes àquelas observadas em escoamentos horizontais, utilizando sensores condutivos e capacitivos (NETTO et al., 1999). Obtiveram então os valores do volume e comprimento das bolhas de gás. A bolha é dividida em quatro regiões: nariz, corpo, cauda e pistão de líquido.

Como se pode observar, as diversas abordagens citadas apresentam algumas desvantagens associadas ao alto custo e a necessidade de pessoal com capacidade técnica para o correto manuseio. A utilização de técnicas baseadas em processamento de imagens tem se apresentado como uma boa alternativa, tendo como vantagens imediatas o baixo custo e a facilidade de implementação/utilização, sendo independente de profissionais especializados para manuseá-las. Entretanto, sua aplicação está condicionada a tubulações transparentes, portanto, restritas a experimentos em laboratórios.

Em aplicações relacionadas a escoamentos bifásicos, técnicas de processamento de imagens, tipicamente são utilizadas para extrair a região de interesse do escoamento (célula unitária) para análises posteriores.

Em (SHI et al., 2004) é proposta uma abordagem baseada em limiarização para segmentar as bolhas de gás. Para tanto, as imagens originais são pré-processadas por meio do algoritmo de subtração possibilitando a diminuição de ruídos. Em seguida, um filtro da mediana é aplicado a fim de suavizar as bordas da imagem. Então, a abordagem de limiarização adaptativa é aplicada para obter a binarização da imagem. Finalmente, operações morfológicas (como a dilatação, erosão, abertura e fechamento) são aplicadas a fim de modificar a forma das bolhas. Porém, o método proposto mostrou-se sensível à presença de ruídos e variações nas condições de iluminação. Em (DINH et al., 1999) é aplicada uma abordagem baseada em subtração de fundo seguida por detecção de bordas, que também apresenta problemas em imagens de baixa qualidade.

A transformada de *Hough* (GONZALEZ; WOODS, 2001) é utilizada em (YU et al., 2009) como base para o desenvolvimento de uma técnica de segmentação para escoamentos bifásicos sólido-líquido, mas esta é limitada a formas que podem ser parametrizadas. No trabalho de (GRAU; HEISKANEN, 2002) a imagem pré-processada por um filtro passa-alta é utilizada para segmentação via transformada de *watershed*. Porém, assume-se que a bolha pode ser aproximada por formas esféricas, o que não ocorre para diversos padrões de escoamento. O método de detecção de partículas proposto em (ZABULIS et al., 2007) é baseado em rastreamento de bordas e casamento de padrões. Entretanto, quando a densidade das partículas cai abaixo de um determinado nível, sua detecção e reconstrução são comprometidas.

Em (MAYOR et al., 2007) é utilizada a abordagem de limiarização seguida da operação morfológica de erosão a fim de transformar as bolhas originais em bolhas binárias, com aumento da área dos pixels brancos. Neste trabalho são calculadas as medidas de comprimento da bolha, velocidade da bolha bem como o comprimento do pistão de líquido. Porém, a abordagem proposta não pode ser considerada precisa, uma vez que o processo de erosão provoca o aumento pouco controlado dos pixels pertencentes à bolha de gás, ou seja, a erosão permite que os objetos em uma cena encolham ou afinem, este processo é definido pela escolha do elemento estruturante. É o elemento estruturante quem determina a vizinhança a ser considerada no cálculo do valor transformado de cada pixel.

(AMARAL et al., 2013) utilizaram como abordagem de segmentação das bolhas de gás em escoamento em golfadas, a segmentação por *watershed*, a filtragem *top-hat* e a transformação *H*-mínima. Os resultados obtidos puderam então ser comparados ao modelo

de correlação de Bendiken (BENDIKSEN, 1984), com resultados promissores.

No trabalho de (RIAÑO et al., 2013) as frações volumétricas (*holdup*) do óleo são calculados por meio de imagens do escoamento óleo-água. Os autores optaram por três etapas: pré-processamento (incluindo melhorias e corte nas imagens) tais como, filtro da mediana e equalização do histograma. Para etapa de segmentação, dois métodos diferentes foram aplicados: contornos ativos e filtragem morfológica. Após a segmentação os valores calculados foram avaliados quantitativamente. Entretanto, conforme se pode observar pelas imagens de exemplo ilustradas, a segmentação do óleo é relativamente mais simples, uma vez que as imagens do escoamento bifásico ar água em golfada apresenta a complexidade relacionada à ocorrência de bolhas dispersas.

Mais recentemente, com o objetivo de medir a espessura da água no escoamento óleo e água, (RIAÑO et al., 2015) segmentaram as imagens de escoamento óleo-água. Para tanto, uma combinação de métodos foi proposta, dentre eles decomposição via Wavelets, partição fuzzy e limiarização baseada em entropia de Tsallis, com resultados promissores.

O trabalho proposto em (DORINI et al., 2011) já havia comparado o método *Level Set* implementado por (LI CHENYANG XU; FOX, 2005), às abordagens de segmentação por *watershed* e limiarização, com a segmentação manual definida por um especialista para segmentar as bolhas de gás das mesmas imagens utilizadas neste trabalho. Apesar dos resultados promissores e superiores da abordagem *Level Set* em relação a limiarização e ao *watershed*, tais resultados motivaram o seu aprofundamento e aperfeiçoamento conforme aqui proposto, uma vez que pode-se observar a dificuldade em segmentar as bolhas em golfada especificamente na ocorrência de bolhas dispersas.

A segmentação das bolhas de gás presentes nos escoamentos bifásicos não é uma tarefa fácil, principalmente para o padrão em golfadas, no qual há a presença de gotículas de gás em meio líquido. Além disso, das três formas aqui estudados (nariz, corpo e cauda), duas (nariz e cauda) possuem variações na forma e tamanho, dificultando a automatização de etapas tais como a extração de marcadores. Outro aspecto complicador está relacionado ao ambiente não controlado de aquisição das imagens, o qual resulta em imagens com baixo contraste entre a borda e o fundo, por exemplo.

Assim, apesar dos diversos estudos experimentais citados na literatura, a análise automática de imagens para identificar e medir parâmetros de escoamentos bifásicos é bastante limitada. Tal fato também motiva o desenvolvimento deste trabalho, que engloba a implementação de um sistema que extrai o formato das bolhas de gás em golfada e posteriormente calcula algumas das propriedades relevantes associadas ao escoamento bifásico horizontal ar água.

## 2.4 CONSIDERAÇÕES FINAIS

Neste capítulo foi apresentado um resumo dos fundamentos básicos dos escoamentos bifásicos. Com base na análise da literatura, pode-se observar a importância da medição dos parâmetros no escoamento, os quais devem retornar valores precisos a fim de obter uma melhor aproximação sobre o que realmente ocorre em aplicações reais. Somente desta forma os sistemas envolvidos podem ser construídos com maior confiabilidade e segurança.

Elaborou-se ainda uma pesquisa sobre os diversos equipamentos utilizados para a caracterização de fluxos bifásicos. Finalmente, foram apresentadas algumas abordagens que envolvem o uso de técnicas de processamento de imagens. Essas tem se mostrado uma alternativa promissora no estudo do escoamento bifásico, motivando a elaboração deste trabalho.

Vale a pena enfatizar que a abordagem aqui proposta vem somar aos equipamentos comumente empregados na caracterização do fluxo bifásico, neste caso oferecendo uma avaliação visual importante. Com isso, poderá auxiliar os profissionais da área, uma vez que será capaz de fornecer valores precisos e automáticos das propriedades essenciais à compreensão desta fenomenologia, a partir da segmentação das bolhas de gás do escoamento bifásico gás líquido, obtidos a partir de imagens digitais.

No próximo capítulo será feita uma revisão sucinta dos conceitos de análise e processamento de imagens, assim como o detalhamento das abordagens de segmentação de imagens que foram base para o desenvolvimento deste trabalho.



### 3 PROCESSAMENTO DE IMAGENS: FUNDAMENTAÇÃO TEÓRICA

No trabalho anteriormente desenvolvido por (DORINI et al., 2011) foi comprovado que a segmentação pelo método *Level Set* apresenta resultados promissores ao segmentar as bolhas de gás das mesmas imagens utilizadas neste trabalho. Tais resultados motivaram o seu aprofundamento e aperfeiçoamento, a fim de sanar problemas relacionados à dificuldade em segmentar as bolhas em golfada especificamente na ocorrência de bolhas dispersas e oclusões. Para tanto, uma combinação do método *Level Set* e conhecimento a priori do formato médio das bolhas de gás será desenvolvido, testado e comparado aos métodos de segmentação por limiarização e corte em grafos, representando respectivamente um método tradicional para segmentação de objetos e outro mais recentemente desenvolvido para este fim.


Este capítulo descreve as técnicas que compõem a base necessária à compreensão do restante deste trabalho. Na Seção 3.1, são apresentados os conceitos básicos sobre processamento de imagens. A Seção 3.2 discute as abordagens de segmentação que apoiam o desenvolvimento deste trabalho. Já a Seção 3.3 apresenta os trabalhos relacionados à segmentação por contornos ativos agrupados de acordo com suas características e modificações. Finalmente na Seção 3.4 um resumo do capítulo será apresentado.

#### 3.1 CONCEITOS BÁSICOS

Uma imagem digital pode ser obtida por um processo denominado *digitalização*, o qual envolve dois passos, a amostragem e a quantização. A amostragem consiste em discretizar o domínio de definição da imagem nas direções  $x$  e  $y$ , gerando uma matriz  $M \times N$  amostras, respectivamente. A quantização consiste em escolher o número inteiro  $L$  de níveis de cinza (em uma imagem monocromática) permitidos para cada ponto da imagem (SCHWARTZ, 2008).

Uma imagem digital pode então ser definida como uma função bidimensional,  $f(x, y)$ , em que  $x$  e  $y$  são coordenadas espaciais (plano), e a amplitude de  $f$  em qualquer par de coordenadas  $(x, y)$  é chamada de intensidade ou nível de cinza da imagem naquele ponto. Cada elemento  $f(x, y)$  dessa matriz de amostras é chamado pixels (*picture elements*) (JAIN; SCHUNCK, 1995).

O valor que cada pixel pode assumir é determinado pela quantização considerada para codificar os níveis de intensidade. Imagens em níveis de cinza tipicamente consideram uma codificação em oito bits, em que a intensidade de um pixel varia de zero (preto) a 255 (branco). Contudo, em algumas aplicações, a faixa de intensidade pode chegar a 4096, por exemplo (GONZALEZ; WOODS, 2001). No outro extremo, estão as imagens binárias, que consideram apenas dois níveis de intensidade. A Figura 6 ilustra a mesma imagem representada em diferentes níveis de quantização. Visando facilitar a visualização, quando imagens binárias são mostradas, este trabalho representa o fundo pela cor preta e o objeto de interesse pela cor branca. A imagem original relativa à Figura 6 e muitos outros exemplos de imagens digitais, podem ser encontrados no web site <https://www.eecs.berkeley.edu/Research/Projects/CS/vision/bsds/>.



**Figura 6: Representação de uma imagem utilizando diferentes níveis de quantização: (a) 256 (oito bits) e (b) dois**

**Fonte: Autoria própria**

### 3.2 SEGMENTAÇÃO

Segmentação é uma palavra usada para descrever o processo de agrupamento de componentes que dizem respeito ao mesmo conteúdo e aplicação e que são semelhantes em relação a alguma característica ou conjunto de características. A consequência é que este agrupamento irá identificar as regiões da imagem que correspondem aos objetos únicos e distintos no ambiente visual (VERNON, 1991). Ou seja, a segmentação define o conjunto de regiões capaz de diferenciar e separar os vários elementos presentes na cena.

Dado  $\mathbb{R}$ , como representação de uma região inteira da imagem, pode-se considerar a segmentação como um processo que particiona  $\mathbb{R}$  em  $n$  sub-regiões  $\mathbb{R}_1, \mathbb{R}_2, \dots, \mathbb{R}_n$  de tal forma que:

- a)  $\bigcup_{i=1}^n \mathbb{R}_i = \mathbb{R}$
- b)  $\mathbb{R}_i$  é um conjunto conectado,  $i = 1, 2, \dots, n$ .
- c)  $\mathbb{R}_i \cap \mathbb{R}_j = \emptyset$  para todo  $i$  e  $j, i \neq j$ .
- d)  $P(\mathbb{R}_i) = \text{VERDADEIRA}$  para  $i = 1, 2, \dots, n$ .
- e)  $P(\mathbb{R}_i \cup \mathbb{R}_j) = \text{FALSO}$  para qualquer região adjacente  $\mathbb{R}_i$  e  $\mathbb{R}_j$ .

Em que,  $P$  é uma propriedade lógica definida sobre os pontos no conjunto  $\mathbb{R}_i$  e  $\emptyset$  é o conjunto vazio. A propriedade é utilizada como uma medida de similaridade para agrupar os pixels em uma região. A condição (a) indica que cada pixel deve pertencer a uma região da imagem, isto é, cada pixel deve estar em uma região. A condição (b) requer que os pontos em uma região estejam conectados de alguma forma predefinida (como por exemplo, adjacência ou pixels na vizinhança). A condição (c) indica que as regiões devem ser disjuntas, ou seja, cada pixel pertence apenas a uma região. A condição (d) refere-se às propriedades que devem ser satisfeitas pelos pixels em uma região segmentada - por exemplo,  $P(\mathbb{R}_i) = \text{VERDADEIRA}$  se todos os pixels em  $\mathbb{R}_i$  tiverem o mesmo nível de cinza, ou seja, a mesma intensidade. Finalmente a condição (e) indica que as regiões adjacentes  $\mathbb{R}_i$  e  $\mathbb{R}_j$  são diferentes, em relação à propriedade definida  $P$  (GONZALEZ; WOODS, 2001).

A propriedade  $P$  é a base para o uso das abordagens de segmentação. Cada abordagem preocupa-se na melhor forma de defini-la, sendo crucial para o sucesso de diversas aplicações de processamento de imagens digitais.

Jain (1989) identifica duas abordagens complementares para o problema de segmentar imagens e isolar objetos: crescimento de regiões e detecção de bordas (JAIN, 1989). A primeira efetua o processo de segmentação pelo agrupamento de áreas elementares que partilham características comuns definindo uma conexão de áreas bidimensionais chamadas regiões. Exemplos de características incluem nível de cinza do pixel ou algum padrão de textura elementar.

A segmentação baseada em bordas preocupa-se em detectar ou acentuar os pixels pertencentes à borda do objeto, o que pode ser influenciado por fatores tais como ruídos ou variações nas condições de iluminação. Nesta categoria, o pressuposto é que as fronteiras das regiões são suficientemente diferentes entre si e em relação ao fundo da imagem para permitir a detecção de limites com base nas discontinuidades locais de intensidades (GONZALEZ;

WOODS, 2001).

A importância da etapa de segmentação para o processamento de imagens tem conduzido vários pesquisadores a buscar soluções eficientes. Algumas metodologias incluem (MA et al., 2010): filtragem local (realce das bordas de intensidade); crescimento e agrupamento de regiões (subdivide em sub-regiões com algum critério de homogeneidade); otimização de funções de energia (usam funções de energia definidas globalmente na imagem); segmentação por corte em grafos e modelos deformáveis, como contornos ativos que fazem uso de informações locais da imagem e sobre o objeto.

A avaliação de um único algoritmo em diferentes conjuntos de dados fornece informações sobre a robustez e a capacidade de lidar com dados adquiridos em diferentes condições e por diferentes modalidades. Podem-se citar duas maneiras de avaliação: avaliação supervisionada e não supervisionada (SONKA et al., 2014).

Na avaliação supervisionada sobre o resultado de uma segmentação supõe-se que a segmentação “correta” é conhecida. Isto implica na definição de uma segmentação modelo definida por um especialista denominada *ground-truth*, tais como desenhos interativos sobre os limites corretos na imagem. Já a avaliação não supervisionada é considerada quando há dificuldade na aquisição das imagens *ground-truth*, tais como definição imprecisa, escassez de informação e carga computacional. Para tanto, considera-se diferentes estatísticas das propriedades da imagem e da segmentação, tais como localização, forma, tamanho, contraste ou intensidade das regiões segmentadas (SHIN et al., 2001).

Independente da forma de avaliação escolhida, as novas abordagens devem ser capazes de lidar com conjuntos de dados de imagens cada vez maiores, bem como com o aumento da dimensionalidade das imagens. Neste sentido, pode-se citar como métodos mais avançados em segmentação de imagens: técnicas que usam a segmentação por média de deslocamento (*mean shift*), conectividade *fuzzy*, modelos deformáveis e cortes em grafos.

A escolha da técnica dependerá dos objetivos específicos de cada aplicação. Neste trabalho, uma abordagem de segmentação baseada em método *Level Set* e conhecimento a priori será desenvolvida e implementada, para segmentar bolhas de gás em escoamento bifásico do tipo golfada. O método será avaliado de forma supervisionada por meio de experimentos, usando comparativamente os resultados obtidos isoladamente pelas técnicas de base: modelo de forma ativa e *Level Set* sem conhecimento a priori, além da técnica tradicionalmente aplicada em problemas de segmentação, limiarização e pela técnica avançada de segmentação por corte em grafos, os quais serão discutidos a seguir.

### 3.2.1 SEGMENTAÇÃO POR LIMIAZIZAÇÃO

Uma das técnicas mais simples de segmentação é conhecida como limiarização ou binarização. Basicamente, é um método que converte uma imagem em níveis de cinza em uma imagem binária, a qual idealmente deve separar os objetos de interesse do fundo. Para tal é preciso especificar um valor, denominado limiar, que define se um determinado pixel pertence ao objeto ou ao fundo. Em suma, qualquer pixel cujo valor de intensidade é maior que o limiar é definido como pertencente ao objeto. Caso contrário, o ponto é classificado como pertencente ao fundo. Matematicamente, a imagem limiarizada  $g(x,y)$  é definida como:

$$g(x,y) = \begin{cases} 1, & \text{se } f(x,y) \geq T \\ 0 & \text{se } f(x,y) < T \end{cases} \quad (22)$$

em que  $T$  denota o limiar e os nível de intensidade 1 e 0 representam, respectivamente, objeto (branco) e fundo (preto) (GONZALEZ; WOODS, 2001).

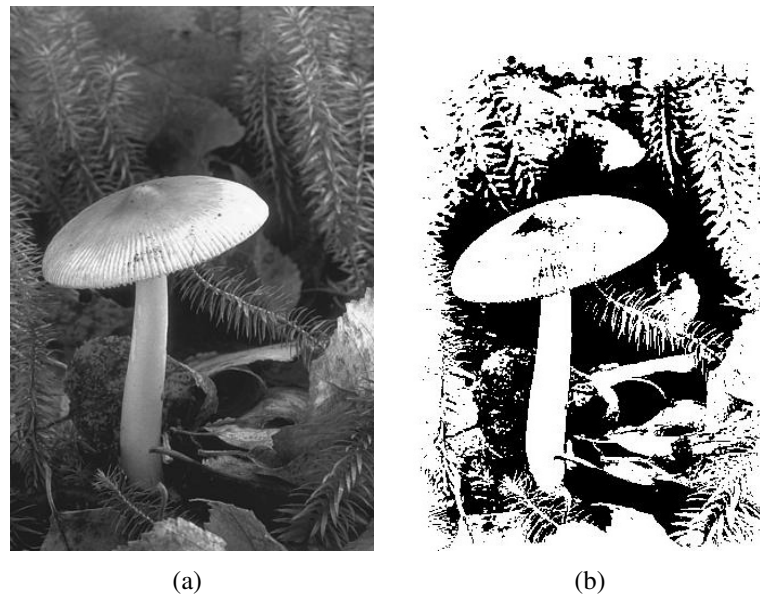
Apesar de o processo ser bastante simples, sua aplicação é condicionada àquelas imagens onde as distribuições de intensidades entre os objetos e o fundo é contrastante, o que na prática raramente ocorre.

Considere a Figura 7 como exemplo de segmentação por limiarização, em que a imagem de entrada é composta por objetos sem contraste significativo com relação ao fundo. O resultado da limiarização pode ser observado na Figura 7 (b). Note que, embora seja possível visualizar o contorno do objeto de interesse, o resultado não é satisfatório. A separação total do fundo requer o uso de técnicas mais sofisticadas, tais como aquelas que serão discutidas na sequência deste trabalho.

### 3.2.2 SEGMENTAÇÃO POR CORTE EM GRAFOS

Conforme descrito anteriormente, a segmentação consiste no processo de particionar uma imagem  $\mathbb{R}$  em  $n$  sub-regiões. Neste sentido, algumas abordagens baseadas na teoria de grafos têm sido empregadas.

Atualmente, existem várias classes de algoritmos que representam imagens como grafos, particionando-o em grupos que representam as  $n$  sub-regiões separadas na imagem. A ideia básica de forma geral consiste na representação de uma imagem em um grafo  $G = (V, E)$ , em que  $V$  representa o conjunto dos vértices (ou nós) correspondentes aos elementos da imagem (tais como, pixels, descritores de características); e  $E$  representa o conjunto de arestas que ligam os vértices no grafo. O peso de uma aresta,  $w_{ij}$ , é proporcional à semelhança entre os vértices  $v_i$



**Figura 7: Exemplo de segmentação: (a) imagem original e (b) imagem segmentada com base na técnica de limiarização**


**Fonte: Autoria própria**

e  $v_j$  e é geralmente referido com a afinidade entre os elementos  $i$  e  $j$  da imagem (SHI; MALIK, 1997).

O valor desta afinidade pode ser qualquer um de uma série de características da imagem, incluindo intensidade dos níveis de cinza, cor, textura, e outras estatísticas da imagem. Também é comum adicionar uma medida de distância ou similaridade que garanta que o grafo é esparsos, unindo somente os nós que correspondem a elementos na imagem que estão próximos uns dos outros. Após a construção do grafo, a segmentação consistirá em determinar que subconjuntos de nós e arestas correspondem às regiões homogêneas na imagem. A ideia a seguir é que nós que pertencem à mesma região ou *cluster* devem estar acompanhados por arestas com grandes pesos, enquanto nós que são unidos por arestas fracas tendem a pertencer a diferentes regiões.

O desafio, portanto, é definir a partição ideal das diferentes regiões ou do grafo. Seja um grafo  $G = (V, E)$  a ser particionado em dois conjuntos disjuntos,  $A, B, A \cup B = V, A \cap B = \emptyset$ , a remoção das arestas que conectam duas partes, é denominada na teoria de grafos como corte (*cut*) (SHI; MALIK, 1997):

$$cut(A, B) = \sum_{i \in A, j \in B} w_{ij} \quad (23)$$



**Figura 8: Corte de Wu e Leahy para grafos gerando partições não ideais**

Fonte: Adaptado de (SHI; MALIK, 1997)

onde  $w_{ij}$  define o peso das arestas que conectam os vértices  $i$  da partição  $A$  e  $j$  da partição  $B$ . Para grafos não ponderados, o corte utiliza a soma das arestas removidas para gerar os subgrafos  $A$  e  $B$ . Busca-se então o particionamento ideal para o grafo, que tipicamente corresponde àquele que minimiza o valor de corte.

Baseando-se nestas definições, (WU; LEAHY, 1993) introduziram o método de corte mínimo para a segmentação de imagens. A ideia básica é utilizar os menores  $(k - 1)$  cortes entre todos os cortes possíveis e as arestas correspondentes são apagadas, formando partições  $k$ -subgrafos. Entretanto, podem ocorrer cortes de nós isolados e com poucas conexões no grafo, resultando em uma má partição em alguns casos, conforme ilustrado na Figura 8. Ou seja, a solução de corte mínimo irá separar um único nó (nós isolados) dos demais nós do grafo. Como resultado, este método irá favorecer a formação de regiões muito pequenas, o que resulta em excesso de segmentação (CAMILUS; GOVINDAN, 2012).

A fim de evitar o particionamento de pequenos conjuntos de pontos, (SHI; MALIK, 1997) propõe a utilização do corte normalizado em grafos para segmentação de imagens, a fim de melhorar a partição. Os autores aplicam técnicas de análise espectral para resolver o problema de segmentação de imagens. A partir da observação de que a corte mínimo tende a preferir as pequenas fronteiras, eles definem uma nova medida de corte entre as regiões  $A$  e  $B$ . Denominado de Corte Normalizado (*Normalized Cuts - NCut*) o algoritmo mede a dissimilaridade total entre os diferentes grupos bem como a semelhança total dentro dos grupos.

### 3.2.2.1 CORTE NORMALIZADO - *NCUT*

A proposta do algoritmo de *NCut* é calcular o custo do corte como uma fração total das ligações das arestas para todos os nós no grafo, definido como:

$$Ncut(A, B) = \frac{cut(A, B)}{assoc(A, V)} + \frac{cut(A, B)}{assoc(B, V)} \quad (24)$$

em que  $cut(A, B)$  é o número de arestas removidas ou, para grafos ponderados, a soma dos pesos das arestas. A variável  $assoc(A, V)$  é o total de conexões, graus dos nós em caso de grafos não ponderados ou, pesos das arestas em grafos ponderados, dos nós em  $A$  para todos os nós do grafo e  $assoc(B, V)$  é similarmente definida (SHI; MALIK, 1997).

Com a dissociação entre os grupos, o corte que particiona pequenos pontos isolados não terá mais valores para  $Ncut$  pequenos, uma vez que o valor do corte será uma grande percentagem da conexão total destes pequenos conjuntos de todos os outros nós.

Dado  $d(i) = \sum_j w_{ij}$  como a conexão total de um nó  $i$  para todos os outros nós. Dado  $D$  como uma matrix diagonal  $N \times N$  com  $d$  na sua diagonal, dado  $W$  como uma matrix simétrica  $N \times N$  com  $W_{ij} = w_{ij}$ . A minimização de  $Ncut(A, B)$  pode ser obtida por meio do cálculo do quociente de Rayleigh,  $R(A, y)$  já que  $D$  é diagonal e  $W$  é uma matriz hermitiana (STEINBRUCH; WINTERLE, 1990):

$$\min R(A, y) = \min_{A, B} Ncut(A, B) = \min_y \frac{y^T (D - W)y}{y^T D y} \quad (25)$$

sendo  $D$  a matriz de graus  $W$  a matriz de similaridade e  $y$  são os autovetores de  $A$ . Da álgebra linear, o valor mínimo do quociente de Rayleigh corresponde ao menor autovalor de  $A$ , logo a Equação 25 pode ser resolvida a partir da solução de:

$$(D - W)y = \lambda D y. \quad (26)$$

em que  $\lambda$  são os autovalores e  $y$  seus autovetores associados. Uma vez que o menor autovalor dessa matriz é zero, o segundo menor autovalor minimiza o corte normalizado.

### 3.2.2.2 ALGORITMO PARA SEGMENTAÇÃO


Os seguintes passos podem ser adaptados para segmentação por corte normalizado:

1. Dada uma imagem  $I$ , o grafo ponderado  $G = (V, E, P)$  é construído, utilizando o valor do peso de cada aresta entre dois nós como medida de similaridade entre eles.
2. Solucionar  $(D - W)y = \lambda D y$ .
3. Utilizar o autovetor do segundo menor autovalor para biparticionar o grafo.



4. Decidir se a partição atual deverá ser subdividida e de forma recursiva reparticionar as partes segmentadas se necessário. Parando se o valor de NCut for maior do que um valor de limiar pré-definido (valores de Ncut altos significam que não há apenas um ponto de partição e sim mais de um). Além disso, deve-se parar se o número total de nós na partição (área) é menor do que o valor limite pré-especificado.

A Figura 9 ilustra o resultado da segmentação para uma imagem em níveis de cinza, obtida pela Equação 26 e a Figura 10 ilustra o resultado dos autovetores obtidos por NCut.



**Figura 9: Resultado da segmentação por NCuts: (a) imagem original e (b) segmentação**

**Fonte: Autoria própria**



**Figura 10: Autovetores obtidos por NCut**


**Fonte: Autoria própria**

O desafio ao utilizar algoritmos de segmentação por cortes em grafos refere-se à super-segmentação. A definição do número de segmentos é obtida empiricamente, o que em alguns casos conduz a resultados não satisfatórios (conforme discutido no Capítulo 5).

### 3.2.3 SEGMENTAÇÃO POR CONTORNOS ATIVOS

Um número significativo de problemas de diversas áreas, tais como, o movimento das ondas do mar, as chamas em um fogo e as bordas de diferentes materiais, se reduzem ao estudo da propagação de interfaces, as quais usualmente correspondem a fronteiras entre diferentes regiões (geometricamente, uma interface pode ser considerada uma curva ou superfície que divide dois meios interagindo entre si). São duas as representações possíveis de uma interface: explícita e implícita. Como o próprio nome indica, no primeiro caso os pontos que pertencem à interface são definidos explicitamente, ao passo que na representação implícita a definição da interface se dá através do volume de alguma função (SETHIAN, 1999).

Considere como exemplo o volume zero de  $\phi(x) = x^2 - 1$ , ou seja, o conjunto de todos os pontos onde  $\phi(x) = 0$  (Figura 11). Neste caso, pode-se realizar uma divisão em três partes distintas, pertencentes ao mesmo espaço dimensional, no qual são definidos três subdomínios separados,  $(-\infty, -1)$ ,  $(-1, 1)$  e  $(1, \infty)$ . A parte interna do domínio é referenciada por  $\Omega^- = (-1, 1)$  e  $\Omega^+ = (-\infty, -1) \cup (1, \infty)$  denota a parte que está fora deste. Dois pontos  $\partial\Omega = \{-1, 1\}$  demarcam a fronteira, aqui denominada *interface*, entre as partes interna e externa.



**Figura 11: Função implícita  $\phi(x) = x^2 - 1$  definindo as regiões  $\Omega^-$  e  $\Omega^+$  bem como a borda  $\partial\Omega$**


**Fonte: Adaptado de (SETHIAN, 1999)**

Tais interfaces se movem de acordo com sua própria geometria ou segundo as leis da física associadas ao problema, podendo se dividir, fundir ou mesmo desaparecer com a evolução do tempo (NAPOLITANO, 2004). Este movimento está relacionado à velocidade dada por uma função  $F$  que pode depender de propriedades locais (determinadas por informações geométricas locais, tais como a curvatura), globais (determinadas pela *forma* e posicionamento da curva) e independentes (aquelas que não dependem da forma da curva como, por exemplo, a velocidade de um fluido sob tal curva) (SETHIAN, 1999).

A escolha da função de velocidade  $F$  adequada caracteriza um desafio em diversos problemas, tais como os encontrados na física cuja velocidade da interface só tem sentido na própria frente; nestes casos, a velocidade da interface muda rapidamente ou de forma descontínua, a frente move-se através do domínio, ou seja, a localização exata da interface determina a velocidade e a construção desta velocidade será a partir da própria posição da interface. Em se tratando do problema de segmentação de imagens aqui estudado, esta escolha é definida em função de um modelo de forma.

Para facilitar a discussão dos conceitos neste momento, assume-se que o modelo da forma é conhecido a priori (para maiores detalhes sobre bons modelos veja (SETHIAN, 1999)). Supõe-se, por exemplo, que a interface se move em direção à sua normal com velocidade proporcional à curvatura local.

A Figura 12 (a) ilustra um exemplo. As setas vazias e preenchidas denotam curvaturas negativas e positivas (dependentes da orientação da curva), respectivamente, e seu tamanho varia de acordo com a magnitude. Um método simples para modelar tal curva consiste na parametrização, o que envolve a utilização de marcadores ao longo da superfície (Figura 12 (b)).



**Figura 12: Utilização da curvatura para definir o movimento de uma curva: (a) curva exemplo e (b) parametrização**

**Fonte: Adaptado de (SETHIAN, 1999)**

A parametrização consiste basicamente em avançar as posições dos pontos segundo especificados pela função de velocidade, recalcular tais pontos e reposicioná-los. Contudo, nesta abordagem, pequenos erros iniciais podem tornar-se problemas sérios, por vezes exigindo que métodos subjetivos sejam usados para adicionar ou remover marcadores (SETHIAN, 1999).

Considere, por exemplo, um caso em que duas curvas separadas evoluem de tal forma que se fundem em um dado instante do tempo. Neste caso, para que o contorno real possa ser identificado, uma solução baseada em parametrização precisaria eliminar os marcadores

que ficassem internos a esta curva. Tal tarefa, já complexa para o caso bidimensional, torna-se ainda mais complicada para dimensões maiores. Além disso, da mesma forma que muitas outras abordagens simples para modelar a evolução de interfaces, o método descrito falha ao modelar movimentos mais complexos.

Neste contexto, Kass, Witkins e Terzopoulos (KASS et al., 1987) propuseram um modelo de propagação e movimentação de curvas para segmentação de imagens. A ideia básica é evoluir uma curva inicialmente definida por meio da minimização da função de energia, até o contorno do objeto de interesse. A função de energia é dada pela combinação das curvas de energia (energia interna) e das características da imagem (energia externa). A energia interna considera aspectos físicos como elasticidade, responsável por deformar a curva sob a ação de uma força específica e aspectos de rigidez, que é responsável por garantir a sua suavização. Por sua vez a energia externa considera as características intrínsecas da própria imagem, tais como, intensidade e gradiente (KASS et al., 1987).

Dependendo da forma de representação da curva, modelos deformáveis (ou simplesmente contornos ativos) podem ser classificados como modelos paramétricos e geométricos. Os modelos paramétricos deformáveis estão relacionados à abordagem de contornos ativos (KASS et al., 1987) e modelos de forma ativa (*Active Shape Model- ASM*) (COOTES et al., 1995) enquanto os modelos geométricos são baseados no método *Level Set* (OSHER; SETHIAN, 1988).


Na próxima seção os conceitos do método *Level Set* e do modelo de forma ativa serão apresentados.

### 3.2.3.1 MÉTODO LEVEL SET

O método *Level Set* é uma técnica computacional para rastrear e propagar uma interface ao longo do tempo que tem se mostrado precisa em muitos problemas com complexidades topológicas, tais como cantos e extremidades. Devido a sua acurácia e versatilidade, esta formulação está sendo amplamente aplicada em diversas áreas científicas, incluindo mecânica dos fluidos, ciência dos materiais e visão computacional (SETHIAN, 1999).

Sua ideia principal consiste na representação de uma determinada interface como a interface de nível zero (zero *Level Set*) de uma função de maior dimensão, denominada função *Level Set*. Tal formulação, ilustrada na Figura 13 para o caso bidimensional, conduz a uma representação eficiente e versátil da evolução das curvas. A região cinza da figura ilustra o nível zero da função *Level Set*.

Uma das principais vantagens do método está relacionada ao fato do método ser capaz



**Figura 13: Princípio do método *Level Set*. A figura à esquerda apresenta unicamente a expansão de uma circunferência, e a figura situada à direita ilustra tal circunferência como sendo a curva de nível zero de uma função de maior dimensão**

**Fonte: Adaptado de (SETHIAN, 1999)**

de tratar eficazmente mudanças topológicas e/ou descontinuidades que podem eventualmente surgir durante a propagação da curva de nível zero estudada.

Dada uma hipersuperfície  $(N - 1)$ -dimensional fechada,  $\Gamma(t = 0)$ , objetiva-se propor uma formulação Euleriana (ou seja, em que o sistema de coordenadas permanece fixo) para a propagação de  $\Gamma(t)$  em direção a sua normal segundo uma função de velocidade,  $F$  (SETHIAN, 1999):

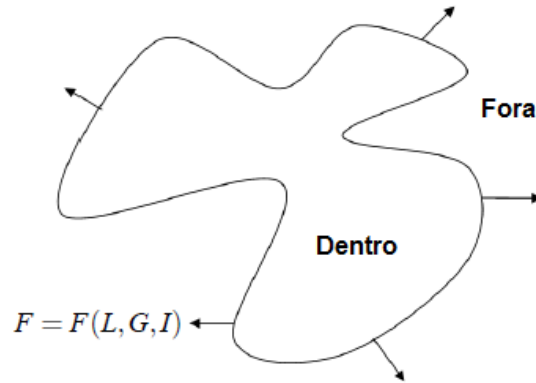
$$F = F(L, G, I), \quad (27)$$

em que  $L$  é uma propriedade local determinada pelas informações geométricas locais,  $G$  é uma propriedade global que depende da forma e posição da interface e  $I$  é uma propriedade independente desta forma. A Figura 14 ilustra um exemplo.

A ideia principal do método *Level Set* consiste em incorporar tal interface como nível zero de uma função  $\phi$ . Seja  $\phi(x, t = 0)$ , em que  $x$  é um ponto no  $\mathbb{R}^N$  definido por (SETHIAN, 1999):

$$\phi(x, t = 0) = \pm d, \quad (28)$$

em que  $d$  é a distância de  $x$  para  $\Gamma(t = 0)$ , e o sinal positivo (negativo) é escolhido se o ponto  $x$  está fora (dentro) da hiper superfície inicial  $\Gamma(t = 0)$ . Desse modo, tem-se uma função inicial  $\phi(x, t = 0) : \mathbb{R}^N \rightarrow \mathbb{R}$  com a seguinte propriedade:



**Figura 14: Propagação com velocidade  $F$**

**Fonte: Adaptado de (SETHIAN, 1999)**

$$\Gamma(t = 0) = \{x \mid \phi(x, t = 0) = 0\}. \quad (29)$$

Neste ponto, é preciso definir como ajustar o valor de  $\phi$  para os demais instantes de tempo, de modo a representar corretamente a propagação da curva. Em suma, deve-se definir uma equação para a função  $\phi(x, t)$  de tal forma que seu *Level Set*,  $\phi = 0$ , contenha a incorporação da propagação de  $\Gamma(t)$ . Para tal, assume-se que  $x(t)$  é o caminho de um ponto na interface sendo propagada, ou seja,  $x(t = 0)$  é um ponto de  $\Gamma(t = 0)$  e  $x'(t) \cdot n = F(x(t))$ , em que  $x'(t)$  é o vetor normal à interface em  $x(t)$  e  $n = \nabla\phi / |\nabla\phi|$ . A exigência de que o nível zero da função  $\phi$  deva corresponder à hiper superfície significa que (SETHIAN, 1999):

$$\phi(x(t), t) = 0. \quad (30)$$

Pela regra da cadeia:

$$\phi_t + \nabla\phi(x(t), t) \cdot x'(t) = 0. \quad (31)$$

Como  $F$  fornece a velocidade na direção normal externa, então  $x'(t) \cdot n = F$ . Obtem-se, assim, uma equação de evolução para  $\phi$ , isto é

$$\phi_t + F|\nabla\phi| = 0, \quad (32)$$

dado  $\phi(x, t = 0)$  (SETHIAN, 1999).

Ao inspecionar a Equação 32, constata-se que ela está na forma de uma lei de con-

servação hiperbólica (NAPOLITANO, 2004). Dependendo da forma de  $F$ , esta é uma equação Hamilton-Jacobi padrão.

Outra característica desejável do método *Level Set* está relacionada aos cálculos numéricos que podem ser realizados em uma grade cartesiana fixa sem a necessidade de parametrizar os pontos sobre o contorno, como em modelos de contornos ativos paramétricos. Como a função  $\phi(x, t)$  mantém o comportamento da curva suave e homogêneo,  $\Gamma(t)$  pode mudar sua topologia no processo de propagação. Tal fato permite que simulações numéricas possam ser desenvolvidas utilizando uma malha discreta no domínio de  $x$ , havendo substituição para derivadas espaciais e temporais. É possível discretizar a Equação 32 por uma aproximação em diferenças finitas progressivas no tempo e então obter (NAPOLITANO, 2004)(SETHIAN, 1999):

$$\frac{\phi_{i,j}^{n+1} - \phi_{i,j}^n}{\Delta t} + F|\nabla_{i,j}\phi_{i,j}^n| = 0. \quad (33)$$

em que  $|\nabla_{i,j}\phi_{i,j}^n|$  representa algum operador de diferenças finitas apropriado para a derivada espacial.

Em princípio, o problema poderia ser solucionado calculando-se  $\phi_{i,j}^{n+1}$  para cada ponto da malha em função de aproximações em diferenças finitas para a derivada espacial de  $\phi$ . Contudo, esta ideia resulta em instabilidades numéricas, fazendo com que o comportamento da curva torne-se não suave no decorrer do processo iterativo. Entretanto, se forem utilizados esquemas hiperbólicos, tais instabilidades são consideravelmente minimizadas e o comportamento da curva estudada permanece suave e homogêneo (NAPOLITANO, 2004).

Pode-se também destacar como vantagens da abordagem *Level Set*, a facilidade de extensão para dimensões maiores e a determinação das propriedades geométricas intrínsecas da interface a partir da função  $\phi$ . Diferentemente da abordagem por contornos ativos tradicionais, os contornos representados pela função *Level Set* podem “quebrar-se” ou “unir-se” durante a evolução, o que permite a manipulação automática nas possíveis mudanças topológicas, frequentemente observadas em problemas de segmentação de imagens em situações práticas.

### 3.2.3.2 MÉTODO *LEVEL SET* - FORMULAÇÃO VARIACIONAL

Na formulação *Level Set* tradicional podem ocasionalmente surgir discontinuidades (*shocks*) no decorrer da evolução da função  $\phi$ , conduzindo a erros em cálculos posteriores. Para evitar tais problemas, esta função precisa ser reinicializada periodicamente. Um esquema numérico comum é usado para inicializar a função  $\phi$  como uma função de distância sinalizada antes da evolução, e então “reformular” (ou “reinicializar”) a função  $\phi$  para se tornar uma

função de distância sinalizada periodicamente durante a evolução.

O processo de reinicialização tem sido utilizado a fim de manter a evolução da curva estável, possibilitando a obtenção de melhores resultados. Porém, do ponto de vista prático, a reinicialização aumenta o custo computacional e gera problemas adicionais que podem surgir a cada reinicialização, como a definição de quando e como fazê-la além de afetar a precisão numérica de forma indesejável. Neste sentido, a formulação do *Level Set* variacional é uma abordagem alternativa implementada pelo esquema de diferenças finitas, sem a necessidade de reinicialização.

A fim de manter a evolução da função *Level Set* como uma função de distância sinalizada, especialmente ao redor do nível zero, a função de distância sinalizada deve satisfazer a propriedade de  $|\nabla\phi| = 1$ . Por outro lado, qualquer função  $\phi$  que satisfaça  $|\nabla\phi| = 1$  corresponde a uma função de distância sinalizada somada a uma constante (LI CHENYANG XU; FOX, 2005)<sup>1</sup>. Para tanto, é definida a seguinte integral:

$$P(\phi) = \int_{\Omega} \frac{1}{2} (|\nabla\phi| - 1)^2 dx dy \quad (34)$$

como uma métrica para caracterizar o quão perto uma função  $\phi$  esta da função da distância sinalizada em  $\Omega \subset \mathbb{R}^2$ . Li e colaboradores (LI CHENYANG XU; FOX, 2005) propõem a seguinte formulação variacional:

$$\varepsilon(\phi) = \mu P(\phi) + \varepsilon_m(\phi) \quad (35)$$

em que  $\mu > 0$  é uma ponderação que penaliza o desvio de  $(\phi)$  a partir de uma função de distância sinalizada e  $\varepsilon_m(\phi)$  é a energia que irá conduzir o movimento da curva do nível zero de  $\phi$ .

Denota-se por  $\frac{\partial \varepsilon}{\partial \phi}$  a derivada de Gâteaux (ou primeira variante) do funcional  $\varepsilon$ , e a seguinte equação de evolução:

$$\frac{\partial \phi}{\partial t} = - \frac{\partial \varepsilon}{\partial \phi} \quad (36)$$

é o fluxo do gradiente que minimiza o funcional  $\varepsilon$ . Para um funcional  $\varepsilon(\phi)$  particular definida explicitamente em termos de  $\phi$ , a derivada de Gâteaux pode ser calculada e expressa em termos da função  $\phi$  e suas derivadas.

A formulação variacional da Equação 35 é aplicada para segmentação de imagens por contornos ativos, de modo que a curva de nível zero de  $\phi$  possa evoluir para as características desejadas em uma imagem. Para este fim, a energia  $\varepsilon_m$  é definida como um funcional que

---

<sup>1</sup>Esta constante é considerada igual a 0 na superfície.



depende dos dados da imagem, e, portanto, é denominada *energia externa*. Analogamente, a energia  $P(\phi)$  é denominada *energia interna* da função  $\phi$ .

Durante a evolução de  $\phi$ , a curva de nível zero será movida pela energia externa  $\epsilon_m$ . Entretanto, devido ao efeito de penalizar a energia interna, a evolução da função  $\phi$  será mantida automaticamente como uma aproximação da função de distância sinalizada durante a evolução. Portanto, o procedimento de reinicialização é completamente eliminado. Devido a estas vantagens, este método foi considerado nos testes experimentais realizados neste trabalho (foi utilizado o código-fonte disponibilizado por (LI CHENYANG XU; FOX, 2005)).

### 3.2.3.3 SEGMENTAÇÃO DE IMAGENS UTILIZANDO MÉTODOS *LEVEL SET*: UMA VISÃO INTUITIVA

O papel do método *Level Set* em aplicações de processamento de imagens está usualmente relacionado a técnicas de equações diferenciais parciais envolvendo uma ou mais das seguintes características: (a) representação de uma imagem como uma função amostrada em um dada malha, cujos valores correspondem à intensidade do pixel em um espaço de cores específico; (b) regularização de soluções; (c) representação de bordas e (d) desenvolvimento de métodos numéricos (TSAI; OSHER, 2003). No contexto deste trabalho, o foco é a aplicação do método para fins de segmentação.

Para que as curvas se movam em direção às bordas do objeto de interesse sem ultrapassá-las, será introduzido o seguinte termo:

$$g_I(x,y) = \frac{1}{1 + |\nabla(G_\sigma * I(x,y))|} \quad (37)$$

em que a expressão  $G_\sigma * I$  denota a convolução da imagem  $I$  com um núcleo Gaussiano com desvio padrão  $\sigma$ . O termo  $\nabla(G_\sigma * I(x,y))$  é essencialmente zero, exceto próximo a variações significativas do gradiente, as quais tipicamente correspondem às bordas da imagem. Desse modo, o filtro  $g_I(x,y)$  aproxima-se de um fora das bordas e tende a zero próximo a elas (SETHIAN, 1999).

Considere uma função de velocidade da forma  $F = \pm 1 - \epsilon \kappa$ , em que  $\epsilon$  é uma constante que atua como um termo de advecção (OSHER; FEDKIW, 2003) e  $\kappa$  um termo baseado na curvatura. Observe que, se  $F$  for multiplicada pelo termo definido pela Equação 37 acima, ocorrerá um retardamento da evolução do fluxo através das bordas.

O algoritmo básico é descrito a seguir:

Tal abordagem tem diferentes aspectos desejáveis, tais como a possibilidade de utiliza-

---


**Quadro 1:** Algoritmo para segmentação de imagens.
 

---

- 1: dada uma nova imagem de entrada  $I$ ;
  - 2: posicionar o marcador (ou curva inicial) fora ou dentro da região a ser segmentada
  - 3: evolui de forma a parar nas bordas, caso em que o termo  $g_I$  reduz a função de velocidade de  $F$  para próximo de zero.
- 

ção de mais de um marcador inicial (devido às propriedades topológicas do método *Level Set*, as regiões definidas por tais marcadores irão se fundir), a facilidade de extensão para extrair formas tri-dimensionais e a baixa sensibilidade a ruídos.


A Figura 15 ilustra resultados da segmentação utilizando a abordagem proposta em (LI CHENYANG XU; FOX, 2005) para diferentes números de iterações.



**Figura 15:** Segmentação do núcleo de células brancas do sangue, para diferentes números de iterações

Fonte: Autoria própria

Outro exemplo, que envolve o problema de segmentar células microscópicas, é ilustrado na Figura 16. Note que o marcador é inicializado na parte de fora da região de interesse e separam-se corretamente para englobar os dois objetos de interesse.



**Figura 16:** Ilustração da Segmentação por método *Level Set* (LI CHENYANG XU; FOX, 2005): (a) imagem original e marcador inicializado, (b) evolução da segmentação e (c) resultado da segmentação

Fonte: Autoria própria

### 3.2.3.4 MODELO DE FORMA ATIVA (*ACTIVE SHAPE MODEL* - ASM)

O processo de segmentação de imagens não é uma tarefa simples, principalmente devido à presença de ruídos na imagem, dificuldades de iluminação e até mesmo a oclusão de parte do objeto de interesse. A inclusão do conhecimento prévio sobre a forma do objeto que se deseja segmentar vem agregar uma informação importante, nestes casos. Em imagens cujos objetos de interesse estão oclusos ou sobrepostos, por exemplo, os valores das intensidades dos níveis de cinza são similares entre esses objetos, comprometendo desta forma a segmentação baseada em técnicas de intensidade.

Os primeiros trabalhos que apresentam o conhecimento prévio sobre a forma do objeto e contornos ativos foram introduzidos pelo Modelo de Forma Ativa (*Active Shape Models* - ASM (COOTES et al., 1995)) e pelo Modelo de Aparência (COOTES et al., 2001) e proporcionaram um grande avanço nas abordagens de segmentação. Para tanto, cria-se um modelo estatístico da forma dos objetos que se deformam iterativamente a fim de atender a um exemplo do objeto em uma nova imagem. As formas são limitadas pelo modelo de distribuição de pontos (*Point Distribution Models* - PDM (COOTES et al., 1995)). O PDM é um modelo que representa a geometria média de uma forma e algumas formas estatísticas da variação geométrica inferida a partir de um conjunto de formas de treinamento. Este trabalho utiliza o PDM para definição do formato médio das bolhas de gás no padrão golfada e nos demais experimentos realizados.

### 3.2.3.5 MODELO DE DISTRIBUIÇÃO DE PONTOS - PDM

No PDM, a forma média do objeto alvo é extraída de modelos estatísticos do seu formato e de sua aparência. Para tanto, é necessário à definição deste modelo por meio do treinamento do conjunto de imagens com diferentes representações do objeto alvo.

O objeto contido nas imagens é marcado individual e manualmente por um especialista por meio da definição de pontos chaves. O PDM faz uma análise das variações no formato e na aparência dos pontos marcados sobre o objeto ao longo do conjunto de treinamento, para então, construir um modelo único que é capaz de descrever corretamente o objeto.

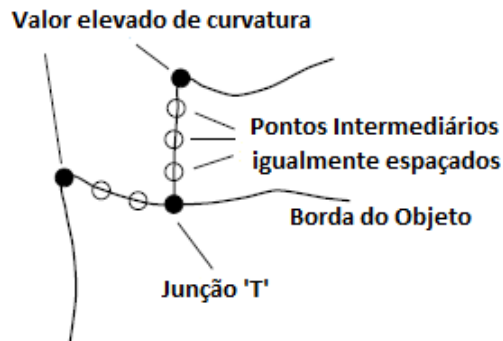
A ideia básica é construir o modelo da aparência do objeto por meio do conjunto de imagens de exemplo deste objeto, os quais serão anotados (ponto a ponto) como exemplos típicos. Os pontos anotados são então representados por coordenadas  $x$  e  $y$  da imagem  $2D$ . É fundamental definir um conjunto adequado de pontos de referência que descrevem a forma do objeto alvo, e que podem ser encontrados em todas as imagens de treinamento (COOTES et al.,

2000). A construção deste modelo é executada da seguinte forma:

1. Rotulação do conjunto de treinamento;
2. Alinhamento do conjunto de treinamento;
3. Estudo das variações admissíveis;
4. Escolha do número de modos de variação para representar o objeto alvo.

A rotulação no conjunto de treinamento deve ser definida de forma plausível sobre todos os objetos do conjunto, de forma que os pontos chaves sejam colocados na mesma posição em cada objeto (Figura 18 (a)).

Boas opções para os pontos chaves são nos locais que melhor descrevem o objeto tais como cantos, junções 'T', pontos de valor elevado de curvatura. Entretanto, tais pontos costumam não representar significativamente o objeto, então se aumenta o número de pontos incluindo os pontos ao redor da borda do objeto alvo, conforme ilustrado na Figura 17.



**Figura 17: Bons pontos chaves são pontos de valor elevado de curvatura ou junções. Os pontos intermediários podem ser usados para definir as bordas mais precisamente**

Fonte: Adaptado de (COOTES et al., 2000)

Os pontos chaves definidos em cada imagem do conjunto de treinamento devem ser comparados a fim de localizar os pontos equivalentes para posterior alinhamento destes pontos. Neste caso, inicialmente é necessário estabelecer as correspondências entre os objetos e guardar suas coordenadas para cada objeto em um vetor:

$$x_i = (x_{i0}, y_{i0}, \dots, x_{ik}, y_{ik}, \dots, x_{in-1}, y_{in-1}) \quad (38)$$

em que  $i = 1 \dots N_s$  com  $N$  representando o número de objetos e  $n$  o número de pontos chave, que deve ser o mesmo para cada objeto no conjunto de treinamento. Se existem  $s$  exemplos de treinamento, serão gerados  $s$  vetores  $x_j$ . Para a análise estatística sobre estes vetores, é importante que a representação das formas esteja no mesmo quadro de coordenadas. Pois, a forma de um objeto é considerada independente da posição, orientação e escala. A abordagem translada, gira e dimensiona cada forma de modo que a soma das distâncias de cada forma média ( $D = \sum |x_i - \bar{x}|^2$ ) seja mínimo.

Se houver  $s$  conjuntos de pontos  $x_i$  alinhados em um quadro de coordenadas comuns, forma-se então uma distribuição no espaço  $2n$  dimensional. Ao modelar esta distribuição é possível gerar novos exemplos e, ao examinar novas formas, verificar se pertencem aos exemplos plausíveis.

O estudo das variações admissíveis, isto é, as formas segundo as quais os pontos tendem a mover-se, é realizado aplicando uma Análise de Componentes Principais - (*Principal Component Analysis* - PCA) aos desvios da média (Figura 18 (b)).

Ao aplicar PCA aos dados, aproxima-se a formação de qualquer conjunto usando  $x$  da seguinte forma ((COOTES et al., 2000)):

$$x \approx \bar{x} + Pb \quad (39)$$

em que  $P = (p_1 | p_2 | \dots | p_t)$  contém os  $t$  autovetores da matriz de covariância e  $b$  é um vetor dimensional  $t$  dado por:

$$b = P^T (x - \bar{x}) \quad (40)$$

O vetor  $b$  define o conjunto de parâmetros do modelo deformável, variando os elementos de  $b$  pode-se variar a forma, por meio da Equação 39.

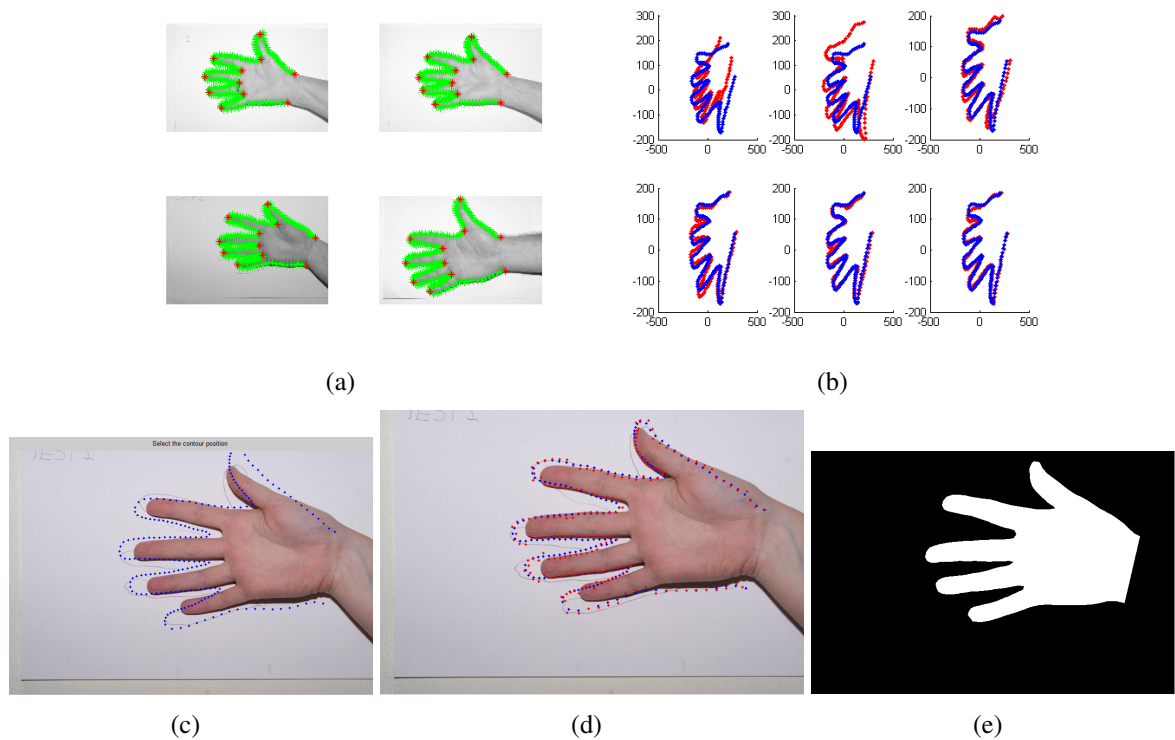
A variação do  $i^{th}$  parâmetro,  $b_i$ , em todo o conjunto de treinamento é dado por  $\lambda_i$ . Aos limites previstos de  $\pm 3\sqrt{\lambda_i}$  o parâmetro  $b_i$  irá garantir que a forma é semelhante à gerada pelo conjunto de treinamento inicial.

A variação correspondente ao modelo para o  $i^{th}$  parâmetro,  $b_i$ , é chamado de  $i^{th}$  forma do modelo. Os auto vetores,  $P$ , definem um quadro de coordenadas rotacionadas, alinhadas com a nuvem de vetores da forma original. O vetor  $B$  define pontos neste quadro rotacionado.

A escolha do número de modos de variação  $t$  para representar o objeto alvo, que se

deseja guardar, pode ser definido de diversas maneiras (COOTES et al., 1995; HAMARNEH, 1998), de acordo com a aplicação em que o modelo será utilizado.

Definida a forma média é possível utilizá-la para localizar uma instância de um objeto em uma nova imagem. A ideia básica é iniciar o processo com uma estimativa inicial, definida manualmente (Figura 18 (c)), em seguida, examinar os vizinhos dos pontos chaves em relação a estimativa da forma e encontrar as melhores localizações dos pontos chaves. Então, mudar a forma e a posição da estimativa (Figura 18 (d)) para melhor atender as novas localizações dos pontos chaves enquanto produz no processo, uma nova forma aceitável ou permitida (Figura 18 (e)). O fato de que as formas são modeladas de modo que só possam variar de uma forma controlada (restringindo os pesos dos componentes principais) explica por que tais modelos são nomeados modelos de forma ativas.



**Figura 18: Segmentação por ASM: (a) Marcação dos pontos chaves, (b) Variações admissíveis, (c) Estimativa inicial, (d) Estimativa da nova posição e (e) Segmentação final**

**Fonte: Adaptado de (COOTES et al., 1995)**

Para a modelagem da forma padrão pelo PDM, aqui considerada, é calculada a avaliação estatística das coordenadas fornecidas pelos pontos de treinamento. Para uma possível comparação entre séries de pontos ou vetores equivalentes de imagens diferentes, os pontos que descrevem a forma do objeto são alinhados em relação a um grupo de eixos de coordenadas.

A etapa de alinhamento dos pontos é um pré-requisito para que se obtenham os valores estatísticos que descrevem a forma padrão. Ao alinhar e sobrepor todos os pontos marcados ao lado do modelo padrão médio, observa-se a superposição de pontos equivalentes assim como a formação de nuvens com pontos difusos, como estas marcações de referência são parcialmente correlacionadas, e não se movem independentemente, o PDM busca um padrão de variação das coordenadas dentro desta zona de pontos difusos ou nuvens (COOTES et al., 1995).

Basicamente, o método PDM define a nuvem de pontos como um domínio permitido para formações. Essas nuvens são elipsoides obtidos usando uma transformação ortogonal de PCA e elas fornecerão um modelo variável de coordenadas, ou regiões, em que uma movimentação dos pontos da forma é permitida, quando comparada com a forma padrão.

O desempenho do modelo estatístico é influenciado pelo tamanho do conjunto de dados de treinamento e pela complexidade da variação anatômica observada do objeto de interesse (TOMOSHIGE et al., 2014). Neste trabalho, os modelos estatísticos obtidos pelo conjunto de treinamento das imagens de escoamento refletem o formato médio do padrão em golfada, entretanto, para imagens da parte traseira da bolha de gás, a variação do conjunto de treinamento devido à presença de bolhas dispersas no rastro da bolha em golfada, pode influenciar no desempenho do modelo. Mais detalhes serão tratados no Capítulo 5.

O principal problema em relação ao modelo de forma ativa está relacionado à necessidade de informações iniciais sobre o contorno a ser segmentado, ou seja, esta informação é fornecida de forma direta pelo usuário do sistema manualmente. Além disso, apresentam dificuldades em aproximar-se dos contornos dos objetos com concavidades, uma vez que as forças externas envolvidas são horizontais, deslocando o contorno verticalmente, mas não progredindo adequadamente para a concavidade (GONÇALVES et al., 2008).

Na próxima seção uma revisão de literatura dos principais métodos de segmentação por *Level Set* sem ou com conhecimento a priori da forma, necessários para embasar esta pesquisa serão descritos de forma resumida.

### 3.3 TRABALHOS RELACIONADOS

Após o desenvolvimento do método *Level Set* em 1988 por Osher e colaboradores (OSHER; SETHIAN, 1988), várias subáreas vem sendo exploradas a fim de otimizar a sua aplicação, dentre elas mecânica dos fluidos, ciência dos materiais e mais especificamente, no escopo deste trabalho, segmentação de imagens.

Neste sentido, é possível estabelecer a seguinte divisão do método *Level Set* aplicado

ao problema de segmentação de imagens:

### 3.3.1 PROPRIEDADES LOCAIS

No método *Level Set* tradicional (OSHER; SETHIAN, 1988), a evolução da curva de nível zero é forçada a manter-se próxima a função de distância sinalizada, a fim de conservar sua evolução estável. Um esquema numérico é usado para reinicializar a função  $\phi$  para se tornar uma função de distância sinalizada antes da evolução, e então reformular a função  $\phi$  para se tornar uma função distância sinalizada periodicamente durante a evolução. Entretanto, este processo pode aumentar o custo computacional entre outros problemas mencionados na Seção 3.2.3.2.

Neste sentido, Li e colaboradores (LI CHENYANG XU; FOX, 2005) introduzem um termo de energia que é capaz de direcionar a evolução da curva de nível zero do *Level Set* às características da imagem e ainda assim manter a evolução da curva estável, eliminando o processo de reinicialização. Durante a evolução de  $\phi$ , a curva de nível zero será movida pela energia externa  $\varepsilon_m$  a qual é definida como uma função que depende dos dados da imagem, como as propriedades locais do gradiente por exemplo. O direcionamento da curva em direção às bordas do objeto é obtido utilizando-se as informações do gradiente da imagem, caso em que a função velocidade  $F$  encontra variações significativas, tipicamente um fora das bordas e zero próximo a elas, reduzindo e finalizando o processo de evolução.

O trabalho anteriormente desenvolvido por (DORINI et al., 2011) utiliza a técnica de Li e colaboradores nas imagens do escoamento bifásico. Como marcador inicial, técnicas de morfologia matemática extraem o gradiente da imagem e geram a curva inicial que conduzirá a evolução da função  $\phi$ . O trabalho, portanto, utiliza informações locais para iniciar a curva de *Level Set* no processo de segmentação. Neste caso, não há inclusão de informação prévia sobre o objeto que se deseja segmentar, deste modo pôde-se constatar a dificuldade em segmentar imagens com problemas de oclusão, como é o caso de algumas imagens do escoamento.

No trabalho de (LANKTON; TANNENBAUM, 2008) é proposta uma estrutura para segmentação baseada em região utilizando estatísticas locais da imagem ao invés de globais. O contorno evolui com base em informações locais. Neste caso, os autores permitem que o primeiro plano e o fundo sejam descritos em termos de regiões locais menores. Então, supõem que a remoção das regiões de primeiro plano e do fundo pode ser representada com estatísticas globais. A análise das regiões locais leva à construção de uma família de energias locais em cada ponto ao longo da curva. Para otimizar estas energias locais, cada ponto é considerado separadamente, e move-se para minimizar (ou maximizar) a energia, calculada em sua própria



região local. Para o cálculo das energias locais, vizinhos locais são divididos em local interior e exterior da curva em evolução. Uma limitação do método proposto refere-se a uma maior sensibilidade à inicialização do que os métodos baseados em região global.

Também baseado em região, um novo modelo de contorno ativo foi proposto por (ZHANG et al., 2010) e implementado com um processamento especial denominado *Selective Binary* e método *Level Set* com Filtro Gaussiano regularizado. Inicialmente, a função *Level Set* é seletivamente penalizada por ser binária, e então usa uma suavização baseada em *kernel* Gaussiana para regularizá-la. O contorno inicial é inserido em qualquer lugar, porém se a evolução baseia-se no gradiente da imagem pode resultar em região segmentada maior do que o necessário.

### 3.3.2 CONHECIMENTO A PRIORI DA FORMA

Mesmo não sendo desenvolvido para inserir a informação da forma do objeto a priori, o método *Level Set* - MLS vem sendo aplicado neste tipo de abordagem por diversos autores (CREMERS et al., 2001; BURGER et al., 2004; TSAI et al., 2001; CHEN et al., 2001; LEVENTON et al., 2000; ROUSSON; PARAGIOS, 2002). O principal objetivo é conduzir a evolução da curva do *Level Set* o mais próximo possível das deformações do objeto em relação ao conjunto de dados de treinamento de modo a limitar, durante o processo de segmentação, a evolução da função *Level Set* com base no conjunto predefinido de formas.

Alguns desafios são frequentemente enfrentados pelos pesquisadores em relação a deformação e evolução da curva de nível zero com o uso da forma do objeto, tais como, a decisão sobre o uso ou não da restrição imposta pela forma ou o limite desta restrição. Neste caso, a curva inicial irá evoluir em função da forma, ocasionando uma imposição no direcionamento da curva. Além disso, outros desafios se relacionam com a ausência de partes do objeto ou oclusão do mesmo, bem como o custo computacional já presente neste tipo de segmentação. A seguir, é apresentada uma síntese das principais técnicas aplicadas a junção conhecimento a priori e método *Level Set*.

#### 3.3.2.1 MÉTODOS BASEADOS EM MODELOS ESTATÍSTICOS

A primeira combinação do uso a priori da forma e segmentação por *Level Set* foi desenvolvida por Leventon e colaboradores em 2000 (LEVENTON et al., 2000) que incorpora a informação da forma no processo de evolução da curva. Os autores propõem realizar uma análise de componentes principais (*Principal Component Analysis*- PCA) em um conjunto de

mapas de distância sinalizada incorporado ao conjunto de treinamento das formas. Primeiro, calcula-se um modelo estatístico para a forma ao longo de um conjunto de treinamento de curvas. Para segmentar a estrutura a partir de uma imagem, evolui o contorno ativo tanto localmente, com base no gradiente da imagem e na curvatura, como globalmente por meio de uma estimativa do máximo a posteriori da forma e da pose. Os autores modelam a representação do *Level Set* das formas do objeto como uma distribuição Gaussiana.

Tsai e colaboradores (TSAI et al., 2001) propõem uma implementação do *Level Set* orientado pela forma por meio de uma otimização direta no subespaço linear, para segmentar a glândula da próstata em imagens médicas. O algoritmo é dividido em duas partes, a fase de treinamento que consiste no alinhamento da forma e na modelagem paramétrica da forma. Mapas de distância sinalizada são gerados para representar cada uma das formas alinhadas da base de dados. Através da aplicação de PCA nessa coleção de mapas de distância, obtém-se a forma média e as formas próprias (*eigenshapes*) particulares desse banco de dados de formas. A forma média e as formas próprias são usadas para formar uma representação paramétrica implícita da forma. A fase de segmentação irá envolver o cálculo dos parâmetros da representação da forma implícita (pesos para as *eigenshapes* e variações da pose), para minimizar uma segmentação funcional. Esta minimização é realizada por meio de um processo iterativo usando um algoritmo de gradiente descendente. A cada passo do algoritmo há uma atualização dos parâmetros da representação da forma implícita para gerar um novo *Level Set*, a segmentação da curva é implicitamente determinada por este novo *Level Set*. Com base na nova posição e forma da curva, são recalculadas as estatísticas da imagem dentro e fora da curva. Um esquema iterativo é repetido até que a convergência seja alcançada para a segmentação. A inicialização da superfície de segmentação é feita no interior da glândula da próstata, de modo que a evolução da superfície não se desvie para os vários outros gradientes que são característicos das outras partes localizadas em torno da próstata. Entretanto, conforme observado pelos autores (TSAI et al., 2003) as funções de distância não são fechadas sobre operações lineares, a representação *Level Set* da curva de segmentação, com base na abordagem PCA, não é uma função de distância. Isto dá origem a uma estrutura para modelagem da forma inconsistente, sendo, portanto, um problema importante e desafiador encontrado pelos autores.

Um modelo estatístico para a forma que combina métodos PCA e modelo de formas não paramétricos foi proposto por Cremers e Rousson (ROUSSON; CREMERS, 2005). A ideia é realizar uma estimativa da densidade do núcleo em um subespaço linear que seja grande o suficiente para incorporar todos os dados de treinamento. Os autores propõem ainda estimar a posição e os parâmetros de translação mais orientada aos dados da forma. Além disso, exploram informações das intensidades da imagem usando modelos probabilísticos sobre as intensidades

dos dados, por meio de estimativas das intensidades previamente observadas.

(CREMERS et al., 2007) elaboram uma revisão das principais abordagens de segmentação por *Level Set* e que apresentam o uso da PCA para modelar as distribuições da forma com duas limitações: primeiro, o espaço das funções de distância sinalizada não é um espaço linear, as combinações lineares em geral, não correspondem a uma função de distância sinalizada. Segundo, enquanto alguns dos componentes principais capturam a maior variação no espaço de funções incorporadas, eles não irão necessariamente capturar a variação no espaço dos contornos incorporados. Como consequência, pode haver necessidade de incluir um maior número de modos próprios, a fim de capturar certos detalhes da forma modelada.

A abordagem de (YANG et al., 2013a) apresenta uma nova restrição no espaço-temporal baseado em forma e aparência e combina esta restrição ao método *Level Set* para segmentar imagens de um ventrículo esquerdo, particularmente na presença de defeitos de perfusão. O modelo incorpora a informação de aparência e forma em uma restrição probabilística e utiliza regularização espaço-temporal por meio de um esquema de máximo a posteriori. A restrição proposta faz uso de um conhecimento a priori da forma, o aspecto e a sua correlação, bem como as variações espaço-temporal do objeto em estudo.

Um novo método *Level Set* baseado em forma probabilística, geométrico e dinâmico é proposto em (ASLAN et al., 2014). A forma prévia é acoplada com a informação de intensidade para melhorar os resultados da segmentação. A análise de componentes principais bidimensionais (2D-PCA) é aplicada sobre as formas de treinamento para representar a variação da forma com um número suficiente de projeções da forma na etapa de formação. O modelo de forma é construído usando a representação implícita das formas projetadas. Uma nova energia funcional é proposta para incorporar o modelo de forma no domínio da imagem e para estimar os coeficientes de forma. O processo de segmentação começa por inicializar a função *Level Set* como uma função distância sinalizada de um círculo centrado em um ponto. A semente é colocada automaticamente usando filtros de correlação (KUMAR et al., 2006) ou com anotação manual, com bons resultados na segmentação final.

### 3.3.2.2 MÉTODOS POR FUNÇÕES DE BASE RADIAL

Uma função de base radial (*radial basis functions* - RBF) é uma função sobre números reais cujos valores dependem apenas da distância a partir da origem. RBFs são populares na interpolação de dados dispersos a fim de produzir superfícies/bordas suaves, como no sistema associado de equações não lineares. As interpolações baseadas em funções de base radial mostram-se eficazes quando as funções que devem ser aproximadas são de múltiplas variáveis,

ou são dadas apenas por uma grande quantidade de dados ou dados dispersos. Em aplicações do mundo real, técnicas de função de base radial tornaram-se úteis aplicadas em reconhecimento de padrões, inteligência artificial, ou para simplesmente resolver equações diferenciais parciais - EDP sobre distribuições de dados irregulares.

Uma RBF aplicada ao método *Level Set* é utilizada a fim de transformar a equação EDP de Hamilton-Jacobi, em um sistema de equações diferenciais ordinárias de primeira ordem, sobre todo o domínio  $D$ . Com isso, busca-se resolver problemas de otimização de topologias utilizando os métodos *Level Set* de forma eficiente com considerável proveito matemático (LUO et al., 2009).

Neste sentido, (GELAS et al., 2007) apresentam uma proposta de aplicação de RBFs para resolução matemática do método *Level Set*. A equação diferencial parcial dirige a evolução do *Level Set* na segmentação e é normalmente resolvida usando esquemas de diferenças finitas. Os autores propõe um esquema alternativo com base no método de colocação usando RBF. O método de colocação pode ser visto como um caso especial do método residual para o cálculo de uma solução numérica para uma PDE. Consiste em aproximar a solução por uma função contínua, que é, por sua vez, construída com uma combinação linear de funções de base. A solução, ou seja, os parâmetros da dilatação linear, são obtidos pela prescrição da PDE a fim de verificar um determinado conjunto de pontos, normalmente chamados de pontos de colocação. Esta abordagem fornece uma representação contínua tanto para função implícita quanto para seu nível zero. A inicialização neste trabalho é feita a partir de uma semente inserida dentro do objeto.

No trabalho de (MORSE et al., 2005) é apresentada uma nova abordagem para o método de contorno ativo implícito baseada em restrições, compartilhando propriedades de ambos contornos ativos paramétricos e implícitos. O artigo propõe uma nova forma para representação implícita do contorno que usa restrições de ponto base para definir e controlar a curva ou superfície, por meio de RBFs. O contorno ativo é inicializado com base em uma estimativa inicial da forma e da posição do objeto. Esta inicialização pode basear-se num atlas anatômico, nos resultados de segmentação de uma fatia ou quadro prévio, ou simplesmente em um ponto de partida padrão, como um círculo simples. Os autores utilizam uma série de valores de restrição-zero ao longo da curva inicial, bem como, ao longo da fronteira da imagem diferentes valores de restrições-não zero para definir o exterior do objeto. No entanto, o método requer uma representação dinâmica com inserções e deleções dos pontos de referência o que não é uma tarefa trivial, a resolução dos pontos de referência podem afetar a precisão da representação do contorno.

Uma proposta interessante é observada no trabalho de (XIE; MIRMEHDI, 2011) que apresentam uma representação *Level Set* com a evolução também por RBFs. Os autores interpolam a função distância inicial usando RBF, que oferecem uma modelagem no espaço dimensional elevado. Sua deformação é considerada como uma atualização das interpolações por RBF que conforme mencionado anteriormente é um problema de equação diferencial ordinária (ODE), em vez de um problema de equação diferencial parcial (PDE), e, portanto, torna-se mais simples de resolver. A re-inicialização torna-se desnecessária, em contraste com os métodos de diferenças finitas (FDM) que são a base do *Level Set* tradicional. A curva inicial é inserida fora do objeto de interesse e uma força externa que é derivada da modelagem por cor usando a múltipla escala *Texem*, força a desaceleração da evolução da curva. Como se pode observar pelos resultados apresentados nesse trabalho, a inicialização fora do objeto e a evolução estão diretamente ligadas às diferenças nas cores e texturas dos diferentes objetos da cena.

### 3.3.2.3 MÉTODOS PARA SEGMENTAR MÚLTIPLOS OBJETOS

O método *Level Set* pode ser aplicado na segmentação de múltiplos objetos, uma vez que o mesmo é capaz de tratar eficazmente descontinuidades bem como, permite a inserção de mais de uma curva inicial. Como é o caso do trabalho de (BRESSION et al., 2006) que propõem a adição de um termo funcional como extensão do trabalho de Chen e colegas (CHEN et al., 2002) e integram com o modelo de forma de Leventon e colaboradores (LEVENTON et al., 2000), além da função de Mumford-Shah (MUMFORD; SHAH, 1989; VESE; CHAN, 2002)). No entanto, esse modelo funciona bem apenas quando a função densidade probabilidade (PDF) do conjunto de treinamento do objeto de interesse é gaussiana, caso contrário, modelos não paramétricos devem ser utilizados. Seguindo o mesmo princípio, Thiruvenkadam e colaboradores (THIRUVENKADAM et al., 2007) usaram uma segmentação para resolver o problema com profundidade, ou seja, estimar os limites, as intensidades e a ordem espacial dos objetos. Para tanto, é desenvolvido uma função de energia complexa, possibilitando a segmentação de múltiplos objetos.

Também com proposta de segmentar vários objetos, (CHANG et al., 2008) implementam uma solução iterativa com os modelos de forma a priori dentro de um *framework* bayesiano. A abordagem inicialmente formula o problema de segmentação em um *framework* bayesiano bem definido, com várias formas a priori. Então estima os parâmetros do modelo bayesiano para finalmente segmentar os múltiplos objetos através das formas especificadas manualmente pelo usuário.

### 3.3.2.4 MÉTODOS COM INCLUSÃO DE FUNÇÕES DE ENERGIA

Chen e colaboradores em 2002 implementam um *framework* variacional para incorporação do conhecimento prévio e contorno ativo. Os autores utilizam uma nova função de energia do contorno dependente do gradiente da imagem, bem como da forma prévia. A ideia-chave do algoritmo é a criação de um termo de energia no contorno ativo, ou seja, insere-se a informação da forma no cruzamento zero em vez de sobre a função *Level Set*. Neste caso, incorpora-se um termo explícito que mede a similaridade da forma entre a curva e a forma prévia que é modelada pela função distância (CHEN et al., 2002).

(BRESSION et al., 2003) implementam uma função de energia para segmentação dos objetos cuja forma global é conhecida a priori utilizando um modelo estatístico. Neste trabalho há um aprofundamento da abordagem variacional de Chen e colaboradores (CHEN et al., 2002), integrando o modelo estatístico da forma de Leventon e colaboradores (LEVENTON et al., 2000). Neste caso, a minimização de um funcional que proporcionará um sistema de equações acopladas, cuja solução no estado estacionário é a solução do problema de segmentação. Este funcional é minimizado quando o contorno ativo geodésico (que define a velocidade da deformação através da energia de uma funcional baseada na equação de Euler-Lagrangeana) e a curva são incorporadas numa função *Level Set*. O funcional permite captar um objeto que exibe gradientes elevados e uma forma compatível com o modelo estatístico que melhor se aproxima do objeto a ser segmentado.

Em (ROUSSON; PARAGIOS, 2002) é apresentada uma formulação matemática para restringir uma superfície implícita para seguir as conformidades da forma global, preservando sua capacidade de capturar deformações locais. O modelo da forma é construído diretamente sobre o espaço *Level Set* usando uma coleção de amostras. Este modelo é utilizado como base para introduzir a forma a priori como um termo de energia. O contorno em evolução é deformado globalmente para atender à imagem de acordo com o critério de segmentação.

Recentemente, Diop e Burdin (DIOP; BURDIN, 2013) combinam técnicas de Mumford-Shah e contornos ativos com conhecimento prévio da forma. A informação da forma prévia é definida por um termo de energia e é incorporado na evolução do *Level Set*. Então outro termo de função de energia impulsiona o *Level Set* para os limites do objeto alvo. Finalmente, um último termo é inserido baseado na função de Mumford-Shah.

(LECELLIER et al., 2014) elaboram uma breve pesquisa sobre abordagens geométricas variacionais e mais precisamente contornos ativos de termos estatísticos baseados em região para segmentação de imagens médicas. Nessas abordagens, características da imagem são con-

sideradas como variáveis aleatórias, cuja distribuição pode ser paramétrica e pertencer à família exponencial, ou estimativas não paramétricas com um método de densidade *kernel*. Os autores descrevem como uma forma prévia pode ser incorporada com os termos estatísticos prévios. Os autores observaram que vários tipos de ruído, muitas vezes contribuem para degradar imagens médicas (Gaussian, Poisson, Rayleigh) e que podem ser recuperados pelos modelos de contornos ativos. Os exemplos mostram que são obtidos resultados relevantes tanto em HMRI (*Heart Magnetic Resonance Imaging*) quanto em imagens ecocardiográficas.

(ZHU et al., 2015) apresentam um método *Level Set* com esquema de supressão de distância para a topologia estrutural e otimização de forma. Uma energia funcional é introduzida na equação *Level Set* para manter a função *Level Set* próxima a função de distância sinalizada e próxima do nível zero, entretanto, força a função *Level Set* a ser constante em locais longe do nível zero.

O trabalho que mais se aproxima da abordagem proposta nesta tese foi desenvolvido por Leventon e colaboradores, em 2000 (LEVENTON et al., 2000), que propuseram a integração de um conjunto de formas deformáveis, durante a evolução do *Level Set*. As formas a priori foram obtidas por meio da definição de uma distribuição de probabilidade sobre as variações dos elementos do conjunto de treinamento. O modelo da forma proposto foi baseado em uma PCA, que então foi aplicado a uma função de distância sinalizada construída com o conjunto de treinamento, composto por contornos do objeto alvo. Em seguida, em cada etapa do algoritmo de segmentação proposto, o *Level Set* evoluiu localmente graças às características intrínsecas da imagem, tais como os gradientes e curvatura. Porém, a evolução também é guiada pelas estimativas do máximo a posteriori da posição anterior da forma previamente definida e da forma a ser localizada.

Na abordagem aqui proposta, entretanto, o formato médio do objeto será obtido por meio do PDM, o qual fará a representação da geometria média da forma sobre as variações dos elementos do conjunto de treinamento. Esta forma média será inserida na evolução do nível zero como uma função de velocidade e da mesma forma contribuirá para evolução local a partir das características da imagem, gradientes e curvatura, porém guiada pela posição anterior da forma previamente definida e da forma a ser localizada, sem a necessidade de utilização de estimativas do máximo a posteriori.

### 3.4 CONSIDERAÇÕES FINAIS

Neste capítulo, além do resumo dos fundamentos básicos da segmentação de imagens, foram listadas as principais abordagens que englobam segmentação por *Level Set* e conhecimento a priori da forma.

Os objetivos das abordagens variam desde a condução da evolução da curva do *Level Set* o mais próximo possível das deformações do objeto, em relação ao conjunto de dados de treinamento, a escolha do método de treinamento para definição da forma média, o tratamento de oclusões e partes do objeto faltantes, até a segmentação de múltiplos objetos, além do custo computacional associado ao número de iterações necessárias para atingir as bordas do objeto.

A maioria das abordagens são baseadas na adição de um termo de energia e no uso da PCA a fim de definir a forma média do objeto a ser segmentado. Entretanto, a forma de inclusão deste termo adicional varia de acordo com a abordagem bem como o uso de PCA. Algumas abordagens consideram a adição do termo de energia à equação de evolução da curva de *Level Set*. Outras abordagens utilizam exclusivamente a informação do gradiente da imagem, ou ainda, aplicam o conhecimento da forma previamente treinada a uma função de distância sinalizada construída sobre o conjunto de treinamento.


Em síntese, pode-se definir que todas as diferentes abordagens tentam realizar algumas tarefas básicas, tais como: implementar um método eficiente para definição correta da forma do objeto; conduzir a curva de *Level Set* em função da forma previamente treinada, entretanto, respeitando as características de cada nova imagem; obter o máximo possível informações do gradiente que contribuam para o direcionamento do modelo da forma; - com objetivo de solucionar os seguintes problemas:

- evoluir a curva de *Level Set* mesmo em situações de oclusão e/ou parte do objeto faltante;
- segmentar múltiplos objetos;
- definir um marcador automático que evolua para representar a forma previamente treinada.

As abordagens estudadas obtiveram resultados satisfatórios para diferentes problemas de segmentação, sendo uma alternativa promissora no estudo do escoamento bifásico, o que motivou a elaboração deste trabalho.

Entretanto, nenhuma dessas abordagens avalia a segmentação de imagens complexas que apresentam níveis de intensidades semelhantes entre o objeto de interesse e o fundo, bem





**Figura 19: Diferenças no formato da cauda: (a) cauda da bolha de gás com sobreposição de pequenas bolhas, (b) cauda da bolha de gás de formato inclinado e (c) cauda da bolha de gás de formato mais alongado**

**Fonte: Autoria própria**

como oclusões, como é o caso das imagens do escoamento bifásico. Este trabalho tem o diferencial de buscar soluções tanto para imagens com pose e forma bem definidos, como para aquelas em que a forma pode conter variações, comprometendo a segmentação por conhecimento a priori com a restrição imposta pela forma.

É importante enfatizar neste ponto, que em relação às imagens do escoamento bifásico, há uma complexidade associada às bolhas dispersas em meio ao líquido. Na verdade, as intensidades dos níveis de cinza, neste caso, geram a sobreposição e oclusão em algumas regiões, conforme pode ser observado pela Figura 19 (a). Além deste fato, outro problema relaciona-se com a parte traseira das bolhas de gás, as quais não possuem um formato apenas. Dependendo da velocidade da bolha de gás, a cauda pode apresentar-se com formato mais inclinado, Figura 19 (b), ou mais alongado, Figura 19 (c) e ainda com as bolhas dispersas em meio líquido formando um emaranhado de difícil separação e identificação, conforme é ilustrado na Figura 19 (a).

Portanto, com o objetivo de segmentar as bolhas de gás do escoamento bifásico e resolver os principais problemas associados a este tipo de imagem, no próximo capítulo será feita a apresentação da abordagem proposta.

#### 4 RESTRICT LEVEL SET - RLS E FREE LEVEL SET - FLS

A proposta desta tese é uma adaptação do método *Level Set* resultante da junção de duas abordagens presentes na literatura, método *Level Set* sem conhecimento a priori (LI CHENYANG XU; FOX, 2005) e Modelo de Distribuição de Pontos (COOTES et al., 1995), com objetivo de otimizar a segmentação de imagens de escoamento bifásico gás-líquido em golfada. Com isso, o desenvolvimento deste novo método para segmentação, tanto de imagens de escoamento bifásico como quaisquer imagens que possuam forma e pose previamente conhecidos, soma-se às demais abordagens existentes que utilizam conhecimento a priori e contornos ativos.

O novo método apresenta duas variações, com forma restrita, denominada *Restric Level Set - RLS*, e com forma livre, denominada *Free Level Set - FLS*, com ênfase na definição de uma nova função de velocidade de extensão baseada no treinamento da forma média. Em ambos os casos, a função velocidade é representada pela forma previamente definida e que é ao mesmo tempo a curva de inicialização da evolução. No primeiro caso, irá conduzir a evolução da curva de nível zero do *Level Set* em função do gradiente da imagem e da forma, impondo uma restrição a evolução da curva. No segundo caso, a evolução da curva de nível zero é livre a partir da forma inicial.

Com isso, as duas variações do método apresentam aspectos desejáveis, como a capacidade de segmentar partes sobrepostas ou faltantes do objeto de interesse, o menor número de iterações para evolução da curva de *Level Set*, bem como a capacidade de tratar tanto objetos com pose e forma bem definidos como objetos que apresentam pequenas variações de formato.

Estas vantagens serão comprovadas pela aplicação do método em diferentes experimentos, usando comparativamente os resultados obtidos isoladamente pelas técnicas de base: MLS sem conhecimento a priori (LI CHENYANG XU; FOX, 2005) e ASM (COOTES et al., 1995), além da técnica tradicionalmente empregada em segmentação de imagens, limiarização adaptativa de Wellner (WELLNER, 1993) e pela técnica baseada na teoria de grafos, segmentação por cortes normalizados - Ncut (SHI; MALIK, 1997).

A segmentação por limiarização será testada a fim de verificar se a segmentação baseada em distribuição de intensidades pode ser empregada em imagens complexas como as imagens do escoamento bifásico. Já a escolha da técnica por cortes normalizados foi definida pelos bons resultados obtidos recentemente em problemas de segmentação (BOYKOV; FUNKA-LEA, 2006), (YANG et al., 2013b). Além disso, uma comparação com a segmentação “ótima” a qual é realizada por um especialista, servirá de referência para a validação da abordagem.

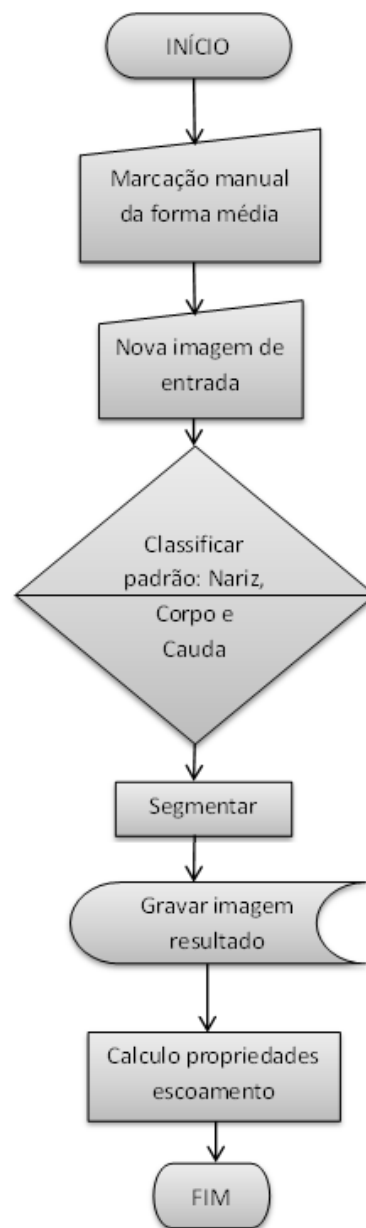
As próximas seções detalham a abordagem proposta da seguinte forma: na Seção 4.1 o fluxograma das etapas do algoritmo de segmentação é descrito; na 4.2 será detalhado como a forma do objeto alvo é definida; a Seção 4.3 descreve a nova abordagem para segmentação de imagens com conhecimento prévio da forma; a Seção 4.4 apresenta uma variação sobre a abordagem proposta, útil em situações em que a forma apresenta grandes alterações; finalmente na Seção 4.5 um resumo do capítulo será apresentado.

#### 4.1 ALGORITMO PARA SEGMENTAÇÃO

O fluxograma da Figura 20 ilustra as etapas do algoritmo de segmentação aqui proposto: o primeiro passo é a marcação manual do conjunto de imagens que representa cada uma das três partes da bolha de gás. Neste caso, o resultado será a forma média que será utilizada como informação prévia conduzindo a segmentação. Vale ressaltar que esta é uma etapa elaborada uma única vez. A partir da definição da forma base, ou do banco de formas base, quando uma nova imagem de entrada do escoamento bifásico é inserida o sistema irá classificá-la de acordo com uma das três formas pré-estabelecidas (nariz, corpo e cauda). Dependendo do resultado da classificação, o sistema irá definir o formato a ser utilizado como curva inicial para o algoritmo de segmentação. Na sequência, o algoritmo segmenta a parte da bolha de gás, utilizando o formato resultante da classificação. Como resultado, as imagens agora segmentadas são gravadas em uma nova pasta contendo o fluxo completo do escoamento. O processo se repete até que a última imagem de entrada seja classificada e segmentada. Finalmente, a partir das imagens segmentadas, o sistema calcula as propriedades relevantes do escoamento já citadas. Estas etapas são detalhadas a seguir.

#### 4.2 DEFINIÇÃO DA FORMA A PRIORI

A utilização da abordagem *Level Set* para segmentação de imagens requer a escolha de um marcador interno (ou externo) à região de interesse, para representar a curva inicial,



**Figura 20: Fluxogram segmentação**

**Fonte: Autoria própria**

$\phi$ , o que pode ser realizado com operações simples (tais como limiarização e morfologia matemática). Neste trabalho, uma abordagem de conhecimento prévio é implementada e utilizada como marcador interno ou externo, dependendo da aplicação e será descrita a seguir.

Primeiramente, é elaborada a seleção e marcação manual dos pontos que definem uma tomada de dados, ou coordenadas do que é considerado pelo especialista como sendo limites para a forma observada. Neste sentido, é necessária a marcação manual de diversas imagens distintas. Neste trabalho foram marcadas 20 imagens para cada uma das partes da bolha de

gás (nariz, corpo e cauda), a fim de serem então treinadas para gerar uma forma média entre as imagens marcadas. Ao final desta etapa, obtém-se uma quantidade de formas interceptadas (os pontos manualmente marcados são alinhados e computadas as distâncias entre seus pontos para gerar a nova forma média) das diferentes imagens que compõem o conjunto de treinamento, que precisam ser convertidas em um único padrão final, capaz de abranger e reconhecer imagens do mesmo fenômeno, porém distintas das utilizadas durante a série de treinamento.

Finalmente, o modelo da forma média obtido pelo treinamento manual será único para cada forma, dotado de parâmetros que o torna flexível para então ser utilizado no reconhecimento e segmentação de imagens que possuem as características e forma a ser localizada.

A opção pelo PDM foi definida principalmente devido ao fato do sistema fornecer de maneira precisa à informação da forma média da estrutura, assim como os seus desvios admissíveis. Com isto, é possível gerar um modelo pontual de distribuição com um número reduzido de parâmetros linearmente independentes, que traduzem a forma média da estrutura em estudo e os desvios permitidos.

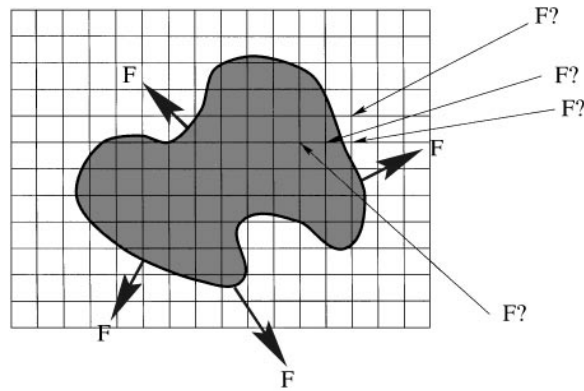
Serão propostos dois métodos para utilização da evolução da curva de *Level Set* baseado no modelo da forma média obtido: forma restrita (*Restrict Level Set - RLS*) ou forma livre (*Free Level Set - FLS*), os quais serão detalhados a seguir.

#### 4.3 RESTRICT LEVEL SET - RLS

O método *Level Set* são técnicas numéricas para acompanhar a evolução das interfaces. Tais técnicas são baseadas em dois pontos centrais: primeiro, a incorporação da interface de nível zero (*zero Level Set*) de uma função de maior dimensão, e, segundo, a incorporação (ou extensão) da velocidade  $F$  da interface para esta função *Level Set* de maior dimensão.

Conforme definido na Seção 4, a Equação 32 nos fornece a evolução de  $\phi$  e é denominada equação de *Level Set*. Tal formulação revela dois pontos centrais:

1. O passo de inicialização (Equação 28) da função de distância sinalizada é utilizado para construir uma função  $\phi$  que corresponde à interface no *Level Set*  $\phi = 0$ . Quando realizado em algum ponto mais tarde no cálculo além de  $t = 0$ , é referida como "re-inicialização."
2. A construção do valor inicial da PDE dada na Equação 32 significa que a velocidade  $F$  está agora definida para todos os *Level Sets*, não apenas o nível zero correspondente à própria interface. A equação de *Level Set* pode ser reescrita como (ADALSTEINSSON; SETHIAN, 1999):



**Figura 21: Construção da velocidade de extensão**

**Fonte: Adaptado de (ADALSTEINSSON; SETHIAN, 1999)**

$$\phi_t + F_{ext} |\nabla \phi| = 0, \quad (41)$$

em que  $F_{ext}$  é algum campo de velocidade que, no conjunto de nível zero, é igual à velocidade dada  $F$ . Em outras palavras,

$$F_{ext} = F \quad (42)$$

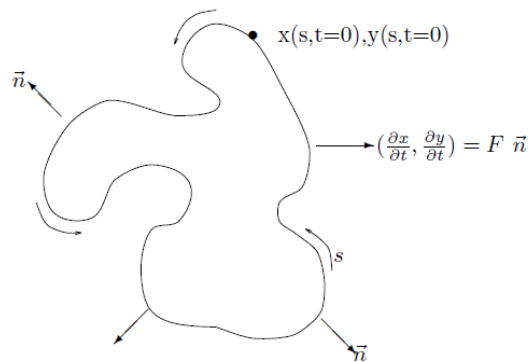
em  $\phi = 0$ .

Este novo campo de velocidade  $F_{ext}$  é denominado “velocidade de extensão”, ilustrado na Figura 21.

Grande parte do desafio em problemas de interface vem da produção de um modelo adequado para a função de velocidade  $F$ . Neste trabalho, a função de velocidade  $F$  corresponde ao modelo de forma prévia. Portanto, a evolução da curva de *Level Set* está diretamente relacionada a um peso definido para esta velocidade, o qual define o quanto a forma prévia irá restringir a evolução da curva de *Level Set* e será detalhado na próxima seção.


#### 4.3.1 FORMULAÇÃO FUNDAMENTAL DO MÉTODO RLS

Dado  $\phi$  como uma curva inicial suave fechada em  $R^2$ , e dado  $\phi(t)$  como a família de curvas paramétricas geradas que move  $\phi = \phi(t = 0)$  em direção a seu vetor normal com velocidade  $F$ . Assim, tem-se que  $\vec{n} \cdot \vec{x} = F$ , em que  $\vec{x}$  é o vetor de posição da curva,  $t$  é o tempo, e  $\vec{n}$  representa a unidade normal para a curva.



**Figura 22: Momento de chegada  $T(x, y)$  da frente para velocidade  $F > 0$**

**Fonte: Adaptado de (SETHIAN, 1996)**



**Figura 23: Configuração para a formulação do valor limite**


**Fonte: Adaptado de (SETHIAN, 1999)**

Considere que em um dado momento  $F > 0$ , neste caso, a frente sempre irá se mover "para fora". Uma maneira de caracterizar a posição desta frente de expansão é calcular o momento de chegada  $T(x, y)$  da frente à medida que atravessa cada ponto  $(x, y)$ , conforme mostrado na Figura 22.

A equação para esta função de chegada  $T(x, y)$  é facilmente derivada. Em uma dimensão, utilizando o fato de que a *distancia = velocidade \* tempo* (ver Figura 23) pode ser escrita da seguinte forma:

$$1 = F \frac{dT}{dx} \quad (43)$$

Em múltiplas dimensões,  $\nabla T$  é ortogonal para os conjuntos de níveis de  $T$ , e, semelhante ao caso unidimensional, a sua magnitude é inversamente proporcional à velocidade. Consequentemente,



**Figura 24: Transformação do movimento da frente em um problema do valor do limite**

Fonte: Adaptado de (SETHIAN, 1999)

$$|\nabla T|F = 1, T = 0 \text{ em } \Gamma \quad (44)$$

em que  $\Gamma$  é a localização inicial da interface.

Assim, o movimento para frente é caracterizado como a solução de um problema de valor limite. Se a velocidade  $F$  depende apenas de posição, então a equação reduz-se ao que é conhecido como equação Eikonal (SETHIAN, 1996). Como exemplo, a superfície de chegada  $T(x, y)$  para expandir uma parte dianteira circular com velocidade  $F = 1$ , é mostrado na Figura 24.

Quando a velocidade de propagação  $F$  é constante, todos os pontos da curva se deslocam de uma mesma distância. Assim, todos os pontos da nova curva evoluída situam-se a uma mesma distância da curva anterior. É justamente essa situação que interessa para o cálculo de propagação com restrição da evolução em função da forma. Neste caso, a ideia básica é evoluir a curva inicial colocando um peso sobre a função velocidade  $F$  a fim de que a propriedade global da forma seja respeitada, criando um novo termo de restrição da velocidade denominado forma global restrita  $\phi_f$ .

A forma global restrita  $\phi_f$  conduzirá a evolução da curva inicial  $\phi$  do *Level Set* pela seguinte formulação:

$$\phi_f = \frac{(\phi_i - \phi(t))}{\lambda_2} \quad (45)$$



em que  $\phi_i$  representa a imagem binária com a forma prévia (curva inicial) e  $\phi(t)$  a curva em evolução.  $\lambda_2$  é obtido empiricamente e reflete o peso a ser definido para a função de velocidade da forma: quanto maior o peso menor é a restrição imposta pela forma previamente treinada. Desta forma, a forma global restrita  $\phi_f$  funcionará pela diferença entre a forma treinada e a forma que se está procurando.

Após a definição da forma média, é necessário considerar uma imagem que contenha um objeto com uma forma similar a uma amostra no conjunto de treinamento. Então, o objetivo é reconhecer a área na imagem que corresponde a este objeto. Para tanto, o modelo da forma é então definido como curva inicial (marcador) para evolução do *Level Set* - MLS (LI CHENYANG XU; FOX, 2005). Neste trabalho, a localização do marcador para as imagens do escoamento é obtida automaticamente, utilizando o vetor posição gerada pelo PDM.

Na segmentação de imagens, contornos ativos são curvas dinâmicas que se movem em direção aos limites do objeto. Para alcançar este objetivo, é definida explicitamente uma função de energia externa que pode mover a curva de nível zero, em direção aos limites do objeto de interesse sem ultrapassá-las.

Li e colaboradores propuseram a utilização de uma função de energia externa  $\varepsilon(\phi)$ , a fim de conduzir o movimento da curva do zero *Level Set* às características da imagem, da seguinte forma (LI CHENYANG XU; FOX, 2005):

$$\varepsilon_{g,\lambda,v}(\phi) = \lambda L_g(\phi) + v A_g(\phi) \quad (46)$$

em que  $\lambda > 0$  e  $v$  são constantes, e os termos  $L_g(\phi)$  e  $A_g(\phi)$  são definidos como:

$$L_g(\phi) = \int_{\Omega} g \delta(\phi) |\nabla \phi| dx dy \quad (47)$$

e

$$A_g(\phi) = \int_{\Omega} g H(-\phi) dx dy \quad (48)$$

respectivamente, em que  $\delta$  é a função univariada Dirac e  $H$  é uma função *Heaviside* (LI CHENYANG XU; FOX, 2005).

O termo  $L_g(\phi)$  calcula o comprimento da curva de nível zero de  $\phi$  e o termo  $A_g(\phi)$  é introduzido para acelerar o movimento do contorno do nível zero no processo de evolução do *Level Set*, o que é necessário quando o contorno inicial é colocado longe dos limites do objeto

desejado.

A função de energia total utilizada, definida por Li e colaboradores é representada como (LI CHENYANG XU; FOX, 2005):

$$\varepsilon(\phi) = \mu P(\phi) + \varepsilon_{g,\lambda,v}(\phi) \quad (49)$$

A energia  $\varepsilon_{g,\lambda,v}(\phi)$  é denominada energia externa e conduz o zero *Level Set* até as bordas do objeto, enquanto  $\mu P(\phi)$  é denominada energia interna e é responsável por penalizar o desvio de  $\phi$  da função de distância sinalizada durante sua evolução (LI CHENYANG XU; FOX, 2005).

Aos termos apresentados acima, a abordagem proposta nesta tese introduz uma restrição na curva inicial, imposta pelo conhecimento prévio que é incorporada às energias externa e interna a cada iteração de acordo com a seguinte equação:

$$\phi(t+1) = \phi(t) + \text{delt} * (\lambda L_g(\phi) + v A_g(\phi) + \mu P(0)) + \phi_f \quad (50)$$

em que *delt* é o passo de tempo e  $\phi_f$  é a função de velocidade da forma em evolução e é obtido pela diferença entre a forma previamente treinada  $\phi_i$ , a qual é ao mesmo tempo definida como marcador inicial, e a curva em evolução no tempo  $\phi(t)$ . Neste caso, o método RLS proposto cria um *framework* composto por 4 termos. Os três primeiros ( $\lambda L_g(\phi) + v A_g(\phi) + \mu P(0)$ ) introduzidos em (LI CHENYANG XU; FOX, 2005) e o último  $\phi_f$  relativo a função de velocidade de extensão do modelo da forma do objeto aqui proposto.

A função de velocidade de extensão,  $\phi_f$ , foi introduzida a fim de orientar a evolução da curva de nível zero. Desta forma, a cada nova iteração a curva segue em direção a sua normal ao mesmo tempo respeitando a restrição imposta pela forma inicialmente definida, ou seja, a função irá penalizar tanto a energia interna quanto a externa quando a evolução da curva for muito diferente da forma ou favorecendo-as quando se aproxima da forma previamente definida.

A constante  $v$  que pondera  $A_g$  pode ser positiva ou negativa, dependendo da posição relativa do contorno inicial em relação ao objeto de interesse. Por exemplo, se os contornos iniciais são colocados fora do objeto, o peso  $v$  deve ter um valor positivo, de modo a que os contornos possam encolher mais rapidamente. Se os contornos iniciais são colocados dentro do objeto, o peso  $v$  deve ter valor negativo para acelerar o expansão dos contornos. O valor dessa constante deve ser testado para cada nova imagem ou objeto a ser segmentado, pois valores muito altos podem desestabilizar a curva e até mesmo gerar a ultrapassagem das fronteiras desejadas.

A função de velocidade de extensão inserida é projetada de modo a não interferir na propriedade importante da função de distância sinalizada desenvolvido em (LI CHENYANG XU; FOX, 2005), o que é necessário para garantir uma boa evolução da curva inicial, uma vez que tal função é calculada pelos termos de energia.

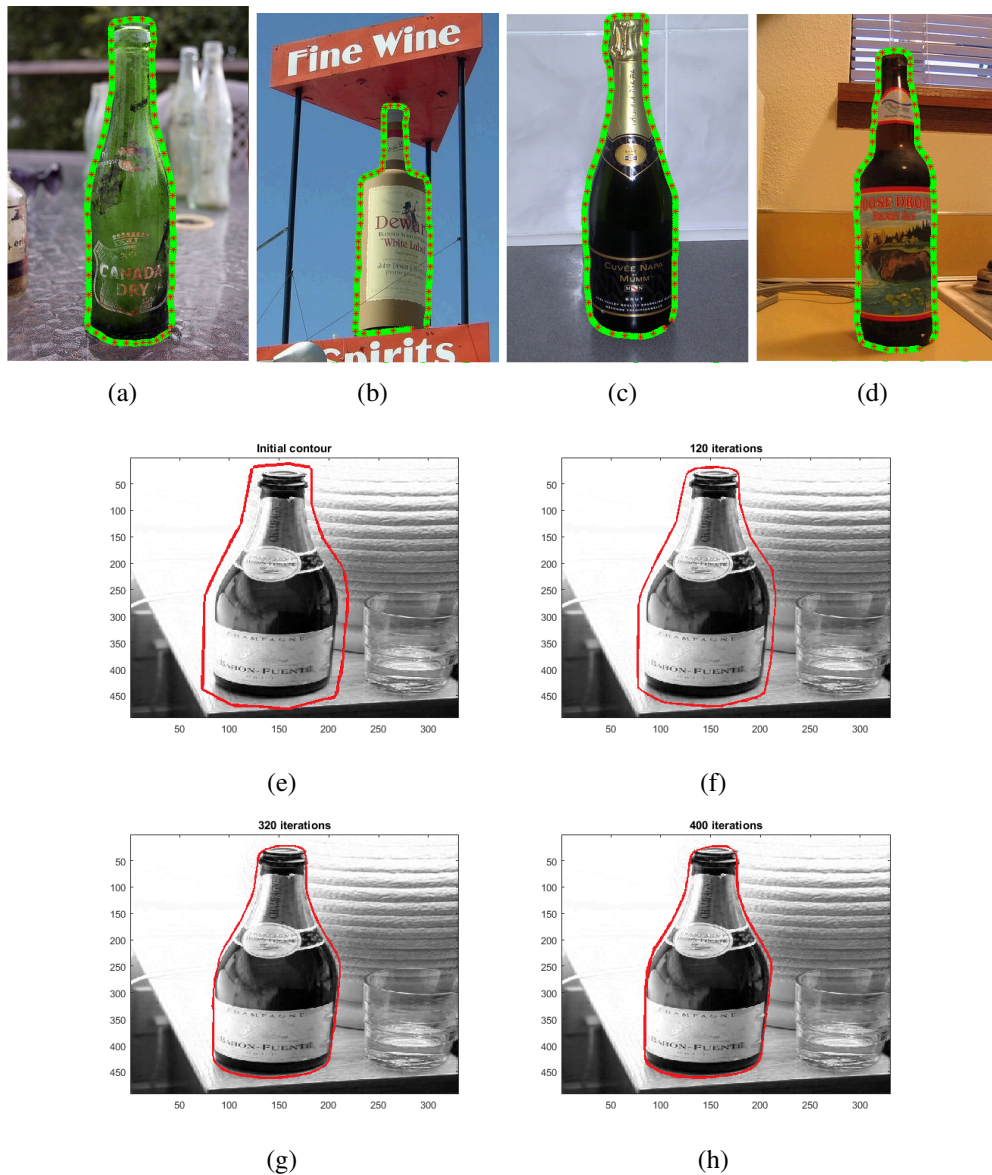
A Figura 25 ilustra a evolução da função  $\phi$  de acordo com a Equação 50. A Figura 25 (a - d) ilustra algumas imagens do conjunto de treinamento da forma, com a marcação dos pontos-chaves. A Figura 25 (e) apresenta a nova imagem com o objeto alvo e a curva inicial definida<sup>1</sup>. As Figuras 25 (f-h) são o resultado da segmentação após diferentes iterações.

A fim de ilustrar a influência da função de velocidade  $\phi_f$ , sobre a evolução da curva de nível zero do *Level Set*, considere a Figura 26. Na figura é possível acompanhar três diferentes evoluções de  $\phi$  para o mesmo número de iterações. A curva inicial é representada sempre pela borda em vermelho mais à esquerda de cada uma das imagens, ou seja, na Figura 26 (a) e (b), a curva inicial é representada por duas formas, garrafa e retângulo e a segmentação é obtida pelo método RLS proposto. Nota-se que a função de velocidade  $\phi_f$  impõe uma restrição a evolução da função *Level Set*. Já na Figura 26 (c) a curva pode evoluir livremente uma vez que não há influência na função velocidade, a segmentação neste caso, é pela abordagem *Level Set* tradicional. Na Figura 26 (d) e (e), é possível visualizar a vantagem da abordagem proposta em relação ao método tradicional, uma vez que a evolução respeita a forma que se deseja segmentar, ignorando a mão sobreposta, o que não ocorre no método tradicional (Figura 26 (f)), gerando uma segmentação final indesejada.

A função *Level Set* final para estas curvas é ilustrada na Figura 27. A Figura 27 (a) e (d) com evolução da curva em formato garrafa, bem como na Figura 27 (b) e (e) em formato retângulo, respeitando a imposição gerada pelo termo  $\phi_f$ . De forma contrária, a Figura 27 (c) e (f) ilustra a função *Level Set* final de forma livre, não sendo capaz, neste caso de ignorar a mão sobreposta.

Em resumo, com a inclusão do conhecimento prévio, o método proposto evolui a curva inicial (modelo da forma), em função do formato médio do objeto e do gradiente da imagem respeitando, entretanto, as características de cada objeto em diferentes imagens. Neste caso, a segmentação de objetos sobrepostos, com oclusões ou partes faltantes é facilitada. No caso de escoamento em golfadas, a utilização deste método soluciona as dificuldades relacionadas à segmentação da parte traseira das bolhas de gás, especificamente a presença de bolhas dispersas em meio líquido.

<sup>1</sup>A localização do objeto pode ser obtida por abordagens de reconhecimento de padrões, tais como encontrado nos trabalhos (KUMAR et al., 2006; FERRARI et al., 2006), não sendo objetivo deste trabalho em imagens diferentes das que compõe o escoamento bifásico.



**Figura 25: Segmentação por *Restrict Level Set*: (a - d) conjunto treinamento com as respectivas marcações manuais, (e) curva inicial com base na forma treinada, (f - h) evolução da curva para diferentes iterações**

**Fonte: Autoria própria**

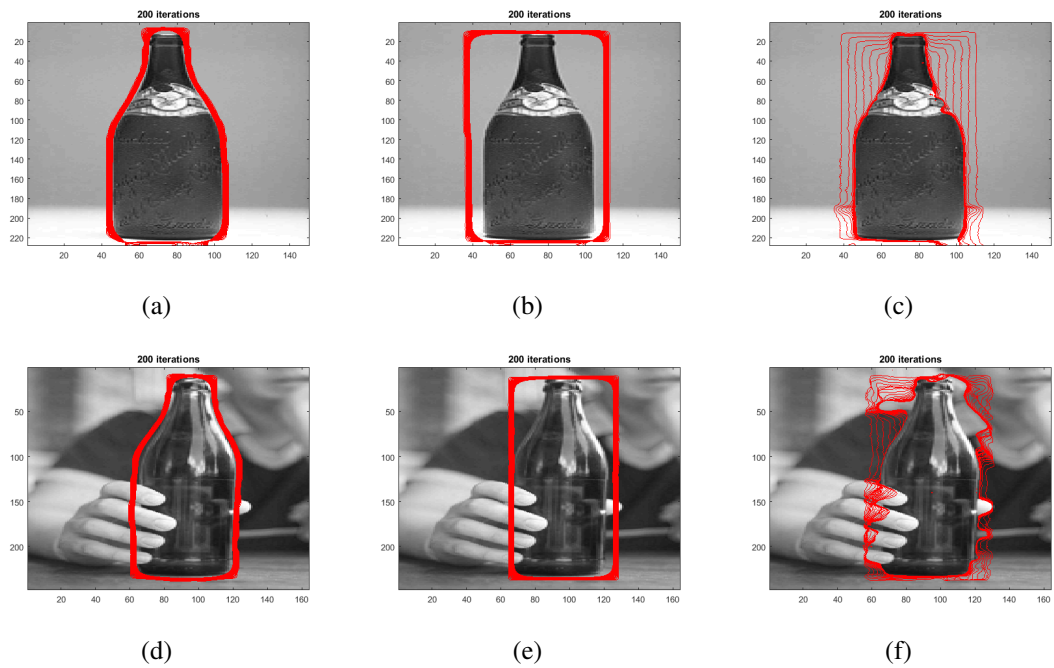
O algoritmo básico do método RLS proposto é descrito a seguir:

---

**Quadro 2: Algoritmo RLS para segmentação de imagens.**

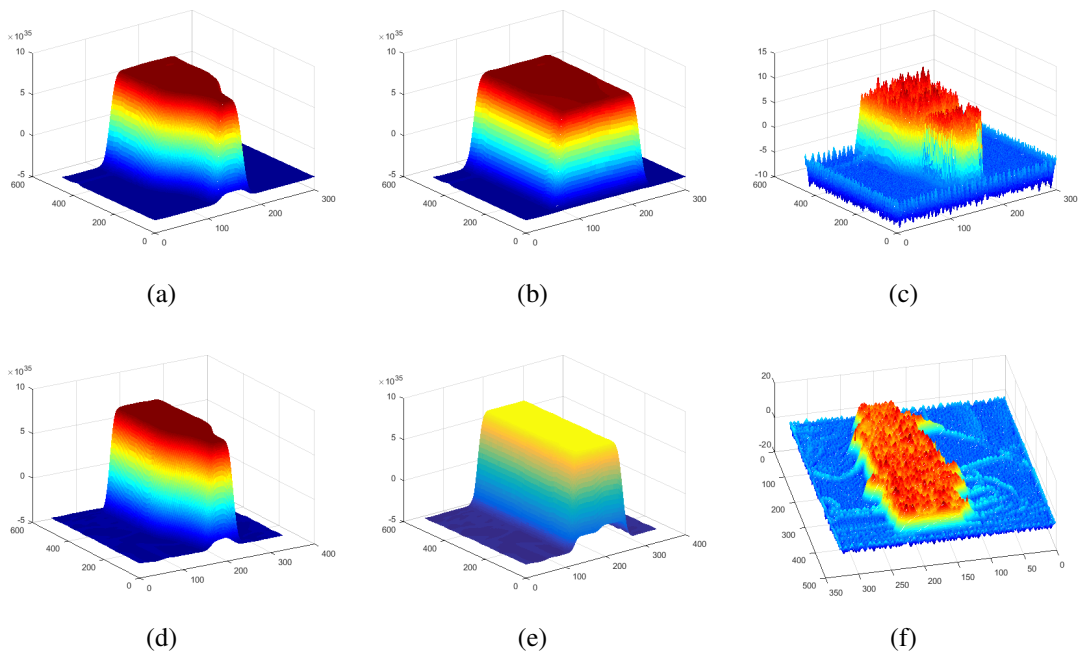
---

- 1: obter o formato médio do objeto por meio do modelo de distribuição de pontos;
  - 2: dada uma nova imagem de entrada  $I$ ;
  - 3: posicionar o marcador (ou curva inicial) fora da região, a partir do formato médio e da localização treinados;
  - 4: evoluir o marcador até obter a redução da função de velocidade  $F$  próxima a zero, obedecendo a restrição imposta pela forma média.
-



**Figura 26: Resultado da segmentação: (a) e (d) evolução pelo RLS em formato garrafa, (b) e (e) evolução pelo RLS em formato retangular, (c) e (f) segmentação MLS**

**Fonte: Autoria própria**



**Figura 27: Resultado da segmentação: (a)-(d) evolução por RLS em formato garrafa, (b)-(e) evolução pelo RLS em formato retangular, (c) segmentação por MLS, (c)-(f)**


**Fonte: Autoria própria**

#### 4.4 FREE LEVEL SET - FLS

O método RLS pode ainda ser adaptado a fim de permitir a livre evolução da curva do marcador inicial previamente treinado. Neste caso não há restrição imposta pela forma e sim uma modelagem da curva inicial. A evolução neste caso será apenas em função dos três termos de energia (discutidos anteriormente) introduzidos por (LI CHENYANG XU; FOX, 2005).

A forma variacional FLS diferencia-se do método RLS principalmente em relação a restrição imposta pela função de velocidade  $\phi_f$ . Em ambos os métodos a forma treinada pelo PDM é utilizada como curva inicial para evolução do *Level Set*, mas no caso do método FLS, o modelo da forma define somente a curva inicial, esta informação é incorporada a função  $\phi_f$  que neste caso, será igual a  $\phi_i$ .

A Figura 28 (b) ilustra o resultado da segmentação usando MLS (após 300 iterações) e a Figura 28 (d) ilustra o resultado da segmentação usando o método FLS aqui proposto (após 300 iterações) de forma variacional. O objetivo do exemplo é segmentar o núcleo da célula, neste caso um monócito. O resultado ilustra a eficiência da abordagem variacional uma vez que conduz a curva inicial de acordo com a forma previamente treinada, porém, o modelo variacional permite a livre evolução da curva previamente treinada, sem a restrição imposta pela forma.



**Figura 28: Resultado da segmentação: (a) evolução por marcador inicial, (b) segmentação MLS, (c) forma previamente treinada e (d) resultado da segmentação por FLS**

**Fonte: Autoria própria**

Esta adaptação pode ser empregada em objetos com formato variável, como é o caso da parte traseira das bolhas de gás no escoamento bifásico, o qual será tratado nas próximas seções.

#### 4.5 CONSIDERAÇÕES FINAIS

Neste capítulo foi descrita a abordagem proposta que tem como objetivo principal a extração das bolhas de gás em imagens representando escoamentos bifásicos gás-líquido horizontal. Inicialmente, foram apresentados os fundamentos da abordagem proposta que corresponde a junção do método *Level Set* e conhecimento a priori.

A definição da abordagem foi baseada principalmente nos resultados obtidos na segmentação das mesmas imagens do escoamento bifásico em trabalhos anteriores (DORINI et al., 2011). Em tal trabalho, constataram-se problemas na segmentação por meio de abordagens de segmentação por limiarização, especificamente na presença de partes sobrepostas. A abordagem proposta possui dois aspectos desejáveis, a possibilidade de segmentar parte sobrepostas, uma vez que a segmentação obedece ao modelo de forma previamente estabelecido e a extensão variacional que corresponde a livre evolução da curva inicial. Neste caso, o modelo da forma evolui sem a restrição imposta pela forma, bastante útil na segmentação de formas ligeiramente variáveis, como é o caso da parte traseira da bolha alongada. No próximo capítulo serão apresentados e discutidos os resultados dos experimentos realizados.

## 5 VALIDAÇÃO EXPERIMENTAL EM BASE DE DADOS *BENCHMARK*

No decorrer do desenvolvimento desta tese, um novo método com duas variações (RLS e FLS) para segmentação de imagens que combina as técnicas *Level Set* e conhecimento a priori da forma foi proposto com ênfase na definição da nova função de velocidade baseada no treinamento da forma média. Neste capítulo será elaborada a análise do comportamento desta função de velocidade em imagens sintéticas e em três categorias de objetos da base dados (FERRARI et al., 2009) que podem ser encontrados no web site <http://www.vision.ee.ethz.ch/datasets/index-en.html>.

Foram elaborados experimentos com imagens sintéticas para o problema da segmentação de objetos na presença de partes sobrepostas tanto em objetos com mesmos níveis de intensidade, quanto em objetos com níveis de intensidade diferentes, além de objetos com alguma de suas partes faltando. A fim de avaliar o comportamento da técnica desenvolvida quando aplicada em imagens diferentes das imagens do escoamento, um conjunto de imagens *benchmark* foi utilizado (símbolos da *Apple*, canecas e garrafas) da base de dados (FERRARI et al., 2009) e comparados aos resultados obtidos por meio das técnicas de segmentação *Level Set* sem conhecimento prévio (LI CHENYANG XU; FOX, 2005) - MLS e *Active Shape Model - ASM* com incorporação de informação a priori (COOTES et al., 1995). Além disso, os resultados de todas as abordagens são comparados à segmentação desejada obtida manualmente por um especialista.

Análises experimentais ajudaram a definir os melhores parâmetros a serem aplicados nos métodos MLS e RLS/FLS, sendo modificados e observados em diversos experimentos. No entanto, os resultados são semelhantes devido ao fato da curva em evolução ser conduzida por sua posição inicial e forma. Portanto, neste trabalho, foram utilizados os seguintes parâmetros,  $\lambda = 5.0$ ,  $\nu = 3.5$ ,  $\mu = 0,04$ , evolução da curva variando entre 150 e 350 iterações,  $\lambda_2 = 2.0$  e o passo do tempo  $delt = 1$ . Tais valores mostraram-se adequados pois em todos os casos estudados, mantém a evolução da curva estável, evitando desta forma que as bordas do objeto sejam ultrapassadas na maioria dos casos.



## 5.1 IMAGENS SINTÉTICAS

Inicialmente o método proposto foi testado em imagens com desenhos simples obtidos artificialmente, aqui denominados imagens sintéticas. A eficiência do método é avaliada pela sua capacidade em segmentar objeto de interesse, até mesmo na ocorrência de oclusões ou se algumas partes do objeto estejam faltando.

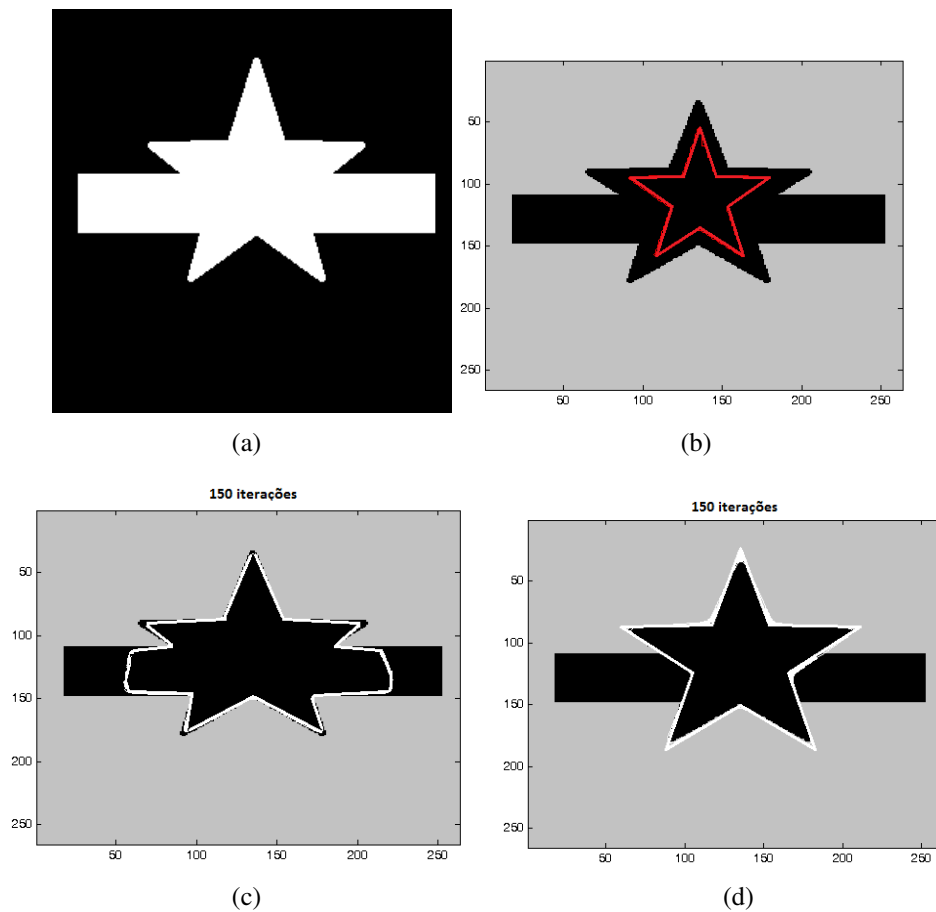
O resultado comparativo é ilustrado na Figura 29, em que uma imagem do objeto de interesse completo “estrela” é mostrada em conjunção com outro objeto “retângulo” (Figura 29 (a)). A Figura 29 (b) (forma média em vermelho) apresenta os benefícios que poderiam ser obtidos com abordagem de segmentação com base em conhecimento a priori da forma - RLS, em comparação aos contornos ativos clássicos - MLS, representados respectivamente pelo resultado da Figura 29 (d) e pela Figura 29 (c). De fato, a abordagem por *Level Set* variacional (LI CHENYANG XU; FOX, 2005) leva em conta principalmente as características locais da imagem, tais como intensidades dos níveis de cinza, gradiente e curvatura, neste caso predominando a segmentação baseada nas intensidades dos níveis de cinza o que provoca a segmentação além da desejada.

A Figura 30 (a) ilustra o problema com objetos sobrepostos, podendo interferir na segmentação. A Figura 30 (b) mostra a curva inicial já representada pela forma média em vermelho. A Figura 30 (c) apresenta o resultado da segmentação pela abordagem MLS. Neste caso, observa-se que mais pixels são segmentados do que o necessário. Já a Figura 30 (d) leva em conta as características locais da imagem, porém a forma previamente treinada restringe a segmentação e principalmente consegue definir a forma final mesmo com objetos sobrepostos.

Das figuras acima, o melhor resultado é alcançado com o método RLS proposto, devido, principalmente, ao bom comportamento da função de velocidade  $\phi_f$  inserido na Equação 8, o qual conduz a evolução da curva de nível zero à segmentação correta.

Em relação ao problema de oclusão com intensidades de níveis de cinza diferentes entre o objeto de interesse e o objeto que cria a oclusão, o resultado da segmentação pelo método proposto (RLS) também é promissor conforme pode ser observado pelo resultado apresentado na Figura 30 (d) em relação ao método proposto por Li et. al. (LI CHENYANG XU; FOX, 2005) - MLS, ilustrada na Figura 30 (c).

Outra aplicação relevante do método proposto é relacionada às imagens que não contêm o objeto completo, ou seja, imagens em que apenas uma parte do objeto de interesse está representada, conforme ilustrado na Figura 31. Os resultados da segmentação obtidos pelo método proposto - RLS e pelo MLS são apresentados na Figura 31 (b) e (c), respectivamente.



**Figura 29: Segmentação de imagem sintética: (a) imagem original, (b) definição do formato médio pelo modelo de distribuição de pontos, (c) resultado da segmentação pelo MLS e (d) resultado da segmentação RLS**


**Fonte: Autoria própria**

Os resultados mostram mais uma vez os benefícios da segmentação pelo método aqui apresentado.

## 5.2 IMAGENS HTZ

O principal objetivo deste trabalho é a identificação e segmentação das bolhas de gás no escoamento bifásico, porém, durante o decorrer desta tese observou-se que o método proposto poderia ser utilizado em diferentes imagens que possuam a mesma forma e pose para o objeto alvo.

Neste sentido, optou-se pela comparação da abordagem proposta em imagens disponíveis na base de imagens do laboratório *Computer Vision Laboratory, ETH Zurich* (FERRARI et al., 2006). Três classes de objetos foram testadas: símbolos da *Apple*, canecas e




**Figura 30: Segmentação de objetos sobrepostos: (a) imagem original, (b) definição do formato médio pelo modelo de distribuição de pontos, (c) resultado da segmentação pelo MLS e (d) resultado da segmentação RLS**

**Fonte: Autoria própria**

garrafas (base de dados composta de 50 imagens de cada modelo). Somente as duas melhores abordagens testadas nas imagens do escoamento foram comparadas com a abordagem aqui proposta nesta etapa: ASM e MLS. Para a abordagem MLS dois teste foram incluídos, com contorno inicial dentro do objeto alvo e fora do objeto alvo. Para a abordagem proposta o contorno inicial foi definido fora do objeto alvo em ambas as variações FLS e RLS.

A Figura 32 (b, i e p) ilustra a segmentação ideal (*ground-truth*), disponibilizada pela própria base de dados. As imagens originais (Figura 32 (a, h e o)) apresentam diferentes fundos e iluminações, o que introduz complexidade ao problema dependendo do método de segmentação a ser empregado. Pela avaliação visual, podem-se notar algumas particularidades, tais como, a fenda presente nos canecos e a separação no símbolo da *Apple*.

Visualmente também, é possível identificar o melhor resultado em relação à segmentação ideal, pela abordagem proposta (RLS), neste caso, a restrição imposta pela forma mostrou-



**Figura 31: Segmentação objeto incompleto: (a) imagem original, (b) resultado da segmentação pela abordagem proposta - RLS e (c) resultado da segmentação por MLS**

**Fonte: Autoria própria**

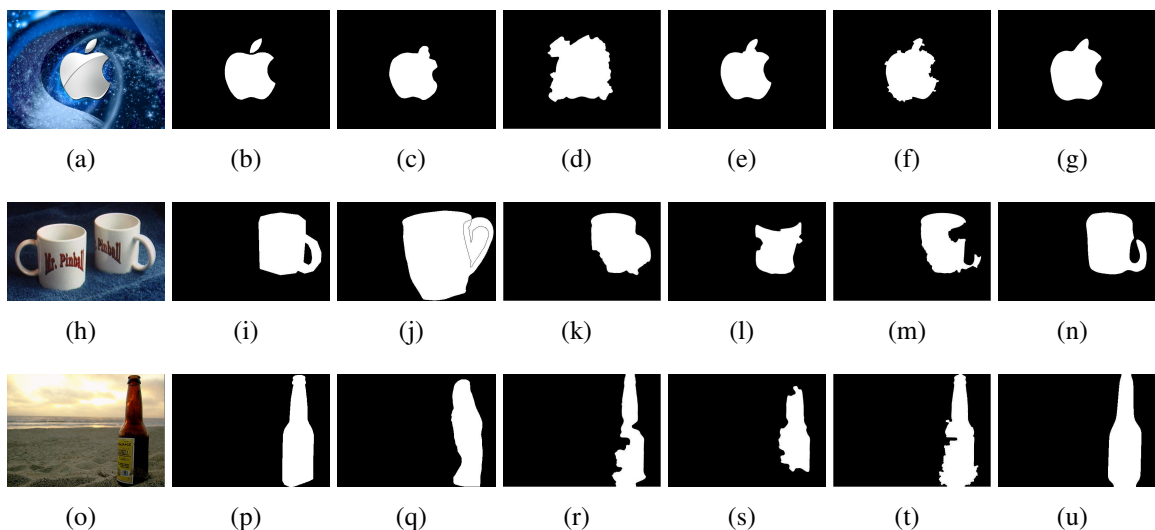
se mais eficiente do que a livre evolução da curva de *Level Set* (FLS) (Figura 32 (g, n e u)). As abordagens testadas confirmaram algumas de suas principais desvantagem:

- ASM (Figura 32 (c, j e q)) - as forças externas horizontais, deslocam os contornos verticalmente, dificultando a progressão para a concavidade. Além disso, a restrição neste caso impede que o objeto alvo seja identificado corretamente uma vez que a energia da forma tende a manter a segmentação mais próxima ao tamanho da forma previamente treinada (Figura 32 (j e q)).
- MLS (Figura 32 (d, k e r)) - a principal dificuldade na evolução da curva de *Level Set* a partir de uma curva inicial quadrada inserida fora do objeto alvo, relaciona-se aos elementos presentes no fundo da imagem, neste caso, o ideal é tentar um pré-processamento (fora do escopo deste trabalho) a fim de minimizar esta influência negativa no resultado final da segmentação.

- MLS curva inicial interna (Figura 32 (e, l e s)) - a dificuldade de evolução da curva *Level Set* a partir de uma curva inicial quadrada inserida dentro do objeto alvo, está relacionada às propriedades particulares de cada objeto, neste caso, a interferência relaciona-se ao gradiente da imagem (com valores baixos nos contornos de todos os objetos da imagem e em objetos ou artefatos que fazem parte do fundo da imagem).
- FLS (Figura 32 (f, m e t)) - para a abordagem aqui proposta com a variação de livre evolução da curva do *Level Set*, o problema apresentado é semelhante ao caso anterior, ou seja, o gradiente da imagem separa o objeto além do contorno desejado. Em outras palavras, a função velocidade  $\phi_f$  conduz eficientemente para o formato e não apenas para o gradiente, sem a função velocidade de extensão o gradiente age como força que irá conduzir ao resultado final o que muitas vezes acaba gerando vazamentos.

A abordagem por RLS mostrou-se adequada até mesmo quando o tamanho do objeto alvo tem grandes variações e a distância da borda seja maior, nestes casos deve-se aumentar o número de iterações até conseguir segmentar de forma ideal. Outra questão a ser levantada relaciona-se aos bons resultados nas imagens com variações de iluminação, da mesma forma, a condução da curva de *Level Set* é guiada pela função velocidade superando tais problemas.

Na próxima seção, a avaliação quantitativa de todos os resultados das segmentações obtidos será discutida, suportando as conclusões apontadas pela análise visual.



**Figura 32: Segmentação base HTZ: (a, h e o) Imagem original, (b, i e p) *Ground-Truth*, (c, j, e q) ASM, (d, k e r) MLS (externo), (e, l e s) MLS (interno), (f, m e t) FLS e (g, n e u) RLS**

**Fonte: Autoria própria**

### 5.3 AVALIAÇÃO DAS SEGMENTAÇÕES

Visando diminuir as avaliações subjetivas as quais são feitas visualmente, a análise aqui realizada compara a segmentação resultante de cada abordagem com aquela obtida manualmente pelo especialista (denominada *ground-truth*). Nesta tese, seis diferentes medidas são utilizadas para quantificar a diferença entre a forma e sua correspondente segmentação: a distância de Hausdorff, os coeficientes de sobreposição de Dice e Jaccard, precisão, sensibilidade e F-measure.

A distância de *Hausdorff* modificada - (MHD) ((DUBUISSON; JAIN, 1994)) que mede em pixels a distância entre as bordas do objeto computados para as duas imagens (imagem segmentada e *ground-truth*). Os coeficientes de sobreposição de Dice *DSC* - *Dice Similarity Coefficient* (CABEZAS et al., 2011) e *Jaccard* (JACCARD, 1912).

O DSC é uma métrica utilizada na área de biologia para uma associação entre duas espécies. Em segmentação é usada como métrica de sobreposição entre duas máscaras binárias, definida por:

$$DSC = 2 \cdot \frac{|A \cap M|}{|A| + |M|} \quad (51)$$

em que  $A$  é a imagem segmentada e  $M$  é a imagem *ground-truth*. O operador de intersecção  $\cap$  fornece a quantidade de *voxels* comuns entre  $A$  e  $M$ . O operador  $+$  é a soma do total de *voxels* das duas regiões. O DSC resultante é uma quantificação normalizada, gerada pelo coeficiente entre a quantidade de *voxels* comuns às duas regiões e a média de *voxels* em cada região. Se não há ocorrência de pixels comuns entre as duas regiões DSC é 0, ao contrário, quando todos os pixels de ambas as regiões são comuns DSC é 1.

O coeficiente de *Jaccard* é definido por:

$$JI = \frac{|A \cap M|}{|A \cup M|} \quad (52)$$

De forma semelhante, se não há ocorrência de pixels comuns entre as duas regiões Jaccard é 0, ao contrário, quando todos os pixels de ambas as regiões são comuns  $JI$  é 1.

Para cada imagem segmentada conta-se a quantidade de classificações em cada uma das categorias de erro ou acerto definidos na Tabela 1. A partir da contagem destas classes calcula-se três métricas diferentes apresentadas na Tabela 2.

Em que  $tp$  é a taxa de verdadeiros positivos (*true positive rate*) e representa o total

**Tabela 1: Classes de resultados**

	positivo	negativo
positivo	Verdadeiro positivo (tp)	Falso negativo (fn)
negativo	Falso positivo (fp)	Verdadeiro negativo (tn)

**Fonte: Autoria própria.**

de pixels corretamente segmentados,  $fp$  é a taxa de falsos positivos (*false positive rate* - FPR) em que um pixel é erroneamente classificado como pertencente ao objeto alvo, porém não pertencente.  $fn$  é a taxa de falsos negativos (*false negative rate* - FNR) e mede a taxa de pixels pertencentes ao alvo que tenham sido classificadas como não pertencentes pelo método de segmentação.

**Tabela 2: Métricas para avaliação de desempenho**

Métrica	Fórmula	Pior desempenho	Valor ótimo
<i>Precision</i> (Precisão)	$\frac{tp}{tp+fp}$	0	1
<i>Recall</i> (Sensibilidade)	$\frac{tp}{tp+fn}$	0	1
<i>F-Measure</i>	$2 \times \frac{Precision \times Recall}{Precision + Recall}$	0	1

**Fonte: Autoria própria.**

A *F-measure* consiste na média harmônica entre os índices de precisão  $P$  (*precision*) e sensibilidade  $R$  (*recall*) (ALPERT et al., 2007) (Tabela 2) e varia de 0 a 1 (o valor 1 representa a segmentação perfeita). A precisão indica a porcentagem dos pixels classificados como parte do objeto que são de fato relevantes, enquanto que a sensibilidade representa a proporção do total de pixels pertencentes ao objeto que foram classificados corretamente como tal (DORINI, 2009).

Estas métricas são apresentadas em tabelas comparativas as quais serão analisadas no decorrer desta seção.

Além das 6 métricas apresentadas acima, as curvas de Características de Operação do Receptor (*Receiver Operating Characteristic* - *ROC*) são utilizadas a fim de demonstrar a relação entre sensibilidade e especificidade para os resultados das segmentações. As Curvas ROC foram desenvolvidas no campo das comunicações como uma forma de demonstrar as relações entre sinal-ruído. No eixo  $Y$  encontra-se a sensibilidade, ou a fração de verdadeiros-positivos definida como:

$$sensibilidade = \frac{tp}{tp + fn} \quad (53)$$

No eixo  $X$  encontra-se a fração de falsos-positivos, ou especificidade definida como


(Note-se que alguns autores traçam 1 - especificidade, em vez de especificidade, no eixo dos X)  
(ZWEIG; CAMPBELL, 1993):

$$especificidade = \frac{fp}{tn + fp} \quad (54)$$

Considere a Figura 33 que ilustra um exemplo de curva ROC. A figura apresenta uma linha diagonal tracejada dividindo o gráfico como uma forma de ilustrar uma técnica de classificação aleatória, ou seja, cada caso tem 50% de chance de obter a classificação de forma correta ou de forma incorreta. Um classificador é considerado bom se sua curva ROC se localiza entre a linha diagonal e a linha reta no topo.

Um teste com a discriminação perfeita (sem sobreposição das duas distribuições) tem uma curva ROC que passa através do canto esquerdo superior onde a taxa de verdadeiros positivos é 1.0 ou 100% (sensibilidade perfeita) e a taxa de falsos positivos é 0 (especificidade perfeita). Portanto, quanto mais perto a curva ROC está do canto superior esquerdo, mais elevada à precisão global do teste ((ZWEIG; CAMPBELL, 1993)).

A partir da curva é possível medir a precisão do método através da área abaixo da curva. Nesse caso, o valor da área varia de 0.5 (pior caso, quando o método mostra um comportamento aleatório) até 1.0 (melhor caso).



**Figura 33: Ilustração da curva ROC**

**Fonte: Adaptado de (ZWEIG; CAMPBELL, 1993)**



#### 5.4 BASE COM 150 IMAGENS DO LABORATÓRIO *COMPUTER VISION LABORATORY, ETH ZURICH* - SÍMBOLO *APPLE*, CANECAS E GARRAFAS

Nesta seção as avaliações quantitativas e qualitativas das imagens do laboratório *ETH* são discutidas, utilizando as métricas definidas anteriormente.

Nas Tabelas 3, 4 e 5 as médias para: índice de *F-Measure - precision e recall*, Jaccard, DSC, FPR, FNR e MHD para as imagens com símbolos da *Apple*, canecas e garrafas, respectivamente, são descritos.

A abordagem que se destaca para este conjunto de imagens é RLS. Os resultados obtidos confirmam a importância do conhecimento prévio sobre o alvo. Nestas imagens, alguns artefatos podem dificultar a segmentação, como sobreposições e problemas de iluminação. Por isso, o método *Level Set* tradicional não consegue resultados satisfatórios. Como pode ser observado, por exemplo, para os valores de FPR e FNR para MLS da Tabela 3, indicando que mais pixels foram segmentados e alguns pixels que realmente compõe o objeto não foram considerados.

O método proposto RLS, pode ser considerado o de melhor desempenho, uma vez que seus índices de F-Measure, Jaccard e DSC estão entre os maiores, indicando uma região segmentada de forma mais confiável, superando inclusive a proposta por FLS. Confirmando os resultados observados visualmente.

Esta mesma análise pode ser concluída para as tabelas 4 e 5, uma vez que os valores encontrados se aproximam. Ou seja, a abordagem RLS proposta apresenta a segmentação do objeto alvo de forma mais próxima ao definido por *ground-truth*. Este fato é confirmado pelos maiores índices de F-Measure e menores de MHD, FPR e FNR em relação à imagem *ground-truth* apresentados pela Tabela 4 e maiores coeficientes de Jaccard e DSC e menor distância MHD da tabela 5.


**Tabela 3: Resultado comparativo conjunto de 50 imagens - Símbolo *Apple***

Método	F	R	P	Jaccard	DSC	FPR	FNR	MHD
FLS	0,872	0,983	0,797	0,763	0,848	0,053	0,225	12,410
RLS	0,876	0,925	0,849	0,790	0,876	0,074	0,151	11,491
ASM	0,533	0,482	0,841	0,374	0,493	2,661	0,296	31,740
MLS	0,798	0,916	0,742	0,601	0,699	5,700	0,359	29,500
MLS interno	0,804	0,893	0,764	0,696	0,804	0,173	0,236	08,412

Fonte: Autoria própria.

A curva ROC da figura 34 (vermelho) para a abordagem proposta RLS obteve uma

área de 96,3% de acerto. A curva ROC da figura 34 (verde) aponta um performance menos eficiente do método MLS, com área de 73,2% de acerto.



**Figura 34:** Curva ROC, em função da sensibilidade e especificidade, para imagens com símbolo da *Apple*. Em preto a curva ROC do FLS, em vermelho curva ROC do RLS, em rosa curva ROC do ASM, em verde curva ROC do MLS e em azul curva ROC do MLS marcador interno


Fonte: Autoria própria.

**Tabela 4: Resultado comparativo conjunto de 50 imagens - canecas**

Método	F	R	P	Jaccard	DSC	FPR	FNR	MHD
FLS	0,972	0,953	0,991	0,864	0,887	0,707	0,290	09,174
RLS	0,976	0,963	0,991	0,818	0,886	0,048	0,147	02,579
ASM	0,532	0,491	0,768	0,374	0,520	1,349	0,283	27,043
MLS	0,829	0,851	0,833	0,409	0,476	3,000	0,511	42,478
MLS interno	0,833	0,849	0,846	0,725	0,830	0,143	0,178	03,716

Fonte: Autoria própria.

A curva ROC da figura 35 (vermelho) para a abordagem proposta RLS obteve uma área de 93,8% de acerto. A curva ROC da figura 35 (verde) aponta novamente para uma performance ineficiente do método MLS, com área de 63,2% de acerto. A principal dificuldade com relação a base de dados cujo objeto alvo são as canecas, está relacionada ao vão do cabo da caneca, conforme é observado na Figura 32. Neste caso, a informação da forma e principalmente a restrição imposta para a evolução da curva conduz a segmentação mais próxima a definida por *ground-truth*, impedindo que o vão seja fechado (Figura 32 (n) - RLS).



**Figura 35: Curva ROC, em função da sensibilidade e especificidade, para imagens com canecas. Em preto a curva ROC do FLS, em vermelho curva ROC do RLS, em rosa curva ROC do ASM, em verde curva ROC do MLS e em azul curva ROC do MLS marcador interno**

**Fonte: Autoria própria.**

A curva ROC da figura 36 (vermelho) para a abordagem proposta RLS confirma para as base de imagens das garrafas um melhor desempenho, com área de 97,90% de acerto.


**Tabela 5: Resultado comparativo conjunto de 50 imagens - garrafas**

Método	F	R	P	Jaccard	DSC	FPR	FNR	MHD
FLS	0,899	0,941	0,869	0,474	0,525	2,354	0,504	39,808
RLS	0,879	0,909	0,883	0,802	0,878	0,128	0,154	4,477
ASM	0,552	0,671	0,646	0,381	0,552	0,474	0,423	21,521
MLS	0,864	0,930	0,817	0,768	0,863	0,193	0,052	3,566
MLS interno	0,831	0,966	0,742	0,718	0,828	0,269	0,016	4,636

**Fonte: Autoria própria.**

Os resultados obtidos pela segmentação com a NCut, MLS, ASM e Limiarização de forma geral, indicam a ocorrência dos três problemas principais associados às abordagens: a super-segmentação, o vazamento da área que delimita o objeto de interesse e a não detecção de partes sobrepostas ou faltantes. A super-segmentação é caracterizada pela divisão excessiva da região segmentada, enquanto o vazamento é observado quando parte do objeto conquista pixels do fundo da imagem ou vice-versa.

Portanto, pode-se concluir (tanto pelos resultados obtidos quantitativos quanto pela



**Figura 36: Curva ROC, em função da sensibilidade e especificidade, para imagens com garrafas. Em azul a curva ROC do FLS, em vermelho curva ROC do RLS, em rosa curva ROC do ASM, em verde curva ROC do MLS interno e em azul (à direita) curva ROC do MLS**

**Fonte: Autoria própria.**

avaliação visual dos resultados), que a abordagem proposta (FLS para imagens do escoamento e RLS para outras bases) conduz aos melhores resultados.

## 5.5 CONSIDERAÇÕES FINAIS

Neste capítulo foram detalhados os resultados experimentais elaborados a partir da abordagem proposta (FLS e RLS). Pode-se comprovar a eficiência da abordagem em ambas as variações FLS e RLS, quando comparada às quatro abordagens amplamente utilizadas em problemas de segmentação, bem como ao resultado esperado definido por um especialista.

A abordagem RLS obteve os melhores índices para a maioria das métricas analisadas, quando aplicado a imagens que possuem o alvo com a mesma forma e pose, como nos exemplos ilustrados da base HTZ. Os resultados promissores sugerem que a abordagem proposta pode ser utilizada em diferentes problemas de segmentação, inclusive quando há ocorrência de sobreposições ou até mesmo quando partes do objeto alvo não são visíveis.

No próximo capítulo será descrito a aplicação da técnica desenvolvida sobre as imagens do escoamento bifásico gás-líquido em golfadas.

## 6 APLICAÇÃO DA TÉCNICA EM ESCOAMENTO BIFÁSICO

Conforme mencionado anteriormente na Seção 2.3, a segmentação das bolhas de gás em escoamento bifásico não é uma tarefa simples, especialmente em relação à presença de bolhas dispersas em meio líquido. Também já foi mencionado que os resultados obtidos a partir do trabalho prévio em (DORINI et al., 2011), apesar de promissores não apresentaram bons resultados na presença de bolhas dispersas. Então, neste trabalho optou-se pelo desenvolvimento de uma nova técnica de segmentação de imagens baseada em conhecimento a priori da forma a fim de conduzir a evolução da curva *Level Set* mais próxima ao formato definido por Wallis (WALLIS, 1969) que caracteriza a célula unitária. Então, poder calcular as propriedades relevantes ao escoamento já citadas. As seções seguintes descrevem cada uma das etapas necessárias para este propósito.

### 6.1 DESCRIÇÃO DA BASE DE IMAGENS

Os dados experimentais foram coletados em um aparato experimental de escoamento bifásico horizontal ar-água localizado no Laboratório de Ciências Térmicas (LACIT) na Universidade Tecnológica Federal do Parana - UTFPR. O ensaio experimental é descrito em (AMARAL et al., 2013) e (PIPA et al., 2014). Tanto a velocidade da água quanto o fluxo das bolhas de ar são medidos independentemente antes da mistura por um medidor de fluxo de *Coriolis* (*Krohne OPTIMASS 6000*, 0,1% de precisão) e um conjunto de rotâmetros calibrados (precisão nominal de 1%), respectivamente. Durante o decorrer desta tese, vários experimentos foram realizados com diversas velocidades de gás e líquido, entre 0,3 m/s a 2 m/s.

As imagens do escoamento são capturadas por uma câmera de alta velocidade modelo *Nano Sense MKIII* (*DantecDynamics*) em resolução de 232x500 pixels. A taxa de aquisição é igualada a velocidade do fluido para garantir a qualidade da imagem e o adequado uso da memória. Uma caixa de acrílico transparente retangular (200 mm x 100 mm x 100 mm) cheia de água foi instalada na posição de gravação para reduzir a distorção da imagem. Uma lâmpada halogena envolta com uma superfície difusora foi utilizada para garantir uma iluminação uni-

forme (veja Apêndice A para ilustração do aparato experimental).

É importante mencionar que algumas imagens do escoamento bifásico podem conter partes sobrepostas, ou seja, caso em que há maior presença de gotículas de gás em meio a bolha em golfada, tal ocorrência é devido ao aumento na velocidade do gás. Além disso, a captura das imagens da câmera digital gera um conjunto de frames que representam uma bolha completa. Os frames neste conjunto são classificados (identificados) da seguinte forma: parte inicial da bolha de gás (nariz), parte central da bolha de gás (corpo) e parte final da bolha de gás (cauda), podendo ou não apresentar bolhas dispersas em meio líquido.


Com isso, considera-se que um escoamento em golfadas possui imagens com três tipos diferentes de estruturas: imagens do nariz da bolha de gás (Figura 37 a, b e c); imagens do corpo da bolha de gás (Figura 37 d, e e f); e imagens da cauda da bolha de gás (Figura 37 g, h e i). Conforme mencionado anteriormente, a presença de gotículas é uma característica inerente a este tipo de escoamento quando há maior velocidade da fase gasosa, portanto, em baixas velocidades tal fenômeno não estará presente (Figura 37).

Para o treinamento do modelo da forma usando os exemplos da Figura 37 como um conjunto de treinamento, foram utilizadas 20 imagens para cada uma das três partes: nariz, corpo e cauda. Os pontos-chaves são então definidos pela marcação manual em torno do limite entre a bolha de gás e líquido, como se mostra na Figura 37 (j, k e l), para cada estrutura. Totalizando um vetor de 80 pontos-chaves para cada modelo de forma. Isso deve ser feito para cada forma no conjunto de treinamento. Com isso, é extraída a representação de cada exemplo, como um conjunto de pontos rotulados, calculando as posições médias dos pontos e as principais formas em que os pontos de cada exemplo tendem a diferir da média.

A rotulagem dos pontos é importante. Cada ponto marcado representa uma parte específica do objeto ou de sua fronteira. Se a rotulagem é incorreta, com determinado ponto colocado em locais diferentes em cada forma de treinamento, o método deixa de capturar a variabilidade da forma de maneira confiável.


Os pontos só são colocados manualmente durante a fase de definição da forma média, não é necessário encontrar esses pontos novamente quando os modelos são usados na segmentação de novas imagens, uma vez que a forma média só é gerada uma vez para cada modelo de forma.

Para realizar os experimentos, foram separadas 450 imagens do escoamento bifásico para o processo de segmentação, divididos em 150 imagens nariz, 150 imagens corpo e 150 imagens cauda, com velocidades superficiais das bolhas de gás variando entre 0.3 m/s a 2 m/s.



**Figura 37: Representação da base de dados do escoamento: (a, b e c) formato do nariz da bolha de gás, (d, e e f) formato do corpo da bolha de gás, (g, h e i) formato da cauda da bolha de gás e (j, k e l) pontos marcados para definição da forma média**

**Fonte: Autoria própria**




**Figura 38: Desprendimento de gotículas de gás em meio ao líquido: (a, b e c) gotículas no nariz da bolha de gás, (d, e e f) gotículas no corpo da bolha de gás, (g, h e i) gotículas na cauda da bolha de gás**

**Fonte: Autoria própria**

## 6.2 DESENVOLVIMENTO DO CLASSIFICADOR

Como a célula unitária tem como característica a ruptura entre as bolhas de gás, é necessário a correta compreensão do conjunto de imagens (frames) que representam uma mesma bolha, conforme ilustrado na Figura 39. A Figura 39 (a) ilustra o início da bolha de gás (nariz), o centro da bolha de gás é ilustrado na Figura 39 (b), o término da bolha de gás (cauda) ilustrado na Figura 39 (c) e uma transição entre as bolhas de gás (ruptura) é mostrada na Figura 39 (d), fazendo com que haja apenas líquido na seção transversal do tubo ou em alguns casos pequenas bolhas dispersas.

Como o objetivo é estabelecer um processo automático de montagem da célula unitária, o operador do sistema escolhe o diretório que contém a base de imagens (adquirida no laboratório experimental) e para cada imagem lida, o sistema identifica qual parte da bolha (nariz, corpo ou cauda) em golfada cada imagem representa. O processo de classificação então, identifica, sobre cada nova imagem qual parte da bolha em golfada a mesma se relaciona. Somente após a classificação o sistema escolhe a forma correta para iniciar o processo de segmentação por meio do método proposto FLS.



**Figura 39:** Ilustração da aquisição para o padrão golfada (célula unitária): (a) início da bolha de gás, (b) área central da bolha de gás, (c) término da bolha de gás e (d) transição entre as bolhas de gás

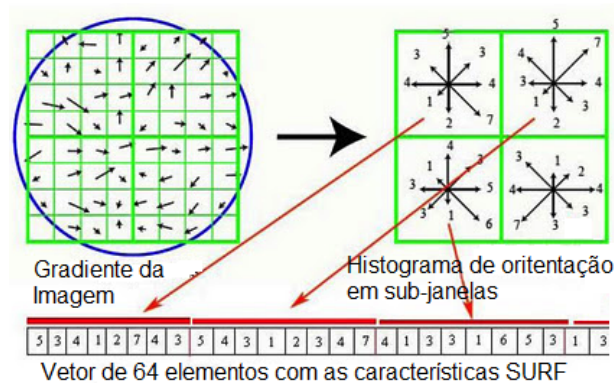
**Fonte:** Autoria própria.

Para a implementação do classificador, um método de recuperação de imagens por conteúdo (*Content-Based Image Retrieval - CBIR*) foi utilizado. A ideia básica do CBIR é localizar imagens similares a uma imagem de consulta. Uma técnica frequentemente utilizada para implementar um sistema CBIR é por Histograma de Palavras Visuais ou *Bag of Words - BOW* (PHILBIN et al., 2007). BOW é uma técnica derivada de algoritmos de classificação de texto em aprendizagem de máquina. Porém, ao invés de usar palavras reais como na recuperação de documentos, BOW utiliza características da imagem como as palavras visuais que descrevem uma imagem. As características das imagens são usadas para medir similaridades entre as imagens e pode incluir características globais da imagem, tais como cor, textura e forma. Neste trabalho, um algoritmo de extração de características auxiliar de localização de pontos de



interesse denominado SURF (*Speeded-Up Robust Features*) foi utilizado, gerando um vetor das características extraídas. SURF é um descritor invariante à rotação e à escala e busca detectar e descrever pontos chave (*keypoints*) da imagem para etapa de classificação (BAY et al., 2006).

Extratores de características modernos selecionam características proeminentes da busca de pixels que demonstram mudanças rápidas em valores de intensidade. Tais pixels fornecem alta pontuação para valores de detecção de cantos de Harris e são referidos como pontos chave. Os pontos chaves são procurados sobre um subespaço  $x, y, \sigma \in \mathbb{R}^3$ . A variável  $\sigma$  representa o espaço escala de Gauss na qual o ponto chave existe. Um vetor descritor de comprimento 64 é construído utilizando um histograma de orientações do gradiente na vizinhança local em torno de cada ponto chave. A Figura 40 ilustra a maneira pela qual um vetor descritor SURF é construído.



**Figura 40: Construção do vetor de característica SURF por meio do gradiente da imagem**

Fonte: Adaptado de (SCHMITT; MCCOY, 2011)

Como a quantidade de pontos em cada imagem é variável, um algoritmo de agrupamento por *K-means* (ARTHUR; VASSILVITSKII, 2007) foi aplicado em todos os pontos de interesse da imagem e então agrupados, para cada grupo foi calculada a média. As médias ou números de grupos do *K-means* definem a quantidade de palavras visuais do vocabulário, em que cada grupo representa uma palavra. Após esse processo as médias também são utilizadas na extração de atributos de cada imagem.

Finalmente, as imagens codificadas em cada categoria alimentam o classificador baseado em *Support Vector Machine* - SVM. SVM é um classificador supervisionado que tem por objetivo encontrar um hiperplano que separa um conjunto de dados em classes discretas, utilizando-se de processo iterativo e de exemplos de treinamento para ajustar este hiperplano. Para isto, SVM encontra um hiperplano que otimiza a separação das classes, também conhecido como hiperplano ótimo ou ideal, que maximiza a distância entre as classes, sendo usado como

fronteira de decisão (VAPNIK; VAPNIK, 1998).

Dado  $X$  observações e  $Y$  legendas correspondentes com valores  $\pm 1$ , encontra-se uma função de classificação da seguinte forma:

$$f(x) = \text{sign}(w^T x + b) \quad (55)$$

em que  $w$  e  $b$  representam os parâmetros no hiperplano. Então, aplica-se SVM para as multi-classes (nariz, corpo e cauda) com a técnica de um contra-todos. Dado um problema de  $m$ -classes, treina-se  $m$  SVM's, cada um distingue imagens de alguma categoria  $i$  a partir de imagens de todas as outras  $m - 1$  categorias de  $j$  não igual a  $i$ . Dada uma imagem de consulta, esta é atribuída à classe com a maior SVM de saída (CSURKA et al., 2004).

A etapa de classificação das imagens do escoamento bifásico de acordo com sua forma pode ser resumida da seguinte forma:

1. Organização e particionamento das imagens em subconjuntos de treinamento e teste para criar subconjuntos de imagens representativas de cada categoria (nariz, corpo e cauda);
2. Divisão da base de dados em imagens de treinamento e teste ( $50\% \times 50\%$ );
3. Criação do vocabulário visual, ou BOW, por meio do descritor de características de pontos SURF, a partir de imagens representativas de cada categoria;
4. Aplicação de *k-means* sobre os descritores das características extraídas dos subconjuntos. O algoritmo agrupa iterativamente os descritores em  $k$  *clusters* mutuamente exclusivos. Os *clusters* resultantes são compactados e separados por características semelhantes. Cada centro de *cluster* representa um recurso ou palavra visual;
5. Aplicação do classificador SVM nas imagens de treinamento a fim de categorizá-las;
6. Avaliação do classificador treinado nas imagens de testes;
7. Aplicação do classificador nas novas imagens que serão utilizadas para extração de propriedades relevantes do escoamento.

A classificação foi realizada em uma base de 840 imagens (50% foi utilizada para treinamento e 50% para testes). A matriz de confusão, ilustrada na Tabela 6, permite analisar de forma mais detalhada os erros de classificação. Pode-se observar que existem erros entre os padrões corpo e nariz, o que é justificado pela semelhança entre os descritores extraídos

destes padrões. Entretanto, com os bons resultados obtidos o sistema será capaz de calcular as propriedades do escoamento de forma confiável.

**Tabela 6: Matriz de confusão**

Classe	Nariz	Corpo	Cauda
Nariz	1,00	0,00	0,00
Corpo	0,00	0,99	0,01
Cauda	0,01	0,00	0,99

**Fonte: A autoria própria.**


### 6.3 VALIDAÇÃO EXPERIMENTAL IMAGENS ESCOAMENTO

Finalmente, a fim de avaliar se a abordagem proposta segmenta de forma eficiente as bolhas de gás no escoamento bifásico gás-líquido, foi elaborada uma análise comparativa dos resultados obtidos por meio das abordagens de segmentação baseadas em limiarização de Wellner (WELLNER, 1993), Corte Normalizado - NCut (SHI; MALIK, 1997), *Level Set* sem conhecimento prévio (LI CHENYANG XU; FOX, 2005) - MLS e *Active Shape Model - ASM* com incorporação de informação a priori (COOTES et al., 1995). Além disso, os resultados de todas as abordagens são comparados à segmentação desejada obtida manualmente por um especialista.

Observe a Figura 41 (d-f) que ilustra a segmentação definida manualmente por um especialista (*ground-truth*) como sendo a segmentação ideal. Visualmente, é possível identificar como melhores resultados em relação à segmentação idealmente sugerida, aquelas representadas pela Figura 41 (s-u) e (v-x), obtidas respectivamente com os métodos RLS e FLS. Os piores resultados são aqueles em que a informação de intensidade dos níveis de cinza é determinante para o resultado final da segmentação, ou seja os ilustrados na Figura 41 (g-i) e (j-l), obtidos respectivamente com os métodos de limiarização de Wellner e MLS. Como resultado intermediário pode-se observar a segmentação da Figura 41 (m-o) e (p-r), obtidos respectivamente com os métodos NCut e ASM.

O principal problema da abordagem NCut é o número de segmentos e o número de imagens que são geradas a partir de cada corte (5 em cada segmentação). Portanto, uma etapa adicional deve ser definida a fim de identificar automaticamente qual das cinco imagens melhor representa a segmentação ideal, bem como, dependendo do número de segmentos aquele que descreve a bolha em golfada. O resultado obtido por ASM apresenta a dificuldade em aproximar-se dos contornos côncavos da bolha, uma vez que as forças externas envolvidas são

horizontais, deslocando o contorno verticalmente, mas não progredindo adequadamente para a concavidade.



**Figura 41: Resultados da segmentação do escoamento: (a, b e c) Original, (d, e e f) *Ground-Truth*, (g, h e i) Limiarização por Wellner, (j, k e l) MLS, (m, n e o) NCut, (p, q e r) ASM, (s, t e u) RLS e (v, w e x) FLS**

**Fonte: Autoria própria**

Uma vantagem do método proposto é que a segmentação é realizada em menos iterações que os métodos de base. Para o exemplo anterior, foram necessárias 150 iterações, enquanto que para o método MLS foram necessárias 350 iterações, e para o método ASM 50 iterações. Entretanto, para cada iteração do método ASM o custo computacional é superior aos métodos FLS e MLS. Assim a abordagem proposta é mais rápida na execução do processo.

A Tabela 7 ilustra o tempo médio computacional para cada método, aplicado a 170 imagens. Os algoritmos são codificados em Matlab (versão R2015b) rodando em Intel Core i3 CPU M370 (2,4 GHz), memória RAM de 4 GB com o Windows 7 Home Basic. Para o método proposto, a curva inicial é mais próxima ao contorno devido à informação *a priori* da forma e de sua localização, necessitando menos iterações para segmentar o alvo.


**Tabela 7: Tempo computacional médio para cada método aplicado em 170 imagens**

Método	Iterações	Tempo computacional por iteração (segundos)	Tempo total (segundos)
ASM	50	29,37	4.992,90
MLS	350	4,61	783,70
FLS/RLS	150	1,98	336,60

**Fonte: Autoria própria.**

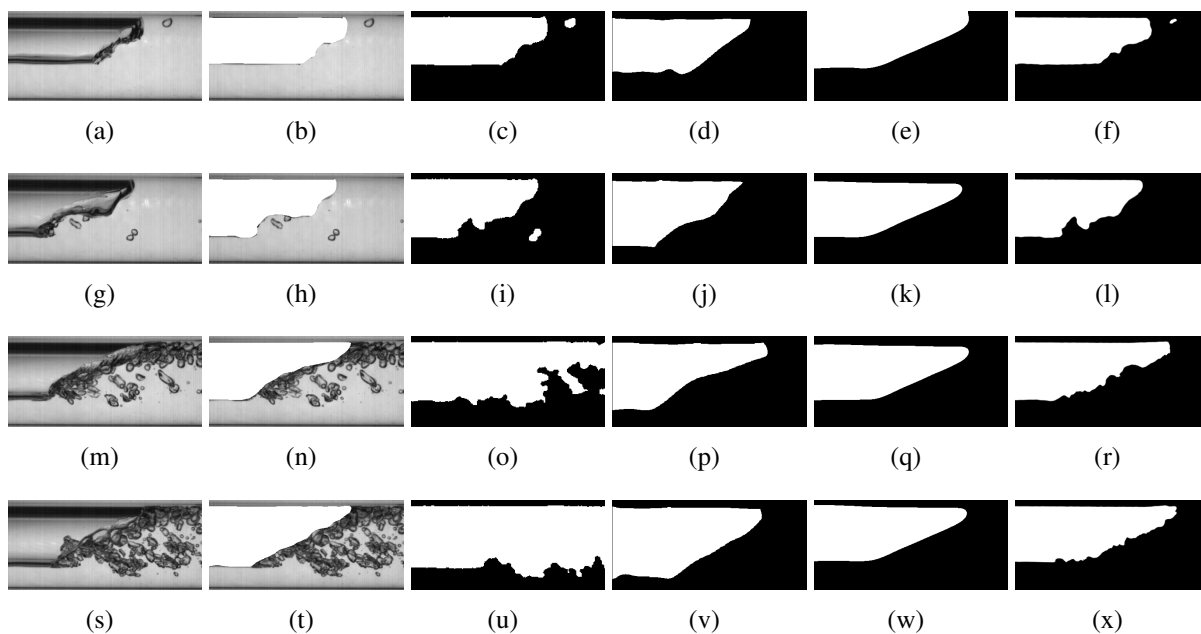
Os resultados apresentados nas Figuras 42 e 43 ilustram a importância da informação *a priori* sobre a forma do objeto alvo no processo de segmentação. Por um lado, a incorporação de uma forma prévia na segmentação ajuda a evolução da curva ao descartar aqueles pixels com valores de intensidade semelhantes que não pertencem ao objeto de interesse. No entanto, em casos em que muitas bolhas dispersas aparecem na imagem, a bolha pode não ser recuperada de forma correta pelas abordagens de limiarização e MLS; Em especial, as segmentações de imagens do nariz e cauda da bolha (Figura 42 e 43), são piores em comparação com os resultados da segmentação obtidos com o método proposto RLS e pela sua variante FLS, bem como pelo ASM. A segmentação por NCut apresenta o problema mencionado anteriormente em relação ao número de segmentos e o número de imagens necessárias para cada corte, por isso não foi inserida nestes exemplos.

É possível observar ainda, que o método proposto (ambas as variações), trata eficazmente o problema de objetos com partes faltantes como ilustrado na Figura 42 (s) em que o formato da bolha de gás é prejudicado pela presença de várias bolhas dispersas acima da bolha alongada. A Figura 43 (s) apresenta o problema de partes sobrepostas o que também prejudica a definição do formato correto da cauda da bolha de gás.



**Figura 42:** Resultados da segmentação do nariz das bolhas de gás: (a, g, m e s) Imagem original, (b, h, n e t) *Ground-Truth*, (c, i, o e u) MLS, (d, j, p e v) ASM, (e, k, q e w) RLS e (f, l, r e x) FLS

Fonte: Autoria própria



**Figura 43:** Resultados da segmentação da cauda das bolhas de gás: (a, g, m e s) Imagem original, (b, h, n e t) *Ground-Truth*, (c, i, o e u) MLS, (d, j, p e v) ASM, (e, k, q e w) RLS e (f, l, r e x) FLS

Fonte: Autoria própria

#### 6.4 AVALIAÇÃO QUANTITATIVA

A seção a seguir é dedicada a avaliação quantitativa dos resultados da segmentação obtidos com a abordagem proposta e suas variações (RLS e FLS) e pelos métodos limiarização de

Wellner, NCut, MLS e ASM para as imagens do escoamento bifásico. A base de dados utilizada é constituída de 150 imagens, para cada uma das formas ilustrada na Figura 37, totalizando 450 imagens. As imagens *ground-truth* das bolhas de gás no escoamento bifásio gás-líquido são parte do banco de dados usado em (AMARAL et al., 2013; PIPA et al., 2014) e são escolhidas conforme discutido nestes documentos.

#### 6.4.1 BASE COM IMAGENS REPRESENTANDO O NARIZ DA BOLHA

Na Tabela 8, as médias para: índice de *F-Measure - precision e recall*, Jaccard, DSC, FPR, FNR e MHD para as imagens do nariz das bolhas de gás são apresentadas. Para calcular os índices de precisão e sensibilidade que compõem o índice *F-Measure* apenas os pixels pertencentes à região segmentada que melhor se aproxima do objeto de interesse (nariz bolha) são considerados, especificamente para a abordagem NCut onde há o problema de supersegmentação. Note-se que a abordagem proposta (FLS) leva a resultados superiores para a maioria das métricas consideradas. Estes números refletem a vantagem de se obter uma informação a priori sobre o objeto a ser segmentado.

Os resultados obtidos por NCut apresentam os melhores índices para *F-measure*, no entanto, esta vantagem não se confirma nas demais métricas (Jaccard, DSC, FPR e FNR). Por exemplo, os valores de FPR e FNR indicam que mais pixels foram segmentados e alguns pixels que realmente compõe o objeto não foram considerados. Ou seja, o maior índice para FPR indica que foram segmentados mais pixels do que o necessário para representar a bolha de gás, em contra partida, FNR mais alto do que as demais abordagens indica que alguns pixels que pertencem bolha de gás ficaram de fora da segmentação final.

Os três métodos (MLS, FLS e RLS) baseados no *Level Set* apresentam resultados semelhantes. O método proposto FLS pode ser considerado o mais promissor, uma vez que seus índices de FPR e FNR são baixos, indicando uma região segmentada de forma mais precisa. Este resultado confirmado também pelos índices Jaccard, DSC e MHD.

Os resultados por limiarização confirmam os observados visualmente, ou seja, a segmentação baseada em intensidade não conduz a bons resultados para as imagens do escoamento. Bem como para ASM, cujos resultados indicam que a segmentação não foi satisfatória.


Portanto, os métodos propostos FLS e RLS apresentam a segmentação da superfície do nariz da bolha de gás de forma mais similar ao da superfície por *ground-truth*, apenas alguns dos pixels estão ausentes. Este fato é confirmado pela menor distância de *Hausdorff* em relação a imagem *ground-truth*.

**Tabela 8: Resultado comparativo conjunto de 150 imagens nariz da bolha de gás**

Método	F	R	P	Jaccard	DSC	FPR	FNR	MHD
FLS	0,737	0,653	0,894	0,622	0,737	0,093	0,566	11,55
RLS	0,703	0,650	0,825	0,571	0,703	0,185	0,512	11,59
ASM	0,679	0,568	0,900	0,536	0,679	0,104	0,788	14,59
MLS	0,702	0,561	0,989	0,559	0,702	0,011	0,855	21,30
Limiar	0,618	0,472	0,956	0,458	0,618	0,046	1,148	35,57
NCut	0,870	0,851	0,897	0,553	0,686	0,223	3,143	11,76

Fonte: Autoria própria.

As curvas ROC para cada método utilizado podem ser acompanhadas na Figura 44. Conforme ilustrado na curva ROC da Figura 44 é possível observar que a curva confirma os valores das métricas acima analisadas. Os melhores valores de área sob a Curva ROC são das abordagens FLS (ROC = 99,3%), ASM (ROC = 98,1%) e RLS (ROC = 94,1). Além disso, a curva indica que estas abordagens estão mais próxima do ponto ideal ilustrado na Figura 33, com maior sensibilidade e menor especificidade. Confirmam também a qualidade inferior da segmentação por limiarização, cuja área sob a curva ROC obteve 72,3% de acerto e encontra-se bastante afastada do ponto ideal.



**Figura 44: Curva ROC, em função da sensibilidade e especificidade, para o nariz das bolhas de gás. Em azul a curva ROC do FLS, em vermelho curva ROC do RLS, em rosa curva ROC do ASM, em verde curva ROC do NCut, em azul claro curva ROC do MLS e em azul (à direita) curva ROC da limiarização**

Fonte: Autoria própria.



#### 6.4.2 BASE COM IMAGENS REPRESENTANDO O CORPO DA BOLHA

Na Tabela 9, as médias para: índice de *F-Measure - precision e recall*, Jaccard, DSC, FPR, FNR e MHD para as imagens do corpo das bolhas de gás são apresentadas. Note-se que todas as abordagens testadas apresentam resultados com ótima qualidade, uma vez que as imagens do corpo das bolhas de gás são relativamente simples de segmentar, pois não possuem o rompimento na bolha de gás e as bolhas dispersas, quando presentes, não comprometem a segmentação final.

Ncut, limiarização e ASM apresentam índices FPR (NCut) e FRN (NCut, limiarização e ASM) mais altos que as métricas baseadas em *Level Set* (ainda assim baixos), podendo ser considerados resultados aceitáveis, uma vez que em todas as demais métricas os índices são admissíveis.

**Tabela 9: Resultado comparativo conjunto de 150 imagens corpo da bolha de gás**


Método	F	R	P	Jaccard	DSC	FPR	FNR	MHD
FLS	0,976	0,995	0,958	0,953	0,976	0,043	0,005	0,207
RLS	0,946	0,963	0,935	0,900	0,946	0,064	0,043	0,702
ASM	0,977	0,958	0,997	0,956	0,977	0,048	0,124	0,787
MLS	0,918	0,893	0,951	0,852	0,918	0,002	0,044	1,240
Limiar	0,932	0,884	0,987	0,875	0,932	0,013	0,129	4,694
NCut	0,964	0,953	0,977	0,750	0,824	0,121	0,620	9,076

Fonte: Autoria própria.

As curvas ROC da Figura 45 ilustram graficamente os resultados para a sensibilidade e especificidade dos métodos nas imagens do corpo das bolhas de gás. A Figura 45 (azul canto superior esquerdo e vermelho) da proposta FLS e RLS, respectivamente, obtiveram áreas superiores a 99,6% de acerto. A curva ROC da Figura 45 (azul canto inferior direito) aponta um performance menor do método por Limiarização, ainda assim com bons resultados com uma área de 93,0% de acerto. Com isso, é possível concluir que em imagens onde se observa bom contraste entre objeto e o fundo, sem presença de ruídos e com boa iluminação, até mesmo uma abordagem considerada simples, conduz a bons resultados.

#### 6.4.3 BASE COM IMAGENS REPRESENTANDO A CAUDA DA BOLHA

Na Tabela 10, as médias para: índice de *F-Measure - precision e recall*, Jaccard, DSC, FPR, FNR e MHD para as imagens da cauda das bolhas de gás são analisadas. Os resultados obtidos por NCut apresentam os melhores índices para *F-measure*, no entanto, esta vantagem não se confirma nas demais métricas. Este fato está relacionado a presença de bolhas dispersas



**Figura 45: Curva ROC, em função da sensibilidade e especificidade, para o corpo das bolhas de gás. Em azul a curva ROC do FLS, em vermelho curva ROC do RLS, em rosa curva ROC do ASM, em verde curva ROC do NCut, em azul claro curva ROC do MLS e em azul (à direita) curva ROC da limirização**

**Fonte: Autoria própria.**

na cauda, ou seja, os índices de intensidade semelhantes dificultam a segmentação correta. Repetidamente, o alto índice para FPR indica que foram segmentados mais pixels do que o necessário para representar a cauda. A FNR mais alta do que as demais abordagens, indica que alguns pixels que pertencem a cauda ficaram de fora da segmentação final, para a abordagem por NCut.


FLS e RLS obtiveram as melhores acurácias, uma vez que seus índices de Jaccard, DSC e MHD são os melhores, indicando uma região segmentada mais semelhante àquela definida por *ground-truth*.

**Tabela 10: Resultado comparativo conjunto de 150 imagens cauda da bolha de gás**

Método	F	R	P	Jaccard	DSC	FPR	FNR	MHD
FLS	0,909	0,961	0,869	0,835	0,909	0,131	0,040	2,486
RLS	0,874	0,893	0,870	0,778	0,874	0,130	0,125	2,942
ASM	0,859	0,820	0,911	0,755	0,859	0,089	0,213	3,550
MLS	0,790	0,687	0,964	0,685	0,790	0,002	0,514	14,252
Limiar	0,765	0,631	0,999	0,631	0,765	0,001	0,660	22,409
NCut	0,913	0,922	0,909	0,486	0,584	0,195	17,532	24,186

**Fonte: Autoria própria.**

A curva ROC da Figura 46 (em azul canto superior esquerdo) para a abordagem proposta FLS obteve uma área de 98,5% de acerto e 96,0% para RLS (em vermelho). A curva ROC da Figura 44 (em azul canto inferior direito) aponta um desempenho pior para o método por Limiarização, com área de 91,11% de acerto, além do afastamento do ponto ideal.



**Figura 46:** Curva ROC, em função da sensibilidade e especificidade, para o cauda das bolhas de gás. Em azul a curva ROC do FLS, em vermelho curva ROC do RLS, em rosa curva ROC do ASM, em verde curva ROC do NCut, em azul claro curva ROC do MLS e em azul (à direita) curva ROC da limiarização

Fonte: Autoria própria.

#### 6.4.4 BASE COM IMAGENS DO ESCOAMENTO PARA DIFERENTES VELOCIDADES DAS BOLHAS DE GÁS

A Tabela 11 apresenta o índice *F-Measure* médio calculado considerando, para cálculo das medidas de precisão e sensibilidade, apenas os pixels pertencentes à região segmentada que melhor aproxima o objeto de interesse. Observe que o método *Level Set* sem conhecimento a priori e o *Active Shape Model* conduzem a resultados inferiores aos métodos propostos, principalmente no que se refere à precisão *P*, indicando uma segmentação em que menos pixels significativos são corretamente classificados. Com relação a sensibilidade *R*, que representa a proporção do total de pixels pertencentes ao objeto que foram classificados corretamente, a segmentação pela abordagem aqui proposta mais uma vez apresenta os melhores resultados em relação a ambas as abordagens (abordagem variacional - FLS).

**Tabela 11: Resultado comparativo por *F-Measure* conjunto de 40 imagens (320 imagens), para diferentes velocidades superficiais**

$J_L/J_G$	<i>Active Shape Model</i>			<i>Level Set - MLS</i>			<i>Abordagem Proposta - FLS</i>		
	F-measure	<i>R</i>	<i>P</i>	F-measure	<i>R</i>	<i>P</i>	F-measure	<i>R</i>	<i>P</i>
0.5-0.3	0,7019	0,8992	0,9801	0,7419	0,6673	0,9822	0,9575	0,9288	0,9923
0.5-0.5	0,6867	0,9250	0,9298	0,7592	0,6860	0,9439	0,9733	0,9540	0,9938
0.5-0.7	0,6602	0,9037	0,8483	0,9301	0,8880	0,9349	0,9728	0,9534	0,9833
0.5-1.0	0,6624	0,8655	0,8130	0,9305	0,8834	0,8156	0,9750	0,9538	0,9186


**Fonte: Autoria própria.**

Estes números refletem o fato de que o método *Level Set* sem conhecimento a priori apresenta dificuldades em segmentar objetos quando aplicado em condições de oclusões ou partes sobrepostas. Já a abordagem *Active Shape Model* apresenta uma maior restrição a forma, segmentando além do necessário.

#### 6.4.5 CÁLCULO DAS PROPRIEDADES RELEVANTES DO PADRÃO GOLFADA

As propriedades relevantes de um escoamento podem ser obtidas a partir da identificação da sua célula unitária. Neste trabalho, uma célula unitária é formada por um conjunto de imagens (frames) contendo nariz, cauda e corpo.

Após as etapas de classificação e segmentação, o sistema desenvolvido detecta automaticamente o início e o fim de cada bolha de gás. Para tanto, foram definidos dois pontos, baseados na representação de linhas e colunas da imagem. Para detectar a entrada e a saída da bolha são consideradas, respectivamente, a última e a primeira coluna da imagem, assim como ilustrado na Figura 47.



**Figura 47: Identificação das colunas da imagem para representação dos pontos inicial (*X*) e final (*Y*)**

**Fonte: Autoria própria**

Cada vez que o nariz da bolha de gás atravessa o ponto inicial, o sistema grava o número do quadro em que este evento ocorre, ou seja, é determinada em qual frame a bolha em análise teve seu início. A partir daí, iniciam-se os cálculos dos parâmetros associados, incluindo

área, comprimento, velocidade da bolha de gás, entre outros, até que a cauda do mesmo atinja o ponto final, determinando a finalização da célula unitária.

Considere como exemplo a Figura 47. Quando a bolha de gás é identificada ao atravessar o ponto inicial (Figura 47 (a)) é armazenada a coluna em que se encontra o primeiro pixel que representa a bolha. Este mesmo procedimento é realizado no último quadro (Figura 47 (b)) em que é possível visualizar o nariz da bolha e, a partir da diferença entre as duas colunas, pode ser calculada a distância que a bolha percorre em média. Considere que  $X$  e  $Y$  denotam as colunas armazenadas. Para a velocidade da bolha  $J_G$  a distância obtida é dividida pelo número de quadros contados neste intervalo.


Nos quadros seguintes, é considerada somente a quantidade de colunas da distância para obter os valores acumulados das áreas da bolha e do pistão de líquido. Para dar continuidade ao cálculo dos valores do pistão de líquido, o sistema continua acumulando seus valores até a chegada da nova bolha de gás, conforme definição de célula unitária (WALLIS, 1969).

Os cálculos realizados após a identificação de cada célula unitária, pela segmentação e representação por imagens binárias, foram baseados nos estudos do Capítulo 2. Dentre elas, as principais foram: cálculo da área  $A_G$  (média) das bolhas de gás (Equações 15, 20 e 25) e a partir dela, volume  $V_G$  das bolhas de gás (Equação 13) e comprimento  $LB$ , velocidade das bolhas de gás  $J_G$  (Equação 11) e velocidade da mistura  $J$  (Equação 11). Esta etapa pode ser realizada em consequência da simplificação gerada pela segmentação, considerando nas imagens binárias resultantes, 1 para bolha e 0 para líquido.

A Figura 48 mostra o comportamento da velocidade da bolha com o aumento da velocidade superficial do gás em uma condição de velocidade superficial do líquido constante. É possível observar que a velocidade da bolha aumenta à medida que há um crescimento de  $J_G$ . Tal fenômeno ocorre devido ao aumento de bolhas dispersas no escoamento.

Os resultados de velocidade da bolha, obtidos nos experimentos, foram comparados ao modelo de fluxo horizontal de Bendiksen (BENDIKSEN, 1984). A Tabela 12 compara os resultados da velocidade  $J$  para a abordagem proposta FLS e para o modelo de fluxo horizontal de Bendiksen. Na Figura 49 pode-se observar os resultados graficamente, tais valores mostraram-se bastante satisfatórios, em que o desvio padrão médio foi de  $0,13m/s$ .

A Figura 50 exemplifica os resultados obtidos sobre os parâmetros associados ao comprimento do gás e do pistão de líquido obtidos pelo FLS, os valores foram comparados aos obtidos pelo sensor wire-mesh (SILVA et al., 2007) e podem ser observados também na Figura 51 para a velocidade média das bolhas de gás.



**Figura 48:** Gráfico do aumento da velocidade da bolha conforme aumenta a velocidade superficial do gás

Fonte: Autoria própria

**Tabela 12:** Resultado comparativo do cálculo da velocidade da mistura ( $J = J_L + J_G$ ) para a metodologia proposta e para Bendiksen (BENDIKSEN, 1984).


$J_L - J_G$	Bendiksen	Level Set
05-03	0,95	0,91
05-05	1,19	1,04
05-07	1,46	1,23
07-03	1,20	1,07
07-05	1,44	1,38
07-07	1,69	1,46
07-10	2,11	1,71

Fonte: Autoria própria.

Observa-se que as medidas obtidas através da segmentação por FLS são bastante precisas em relação aos valores obtidos a partir da correlação de Bendiksen, bem como, aos resultados obtidos pelo sensor *wire-mesh* para a velocidade média das bolhas de gás.

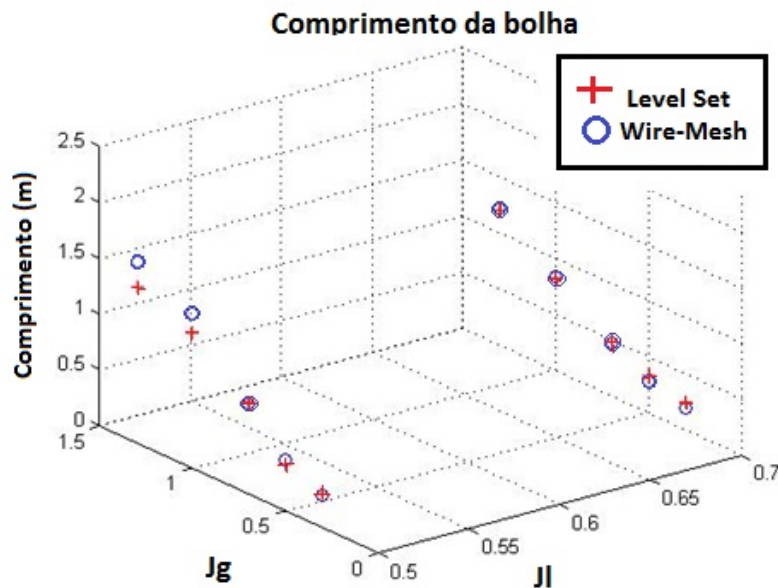
## 6.5 CONSIDERAÇÕES FINAIS

Neste capítulo foram detalhados os resultados experimentais elaborados a partir da abordagem proposta (FLS e RLS). Pode-se comprovar a eficiência da abordagem em ambas as variações FLS e RLS, quando comparada às quatro abordagens amplamente utilizadas em problemas de segmentação, bem como ao resultado esperado definido por um especialista.



**Figura 49:** Gráfico comparativo da velocidade da mistura  $J$


Fonte: Autoria própria



**Figura 50:** Gráfico comparativo do comprimento da bolha de gás e do pistão de líquido

Fonte: Autoria própria

A abordagem FLS mostrou-se eficiente ao segmentar as bolhas de gás do escoamento bifásico gás-líquido em golfadas, especificamente em se tratando da variação do modelo de forma da cauda das bolhas de gás. Também comprovou sua acurácia ao tratar os problemas de bolhas dispersas, sobrepostas ou não a célula unitária. Os resultados sugerem que o método proposto pode ser utilizado para fornecer informações complementares às obtidas com os equi-



**Figura 51: Gráfico comparativo da velocidade da bolha de gás**

**Fonte: Autoria própria**

pamentos normalmente utilizados na medição das propriedades do escoamento.

A abordagem RLS obteve os melhores índices para a maioria das métricas analisadas, quando aplicado a imagens que possuem o alvo com a mesma forma e pose, como nos exemplos ilustrados da base HTZ. Os resultados promissores sugerem que a abordagem proposta pode ser utilizada em diferentes problemas de segmentação, inclusive quando há ocorrência de sobreposições ou até mesmo quando partes do objeto alvo não são visíveis.

A classificação das imagens também se mostrou eficiente ao classificar corretamente conforme as três classes pré-definidas: nariz, corpo e cauda. A criação do vocabulário visual BOW, por meio do descritor SURF e posterior agrupamento por  $k - means$  resultou nos altos índices de acerto do classificador SVM o qual garantiu uma identificação correta da forma para cada nova imagem lida.

No próximo capítulo será descrito as conclusões e perspectivas de trabalhos futuros.



## 7 CONCLUSÕES E TRABALHOS FUTUROS

Neste capítulo são apresentadas as conclusões mais relevantes resultantes do estudo realizado, suas limitações, além de algumas sugestões para desenvolvimento de trabalhos futuros.

### 7.1 CONCLUSÕES

A eficiência nos processos industriais que envolvem os escoamentos multifásicos, bem como a garantia de segurança de seus equipamentos, tem levado pesquisadores de diversas áreas de atuação, a desenvolver sistemas e equipamentos para a correta definição de propriedades importantes que representam o comportamento dos fluidos no escoamento. Apesar da vasta gama de equipamentos já desenvolvidos com objetivo de extrair os valores dessas propriedades, o desenvolvimento de um sistema computacional que possa servir de apoio para a validação e/ou calibração destes equipamentos se faz necessário.

Neste sentido, este trabalho teve como objetivo o desenvolvimento de uma metodologia baseada em processamento de imagens para identificar as bolhas de gás presentes em imagens do escoamento bifásico gás-líquido horizontal em golfadas.

Para tanto, uma nova abordagem baseada em conhecimento a priori da forma e representações *Level Set* foi desenvolvida, com ênfase na definição de uma nova função de velocidade de extensão baseada no treinamento da forma, com duas variações: forma restrita (RLS) ou forma livre (FLS). No método RLS, a função velocidade, representada pela forma previamente conhecida e definida, irá conduzir à evolução da curva de nível zero do *Level Set* em função do gradiente da imagem e da forma, impondo uma restrição a evolução da curva pela diferença entre a forma treinada e a forma que se está procurando. Na variação do método FLS, a função velocidade é representada pela forma e inserida como curva inicial, entretanto, a evolução da curva de nível zero é livre a partir da forma inicial.

O método RLS é executado em quatro etapas: i) obtenção do formato médio do objeto

aplicando o PDM; ii) dada uma nova imagem; iii) posicionamento do marcador (forma) dentro ou fora da região a ser segmentada e iv) evoluir o marcador até reduzir a função de velocidade para próximo de zero, condicionando esta velocidade a velocidade de extensão imposta pela restrição da forma.

O método FLS é executado de forma semelhante ao RLS, ou seja, definição da forma média pelo PDM, definição da forma como marcador inicial e evolução da curva de *Level Set*. Neste caso, não há restrição imposta pela velocidade de extensão, o valor de  $\phi_f$  é definido exclusivamente por  $\phi_i$ .

A grande vantagem da abordagem proposta está relacionada à capacidade de segmentar tanto imagens do escoamento bifásico como imagens que possuam forma e pose previamente conhecidas. Além disso, os resultados comprovaram a capacidade do método de segmentar objeto com partes sobrepostas ou que apresentam oclusões, bem como quando há pequenas variações no formato do objeto.

A robustez e eficiência da abordagem RLS e FLS foram apresentadas no Capítulo 5 na base de dados HTZ e no Capítulo 6 em imagens de escoamento bifásico gás-líquido, juntamente com avaliações quantitativas dos resultados da segmentação, que foram relatadas nas Tabelas 3, 4, 5, 8, 9, 10, 11 e 12. Ambos os resultados qualitativos e quantitativos confirmam o bom desempenho do algoritmo proposto (RLS e FLS).

Foram ilustrados alguns exemplos cujos resultados comprovam a necessidade de conhecimento prévio do objeto no processo de segmentação. As curvas ROC sugerem para ambos os conjuntos de dados, que o método aqui proposto pode ser considerado vantajoso quando comparado tanto com as abordagens de base (ASM e MLS), quanto com as abordagens tradicionais (Limiarização) e atual (*Graph Cut*). Uma vantagem a ser considerada está relacionada ao fato do método poder ser utilizado de duas formas: com evolução restrita ou livre da curva de nível zero. O que não se observa nas demais abordagens, sugerindo que o método aqui proposto poderá ser utilizado num número amplo de problemas de segmentação.

Com relação ao problema de bolhas dispersas em meio líquido das imagens do escoamento, as quais estão relacionadas às intensidades dos seus níveis de cinza, a segmentação pelo método proposto FLS foi superior às demais abordagens comparadas, mostrando-se promissora. Com efeito, a maior parte dos problemas de oclusão e/ou sobreposição é resolvida. Além disso, os bons resultados obtidos na segmentação da base HTZ, sugerem que o método proposto RLS pode ser aplicado para segmentar outras bases de dados, como em imagens médicas por exemplo.

O método proposto foi aplicado no desenvolvimento de um sistema computacional para o escoamento bifásico em golfadas, de forma a identificar e calcular propriedades das células unitárias representadas por um conjunto de imagens. O sistema contou com uma fase de reconhecimento de padrões que identifica as três formas que compõe a bolha em golfada: nariz, corpo e cauda. Para esta etapa, o sistema desenvolvido utilizou a criação do vocabulário visual, ou BOW, para extrair as características que diferenciaram cada padrão, por meio do descritor de características de pontos SURF. Então, a aplicação de *k – means* sobre os descritores gerou agrupamentos com as características semelhantes. Finalmente, aplicando o classificador SVM as imagens puderam ser corretamente categorizadas, o que pôde ser comprovado pelos altos índices de acerto apresentados na matriz de confusão.

Com isso, foi possível desenvolver um software que classifica as imagens do escoamento bifásico dentre as três partes que a compõem, obter a forma correta de cada parte, segmentar a imagem pelo método proposto FLS para finalmente fornecer os valores médios das propriedades acima citadas. A construção da célula unitária possibilitou o cálculo das propriedades relevantes do escoamento e foram comparados através do modelo matemático de *Bendkisen*, bem como pelo sensor *Wire-Mesh*, validando a técnica.

A aplicação do método desenvolvido visou o acompanhamento e a validação dos instrumentos de medição de fração de líquido e gás utilizados pelo Laboratório de Ciências Térmicas - LACIT da UTFPR, de modo que o operador do sistema tivesse acesso às informações das características do padrão golfadas.

Finalmente, o trabalho desenvolvido nessa tese resultou em uma plataforma de ensaio para o processamento e análise de imagens do escoamento bifásico horizontal em golfadas, possibilitando o acompanhamento e validação dos instrumentos de medição de fração de líquido e gás, tal qual utilizado em conjunto com o sensor *Wire-Mesh*. O sistema, portanto, poderá ser empregado na calibração e/ou validação de outros equipamentos que medem as propriedades do escoamento, inclusive em outras representações do escoamento tais como, em tubulações verticais e inclinadas.

Também contou com a criação de uma base de imagens com as informações de validação que poderão ser úteis para o apoio a novas pesquisas na área de escoamento multifásico. Bem como, como resultado desse trabalho, uma abordagem de segmentação genérica que irá contribuir na segmentação de outras bases de dados com objetos que possuam forma e pose previamente conhecidos.

## 7.2 LIMITAÇÕES DO PRESENTE ESTUDO

Algumas limitações foram observadas durante o desenvolvimento deste trabalho e relacionam-se as seguintes questões:

- O sistema desenvolvido ficará restrito a utilização em laboratórios experimentais, uma vez que para aquisição das imagens do escoamento a tubulação deve ser transparente;
- Em relação à aquisição das imagens, para obtenção de imagens com boa resolução é necessário um número alto de frames. Consequentemente, o processo desde aquisição até o cálculo das propriedades relevantes das bolhas em golfada torna-se dispendioso e lento.
- A aplicação em outras bases de dados de imagens fica sujeita ao processo de reconhecimento do objeto para que a curva inicial da forma seja inserida automaticamente.
- O método aqui proposto não trata o problema de rotação dos objetos, neste caso, poderá comprometer a segmentação final.

## 7.3 TRABALHOS FUTUROS

A seguir, são apresentadas algumas sugestões para elaboração de futuros trabalhos:

- Nas imagens do escoamento o sistema é todo automático, uma vez que o treinamento da forma resultou em um conjunto de coordenadas que posicionaram a curva inicial sobre a bolha de gás. Entretanto, para a base de dados *HTZ* a inserção da curva inicial foi manual. Consequentemente, um sistema de reconhecimento de objetos precisará ser implementado a fim de resolver esta questão.
- Os bons resultados obtidos pelo método proposto nas imagens do escoamento horizontal sugerem que tal método poderá ser aplicado em imagens do escoamento vertical, neste caso, novos experimentos serão necessários a fim de confirmar sua aplicabilidade.
- O método *Level Set* pode ser aplicado para a reconstrução 3D de imagens, esta extensão auxiliará na visualização do comportamento dos fluidos no fluxo.
- O desenvolvimento de um mecanismo que permita a rotação da forma, a fim de segmentar objeto com rotações diferentes daquela gerada pelo treinamento da forma.

- Aplicar o método proposto em imagens médicas, área de grande interesse da comunidade científica.

## REFERÊNCIAS

- ADALSTEINSSON, D.; SETHIAN, J. The fast construction of extension velocities in level set methods. **J. Comput. Phys.**, Academic Press Professional, Inc., San Diego, CA, USA, v. 148, n. 1, p. 2–22, jan. 1999. ISSN 0021-9991. Disponível em: <<http://dx.doi.org/10.1006/jcph.1998.6090>>.
- ALPERT, S. et al. Image segmentation by probabilistic bottom-up aggregation and cue integration. In: **IEEE Conf. on Computer Vision and Pattern Recognition, Minneapolis, CVPR-07**. [S.l.: s.n.], 2007.
- AMARAL, C. do et al. Image processing techniques for high-speed videometry in horizontal two-phase slug flows. **Flow Measurement and Instrumentation**, v. 33, n. 0, p. 257 – 264, 2013. ISSN 0955-5986. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0955598613000939>>.
- ARTHUR, D.; VASSILVITSKII, S. k-means++: The advantages of careful seeding. In: SOCIETY FOR INDUSTRIAL AND APPLIED MATHEMATICS. **Proceedings of the eighteenth annual ACM-SIAM symposium on Discrete algorithms**. [S.l.], 2007. p. 1027–1035.
- ASLAN, M. S. et al. Probabilistic shape-based segmentation method using level sets. **Computer Vision, IET, IET**, v. 8, n. 3, p. 182–194, 2014.
- AZZOPARDI, B. **Gas - Liquid Flows**. [S.l.]: Begell House, 2006.
- BAY, H.; TUYTELAARS, T.; GOOL, L. V. Surf: Speeded up robust features. In: **Computer vision–ECCV 2006**. [S.l.]: Springer, 2006. p. 404–417.
- BENDIKSEN, K. H. An experimental investigation of the motion of long bubbles in inclined tubes. **International Journal of Multiphase Flow**, v. 10, n. 4, p. 467 – 483, 1984. ISSN 0301-9322. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0301932284900570>>.
- BOYKOV, Y.; FUNKA-LEA, G. Graph cuts and efficient nd image segmentation. **International journal of computer vision**, Springer, v. 70, n. 2, p. 109–131, 2006.
- BRESSON, X.; VANDERGHEYNST, P.; THIRAN, J. A priori information in image segmentation: energy functional based on shape statistical model and image information. In: **Image Processing, 2003. ICIP 2003. Proceedings. 2003 International Conference on**. [S.l.: s.n.], 2003. v. 3, p. III–425–8 vol.2. ISSN 1522-4880.
- BRESSON, X.; VANDERGHEYNST, P.; THIRAN, J.-P. A variational model for object segmentation using boundary information and shape prior driven by the mumford-shah functional. **International Journal of Computer Vision**, Springer, v. 68, n. 2, p. 145–162, 2006.
- BURGER, M.; HACKL, B.; RING, W. Incorporating topological derivatives into level set methods. **Journal of Computational Physics**, Elsevier, v. 194, n. 1, p. 344–362, 2004.

CABEZAS, M. et al. A review of atlas-based segmentation for magnetic resonance brain images. **Comput. Methods Prog. Biomed.**, Elsevier North-Holland, Inc., New York, NY, USA, v. 104, n. 3, p. e158–e177, dez. 2011. ISSN 0169-2607. Disponível em: <<http://dx.doi.org/10.1016/j.cmpb.2011.07.015>>.

CAMILUS, K. S.; GOVINDAN, V. A review on graph based segmentation. **International Journal of Image, Graphics and Signal Processing (IJIGSP)**, v. 4, n. 5, p. 1, 2012.

CHANG, H.; YANG, Q.; PARVIN, B. A bayesian approach for image segmentation with shape priors. In: IEEE. **Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on**. [S.l.], 2008. p. 1–8.

CHEN, Y. et al. Using prior shapes in geometric active contours in a variational framework. **International Journal of Computer Vision**, Springer, v. 50, n. 3, p. 315–328, 2002.

CHEN, Y. et al. On the incorporation of shape priors into geometric active contours. In: IEEE. **Variational and Level Set Methods in Computer Vision, 2001. Proceedings. IEEE Workshop on**. [S.l.], 2001. p. 145–152.

COOTES, T.; BALDOCK, E.; GRAHAM, J. An introduction to active shape models. **Image processing and analysis**, Oxford University Press, p. 223–248, 2000.

COOTES, T.; EDWARDS, G.; TAYLOR, C. Active appearance models. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, v. 23, n. 6, p. 681–685, Jun 2001. ISSN 0162-8828.

COOTES, T. F. et al. Active shape models-their training and application. **Computer vision and image understanding**, Elsevier, v. 61, n. 1, p. 38–59, 1995.

CREMERS, D.; ROUSSON, M.; DERICHE, R. A review of statistical approaches to level set segmentation: Integrating color, texture, motion and shape. **International Journal of Computer Vision**, Kluwer Academic Publishers, v. 72, n. 2, p. 195–215, 2007. ISSN 0920-5691. Disponível em: <<http://dx.doi.org/10.1007/s11263-006-8711-1>>.

CREMERS, D.; SCHNORR, C.; WEICKERT, J. Diffusion-snakes: combining statistical shape knowledge and image information in a variational framework. In: IEEE. **Variational and Level Set Methods in Computer Vision, 2001. Proceedings. IEEE Workshop on**. [S.l.], 2001. p. 137–144.

CSURKA, G. et al. Visual categorization with bags of keypoints. In: **Workshop on statistical learning in computer vision, ECCV**. [S.l.: s.n.], 2004. v. 1, n. 1-22, p. 1–2.

DINH, T. B.; KIM, B. S.; CHOI, T.-S. Application of image processing techniques to air/water two-phase flow. **Proc. SPIE 3808**, p. 725–730, 1999.

DIOP, E. H. S.; BURDIN, V. Bi-planar image segmentation based on variational geometrical active contours with shape priors. **Medical Image Analysis**, v. 17, n. 2, p. 165 – 181, 2013. ISSN 1361-8415. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1361841512001351>>.

DORINI, L. B. **Transformação de imagens baseadas em Morfologia Matemática**. Tese (Doutorado) — Unicamp - Universidade Estadual de Campinas, Campinas, 2009.

DORINI, L. B.; ANDRADE, M. L. S. C.; ARRUDA, L. V. R. Level set based image segmentation for two-phase flow parameter measurement. **Proceedings of IEEE International Conference on Imaging Systems and Techniques**, 2011.

DUBUISSON, M.-P.; JAIN, A. A modified hausdorff distance for object matching. In: **Pattern Recognition, 1994. Vol. 1 - Conference A: Computer Vision and Image Processing., Proceedings of the 12th IAPR International Conference on**. [S.l.: s.n.], 1994. v. 1, p. 566–568 vol.1.

FERRARI, V. et al. From images to shape models for object detection. **International Journal of Computer Vision**, 2009. In press.

FERRARI, V.; TUYTELAARS, T.; GOOL, L. V. Object detection by contour segment networks. In: **Proceeding of the European Conference on Computer Vision**. [S.l.]: Elsevier, 2006. (LNCS, v. 3953), p. 14–28.

GELAS, A. et al. Compactly supported radial basis functions based collocation method for level-set evolution in image segmentation. **Image Processing, IEEE Transactions on, IEEE**, v. 16, n. 7, p. 1873–1887, 2007.

GONÇALVES, P.; TAVARES, J. M.; JORGE, R. Segmentation and simulation of objects represented in images using physical principles. **Computer Modeling in Engineering & Sciences**, 2008.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. [S.l.]: Prentice Hall, 2001.

GRANGEIRO, F. F. **Caracterização do escoamento intermitente horizontal água-ar através de ultrassom auxiliado por filmagem ultrarrápida**. Dissertação (Mestrado) — Universidade Estadual de Campinas, Campinas, Brasil, 2010.

GRAU, R.; HEISKANEN, K. Visual technique for measuring bubble size in flotation machines. **Minerals Engineering**, v. 15, p. 507–513, 2002.

HAMARNEH, G. **Active shape models, modeling shape variations and gray level information and an application to image search and classification**. [S.l.]: Citeseer, 1998.

HEWITT, G. F. **Handbook of Multiphase Systems**. [S.l.]: Hemisphere Publishing Corporation, 1982.

JACCARD, P. The distribution of the flora in the alpine zone.1. **New Phytologist**, Blackwell Publishing Ltd, v. 11, n. 2, p. 37–50, 1912. ISSN 1469-8137. Disponível em: <<http://dx.doi.org/10.1111/j.1469-8137.1912.tb05611.x>>.

JAIN, A. K. **Fundamentals of Digital Image Processing**. [S.l.]: Prentice Hall, 1989.

JAIN, R. K. R.; SCHUNCK, B. G. **Machine Vision**. [S.l.: s.n.], 1995.

JONES, O. C.; ZUBER, N. The interrelation between void fraction fluctuations and flow patterns in two phase flow. **International Journal Multiphase Flow**, v. 2, p. 273–306, 1975.

KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: Active contour models. **International Journal of Computer Vision**, v. 1, n. 4, p. 321–331, 1987.



KUMAR, B. V.; SAVVIDES, M.; XIE, C. Correlation pattern recognition for face recognition. **Proceedings of the IEEE**, IEEE, v. 94, n. 11, p. 1963–1976, 2006.

KUMAR, S. B.; MOSLEMIAN, D.; DUDUKOVIC, M. P. Gas-holdup measurements in bubble columns using computed tomography. **AIChE Journal**, American Institute of Chemical Engineers, v. 43, n. 6, p. 1414–1425, 1997. ISSN 1547-5905. Disponível em: <<http://dx.doi.org/10.1002/aic.690430605>>.

LANKTON, S.; TANNENBAUM, A. Localizing region-based active contours. **Image Processing, IEEE Transactions on**, v. 17, n. 11, p. 2029–2039, Nov 2008. ISSN 1057-7149.

LECELLIER, F.; JEHAN-BESSON, S.; FADILI, J. Statistical region-based active contours for segmentation: an overview. **IRBM**, Elsevier, v. 35, n. 1, p. 3–10, 2014.

LEVENTON, M. E.; GRIMSON; FAUGERAS, O. Statistical shape influence in geodesic active contours. In: **Computer Vision and Pattern Recognition, 2000. Proceedings. IEEE Conference on**. [s.n.], 2000. v. 1, p. 316–323. Disponível em: <<http://dx.doi.org/10.1109/cvpr.2000.855835>>.

LI CHENYANG XU, C. G. C.; FOX, M. Level set evolution without re-initialization: A new variational formulation. **IEEE Computer Society Conference on Computer Vision and Pattern Recognition**, IEEE Computer Society, Washington, DC, USA, v. 1, p. 430–436, 2005.

LUO, Z.; TONG, L.; KANG, Z. A level set method for structural shape and topology optimization using radial basis functions. **Computers & Structures**, v. 87, n. 778, p. 425 – 434, 2009. ISSN 0045-7949. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0045794909000273>>.

MA, Z. et al. A review of algorithms for medical image segmentation and their applications to the female pelvic cavity. **Computer Methods in Biomechanics and Biomedical Engineering**, Taylor & Francis, v. 13, n. 2, p. 235–246, 2010.

MANDHANE, J.; GREGORY, G.; AZIZ, K. A flow pattern map for gas liquid flow in horizontal pipes. **International Journal of Multiphase Flow**, v. 1, n. 4, p. 537 – 553, 1974. ISSN 0301-9322. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0301932274900068>>.

MAYOR, T.; PINTO, A.; CAMPOS, J. An image analysis technique for the study of gas-liquid slug flow along vertical pipes - associated uncertainty. **Flow Measurement and Instrumentation**, v. 18, n. 3-4, p. 139–147, 2007. Disponível em: <<http://dx.doi.org/10.1016/j.flowmeasinst.2007.05.004>>.

MORSE, B. et al. Active contours using a constraint-based implicit representation. In: **Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on**. [S.l.: s.n.], 2005. v. 1, p. 285–292 vol. 1. ISSN 1063-6919.

MUMFORD, D.; SHAH, J. Optimal approximations by piecewise smooth functions and associated variational problems. **Communications on pure and applied mathematics**, Wiley Online Library, v. 42, n. 5, p. 577–685, 1989.

NAPOLITANO, L. M. B. **Implementação numérica do Método Level Set para Propagação de Curvas e Superfícies**. Dissertação (Mestrado) — Instituto de Física da USP, 2004.

NETTO, J. F.; FABRE, J.; PERESSON, L. Shape of long bubbles in horizontal slug flow. **International Journal of multiphase flow**, Elsevier, v. 25, n. 6, p. 1129–1160, 1999.

OSHER, S.; FEDKIW, R. **Level Set Methods and Dynamic Implicit Surfaces**. [S.l.]: Springer, 2003.

OSHER, S.; SETHIAN, J. A. Fronts propagating with curvature-dependent speed: algorithms based on hamilton-jacobi formulations. **Journal of computational physics**, Elsevier, v. 79, n. 1, p. 12–49, 1988.

PHILBIN, J. et al. Object retrieval with large vocabularies and fast spatial matching. In: **IEEE. Computer Vision and Pattern Recognition, 2007. CVPR'07. IEEE Conference on**. [S.l.], 2007. p. 1–8.

PIPA, D. R. et al. Typical bubble shape estimation in two-phase flow using inverse problem techniques. **Flow Measurement and Instrumentation**, v. 40, p. 64 – 73, 2014. ISSN 0955-5986. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0955598614001022>>.

POWELL, R. L. Experimental techniques for multiphase flows. **Physics of Fluids**, v. 20, p. 1–20, 2008.

PRASSER, H.; BÖTTGER, A.; ZSCHAU, J. A new electrode-mesh tomograph for gas-liquid flows. **Flow Measurement and Instrumentation**, v. 9, n. 2, p. 111 – 119, 1998. ISSN 0955-5986. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0955598698000156>>.

QIN, X. et al. Adaptive shape prior constrained level sets for bladder mr image segmentation. **Biomedical and Health Informatics, IEEE Journal of**, v. 18, n. 5, p. 1707–1716, Sept 2014. ISSN 2168-2194.

RIAÑO, A. B.; BANNWART, A.; RODRIGUEZ, O. Holdup estimation in core flow using image processing. In: **Instrumentation and Measurement Technology Conference (I2MTC), 2013 IEEE International**. [S.l.: s.n.], 2013. p. 334–338. ISSN 1091-5281.

RIAÑO, A. B. et al. Film thickness measurement in oil–water pipe flow using image processing technique. **Experimental Thermal and Fluid Science**, Elsevier, v. 68, p. 330–338, 2015.

RODRIGUES, H. T. **Simulação Numérica do Escoamento Bifásico Gás-líquido no Padrão de Golfadas Utilizando um Modelo Lagrangeano de Seguimento de Pistões**. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, Curitiba, Brasil, Outubro 2009.

ROUSSON, M.; CREMERS, D. Efficient kernel density estimation of shape and intensity priors for level set segmentation. In: **Medical Image Computing and Computer-Assisted Intervention–MICCAI 2005**. [S.l.]: Springer, 2005. p. 757–764.

ROUSSON, M.; PARAGIOS, N. Shape priors for level set representations. In: **Computer Vision ECCV 2002**. [S.l.]: Springer Berlin Heidelberg, 2002, (Lecture Notes in Computer Science, v. 2351). p. 78–92. ISBN 978-3-540-43744-4.

SCHMITT, D.; MCCOY, N. **Object classification and localization using SURF descriptors**. [S.l.]: Citeseer, 2011.

SCHWARTZ, H. P. e W. R. **Análise de Imagens Digitais**. [S.l.]: Thomson Learning, 2008.

SETHIAN, J. A. Theory, algorithms, and applications of level set methods for propagating interfaces. **Acta numerica**, Cambridge Univ Press, v. 5, p. 309–395, 1996.

SETHIAN, J. A. **Level Set Methods and Fast Marching Methods: Evolving Interfaces in Computational Geometry, Fluid Mechanics, Computer Vision and Materials Science**. [S.l.]: Cambridge UPress, 1999.

SHI, J.; MALIK, J. Normalized cuts and image segmentation. In: **Computer Vision and Pattern Recognition, 1997. Proceedings., 1997 IEEE Computer Society Conference on**. [S.l.: s.n.], 1997. p. 731–737. ISSN 1063-6919.

SHI, L.; ZHOU, Z.; REN, R. Parameter measurements of two-phase bubbly flow using digital image processing. In: **5th World Congress on Intelligent Control and Automation**. [S.l.: s.n.], 2004. p. 3858–3861.

SHIN, M. C.; GOLDFOG, D. B.; BOWYER, K. W. Comparison of edge detector performance through use in an object recognition task. **Computer Vision and Image Understanding**, v. 84, n. 1, p. 160 – 178, 2001. ISSN 1077-3142. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1077314201909324>>.

SHOHAM, O. **Mechanistic modelling of gas-liquid two-phase flow in pipes**. [S.l.]: Richardson, Tx(USA):SPE, 2006.

SILVA, M. D.; SCHLEICHER, E.; HAMPEL, U. Capacitance wire-mesh sensor for fast measurement of phase fraction distributions. **Measurement Science and Technology**, IOP Publishing, v. 18, n. 7, p. 2245, 2007.

SONKA, M.; HLAVAC, V.; BOYLE, R. **Image processing, analysis, and machine vision**. [S.l.]: Cengage Learning, 2014.

STEINBRUCH, A.; WINTERLE, P. **Introdução à Álgebra Linear**. [S.l.]: McGraw-Hill, 1990.

TAITEL, Y.; BARNEA, D. 1990 taitel, y[1]. e barnea, d. - a consistent approach for calculating pressure drop in inclined.pdf. **Chemical Engineering Science**, v. 45, n. 5, p. 1199–1206, 1990.

TAITEL, Y.; DUKLER, A. E. A model for predicting flow regime transitions in horizontal and near horizontal gas-liquid flow. **AIChE Journal**, Wiley Online Library, v. 22, n. 1, p. 47–55, 1976. Disponível em: <<http://dx.doi.org/10.1002/aic.690220105>>.

THIRUVENKADAM, S. R.; CHAN, T. F.; HONG, B.-W. Segmentation under occlusions using selective shape prior. In: **Scale Space and Variational Methods in Computer Vision**. [S.l.]: Springer, 2007. p. 191–202.

TOMOSHIGE, S. et al. A conditional statistical shape model with integrated error estimation of the conditions; application to liver segmentation in non-contrast {CT} images. **Medical Image Analysis**, v. 18, n. 1, p. 130 – 143, 2014. ISSN 1361-8415. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1361841513001473>>.

TSAI, A. et al. Model-based curve evolution technique for image segmentation. In: IEEE. **Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on**. [S.l.], 2001. v. 1, p. I–463.

TSAI, A. et al. A shape-based approach to the segmentation of medical imagery using level sets. **Medical Imaging, IEEE Transactions on**, IEEE, v. 22, n. 2, p. 137–154, 2003.

TSAI, R.; OSHER, S. Level set methods and their applications in image science. **Comm. Math Sci**, v. 1, p. 623–656, 2003.

TSOUKALAS, L. H.; ISHII, M.; MI, Y. A neurofuzzy methodology for impedance-based multiphase flow identification. **Engineering Applications of Artificial Intelligence**, v. 10, n. 6, p. 545–555, 1997. Disponível em: <<http://www.sciencedirect.com/science/article/B6V2M-3TDH5YN-6/2/232e6236b79038d08e3b4ac9cc045d6c>>.

VAPNIK, V. N.; VAPNIK, V. **Statistical learning theory**. [S.l.]: Wiley New York, 1998.

VERNON, D. **Machine Vision: Automated Visual Inspection and Robot Vision**. [S.l.]: Prentice Hall, 1991.

VESE, L. A.; CHAN, T. F. A multiphase level set framework for image segmentation using the mumford and shah model. **International journal of computer vision**, Springer, v. 50, n. 3, p. 271–293, 2002.

WAHAB, Y. A. et al. Non-invasive process tomography in chemical mixtures—a review. **Sensors and Actuators B: Chemical**, Elsevier, v. 210, p. 602–617, 2015.

WALLIS, G. B. **One-dimensional two-phase flow**. [S.l.]: McGraw-Hill, 1969.

WARBITO, M. Cross-sectional distributions of gas and solid holdups in slurry bubble column investigated by ultrasonic computed tomography. **Chemical Engineering Science**, v. 54, n. 21, p. 4711–4728, 1999. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S000925099900175X>>.

WELLNER, P. Interacting with paper on the digitaldesk. **Communications of the ACM**, ACM, v. 36, n. 7, p. 87–96, 1993.

WU, Z.; LEAHY, R. An optimal graph theoretic approach to data clustering: theory and its application to image segmentation. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, v. 15, n. 11, p. 1101–1113, Nov 1993. ISSN 0162-8828.

XIE, X.; MIRMEHDI, M. Radial basis function based level set interpolation and evolution for deformable modelling. **Image and Vision Computing**, v. 29, n. 2?3, p. 167 – 177, 2011. ISSN 0262-8856. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0262885610001277>>.

YANG, R. et al. Shape and appearance priors for level set-based left ventricle segmentation. **Computer Vision, IET**, v. 7, n. 3, p. 170–183, June 2013. ISSN 1751-9632.

YANG, Y. et al. Multilayer graph cuts based unsupervised color–texture image segmentation using multivariate mixed student’s t-distribution and regional credibility merging. **Pattern Recognition**, Elsevier, v. 46, n. 4, p. 1101–1124, 2013.

YU, X. et al. Measurement technique for solid-liquid two-phase flow using a normal-line hough transform method. **Journal of Physics**, p. 147(1):81–89, 2009.

ZABULIS, X. et al. Detection of densely dispersed spherical bubbles in digital images based on a template matching technique application to wet foams. **Colloids and Surfaces**, v. 309, n. 1-3, p. 96–106, 2007. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0927775707000210>>.

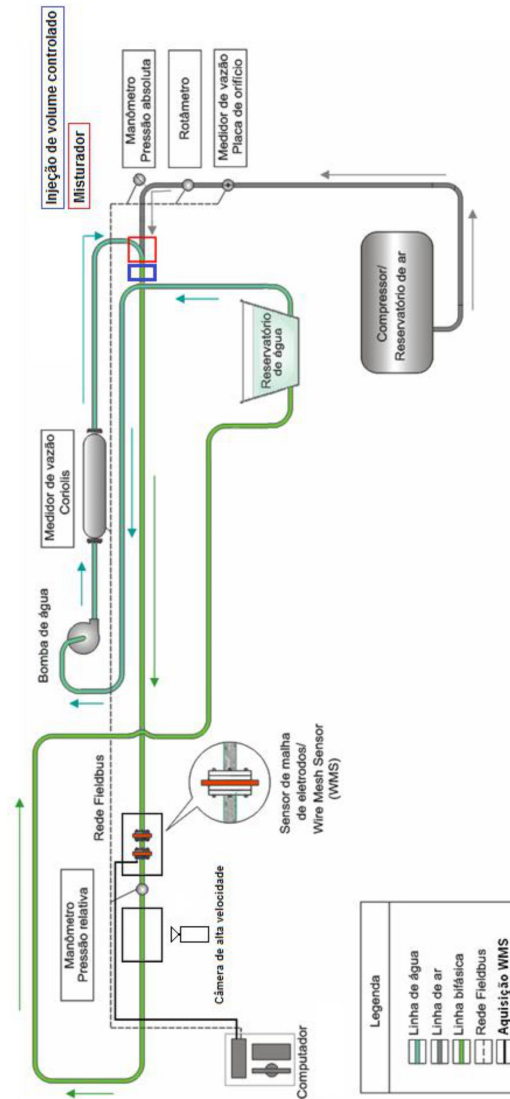
ZHANG, K. et al. Active contours with selective local or global segmentation: A new formulation and level set method. **Image and Vision Computing**, v. 28, n. 4, p. 668 – 676, 2010. ISSN 0262-8856. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0262885609002303>>.

ZHU, B.; ZHANG, X.; FATIKOW, S. Structural topology and shape optimization using a level set method with distance-suppression scheme. **Computer Methods in Applied Mechanics and Engineering**, v. 283, n. 0, p. 1214 – 1239, 2015. ISSN 0045-7825. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0045782514002874>>.

ZWEIG, M. H.; CAMPBELL, G. Receiver-operating characteristic (roc) plots: a fundamental evaluation tool in clinical medicine. **Clinical chemistry**, Am Assoc Clin Chem, v. 39, n. 4, p. 561–577, 1993.

## **APÊNDICE A – CIRCUITO PARA AQUISIÇÃO DAS IMAGENS DA BASE DE TESTES**

As imagens utilizadas nos experimentos deste trabalho foram adquiridas no LACIT - Laboratório de Ciências Térmicas - da Universidade Tecnológica Federal do Paraná, campus Curitiba. O circuito utilizado é ilustrado na Figura 52.



**Figura 52: Circuito experimental de escoamentos bifásicos do Laboratório de Escoamento de Fluidos da UTFPR**

## APÊNDICE B – CÁLCULO DA DERIVADA GÂTEAUX E FUNÇÃO DIRAC

Ao cálculo das variações, a derivada Gâteaux da funcional  $\varepsilon$  na Equação 49 pode ser escrita por:

$$\frac{\partial \varepsilon}{\partial \phi} = -\mu[\Delta\phi - \operatorname{div}\left(\frac{\nabla\phi}{|\nabla\phi|}\right)] - \lambda\delta(\phi)\operatorname{div}\left(g\frac{\nabla\phi}{|\nabla\phi|}\right) - v g\delta(\phi) \quad (56)$$

em que  $\partial$  é o operador Laplaciano. Portanto, a função  $\phi$  que minimiza esta funcional, satisfaz a equação Euler-Lagrangeana  $\frac{\partial \varepsilon}{\partial \phi} = 0$ . O processo de descida mais íngreme para a minimização da funcional é o seguinte fluxo do gradiente:

$$\frac{\partial \phi}{\partial t} = \mu[\Delta\phi - \operatorname{div}\left(\frac{\nabla\phi}{|\nabla\phi|}\right)] + \lambda\delta(\phi)\operatorname{div}\left(g\frac{\nabla\phi}{|\nabla\phi|}\right) - v g\delta(\phi) \quad (57)$$

Este fluxo do gradiente é a equação de evolução do *Level Set* proposto em Li e colaboradores (2005). O segundo e o terceiro termo do lado direito correspondem aos fluxos de gradiente da energia funcional  $\lambda L_g(\phi)$  e  $v A_g(\phi)$  respectivamente e são responsáveis por dirigir a curva de nível zero na direção dos limites do objeto (LI CHENYANG XU; FOX, 2005).

A função Dirac  $\delta(x)$  na Equação 57 é suavizada pela função  $\delta_\varepsilon(x)$  definida por:

$$\delta_\varepsilon(x) = \begin{cases} 0 & \text{se, } |x| > \varepsilon \\ \frac{1}{2\varepsilon}[1 + \cos(\frac{\pi x}{\varepsilon})] & \text{se, } |x| \leq \varepsilon. \end{cases} \quad (58)$$

Todas as derivadas parciais espaciais  $\frac{\partial \phi}{\partial x}$  e  $\frac{\partial \phi}{\partial y}$  são aproximadas pela diferença central, e a derivada parcial temporal  $\frac{\partial \phi}{\partial t}$  é aproximada pela diferença para a frente. A aproximação da Equação 57 pelo esquema de diferença acima pode ser simplesmente escrita por:

$$\frac{\phi_{i,j}^{k+1} - \phi_{i,j}^k}{\tau} = L(\phi_{i,j}^k) \quad (59)$$

em que  $\phi_{i,j}$  é a aproximação do lado direito da Equação 57 pelo regime de diferença espacial acima. A equação diferença 59 pode ser expressa com a seguinte iteração:



$$\phi_{i,j}^{k+1} = \phi_{i,j}^k + \tau L(\phi_{i,j}^k) \quad (60)$$

## APÊNDICE C – LISTA DE PUBLICAÇÕES

SGUARIO, M. L, ARRUDA, MORALES, R. Segmentation of two-phase flow: A free representation for Level Set method with a priori knowledge. **Journal: Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization**, pages 1-14, 2015. Disponível em: <http://dx.doi.org/10.1080/21681163.2015.1064030>.

SGUARIO, M. L, ARRUDA, L. V. R., Buss, I. and Nascimento, H. C. Segmentation of two-phase flow: A free representation for level set method with a priori knowledge. **Computational Modeling of Objects Presented in Images. Fundamentals, Methods, and Applications**. Springer International Publishing, 2014, (Lecture Notes in Computer Science, v. 8641). p. 115/132. ISBN 978-3-319-09993-4. Disponível em: <http://dx.doi.org/10.1007/978-3-319-09994-111>:

ANDRADE, M. L. S. C.; SANTOS, E. N.; DORINI, L. B.; ARRUDA, L. V. R.; SILVA, M. J.. Estudo Comparativo da Velocidade Superficial de Bolhas de Ar em Escoamento Bifásico Horizontal: Método Level Set vs. Sensor Wire-Mesh. In: Encontro Brasileiro sobre Ebulição, Condensação e Escoamento Multifásico, 2012, Curitiba. **Proceedings of 3rd EBECM, 2012**.

ANDRADE, M. L. S. C. de; E. N.; DORINI, L. B.; ARRUDA, L. V. R.; Digital Image Segmentation To Apply Two-Phase Flow Gas-Liquid In Golf. In: Rio Oil & Gas Expo and Conference, 2012, Rio de Janeiro. **Proceedings of Rio Oil & Gas Expo and Conference, 2012**.

DORINI, L. B.; ANDRADE, M. L. S. C.; ARRUDA, L. V. R. Level set based image segmentation for two-phase flow parameter measurement. **Proceedings of IEEE International Conference on Imaging Systems and Techniques, 2011**.