

MARCELO ADRIÁN FLORES MANRIQUE

Uma Proposta de Solução Algorítmica para Monitoração de Processos Industriais: Aplicação de Processamento de Imagens na Detecção de Níveis de Líquidos

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Informática, Instituto de Matemática, Núcleo de Computação eletrônica, Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Informática.

Orientadores:

Antonio Carlos Gay Thomé
Ph. D.

Josefino Cabral Melo Lima
Ph. D.

RIO DE JANEIRO

2008

MARCELO ADRIÁN FLORES MANRIQUE

Uma Proposta de Solução Algorítmica para Monitoração de Processos Industriais: Aplicação de Processamento de Imagens na Detecção de Níveis de Líquidos

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Informática, Instituto de Matemática, Núcleo de Computação Eletrônica, Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Informática.

Aprovada em:

Rio de Janeiro, de de 2008

Antonio Carlos Gay Thomé, Ph. D. - DCC/UFRJ - Orientador

Josefino Cabral Melo Lima, Ph. D. - DCC/UFRJ - Orientador

Antonio Alberto Fernandes de Oliveira, D. Sc. - COPPE/UFRJ

Adriano Joaquim de Oliveira Cruz, Ph. D. – DCC/UFRJ

*“Quem nunca errou nunca experimentou
nada novo”
Albert Einstein*

*“A imaginação é mais importante
que o conhecimento.”
Albert Einstein*

*“O único lugar onde o sucesso vem antes
do trabalho é no dicionário.”
Albert Einstein*

*À minha família, Mamá, Papá,
André, Abuelita Gabi*

A Deus

AGRADECIMENTOS

Em primeiro lugar para Deus e para minha família, por me ajudar a realizar este sonho.

Aos meus orientadores, professores Thomé e Cabral, pela sua dedicação e apoio ao longo da dissertação.

Ao professor Adriano por sua grande colaboração e sugestões.

Aos professores que são parte da banca, por aceitar o convite para avaliar esta dissertação.

Aos professores do NCE, não somente pelos conhecimentos transmitidos ao longo deste mestrado, mas também pelos conselhos e experiências que levarei comigo por sempre.

Continuem na luta.

À minha grande amiga Vanessa Godoy. Sem você este trabalho não teria sido possível.

Obrigado por me ajudar com as correções da tese. Cuida do Bob!

Aos grandes amigos que conheci ao longo deste mestrado, Rogério, Allan, Marcelo Índio, Ana e Danielle. Muito sucesso para vocês! Rogério, obrigado por me ajudar com as correções da tese.

Agradeço também ao CENPES, PETROBRAS e ao NCE pelo suporte financeiro e pelos recursos brindados para realizar esta pesquisa.

A Maurício Carvalho dos Santos (CENPES), por me permitir fazer parte deste projeto.

Ao Henrique pela ajuda na programação do módulo de captura DirectX.

RESUMO

FLORES, Marcelo Adrián, **Uma Proposta de Solução Algorítmica para Monitoração de Processos Industriais: Aplicação de Processamento de Imagens na Detecção de Níveis de Líquidos**. Rio de Janeiro, 2008. Dissertação (Mestrado em Informática)-Instituto de Matemática, Núcleo de Computação Eletrônica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2008.

O controle do nível de líquidos é uma tarefa comum nos processos químicos. A monitoração em tempo real de fluidos com diferentes densidades não é uma tarefa fácil de ser executada utilizando sensores tradicionais como, por exemplo, bóias. A maioria desses sensores clássicos possui parâmetros que devem de ser reconfigurados quando utilizados para monitorar seqüencialmente líquidos com densidades e cores variáveis. Toda vez que um novo tipo de líquido é monitorado, faz-se necessário recalibrar os parâmetros do sensor. Uma grande desvantagem da recalibragem do sensor é a necessidade de pausar o processo que está sendo monitorado. Outra desvantagem de alguns sensores tradicionais é a falta de segurança dos mesmos quando utilizados na monitoração de líquidos inflamáveis. Na presente dissertação será descrito um modelo proposto para resolver o problema de monitoração de líquidos com densidades variáveis em tempo real baseado no uso de técnicas de processamento de imagens. O estudo se encaixa na área de Visão de Máquina. O método proposto foi testado em um estudo de caso real: a destilação de frações de petróleo em batelada.

Palavras-chave: processamento de imagens, visão de máquina, destilação em batelada.

ABSTRACT

FLORES, Marcelo Adrián, **Uma Proposta de Solução Algorítmica para Monitoração de Processos Industriais: Aplicação de Processamento de Imagens na Detecção de Níveis de Líquidos**. Rio de Janeiro, 2008. Dissertação (Mestrado em Informática)-Instituto de Matemática, Núcleo de Computação Eletrônica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2008.

Fluid level monitoring is a common control task in chemical processes. The on-line level monitoring of fluids with different densities is not an easy task to be accomplished using traditional sensors, as floats for example. Most of the classic sensors have parameters that require to be recalibrated several times when used in liquid monitoring with varying densities. In order to accomplish the recalibration, the process must be paused to suit the new liquid characteristics. Another disadvantage of some traditional level monitoring methods is that they are not safe to be used with flammable liquids. In this dissertation we describe a density invariant and non contact approach for level monitoring based on image processing techniques. The proposed method was tested in the monitoring of the level of different fractions produced during a crude oil distillation process.

Keywords: image processing, machine vision, oil distillation process

SUMÁRIO

1	INTRODUÇÃO	20
1.1	ESCOPO DO SISTEMA	21
1.2	SISTEMAS EM TEMPO REAL	22
1.3	VANTAGENS DO USO DE PROCESSAMENTO DE IMAGENS NO CONTROLE DE PROCESSOS ..	23
1.4	COMPONENTES BÁSICOS DE UM SISTEMA DE VISÃO DE MÁQUINA	24
1.5	MOTIVAÇÃO	25
1.6	OBJETIVOS DA PESQUISA	26
1.6.1	<i>Objetivo Principal</i>	26
1.6.2	<i>Secundários</i>	27
1.7	ESTUDO DE CASO DESENVOLVIDO	27
1.8	ORGANIZAÇÃO DA DISSERTAÇÃO.....	27
2	VISÃO DE MÁQUINA	28
2.1	INTRODUÇÃO	28
2.2	DEFINIÇÃO DE VISÃO DE MÁQUINA.....	28
2.3	HISTÓRIA VISÃO DE MÁQUINA.....	28
2.4	VISÃO HUMANA X VISÃO DE MÁQUINA.....	30
2.5	COMPONENTES BÁSICOS DE UM SISTEMA DE VISÃO DE MÁQUINA	31
2.5.1	<i>Iluminação</i>	31
2.5.2	<i>Sensor de Imagem</i>	34
2.6	ALGORITMOS PARA O TRATAMENTO DE IMAGENS	37
2.6.1	<i>Pré-processamento</i>	37

2.6.2	<i>Segmentação</i>	45
2.6.3	<i>Extração de características</i>	62
2.6.4	<i>Análise da Imagem (Interpretação/Classificação)</i>	63
3	PROCESSAMENTO DE IMAGENS E A ATIVIDADE INDUSTRIAL	66
3.1	INTRODUÇÃO	66
3.2	CLASSIFICAÇÃO QUANTO AO PROCESSO DOS APLICATIVOS DE VISÃO DE MÁQUINA	67
3.2.1	<i>Monitoração de Processos</i>	67
3.2.2	<i>Controle de Processos</i>	68
3.2.3	<i>Controle de Qualidade</i>	69
3.3	CLASSIFICAÇÃO QUANTO AO SEGMENTO ECONÔMICO	70
3.3.1	<i>Indústria Petrolífera</i>	70
3.3.2	<i>Indústria Automotiva</i>	72
3.3.3	<i>Indústria Eletrônica</i>	74
3.3.4	<i>Indústria de alimentos e bebidas</i>	76
3.3.5	<i>Indústria Farmacêutica</i>	77
3.3.6	<i>Segurança e Biometria</i>	79
3.3.7	<i>Indústria Têxtil</i>	81
3.3.8	<i>Indústria Madeireira</i>	83
4	MODELO PROPOSTO PARA MEDIÇÃO DO NÍVEL NA DESTILAÇÃO DE PETRÓLEO EM BATELADA	85
4.1	INTRODUÇÃO	85
4.2	DESCRIÇÃO DO PROCESSO DE DESTILAÇÃO EM BATELADA	85
4.3	TIPOS DE PETRÓLEO	86
4.4	O CENÁRIO	87

4.5	AMBIENTE DE SIMULAÇÃO	90
4.6	DIFICULDADES ENCONTRADAS	90
4.6.1	Ângulo e posicionamento da Câmera.....	90
4.6.2	Baixo contraste nos líquidos transparentes	91
4.6.3	Distorções Geométricas da Imagem.....	91
4.6.4	Reflexo do vidro.....	92
4.6.5	Mínimo volume detectável requerido	93
4.7	ARQUITETURA DO SISTEMA DE MONITORAÇÃO ATRAVÉS DE IMAGEM	93
4.7.1	Modularização do sistema de monitoração	93
4.7.2	Módulo de detecção do Nível	96
4.7.3	Lógica de comunicação entre o Sistema Supervisor e o Sistema de Monitoração por imagem	98
4.8	MODELO PROPOSTO PARA A MEDIÇÃO DO NÍVEL EM DESTILAÇÃO DE PETRÓLEO EM BATELADA.....	99
4.8.1	Detecção das laterais da Garrafa	100
4.8.2	Detecção do fundo da garrafa.....	104
4.8.3	A detecção do nível.....	106
4.8.4	Correção da deformação em barril da imagem e obtenção da altura em centímetros 118	
4.8.5	Interpolação altimétrica através de polinômios de terceiro grau utilizando triangulação de Delaunay	124
4.8.6	Região de segurança para detecção do nível.....	130
4.9	RESTRICÇÕES DO MODELO PROPOSTO.....	131
4.9.1	Precisão na medição do Nível.....	131
4.9.2	Formato e dimensões da garrafa	132

4.9.3	<i>Comportamento do líquido</i>	133
4.10	OBTENÇÃO E AVALIAÇÃO DOS RESULTADOS	133
4.10.1	<i>Marcação manual do nível</i>	134
4.10.2	<i>Resultados</i>	134
5	CONCLUSÕES E TRABALHOS FUTUROS	137
5.1	CUMPRIMENTO DOS OBJETIVOS	137
5.2	CONCLUSÕES SOBRE O ESTUDO DE CASO	137
5.3	CONTRIBUIÇÕES DA PESQUISA	140
5.4	TRABALHOS FUTUROS	141
	REFERÊNCIAS BIBLIOGRÁFICAS	144
	APÊNDICE I	147
	APÊNDICE II	153
	O PROTÓTIPO.....	153

LISTA DE FIGURAS

CAPÍTULO 1

FIGURA 1.1 INTERAÇÃO ENTRE OS COMPONENTES DE UM SISTEMA DE VISÃO DE MÁQUINA..... 25

CAPÍTULO 2

FIGURA 2.1: ROBÔ INTELIGENTE QUE MONTA PRODUTOS A PARTIR DE PROJEÇÕES 2D (EJIRI, 1990).....	29
FIGURA 2.2: ILUMINAÇÃO ATIVA DE UM OBJETO (ZUECH, 2000).....	32
FIGURA 2.3: EXEMPLO DE PROPAGAÇÃO DA LUZ DENTRO DE FIBRA ÓTICA (ZUECH, 2000)	32
FIGURA 2.4: MUDANÇAS NA LUZ EMANADA POR UM OBJETO (ZUECH, 2000).....	32
FIGURA 2.5: ILUMINAÇÃO ESTRUTURADA UTILIZANDO UM LASER (ZUECH, 2000).	33
FIGURA 2.6: PASSOS DO TRATAMENTO DE IMAGENS NA VISÃO DE MÁQUINA (ZUECH, 2000) .	36
FIGURA 2.7: EXEMPLO DE SUBTRAÇÃO DE DUAS IMAGENS. (GONZALEZ; WOODS, 2002). A) FIGURA ORIGINAL 1. B) FIGURA ORIGINAL 2. C) RESULTADO DA SUBTRAÇÃO ENTRE AS FIGURAS A E B. D) APLICAÇÃO DE EQUALIZAÇÃO DE HISTOGRAMA NA FIGURA C PARA MELHOR VISUALIZAÇÃO DO RESULTADO.	38
FIGURA 2.8: FILTRAGEM ESPACIAL. (GONZALEZ; WOODS, 2002).....	41
FIGURA 2.9: APLICAÇÃO DA DILATAÇÃO COM UM ELEMENTO ESTRUTURANTE EM FORMA DE CRUZ (BATCHELOR; WHELAN, 2002)	43
FIGURA 2.10: EROÇÃO DE UMA IMAGEM ATRAVÉS DE UM ELEMENTO ESTRUTURANTE EM FORMA DE CRUZ DE DIMENSÃO 3 X 3 (BATCHELOR; WHELAN, 2002)	43
FIGURA 2.11: EXEMPLO DE ABERTURA COM UM ELEMENTO ESTRUTURANTE EM FORMA DE BOLA. (GONZALEZ; WOODS, 2002).....	44

FIGURA 2.12: EXEMPLO DE FECHAMENTO COM ELEMENTO ESTRUTURANTE EM FORMA DE BOLA. (GONZALEZ; WOODS, 2002).....	45
FIGURA 2.13: MÁSCARAS PARA DETECÇÃO DE LINHAS.....	46
FIGURA 2.14: EXEMPLO DA UTILIZAÇÃO DE MÁSCARAS NA DETECÇÃO DE LINHAS COM -45 GRAUS DE ORIENTAÇÃO.	47
FIGURA 2.15: TRANSFORMADA DE HOUGH. (A) IMAGEM ORIGINAL. (B) TRANSFORMADA DE HOUGH. (C) INVERSA DA TRANSFORMADA DE HOUGH APLICADA A UM ÚNICO PIXEL BRANCO LOCALIZADO NO PONTO DE INTENSIDADE MÁXIMA EM (B). O PROCESSO LOCALIZA A LINHA EXISTENTE NA IMAGEM, APESAR DA PRESENÇA DE MUITO RUÍDO. (BATCHELOR; WHELAN, 2000).....	49
FIGURA 2.16: CIRCUNFERÊNCIA DE RAIO r E CENTRO (x_C, y_C) (PISTORI; PISTORI; COSTA, 2005).....	50
FIGURA 2.17: A) CIRCUNFERÊNCIA ALTAMENTE CORROMPIDA. B) O RESPECTIVO ESPAÇO DE HOUGH DA IMAGEM (A). C) IMAGEM COMPOSTA PELA ADIÇÃO DA IMAGEM ORIGINAL COM O ESPAÇO DE HOUGH (D) (PISTORI; PISTORI; COSTA, 2005).....	52
FIGURA 2.18: EXEMPLO DO USO DA TRANSFORMADA DE HOUGH.....	53
FIGURA 2.19: MODELOS DE BORDAS (GONZALEZ; WOODS; EDDINS, 2004).....	54
FIGURA 2.20: DIREÇÃO DO GRADIENTE E DIREÇÃO DA BORDA (SONKA; HLAVAC; BOYLE, 2007).....	55
FIGURA 2.21. MÁSCARAS DO OPERADOR DE ROBERTS	57
FIGURA 2.22. OPERADOR LAPLACIANO	57
FIGURA 2.23. MÁSCARAS DE PREWITT.	58
FIGURA 2.24. MÁSCARAS DE SOBEL.....	58
FIGURA 2.25: EXEMPLIFICAÇÃO DO COMPORTAMENTO DAS DERIVADAS DA FUNÇÃO DA IMAGEM. A) FUNÇÃO DA IMAGEM. B) DERIVADA PRIMEIRA DA FUNÇÃO. C) DERIVADA SEGUNDA..	59

FIGURA 2.26: LIMIAZAMENTO DE UMA IMAGEM PARA DESTACAR SUAS CARACTERÍSTICAS PRINCIPAIS	61
FIGURA 2.27: FUNÇÃO DE LIMIAZAMENTO.....	62
FIGURA 2.28. CLASSIFICAÇÃO DE DOIS OBJETOS, (BISHOP, 1995).....	64
 CAPÍTULO 3	
FIGURA 3.1: QUEDA DA PRIMEIRA GOTA EM UMA DESTILAÇÃO DE PETRÓLEO EM BATELADA. ..	68
FIGURA 3.2: SISTEMA DE CONTROLE DA CHAMA DE AQUECEDORES INDUSTRIAIS (HONGLU; MACGREGOR, 2004)	68
FIGURA 3.3: ESTADOS POSSÍVEIS DA CHAMA DOS AQUECEDORES (HONGLU; MACGREGOR, 2004).....	69
FIGURA 3.4: SALGADOS. (A) PRODUTO A. (B) PRODUTO B (HONGLU ET AL., 2003).	69
FIGURA 3.5: SISTEMA DE CONTROLE DE QUALIDADE DE SALGADOS (HONGLU ET AL., 2003)..	70
FIGURA 3.6. IMAGEM EXTRAÍDA DO SATÉLITE RADARSAT-1 ATRAVÉS DE UM SENSOR RAS CONTENDO DERRAMAMENTOS DE PETRÓLEO (BREKKE; SOLBERG, 2005).....	71
FIGURA 3.7. ARCABOUÇO PARA ALGORITMOS DE DETECÇÃO DE DERRAMAMENTOS DE PETRÓLEO (BREKKE; SOLBERG, 2005).....	71
FIGURA 3.8: IMAGEM DA APLICAÇÃO ANALISADORA DE FARÓIS DE CARROS WG-AUTO LUX ...	73
FIGURA 3.9: VERIFICAÇÃO DA SUPERFÍCIE DO PNEU (BLACKWELL, 1989)..	74
FIGURA 3.10: SISTEMA DE INSPEÇÃO DE PLACAS ELETRÔNICAS	75
FIGURA 3.11: IMAGEM BINÁRIA DE UM COMPONENTE ELETRÔNICO.....	75
FIGURA 3.12: CÂMERA MULTI-ESPECTRAL	76
FIGURA 3.13: A) FAIXA QUE JUNTA IMAGENS DA REGIÃO CENTRAL DO FRUTO GIRANDO. B) IMAGEM SEGMENTADA. C) DEFORMIDADES DETECTADAS	77
FIGURA 3.14: FLUXOGRAMA DA FASE DE TREINAMENTO DO SISTEMA (DERGANC ET AL., 2003)	78

FIGURA 3.15: FLUXOGRAMA DA FASE DE INSPEÇÃO (DERGANÇ ET. AL., 2003).....	78
FIGURA 3.16: A) IMAGEM COM NÃO UNIFORMIDADE DE COR. B) IMAGEM SEGMENTADA. C) IMAGEM COM CORREÇÃO DE COR. D) IMAGEM SEGMENTADA CORRESPONDENTE À IMAGEM COM CORREÇÃO DE COR.....	79
FIGURA 3.17. RESULTADOS OBTIDOS PELO SISTEMA DE DETECÇÃO DE FACES PROPOSTO EM (MOUTINHO; THOMÉ, 2005).....	81
FIGURA 3.18: A. IMAGEM APRESENTADA PARA O SISTEMA. B. RESULTADO DA DETECÇÃO DE DEFEITOS, ONDE AS JANELAS MARCADAS COM A LETRA D FORAM DETECTADAS COMO SENDO REGIÕES DEFEITUOSAS (COHEN; ZHIGANG; ATTALI, 1991).....	82
FIGURA 3.19: TECIDO COM DEFEITO EM FORMA DE LINHA HORIZONTAL NA PARTE SUPERIOR DA IMAGEM.....	82
FIGURA 3.20: A) AMOSTRA DE MADEIRA. B) DEFEITOS ENCONTRADOS PELO SISTEMA (CHO; CONNERS, 1991)	84

CAPÍTULO 4

FIGURA 4.1: MEDIÇÃO DO NÍVEL	85
FIGURA 4.2: UNIDADE DE DESTILAÇÃO.....	86
FIGURA 4.3: ESQUEMA DA ÁREA DE TRABALHO	88
FIGURA 4.4: ESQUEMA DO POSICIONAMENTO DOS EQUIPAMENTOS DO SISTEMA DE MONITORAÇÃO DO NÍVEL.....	89
FIGURA 4.5: ILUMINAÇÃO ARTIFICIAL.....	89
FIGURA 4.6: MATERIAL UTILIZADO NO AMBIENTE DE SIMULAÇÃO	90
FIGURA 4.7: CONTRASTE GERADO PELAS FRAÇÕES DE PETRÓLEO	91
FIGURA 4. 8: DISTORÇÕES GEOMÉTRICAS DAS IMAGENS.....	92
FIGURA 4.9: DISTORÇÃO GERADA PELA LENTE GRANDE ANGULAR DA CÂMERA	92

FIGURA 4.10: REFLEXOS INDESEJADOS NA SUPERFÍCIE DA GARRAFA DELIMITADOS PELAS ELIPSES.....	93
FIGURA 4.11: MÓDULOS DE MONITORAÇÃO DA UNIDADE DE DESTILAÇÃO	94
FIGURA 4.12: SUBMÓDULOS DO MÓDULO DE DETECÇÃO DO NÍVEL	97
FIGURA 4.13: PROTOCOLO DE COMUNICAÇÃO DE SINAIS ENTRE O <i>SS</i> E O <i>SM</i>	99
FIGURA 4.14: IMAGENS CAPTURADAS COM A CÂMERA.....	99
FIGURA 4.15: PROPOSTA PARA ENCONTRAR AS LATERAIS DA GARRAFA	100
FIGURA 4.16: DETECÇÃO DE BORDAS HORIZONTAIS APLICANDO UNICAMENTE O FILTRO DE SOBEL.....	101
FIGURA 4.17: ALGORITMOS UTILIZADOS PARA A DETECÇÃO DAS LATERAIS DA GARRAFA	102
FIGURA 4.18. MÉTODO DE BUSCA POR JANELAS	104
FIGURA 4.19 A) FIGURA ORIGINAL. B) FIGURA REDIMENSIONADA COM A ELIPSE ASSEMELHANDO UMA CIRCUNFERÊNCIA.....	105
FIGURA 4.20: A) ACUMULADOR DA TRANSFORMADA DE HOUGH. B) POSSÍVEIS CIRCUNFERÊNCIAS DETECTADOS	106
FIGURA 4.21: RESULTADO APÓS DETECÇÃO DO FUNDO	106
FIGURA 4.22. PRIMEIRA TENTATIVA DE DETECÇÃO DO NÍVEL.....	107
FIGURA 4.23. ABORDAGEM 2 PARA DETECÇÃO DO NÍVEL. (AS CORES DA IMAGEM E FORAM INVERTIDAS PARA MELHOR VISUALIZAÇÃO DO RESULTADO)	109
FIGURA 4.24. REMOÇÃO DE PIXELS MENOS RELEVANTES	110
FIGURA 4.25: ABORDAGEM 3 PARA DETECÇÃO DO NÍVEL.....	112
FIGURA 4.26: COMPARATIVO ENTRE IMAGENS COM E SEM SOMATÓRIO.....	115
FIGURA 4.27: DETECÇÃO DAS INTERSEÇÕES DO NÍVEL COM AS LATERAIS DA GARRAFA.....	117
FIGURA 4.28: MAPEAMENTO DOS PIXELS	119

FIGURA 4.29: EXEMPLO DE MALHA UTILIZADA PARA O MAPEAMENTO DA RELAÇÃO PIXELS – CENTÍMETROS (DISTORÇÃO DO TIPO BARRIL APRESENTADA PELA CÂMERA UTILIZADA) ..	120
FIGURA 4.30: RESULTADO DA FUNÇÃO MAPEIA.....	122
FIGURA 4.31: FUNÇÃO INTERPOLADA COM O MAPEAMENTO PIXELS X CENTÍMETROS	123
FIGURA 4.32: CÁLCULO DA ALTURA DO NÍVEL (H_N).....	124
FIGURA 4.33: PONTOS AMOSTRADOS NA SUPERFÍCIE (MITISHITA; TREVIZAN, 2001).....	126
FIGURA 4.34: PROPRIEDADE DO CIRCUNCÍRCULO NA DEFINIÇÃO DE TRIÂNGULOS DE DELAUNAY (MITISHITA; TREVIZAN, 2001)	127
FIGURA 4.35 SUPERFÍCIE DE REFERÊNCIA (MITISHITA; TREVIZAN, 2001)	127
FIGURA 4.36: REGIÃO DE SEGURANÇA DE DETECÇÃO DO NÍVEL	130
FIGURA 4.39. TESTES PARA ACHAR A ALTURA MÍNIMA H_{MIN} QUE O SISTEMA SERÁ CAPAZ DE CALCULAR	132
FIGURA 4.40: ALTURA UTILIZÁVEL PARA DETECÇÃO DO NÍVEL (H_{UTIL})	132
FIGURA 4.41: MARCAÇÃO MANUAL DO NÍVEL.....	134

CAPÍTULO 5

FIGURA 5.1. CÁLCULO DAS MÉDIAS UTILIZANDO SOBREPOSIÇÃO	142
FIGURA 5.2. CÁLCULO DAS MÉDIAS COM SOBREPOSIÇÃO	142

APÊNDICE

FIGURA A. 1: ERRO DA ABORDAGEM 1 APLICADA NA AMOSTRA 1	147
FIGURA A.2: ERRO DA ABORDAGEM 2 APLICADA NA AMOSTRA 1.....	147
FIGURA A. 3: ERRO DA ABORDAGEM 3 APLICADA NA AMOSTRA 1	148
FIGURA A.4: ERRO DA ABORDAGEM 4 APLICADA NA AMOSTRA 1	148
FIGURA A.5: ERRO DA ABORDAGEM 1 APLICADA NA AMOSTRA 2.....	149
FIGURA A.6: ERRO DA ABORDAGEM 2 APLICADA NA AMOSTRA 2.....	149

FIGURA A.7: ERRO DA ABORDAGEM 3 APLICADA NA AMOSTRA 2.....	150
FIGURA A.8: ERRO DA ABORDAGEM 4 APLICADA NA AMOSTRA 2.....	150
FIGURA A.9: ERRO DA ABORDAGEM 1 APLICADA NA AMOSTRA 3.....	151
FIGURA A.10: ERRO DA ABORDAGEM 2 APLICADA NA AMOSTRA 3.....	151
FIGURA A.11: ERRO DA ABORDAGEM 3 APLICADA NA AMOSTRA 3.....	152
FIGURA A.12: ERRO DA ABORDAGEM 4 APLICADA NA AMOSTRA 3.....	152
FIGURA A.13: PROTÓTIPO PARA DETECÇÃO DO NÍVEL.....	153

LISTA DE TABELAS

CAPÍTULO 4

TABELA 4. 1: MATRIZ M DE POSIÇÕES DAS INTERSEÇÕES DA MALHA (EM PIXELS, COM DEFORMAÇÃO).....	120
TABELA 4. 2: ALTURAS EM CENTÍMETROS DE CADA INTERSEÇÃO DA MALHA.....	120
TABELA 4. 3: RELAÇÃO RAIO (R) – VOLUME (V)- ALTURA DO LÍQUIDO (H_{UTIL})	133
TABELA 4. 4: AMOSTRAS UTILIZADAS NOS TESTES DE LABORATÓRIO.....	135
TABELA 4. 5: PARÂMETROS UTILIZADOS PARA CADA ABORDAGEM	135
TABELA 4. 6: RESULTADOS DOS TESTES APLICANDO TODAS AS ABORDAGENS (CIFRAS ARREDONDADAS EM 2 CASAS DECIMAIS).	135

1 INTRODUÇÃO

Um processo (do latim *processus* - movimento) é uma seqüência de alterações de propriedades ou atributos de um objeto ou sistema. Toda medição, conceito fundamental da ciência e da engenharia, é um processo.

O controle de processos é uma disciplina da estatística e da engenharia que trabalha com arquiteturas, mecanismos e algoritmos para controlar a saída de um processo específico. Por exemplo, aquecer a temperatura em um quarto é um processo que tem como resultado esperado atingir e manter uma temperatura definida constante através do tempo.

Informalmente pode-se dizer que os programas de controle de processos industriais são sistemas que monitoram e controlam automaticamente um processo para garantir que a saída destes estejam conforme o estabelecido nas especificações de fabricação pertinentes.

Atualmente o desafio para os profissionais da área de produção reside em reduzir custos e ao mesmo tempo melhorar a qualidade dos produtos. Para isto é necessário contar com instrumentos efetivos e baratos.

Inicialmente, antes da existência de métodos automáticos, o controle de muitos processos era realizado por um operador humano manualmente. Assim, detecção de defeitos em produtos e medição de variáveis como temperatura ou nível de líquidos eram todos monitorados visualmente por um operário.

A análise de imagens é definida como uma forma de processamento computacional na qual os dados de entrada são imagens, tais como fotografias ou quadros de vídeo, e a saída é uma imagem resultante ou informações qualitativas extraídas e interpretadas a partir da imagem de origem. Estas características tornam a análise de imagens uma forma possível de ser usada para automatizar o controle de processos que antigamente eram verificados visualmente por um operário.

As técnicas de processamento de imagens têm um alto custo computacional, o que resultava em um baixo desempenho nos microcomputadores existentes na primeira metade da década de 1990. O aumento da capacidade de processamento dos microprocessadores nos últimos dez anos tornou viável o controle automático de processos em tempo real através de técnicas de processamento de imagens com custos reduzidos. Nesse período a comunidade acadêmica demonstrou com sucesso a aplicabilidade destas técnicas, em processos simples de inspeção industrial. A Visão de Máquina (*Machine Vision*) é a área que estuda a utilização destas técnicas especificamente no setor industrial.

Apesar dos resultados positivos alcançados nas pesquisas e o sucesso de alguns sistemas comerciais, o processamento de imagens ainda não se encontra muito difundido na sociedade atual. As empresas ainda estão temerosas frente aos custos de desenvolvimento que envolve um sistema de inspeção visual e pelo curto tempo de existência destes sistemas no mercado.

O potencial de emprego de técnicas envolvendo processamento de imagens na área industrial é enorme e está apenas começando.

1.1 Escopo do Sistema

Na projeção de um sistema de Visão de Máquina é importante definir o contexto e o escopo do mesmo. Segundo a literatura (BATCHELOR; WHELAN, 2002) existem duas grandes abordagens neste sentido:

- a) A projeção de sistemas de propósito geral.
- b) A projeção de sistemas de propósito específico.

A primeira abordagem refere-se à criação de sistemas de propósito geral, que visam resolver todos os problemas de controle através de um único módulo genérico que seja adaptável a qualquer novo ambiente apresentado. Esta foi a abordagem inicialmente adotada

pelos pesquisadores, mas o sucesso da mesma foi reduzido devido à alta complexidade e a ampla variedade de ambientes encontrados nas linhas de produção industriais. Os aplicativos projetados dessa maneira derivaram em sistemas complexos e de difícil manutenção, que não atendiam às necessidades de orçamento reduzido, simplicidade e velocidade que as indústrias requerem. O sucesso destes sistemas foi muito limitado devido ao grande esforço de reprogramação requerido para conseguir adaptá-los a ambientes que não têm características semelhantes ao ambiente para o qual o aplicativo foi originalmente projetado e pelo excessivo tempo para desenvolvê-los.

A segunda abordagem visa a criação de soluções específicas para uma tarefa industrial, projetando sistemas menos genéricos, porém mais eficientes. Esses sistemas têm a vantagem de serem projetados e otimizados para uma única tarefa, conseguindo assim um melhor desempenho.

Devido à natureza prática desta pesquisa a segunda abordagem foi a escolhida para desenvolver o estudo de caso aqui apresentado.

1.2 Sistemas em Tempo Real

Os sistemas de controle são, em geral, classificados como sistemas de tempo real. Esta característica confere a este tipo de sistema uma dificuldade considerável quando atacado com processamento de imagens, devido a que estas técnicas são, em geral, muito custosas em termos computacionais. Portanto, os sistemas de monitoração e controle de processos baseados em imagens exigem planejamento meticuloso, visando à redução de efeitos que um código não otimizado pode provocar no tempo de resposta do sistema (LIMA; THOMÉ, 2004).

1.3 Vantagens do uso de processamento de imagens no controle de processos

O processamento de imagens tem como principal vantagem o fato de ser um método de controle e inspeção do tipo não destrutivo. Isso significa que não é necessário extrair uma amostra do produto e danificá-la, como é o caso em alguns métodos de controle de qualidade.

Pode-se citar como outra vantagem a possibilidade de verificar a qualidade de todos os produtos, e não somente de algumas amostras como acontece com o controle de qualidade baseado em amostras e cálculos estatísticos.

Através da Visão de Máquina é possível realizar inspeção *on-line*, em tempo real. Isto significa que é possível detectar defeitos em várias etapas da montagem de um produto, antes deste estar terminado. Isto é vantajoso porque a detecção do defeito acontece prematuramente antes de continuar desperdiçando material em um produto defeituoso (HAGENIERS, 2001).

Os sistemas de visão podem ser instalados em lugares de difícil acesso, ou que oferecem poucas condições de segurança para seres humanos. Estes sistemas não sujam o ambiente do processo, enquanto que pessoas podem ser fonte de poeira, oleosidade e outras impurezas. Erros podem ser cometidos por inspetores humanos devido a fadiga (HARMS, 1992). A inspeção através desses sistemas não é subjetiva como acontece no caso da inspeção realizada por seres humanos, o que é uma vantagem para o controle de processos que tem como medidas parâmetros numéricos como, por exemplo, o valor da temperatura de um líquido.

O custo reduzido de manutenção e do equipamento do sistema, quando projetado corretamente, representa também uma grande vantagem. Atualmente contamos com processadores potentes e baratos o suficiente como para competir com outros métodos de

inspeção e controle. Além disso, o custo das câmeras tem caído muito, e de maneira inversa a qualidade das mesmas tem sido incrementada.

1.4 Componentes básicos de um sistema de Visão de Máquina

Os elementos essenciais da Visão de máquina são (EDWARDS, 1990):

- Equipamento de Iluminação: os sistemas de visão de máquina não se adaptam facilmente às mudanças de iluminação. Por isso é bom projetar iluminação artificial consistente para a situação de trabalho, melhorando a visualização das características básicas dos componentes, fazendo com que o sistema precise pré-processar menos a imagem.
- Sensor: usualmente uma câmera do tipo CCD ou CMOS. As imagens podem também ser extraídas desde outras fontes como aparelhos de raios X ou qualquer outro sensor visual.
- Capturador de quadros (*Frame Grabber*): unidade que converterá a entrada analógica do sensor para o formato digital, por exemplo, uma placa de captura de vídeo.
- Uma unidade de processamento de dados, por exemplo, um computador para efetuar operações nas imagens, extraindo informação relevante da cena e interpretando esta informação.

A Figura 1.1 contém um diagrama que mostra a interação entre os elementos básicos dos sistemas de visão de máquina (BATCHELOR; WHELAN, 2002). A retroalimentação se aplica somente aos sistemas visuais que pretendem controlar o processo, gerando alguma resposta do sistema. Os sistemas cujo objetivo é somente a monitoração do processo carecem desta retroalimentação e se limitam a repassar os dados monitorados para uma unidade controladora ou simplesmente a salvá-los em algum meio físico para sua posterior avaliação

por algum supervisor humano. Cabe ressaltar que algumas das tarefas apresentadas na Figura 1.1 podem ser executadas em paralelo.

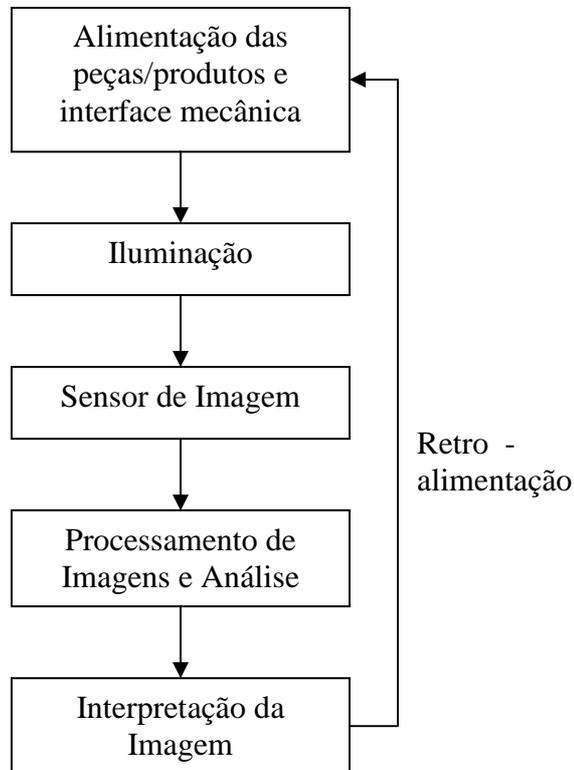


Figura 1.1 Interação entre os componentes de um sistema de Visão de Máquina

1.5 Motivação

Em qualquer processo industrial, as condições de operação estão sujeitas à mudança ao longo do tempo. Como exemplo destas condições variáveis pode-se citar: o nível de líquido em um equipamento, a pressão em um vaso, a temperatura de uma solução química entre outros. Normalmente precisa-se que as variáveis dos processos não ultrapassem alguns limites para garantir a segurança do processo e a qualidade do produto. Para isto é necessário controlar o processo, o que significa atuar sobre ele de modo a atingir um objetivo.

Como muitos processos industriais são monitorados visualmente por um operário, surgiu a idéia de automatizar esta monitoração através de técnicas de processamento de imagens. O artigo de (CHIN; DYER, 1989) é um exemplo das pesquisas iniciais nesta área.

Nele foi desenvolvido um sistema que diferenciava entre diversos tipos de peças de maquinaria através de métodos clássicos de processamento de imagens.

Hoje em dia existem empresas que continuam utilizando os métodos clássicos, como por exemplo, sensores de presença, para controlar processos que poderiam ser gerenciados de uma maneira mais simples, econômica e robusta, com uma solução através de processamento de imagens.

Este trabalho visa difundir as vantagens dos sistemas de visão de máquina realizando uma demonstração da aplicabilidade de processamento de imagens na monitoração de processos. Será através de um estudo de caso real de uma tarefa de controle muito importante: a verificação do nível de líquidos.

Especificamente, será resolvido pragmaticamente um problema existente na Petrobras: a medição do nível de frações de petróleo em uma destilação em batelada, problema no qual os sensores tradicionais não têm conseguido bons resultados.

1.6 Objetivos da Pesquisa

A presente dissertação apresenta um estudo de caso orientado à monitoração de processos industriais. Propor um modelo para resolver o estudo de caso é o alvo principal da pesquisa. Espera-se de maneira indireta colaborar com a difusão do uso do processamento de imagens no setor industrial além de capacitar-se na concepção e desenvolvimento de algoritmos que possam ser utilizados em situações reais.

1.6.1 Objetivo Principal

- Conceber um modelo computacional que permita resolver o problema de detecção de níveis de líquidos bem comportados.

1.6.2 Secundários

- Implementar de um protótipo usando o modelo proposto
- Avaliar o desempenho alcançado pelo protótipo

1.7 Estudo de Caso Desenvolvido

Para a presente pesquisa foi escolhido um estudo de caso que se encaixa dentro da monitoração de processos. Neste estudo realiza-se a medição do menisco (nível) gerado pelas frações líquidas de petróleo coletadas em um processo de destilação em batelada.

1.8 Organização da Dissertação

A dissertação está organizada como descrita a seguir: no capítulo 2 está definida formalmente a área de visão de máquina. Serão também introduzidos os conceitos de processamento de imagens necessários para o entendimento dos modelos descritos no capítulo 3 e do modelo proposto no capítulo 4. O capítulo 3 contém uma revisão bibliográfica do estado da arte da área de visão de máquina. No capítulo 4 será apresentado o estudo de caso da medição do nível das frações de petróleo geradas na destilação em batelada em conjunto com os modelos propostos e os resultados obtidos com cada modelo. O capítulo 5 apresenta as conclusões e recomendações finais da pesquisa.

2 VISÃO DE MÁQUINA

2.1 Introdução

A visão de máquina surgiu como uma alternativa para a automatização de tarefas de controle de processos industriais e controle de qualidade de produtos que antigamente eram executadas por operários humanos. A melhora do hardware utilizado (câmeras e microprocessadores) nas últimas duas décadas tornou viável o aumento do uso da visão de máquina nas indústrias.

Neste capítulo faz-se um estudo dos componentes, dos detalhes operacionais, e das principais técnicas necessárias para o desenvolvimento de um sistema de visão de máquina.

2.2 Definição de Visão de Máquina

Segundo a *Machine Vision Association of the Society of Manufacturing Engineers* e a *Automated Imaging Association* pode-se definir a Visão de Máquina como sendo:

“O uso de dispositivos para sensoriamento ótico, sem contato, para receber e interpretar automaticamente uma imagem de uma cena real com o fim de obter informação e/ou controlar máquinas ou processos”, (ZUECH, 2000 p. 46).

2.3 História Visão de Máquina

As primeiras pesquisas sobre visão de máquina datam do ano de 1970 aproximadamente. No ano de 1973 a General Motors simulou a montagem de pneus de carros utilizando robótica guiada por visão. Nesse mesmo ano foi criado também um sistema de reconhecimento de microprocessadores utilizando o processador 8080 da Intel. O surgimento dos micropocessadores e das câmeras de estado sólido foram os grandes acontecimentos que tornaram possível a produção bem sucedida dos primeiros aplicativos de visão de máquina.

Neste mesmo ano, a Fundação Nacional de Ciência dos Estados Unidos começou a promover a pesquisa sobre visão de máquina na Universidade de Rhode Island, no Instituto de Pesquisa de Stanford e no Instituto Carnegie Mellon. Estas três faculdades realizaram várias demonstrações de projetos relacionados com aplicações industriais (ZUECH, 2000).

No Japão apareceram os primeiros robôs com capacidades visuais no ano de 1970 (EJIRI, 1990). Estes robôs montavam objetos controlando um braço mecânico utilizando as projeções 2D dos mesmos (Figura 2.1).

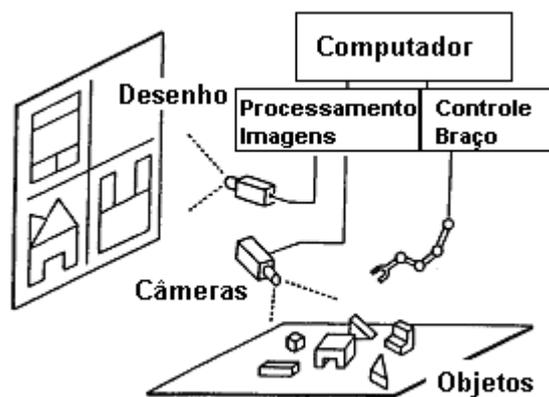


Figura 2.1: Robô inteligente que monta produtos a partir de projeções 2D (EJIRI, 1990).

A partir dessa época outras empresas começaram a desenvolver sistemas de visão de máquina. Porém, os primeiros sensores CDD comerciais produzidos na época tinham uma capacidade reduzida de captura e eram muito caros. Uma câmera CCD com resolução de 32 x 32 pixels custava 4000 dólares, o que dificultava sua massificação, limitando o uso dos aplicativos de visão de máquina às grandes indústrias com grandes orçamentos (ZUECH, 2000).

No ano de 1984 foram criadas nos Estados Unidos a Associação de Visão de Máquina e a *Automated Imaging Association*. O termo *Visão de Máquina* foi criado por estas associações, e se tornou a definição padrão para descrever esta tecnologia (ZUECH, 2000).

O pouco sucesso de algumas empresas dedicadas à visão de máquina se deve em grande parte a algumas expectativas pouco realistas por parte dos usuários finais dos sistemas, como por exemplo, achar que existe um único sistema genérico que será capaz de resolver todos os problemas de inspeção da indústria (BATCHELOR; WHELAN, 2000).

Na década dos anos 90 com a aparição de processadores de baixo custo com altas capacidades de tratamento de gráficos (como os processadores com tecnologia MMX da Intel e 3DNow da AMD) e de sistemas operacionais com interfaces mais amigáveis (como o Windows da Microsoft e o MAC OS da Apple) foi que realmente começou a popularização dos sistemas de visão de máquina. Simultaneamente, os custos associados com estes produtos têm diminuído, possibilitando o desenvolvimento e implantação de soluções através de visão de máquina com orçamentos mais reduzidos. Estas condições continuam melhorando, aumentando a cada dia as possibilidades para o mercado da visão de máquina (ZUECH, 2000).

2.4 Visão Humana X Visão de Máquina

A visão humana é basicamente qualitativa, boa para realizar decisões, julgamentos sobre aparência de objetos e a qualidade geral associada a esta aparência. Lida instantaneamente com informação global em uma cena, pode resolver ambigüidades devido à perspectiva, iluminação e amplitude.

Por sua parte, os sistemas de visão de máquina são considerados melhores para tarefas quantitativas, como ajudar a medir e quantificar um valor. Na atualidade nenhum sistema de visão de máquina possui o poder interpretativo da visão humana (CHAN; PALMER, 1995). Na contramão, os sistemas de visão de máquina podem efetuar tarefas de reconhecimento simples a uma velocidade muito mais alta do que a visão humana. Existem na atualidade sistemas de visão de máquina capazes de inspecionar 3000 objetos por minuto. É possível esperar uma taxa de 60 até 70% de eficiência em uma tarefa de inspeção realizada por uma

peessoa em condições normais de operação. Esta taxa diminui com a fadiga de exercer uma tarefa repetitiva. Inversamente os sistemas de visão de máquina podem executar a mesma tarefa indefinidamente sem que isto modifique a objetividade do seu julgamento. (CHAN; PALMER, 1995).

2.5 Componentes básicos de um Sistema de Visão de Máquina

Para o correto desenvolvimento de um sistema de visão de máquina é necessário estruturá-lo cuidadosamente. Este tipo de sistemas se compõe de alguns módulos principais fundamentais com objetivos e algoritmos bem definidos para cada um deles.

Nesta subseção são descritos com maior detalhe os módulos básicos de um sistema de visão de máquina que foram apresentados anteriormente na Figura 1.1.

2.5.1 Iluminação

A iluminação artificial do ambiente é em quase todos os casos um fator que simplifica muito a tarefa de controle visual, aumentando o contraste dos objetos de interesse e ressaltando detalhes importantes. Isto diminui a quantidade de pré-processamento que o software e hardware realizarão, otimizando assim o desempenho do sistema. A iluminação pode ser de dois tipos, ativa ou passiva (ZUECH, 2000).

A iluminação passiva consiste em técnicas projetadas para iluminar diretamente (o mais uniformemente possível) o objeto, com a finalidade de produzir uma imagem clara para o sensor da câmera (ZUECH, 2000).

A iluminação ativa envolve métodos que operam em imagens ou sombras projetadas pela luz. A iluminação estruturada é um método clássico de iluminação ativa. Tipicamente, uma linha de luz é projetada através do objeto e a imagem desta linha, deformada pela geometria do objeto, é adquirida e analisada (Figura 2.2), (ZUECH, 2000).

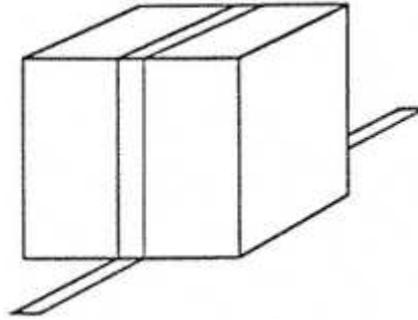


Figura 2.2: Iluminação ativa de um objeto (ZUECH, 2000)

Um material comum utilizado para iluminação é a fibra ótica, que permite abrihantar lugares de difícil acesso e emite uma luz direcionada, evitando assim iluminar áreas muito extensas ou não desejadas (Figura 2.3), (ZUECH, 2000).

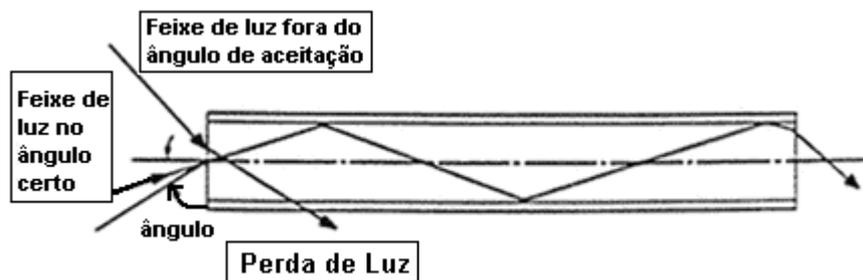
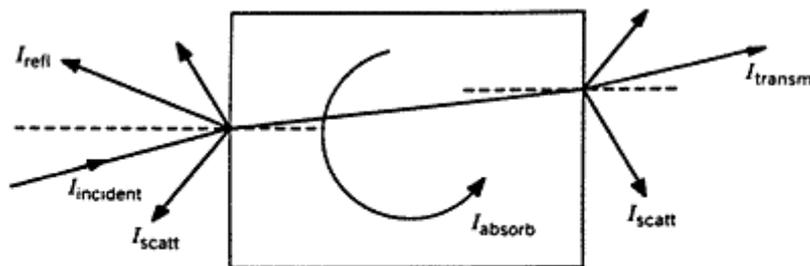


Figura 2.3: Exemplo de propagação da luz dentro de fibra ótica (ZUECH, 2000)

É importante também considerar a superfície do objeto que será iluminada. O comportamento da luz refletida no objeto depende da superfície e do material que o compõem (Figura 2.4).



$$I_{inc} = I_{refl} + I_{front\ sc} + I_{absorb} + I_{back\ sc} + I_{transm}$$

Figura 2.4: Mudanças na luz emanada por um objeto (ZUECH, 2000)

Se a superfície do objeto está bem polida, a luz incidente retornará com um ângulo com vetor normal igual ao ângulo de incidência. A luz refletida pode ter ou não a mesma

distribuição de comprimento de onda que a luz incidente. Além disso, o ângulo de incidência causa mudanças na reflexão de alguns materiais (ZUECH, 2000).

A projeção da iluminação depende da aplicação, especificamente das propriedades do objeto e da tarefa a ser realizada. Para o realce de parâmetros geométricos, como o contorno, de um objeto não transparente uma escolha comum é a iluminação desde o fundo da imagem (*backlighting*). Isto delinea nitidamente as bordas do objeto (ZUECH, 2000).

Quando os métodos mais simples não funcionam é possível utilizar iluminação estruturada para marcar o perfil desejado do objeto (Figura 2.2 e Figura 2.5). O sensor de imagem visualiza a projeção do perfil da estrutura. As distorções no feixe de luz podem ser traduzidas como variações de altura (ZUECH, 2000).

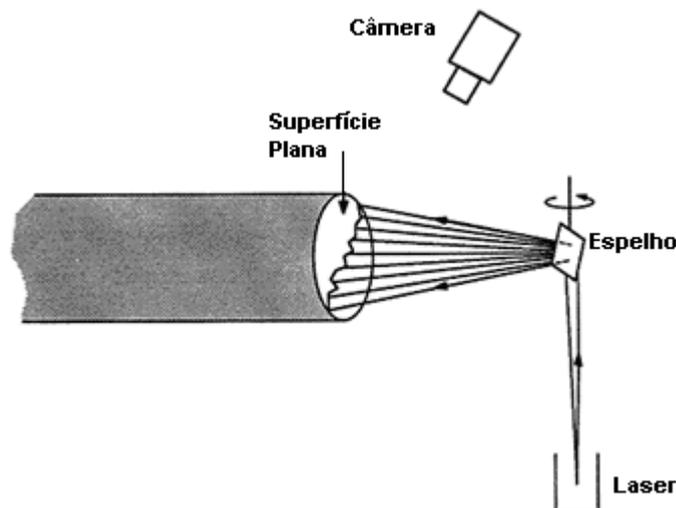


Figura 2.5: Iluminação estruturada utilizando um laser (ZUECH, 2000).

A seleção da iluminação precisa de um julgamento baseado na experiência e na experimentação. Um sistema ótimo de iluminação provê uma imagem clara e permite distinguir com maior facilidade as características a serem inspecionadas.

Pode-se concluir que a iluminação artificial é uma tarefa crítica que tem grande impacto na eficiência do sistema e deve ser utilizada sempre que o problema o permita (ZUECH, 2000).

2.5.2 Sensor de Imagem

2.5.2.1 Sensores de Estado Sólido

Nos primeiros sistemas de visão de máquina eram utilizados sensores do tipo Vidicon. Estes sensores eram muito instáveis, o que contribuiu para o fracasso de vários sistemas. A aparição dos sensores de estado sólido possibilitou o desenvolvimento de sistemas mais confiáveis. Hoje em dia se encontram disponíveis vários tipos de sensores de estado sólido, como por exemplo, o CCD (*Charged Coupled Device*), o CID (*Charge Injection Device*) e o MOS (*Metal Oxide Sensor*). As câmeras de estado sólido são pequenas, leves e são insensíveis a campos magnéticos. Os sensores de estado sólido são compostos de um arranjo de vários centos de diodos fotossensíveis. Uma carga proporcional aos níveis de fótons recebidos pelo sensor é armazenada eletronicamente. A seleção do diodo a ser utilizado é realizada eletronicamente e os pontos são bem definidos obtendo um desempenho geométrico alto (ZUECH, 2000).

Os tipos de sensor de imagem mais comumente utilizados na atualidade são os sensores do tipo CCD (*Charged Coupled Image Sensor*) e os do tipo CMOS (*Complementary Metal Oxide Semiconductor*).

As câmeras de estado sólido são conectadas a placas digitalizadoras que transformam os dados analógicos recebidos do sensor em dados digitais que podem ser interpretados pelo computador.

2.5.2.2 Câmeras digitais

São câmeras que têm como saída dados digitais, eliminando assim a necessidade de uma placa digitalizadora. As câmeras digitais têm comumente uma resolução maior que as câmeras analógicas. Utilizam um conversor analógico-digital (ADC) para digitalizar o sinal analógico de cada pixel. A precisão das câmeras digitais aumenta porque são menos sensíveis a ruídos elétricos. Uma câmera digital opera em um modo de barramento progressivo, rastreando a imagem completa (ZUECH, 2000).

2.5.2.3 Alternativas aos sensores

Além da captura baseada em sensores que lidam com a parte do espectro eletromagnético visível por humanos, é possível utilizar sensores que capturam imagens no espectro ultravioleta, infravermelho ou dos raios X. Isto faz com que os sistemas de visão de máquina possam realizar tarefas de inspeção que não poderiam ser realizadas através de inspeção humana direta (ZUECH, 2000).

2.5.2.4 Tratamento de Imagens

O tratamento das imagens pode ser feito através de software ou hardware. O hardware tem a vantagem de ter uma execução mais rápida do que o software, porém o software é mais flexível e pode ser alterado com mais facilidade. A Figura 2.6 contém um diagrama com os passos que são seguidos no tratamento de imagens na visão de máquina (ZUECH, 2000).

Aquisição da imagem: a aquisição das imagens é realizada através dos sensores apresentados na seção 3.4.2.

Pré-processamento: são operações que realizam alterações na imagem original visando realçar as regiões de interesse.

Segmentação: processo que consiste em separar os objetos de interesse do resto da imagem, dividindo-a em vários grupos.

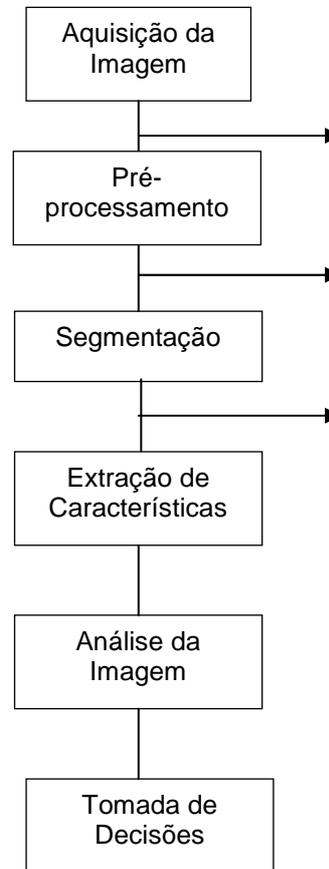


Figura 2.6: Passos do tratamento de imagens na Visão de Máquina (ZUECH, 2000)

Extração de Características: são operações que extraem informação que caracteriza os objetos de interesse das imagens pré-processadas e/ou segmentadas.

Análise/Classificação/Interpretação de Imagens: estas operações usam as características extraídas na etapa anterior e as comparam com padrões conhecidos de antemão. Este passo tem como resultado as informações que serão utilizadas na tomada de decisões, que será o passo final do processo.

Alguns algoritmos utilizados em cada um destes passos serão descritos com maior detalhe na seção 2.6.

2.6 Algoritmos para o Tratamento de Imagens

Existe uma grande quantidade de algoritmos para tratamento de imagens na bibliografia.

Serão aqui descritos alguns algoritmos utilizados nos sistemas de visão de máquina, dando preferência aos algoritmos utilizados no desenvolvimento das estratégias para detecção do nível do capítulo 4.

2.6.1 Pré-processamento

As técnicas de pré-processamento visam “melhorar” a imagem, no sentido de torná-la mais adequada para os passos subseqüentes no tratamento da imagem. Existem três tipos fundamentais de pré-processamento: transformações de pixels, transformações globais (na imagem toda) e transformações por vizinhança (ZUECH, 2000).

Uma imagem é representada através de uma matriz bidimensional para o caso de imagens em tons de cinza. Cada elemento desta matriz representa o valor de cada pixel da imagem.

2.6.1.1 Algoritmos de transformações de pixels

2.6.1.1.1 Adição ou subtração de uma constante a cada pixel da imagem

Modificar o brilho envolve a adição ou subtração de um valor constante a todos os pixels na imagem. Isto movimentará toda a distribuição da frequência dos tons de cinza (ZUECH, 2000).

2.6.1.1.2 Inversão

Substituição de cada pixel pelo seu valor complemento. Branco se torna preto e vice versa, e os tons de cinza se invertem de claros para escuros (ZUECH, 2000).

2.6.1.2 Algoritmos de transformações globais

As transformações globais são executadas na imagem toda. Aumento e diminuição de tamanho, translação, rotação, subtração e manipulação de perspectivas são utilizados previamente às operações de aprimoramento das imagens. Apresentam-se aqui algumas destas técnicas.

2.6.1.2.1 Subtração

A subtração entre duas imagens $f(x, y)$ e $h(x, y)$ é expressa como:

$$g(x, y) = f(x, y) - h(x, y)$$

Equação 2.1

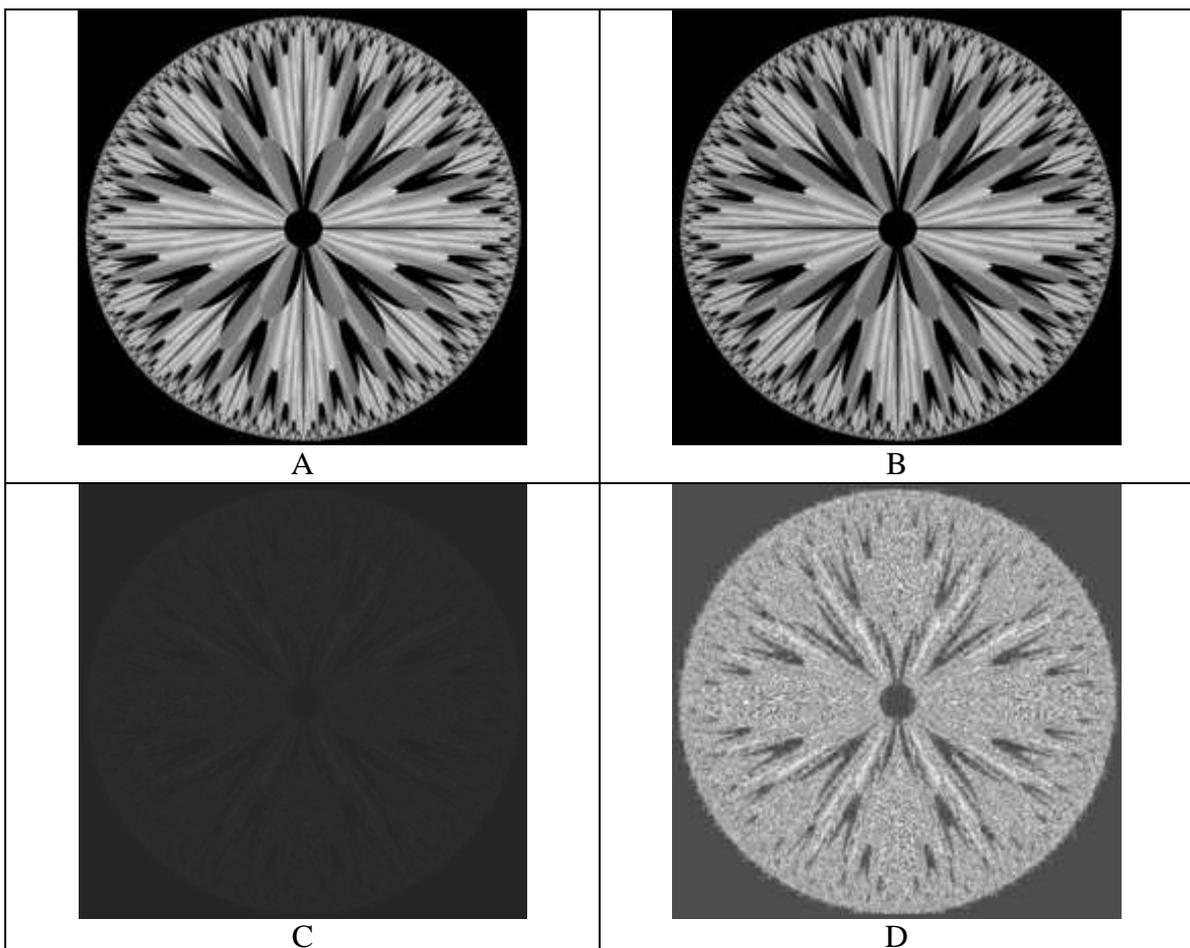


Figura 2.7: Exemplo de subtração de duas imagens. (GONZALEZ; WOODS, 2002). A) Figura Original 1. B) Figura Original 2. C) Resultado da subtração entre as figuras A e B. D) Aplicação de equalização de histograma na figura C para melhor visualização do resultado.

A grande utilidade da subtração é o aprimoramento de desigualdades entre as imagens (Figura 2.7). A diferença entre as imagens A e B da Figura 2.7 tem como resultado a imagem C. Esta diferença é pouco perceptível, mas é relevante. Na Figura 2.7D foi realizada uma equalização no histograma para visualizar melhor estas diferenças, que mesmo sendo pequenas são relevantes (GONZALEZ; WOODS, 2002).

2.6.1.3 Transformações por vizinhança

Antes de definir as transformações por vizinhança serão apresentados dois conceitos prévios importantes: a vizinhança entre pixels e a conectividade.

- *Vizinhança entre pixels*

Um pixel p com coordenadas (x, y) na matriz da imagem tem quatro vizinhos horizontais e verticais com coordenadas $(x + 1, y)$, $(x - 1, y)$, $(x, y + 1)$, $(x, y - 1)$. Este conjunto de coordenadas é chamado de vizinhos de 4 de p e é denotado por $N_4(p)$. Os quatro vizinhos diagonais de p com coordenadas $(x + 1, y + 1)$, $(x + 1, y - 1)$, $(x - 1, y + 1)$, $(x - 1, y - 1)$, são denotados como $N_D(p)$. Juntando $N_4(p)$ e $N_D(p)$ são obtidos os vizinhos de 8 de “ p ”, denotados como $N_8(p)$ (GONZALES; WOODS, 2002).

- *Conectividade*

Para determinar se dois pixels são conexos, deve de ser determinado primeiro se são vizinhos e se seus níveis de cinza satisfazem um critério específico de similaridade (por exemplo, pode-se verificar se os níveis de cinza dos dois pixels são iguais). Seja V o conjunto de níveis de cinza usados para definir adjacência existem três tipos de adjacência (GONZALES; WOODS, 2002):

- Adjacência de 4: dois pixels p e q com valores que pertencem ao conjunto V são adjacentes de 4 se q está no conjunto $N_4(p)$.

- Adjacência de 8: dois pixels p e q com valores que pertencem ao conjunto V são adjacentes de 8 se q está no conjunto $N_8(p)$.
- Adjacência de m (misturada): dois pixels p e q , com valores que pertencem ao conjunto V são adjacentes de m se:
 - q está em $N_4(p)$,
 OU
 - “ q ” está em $N_D(p)$ e o conjunto $N_4(p) \cap N_4(q)$ não tem valores que pertençam a V .

A adjacência de m elimina ambigüidades geradas pela adjacência de 8.

2.6.1.3.1 Filtros Espaciais

São operações que trabalham com os valores dos pixels vizinhos e os valores correspondentes de uma sub-imagem que possuem a mesma dimensão do que a vizinhança. Esta sub-imagem é chamada de filtro ou máscara. Os valores de cada elemento do filtro são conhecidos como coeficientes. O mecanismo de trabalho dos filtros espaciais em uma imagem em tons de cinza é ilustrado na Figura 2.8.

O processo consiste em deslocar a máscara através de cada ponto da imagem. Para cada ponto (x, y) a resposta do filtro é calculada utilizando uma relação predefinida. Para filtragem espacial linear a resposta é dada pela soma dos produtos entre os coeficientes dos filtros e os pixels correspondentes na imagem onde o filtro se encontra atualmente posicionado. Para a máscara de 3 x 3 utilizada na Figura 2.8 o resultado R é calculado como:

$$R = w(-1, -1)f(x - 1, y - 1) + w(-1, 0)f(x - 1, y) + \dots + w(0, 0)f(x, y) + \dots + w(1, 0)f(x + 1, y) + w(1, 1)f(x + 1, y) \quad \text{Equação 2. 2}$$

O resultado R é a soma dos produtos dos coeficientes da máscara com os correspondentes pixels da imagem. O coeficiente $w(0, 0)$ coincide com o valor $f(x, y)$ da

imagem, indicando que a máscara é centrada em (x, y) . Para uma máscara de tamanho $m \times n$ assume-se que $m = 2a + 1$ e $n = 2b + 1$, onde a e b são inteiros não negativos. Isto implica que as máscaras serão de tamanho ímpar (GONZÁLES; WOODS, 2002).

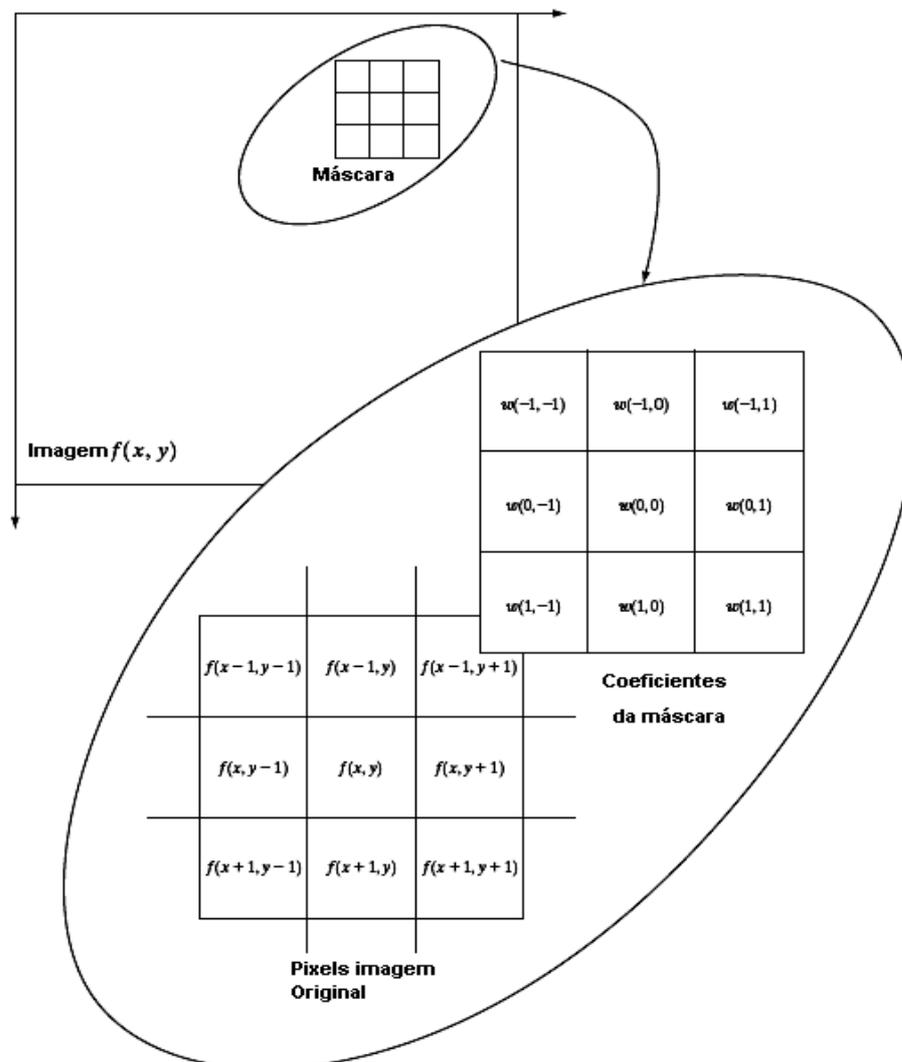


Figura 2.8: Filtragem espacial. (GONZALEZ; WOODS, 2002)

A filtragem linear de uma imagem f de tamanho $M \times N$ com uma máscara de tamanho $m \times n$ é dada pela expressão:

$$g(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f(x + s, y + t)$$

Equação 2.3

O processo de filtragem linear da Equação 2. 3 é semelhante ao conceito conhecido como convolução. Por este motivo a filtragem linear espacial é freqüentemente citada como “convoluir uma máscara com uma imagem” (GONZÁLEZ; WOODS, 2002).

2.6.1.3.2 Filtro de medianas

Substitui o valor de um pixel pelo valor da mediana dos níveis de cinza da vizinhança do pixel a ser substituído. Os filtros de mediana são comumente utilizados para diminuir ruídos aleatórios na imagem (GONZÁLEZ; WOODS, 2002).

2.6.1.3.3 Dilatação

É uma operação que corresponde à chamada morfologia matemática. A dilatação é a expansão de uma imagem A através do elemento estruturante B. Este elemento estruturante pode ser considerado como uma máscara de convolução que será aplicada na imagem. Marcando as posições onde a máscara se ajusta é possível colher informação estrutural da imagem. Os elementos estruturais comumente utilizados são freqüentemente mais simples geometricamente do que a imagem onde são aplicados, porém este nem sempre é o caso. Os elementos estruturais mais comuns são: pontos, vetores, linhas, quadrados, octógonos, discos, rombos e anéis. Devido a que a forma é um importante recipiente de informação para os sistemas de visão, a morfologia matemática cumpre um papel importante. A aplicação da morfologia matemática aqui apresentada se restringe a imagens binárias no espaço bidimensional dos inteiros, Z^2 . A imagem a ser analisada será denotada como A e o elemento estruturante como B, com elementos $b = (b_1, b_2)$, (BATCHELOR; WHELAN, 2002).

A operação de dilatação é formalmente definida como:

$$A \oplus B = \{z | (B)_z \cap A \neq \emptyset\}$$

Equação 2. 4

Esta operação pode ser entendida como a varredura do elemento B sobre a imagem A. Na Figura 2.9 a imagem é dilatada por um elemento estruturante em forma de cruz de 3 x 3 pixels. Cada quadrado da quadrícula representa um pixel (BATCHELOR; WHELAN, 2002).

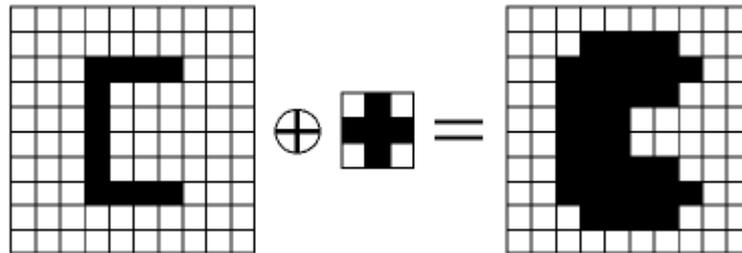


Figura 2.9: Aplicação da dilatação com um elemento estruturante em forma de cruz (BATCHELOR; WHELAN, 2002)

2.6.1.3.4 Erosão

É uma operação morfológica equivalente a redução dos objetos (GONZALEZ; WOODS, 2002).

É denotada por:

$$A \ominus B = \{z | (B)_z \subseteq A\}. \quad \text{Equação 2.5}$$

Isto consiste em deslocar o elemento estruturante B através da imagem A, onde B seja completamente contido em A. Na Figura 2.10 a imagem foi erodida por um elemento estruturante de dimensão 3 x 3, (BATCHELOR; WHELAN, 2002).

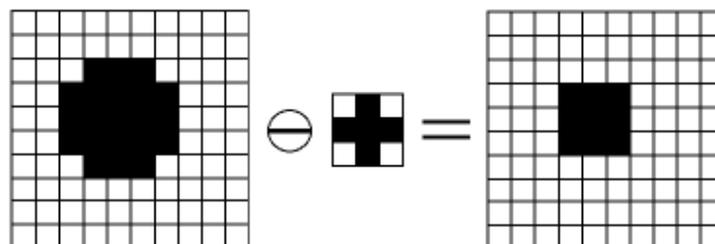


Figura 2.10: Erosão de uma imagem através de um elemento estruturante em forma de cruz de dimensão 3 x 3 (BATCHELOR; WHELAN, 2002)

2.6.1.3.5 Abertura

É a combinação das operações de erosão e dilatação. Tem o efeito de remover elementos isolados de uma imagem A que sejam menores que o elemento estruturante B e aquelas seções da imagem A mais estreitas que B. É vista como um arredondamento geométrico e denotada formalmente como (BATCHELOR; WHELAN, 2002):

$$A \circ B = (A \ominus B) \oplus B. \quad \text{Equação 2. 6}$$

Assim a abertura implica aplicar a erosão em A e seguidamente aplicar a dilatação, ambas com elemento estruturante B (Figura 2.11).

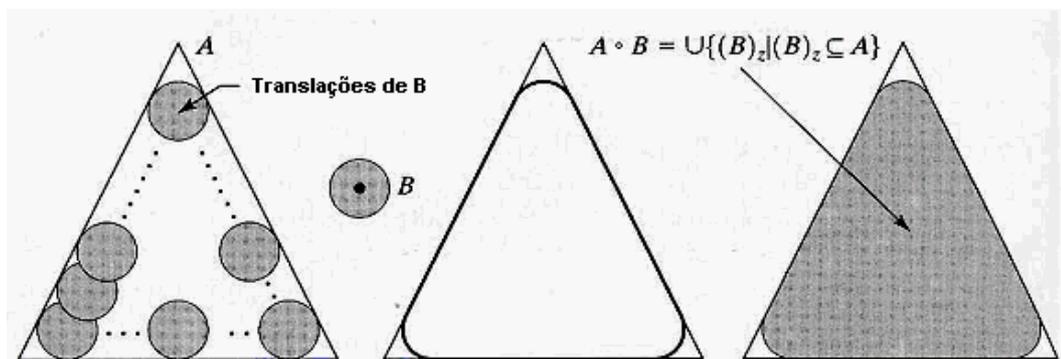


Figura 2.11: Exemplo de abertura com um elemento estruturante em forma de bola. (GONZALEZ; WOODS, 2002)

2.6.1.3.6 Fechamento

Esta transformação possui o efeito de encher buracos e bloquear vales estreitos quando um elemento estruturante B (de tamanho semelhante aos buracos e vales) é aplicado (Figura 2.12). O fechamento de uma imagem A através de um elemento estruturante B é definido como (GONZALEZ; WOODS, 2002):

$$A \bullet B = (A \oplus B) \ominus B, \quad \text{Equação 2. 7}$$

Que simplesmente significa que o fechamento consiste em aplicar primeiro uma dilatação em A seguida de uma erosão, ambas as operações com elemento estruturante B.

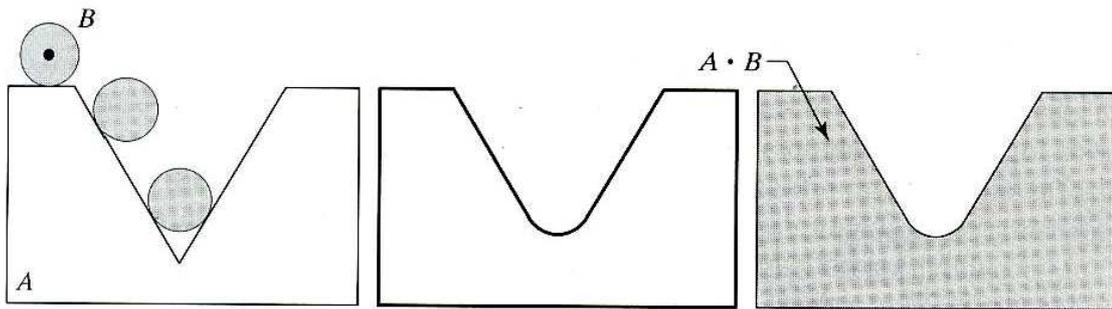


Figura 2.12: Exemplo de fechamento com elemento estruturante em forma de bola. (GONZALEZ; WOODS, 2002)

2.6.1.3.7 Remoção de pixels isolados em imagens binárias

Esta operação é muito simples, porém muito útil para remoção de ruídos em imagens binárias. Se os vizinhos de 8 de um pixel p são todos de uma mesma cor (ou com valor próximo definido por um limiar), então atribui-se essa cor para o pixel p .

Esta operação elimina pixels isolados da imagem e é comumente aplicada antes de utilizar operadores de vizinhança como a dilatação, que pode tornar um pixel em uma área grande. (ZUECH, 2000).

2.6.2 Segmentação

Segmentação é o processo de subdividir uma imagem em suas regiões ou objetos constituintes. A segmentação de imagens não triviais é uma tarefa complexa. A precisão do processo de segmentação determina o eventual sucesso ou falha de processos computadorizados de análise de imagens (GONZALES; WOODS; EDDINS, 2004).

Existem três tipos de descontinuidades básicas em uma imagem: pontos, linhas e bordas.

O método mais básico de segmentação é o uso de máscaras, que envolve calcular o somatório dos produtos dos coeficientes da máscara com os níveis de intensidade contidos na região que é coberta pela máscara (GONZALES; WOODS; EDDINS, 2004):

$$R = w_1 z_1 + w_2 z_2 + \dots + w_9 z_9 = \sum_{i=1}^9 w_i z_i$$

Equação 2. 8

Onde z_i é a intensidade do pixel associado ao coeficiente da máscara w_i .

Descreve-se a seguir a detecção de linhas e de bordas, que são os temas de maior relevância para este trabalho.

2.6.2.1 Detecção de linhas aplicando máscaras

Para a detecção de linhas aplicamos as seguintes máscaras na imagem utilizando a Equação 2. 3:

-1	-1	-1
2	2	2
-1	-1	-1
Horizontal		
A		

-1	-1	2
-1	2	-1
2	-1	-1
+45 graus		
B		

-1	2	-1
-1	2	-1
-1	2	-1
Vertical		
C		

2	-1	-1
-1	2	1
-1	-1	2
-45 graus		
D		

Figura 2.13: Máscaras para detecção de linhas

A primeira máscara (A) da Figura 2.13 responderá melhor a linhas orientadas horizontalmente que tenham 1 pixel de largura. A segunda máscara (B) responde melhor para as linhas orientadas a +45 graus do eixo vertical absoluto, a terceira máscara (C) as linhas verticais e a última máscara (D) as linhas a -45 graus do eixo vertical absoluto. Os coeficientes em cada máscara somam zero, indicando uma resposta de zero para regiões com níveis constantes de tons de cinza (GONZALES; WOODS, 2002).

Por exemplo, a Figura 2.14 (A) contém uma imagem binária de um circuito eletrônico. Para encontrar as linhas de um pixel de largura orientadas a -45 graus foi utilizada a máscara (D) da Figura 2.13. O valor absoluto do resultado se encontra na Figura 2.14 (B). Nesta figura os componentes verticais e horizontais foram eliminados e os componentes da imagem original que tendem a uma direção de -45 graus produziram as respostas mais fortes. Para determinar qual das linhas é a que mais se adequou à máscara, limiarizou-se a imagem. O resultado de utilizar um limiar igual ao valor máximo da imagem é apresentado na Figura

2.14 (C). O processo extraiu o único segmento de linha com um pixel de largura e orientado a -45 graus (parte inferior direita da imagem). Os pontos isolados podem ser removidos através de um algoritmo de redução de ruído (GONZALES; WOODS, 2002).

O grande problema deste método é que através destas máscaras é possível encontrar somente linhas de exatamente um pixel de largura, com ângulo muito próximo ao ângulo da máscara e que sejam estritamente retas. Estas variáveis (ângulo, largura da reta) muitas vezes não conhecidos de antemão nos problemas industriais, limitando a utilidade do método.

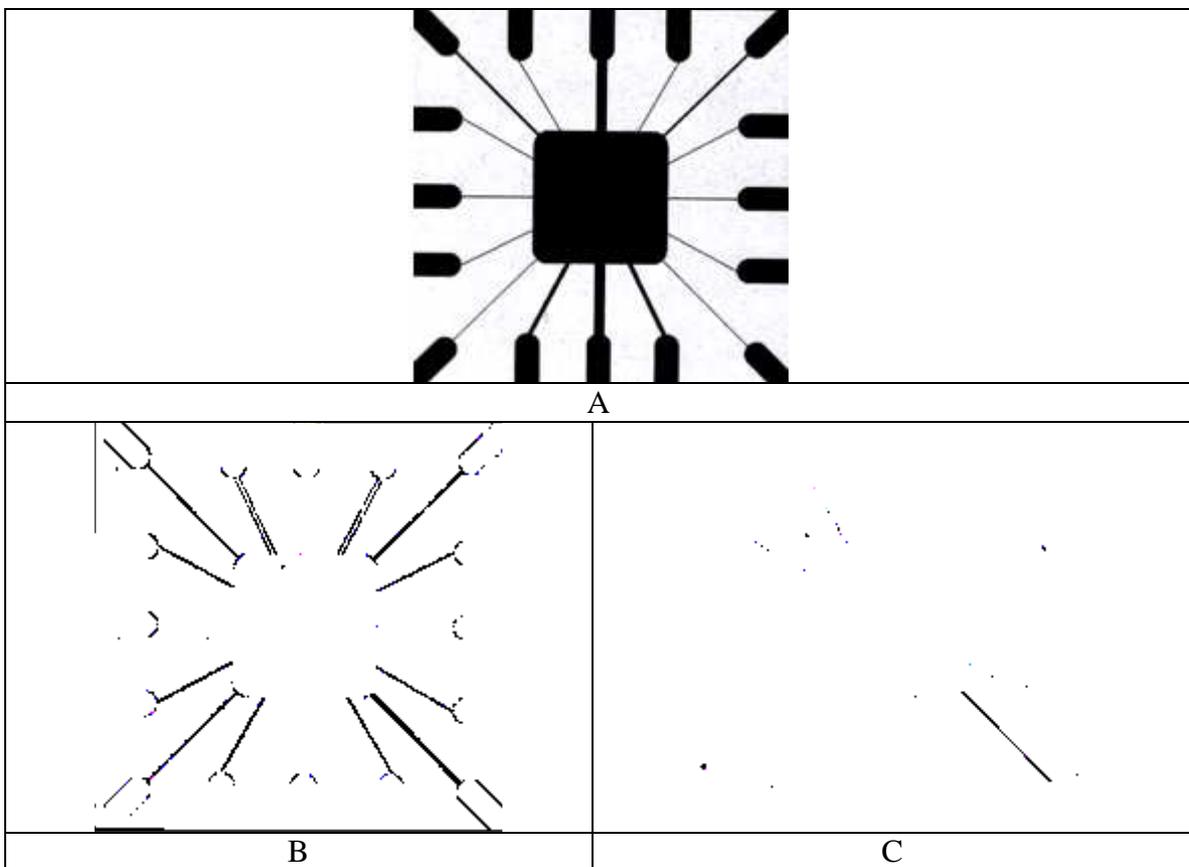


Figura 2.14: Exemplo da utilização de máscaras na detecção de linhas com -45 graus de orientação.

2.6.2.2 Detecção de linhas aplicando a transformada de Hough

A transformada de Hough é uma técnica robusta para detecção de linhas, circunferências, elipses, parábolas e outras curvas com forma conhecida de antemão. A transformação básica de Hough visa o reconhecimento de retas. O objetivo é localizar

arranjos quase lineares de pontos brancos desconectados e linhas entrecortadas. Pode-se considerar que uma linha na imagem é definida (em coordenadas polares) pela equação:

$$r = x \cdot \cos \phi + y \cdot \text{sen} \phi \quad \text{Equação 2.9}$$

Onde r e ϕ são os parâmetros desconhecidos, cujos valores é necessário descobrir. Claramente, se esta linha intersecta o ponto (x_i, y_i) , então $r = x_i \cdot \cos \phi + y_i \cdot \text{sen} \phi$ pode ser resolvido com diferentes valores de r e ϕ . Assim cada ponto branco (x_i, y_i) na imagem pode ser associado com um conjunto de valores r e ϕ . Este conjunto de valores forma uma curva sinusoidal no espaço (r, ϕ) . Devido a que cada ponto na imagem gera uma curva deste tipo, a imagem completa gera um número grande de senóides (Figura 2.15B). Em muitas ocasiões, as senóides convergem para um ponto comum. O par (r, ϕ) do ponto de convergência das senóides indica a inclinação ϕ , e a posição r , de uma reta que pode ser desenhada atravessando um grande número de pontos brancos na imagem (BATCHELOR; WHELAN, 2002).

Pode-se encontrar uma descrição passo a passo do algoritmo da transformada de Hough para detecção de retas em (JAMUNDÁ, 2000).

A transformada de Hough pode ser generalizada para detectar grupos de pontos contidos em uma curva. Na prática esta não é uma tarefa trivial, já que a complexidade aumenta exponencialmente com o número de parâmetros necessários para definir a curva. Para detecção de uma circunferência, por exemplo, faz-se necessário defini-la parametricamente como $r^2 = (x - a)^2 + (y - b)^2$, onde (a, b) determina as coordenadas do centro do circunferência e r representa o rádio. Este problema precisa de um espaço de parâmetros tridimensional, que não pode ser representado e processado como uma imagem única. (BATCHELOR; WHELAN, 2002).

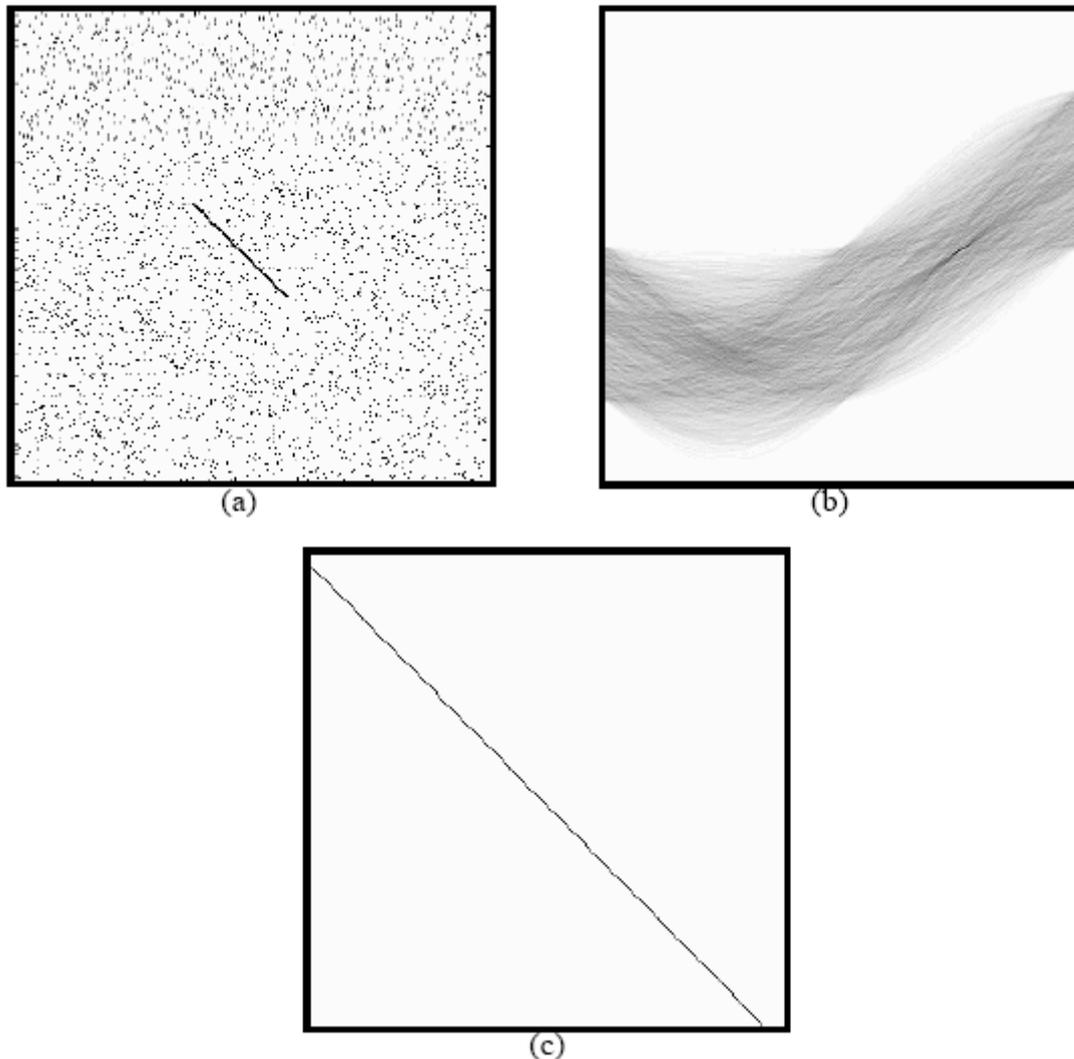


Figura 2.15: Transformada de Hough. (a) Imagem Original. (b) Transformada de Hough. (c) Inversa da transformada de Hough aplicada a um único pixel branco localizado no ponto de intensidade máxima em (b). O processo localiza a linha existente na imagem, apesar da presença de muito ruído. (BATCHELOR; WHELAN, 2000).

2.6.2.3 Detecção de circunferências aplicando a transformada de Hough

O problema da detecção de circunferências com raio fixo consiste em determinar quais os pontos de uma imagem pertencem a uma mesma circunferência de raio r . Ou seja, tem-se um conjunto de coordenadas (x, y) e pretende-se encontrar valores possíveis para os parâmetros (x_C, y_C) , correspondentes aos pontos centrais de circunferências. Para isto, constrói-se um espaço de Hough, que para o caso específico, pode ser visto como uma matriz, com a mesma dimensão da imagem digital, em que as colunas e linhas representam, respectivamente, os possíveis valores de x_C e y_C . Cada célula dessa matriz recebe,

inicialmente, o valor zero, e para cada ponto (x, y) da imagem, incrementa-se no espaço de Hough, todas as células (x_c, y_c) representando centros de circunferências, de raio r , que passam por (x, y) . Ao final, as células contendo os valores mais altos indicarão os centros “mais prováveis” de circunferências (PISTORI; PISTORI; COSTA, 2005).

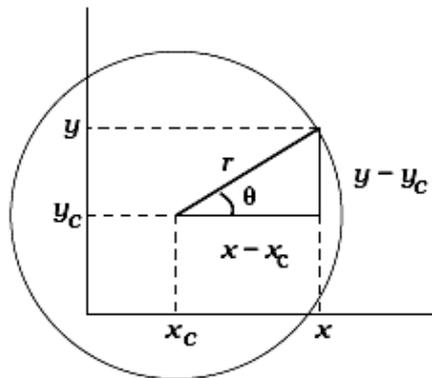


Figura 2.16: Circunferência de raio r e centro (x_c, y_c) (PISTORI; PISTORI; COSTA, 2005).

Para calcular todos os valores de (x_c, y_c) para um determinado ponto (x, y) , geralmente não se utiliza a equação 2.10, pois sua parametrização em função de x_c e y_c não produz, diretamente, implementações eficientes (PISTORI; PISTORI; COSTA, 2005).

$$r^2 = (x - x_c)^2 + (y - y_c)^2 \quad \text{Equação 2.10}$$

A fórmula mais utilizada é baseada em uma representação através coordenadas polares.

É fácil perceber, através da Figura 2.16, que utilizando conceitos elementares de trigonometria as duas equações seguintes são validas (PISTORI; PISTORI; COSTA, 2005):

$$x_c = x - r * \cos(\theta) \quad \text{Equação 2.11}$$

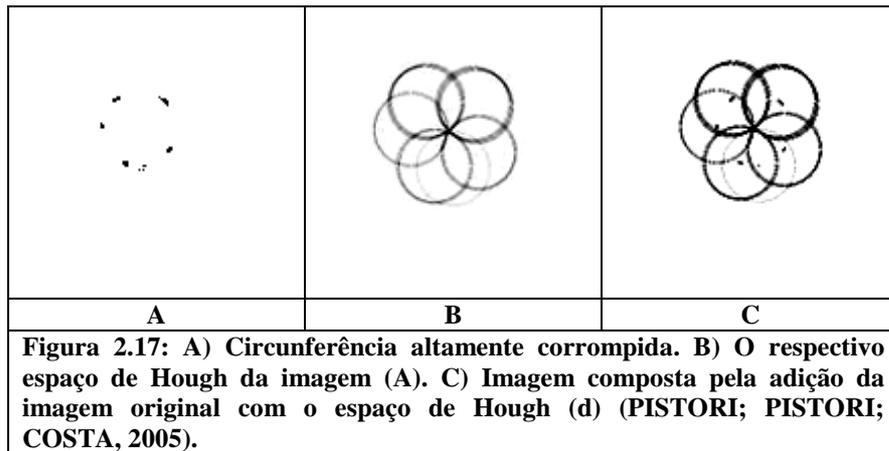
$$y_c = y - r * \text{sen}(\theta) \quad \text{Equação 2.12}$$

O Algoritmo 3.1 mostra como um espaço de Hough, H , pode ser criado a partir de uma imagem digital, I . Depois que o espaço é criado, a detecção de circunferências passa a ser

um problema de se encontrar pontos de máximo no espaço de Hough (por exemplo através do método do gradiente ascendente). É importante notar que o conceito de transformada de Hough aplica-se somente quando é possível se distinguir, na imagem original, os pontos pertencentes ao contorno, ou borda, dos objetos. O Algoritmo 3.1 assume então que imagem é previamente processada através de um filtro de detecção de borda e de um filtro de binarização (que “marca” os pixels pertencentes a uma borda com o valor 255, e todos os outros com o valor 0), (PISTORI; PISTORI; COSTA, 2005).

Algoritmo 3.1: Criação do espaço de Hough	
entrada:	Matriz I , $n * m$, representando a imagem binarizada.
saída:	Matriz H , com o mesmo tamanho da imagem, representando o espaço de Hough.
1:	para $x = 0$ até n faça
2:	para $y = 0$ até m faça
3:	se $I(x; y) = 255$ então
4:	para $\theta = 0$ até $2 * \pi$ faça
5:	$x_c = x - r * \cos(\theta)$
6:	$y_c = y - r * \sin(\theta)$
7:	$H(x_c, y_c) = H(x_c, y_c) + 1$
8:	fim para
9:	fim se
10:	fim para
11:	fim para

Esse espaço de Hough corresponde à imagem contendo uma circunferência altamente corrompida, mostrada na Figura 2.17 A. Na Figura 2.17 B apresenta-se o espaço de Hough através de uma imagem em tons de cinza, em que o brilho é diretamente proporcional ao valor acumulado em cada célula da matriz. O espaço de Hough foi construído para um valor de raio igual ao raio da circunferência da imagem original. Nota-se que o valor máximo (mais claro, com maior concentração de interseções de circunferências) desse espaço coincide com o centro da circunferência presente na imagem. A Figura 2.17 C contém uma imagem composta pela adição da imagem original com o espaço de Hough (PISTORI; PISTORI; COSTA, 2005).



Finalmente é recomendável aplicar um passo de pós-processamento para decidir se os parâmetros encontrados correspondem a uma circunferência na imagem. Para fazer isso, conta-se o número de pixels que ficam próximos de cada circunferência e divide-se pelo perímetro do mesmo. Se a relação estiver abaixo de um valor limiar, descarta-se como ruído (JAMUNDÁ, 2000).

Na Figura 2.18 mostra-se a utilização da implementação em MATLAB da transformada de Hough para circunferências criada por (PENG, 2007). A Figura 2.18 (A) é a imagem original. A Figura 2.18 (B) é o resultado obtido da aplicação do algoritmo de Hough, com os perímetros e os centros das circunferências detectados. A Figura 2.18 (C) contém a visualização do acumulador, onde são procurados os pontos de máximo na superfície, os quais representam os possíveis centros das circunferências.

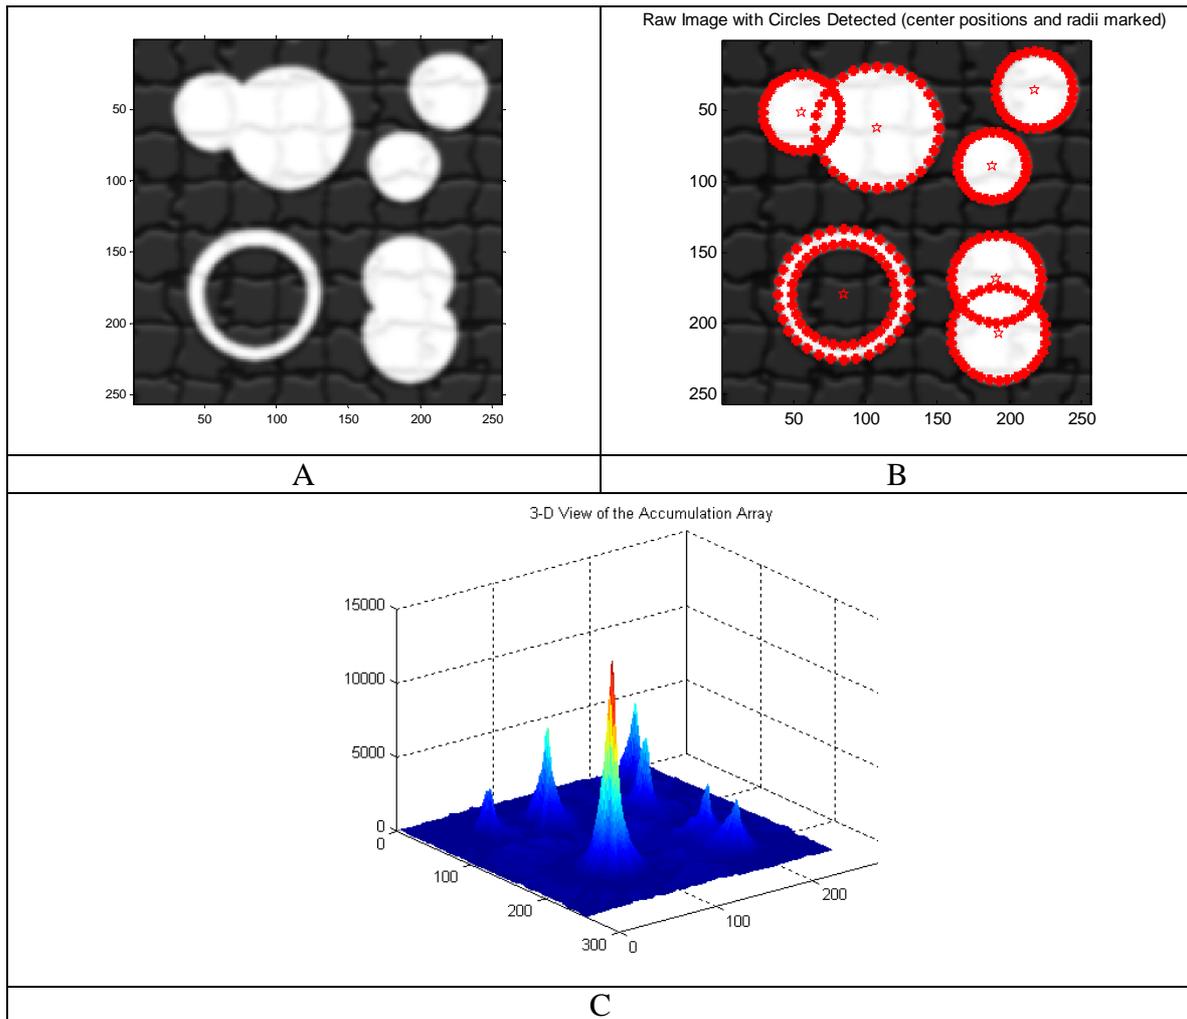


Figura 2.18: Exemplo do uso da transformada de Hough

2.6.2.4 Detecção de Bordas

A detecção de bordas é uma abordagem muito comum para detecção de discontinuidades relevantes. Uma borda ideal cumpre as propriedades do modelo da Figura 2.19 (A). Uma borda ideal é um conjunto de pixels conectados cada um dos quais está localizado em uma transição ortogonal em tons de cinza. Na prática, a ótica, a amostragem e outras imperfeições na aquisição da imagem geram bordas manchadas. Como resultado as bordas podem ser modeladas como tendo o perfil de uma rampa (Figura 2.19 B) (GONZALEZ; WOODS; EDDINS, 2004).

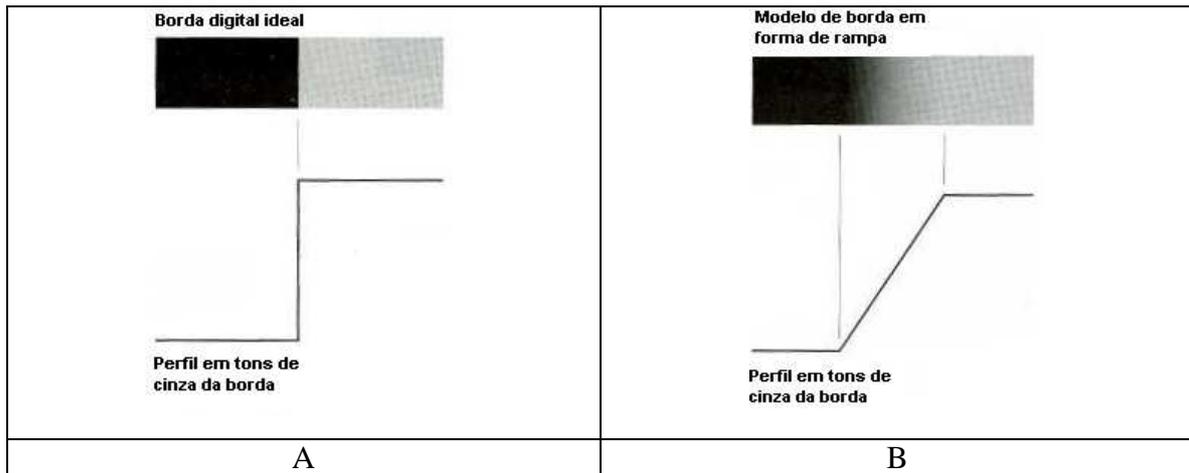


Figura 2.19: Modelos de bordas (GONZALEZ; WOODS; EDDINS, 2004).

Os métodos para detecção de bordas são utilizados para encontrar mudanças na função de intensidade. As bordas são pixels onde esta função (brilho) muda abruptamente. Os pixels da borda com maior magnitude comumente contêm informação suficiente para o entendimento da imagem. O efeito positivo da utilização das bordas é a redução significativa da complexidade da imagem. Em muitos casos esta redução de complexidade não implica a perda de qualidade na interpretação da imagem (SONKA; HLAVAC; BOYLE, 2007).

O cálculo descreve mudanças de funções contínuas utilizando derivadas; devido a que uma imagem pode ser representada como uma função com duas variáveis independentes (as coordenadas no plano) e as bordas são mudanças abruptas nessa função, os operadores de bordas são expressos utilizando derivadas parciais. Uma mudança na função da imagem pode ser descrita pelo gradiente que aponta na direção de maior crescimento da função (SONKA; HLAVAC; BOYLE, 2007).

Uma borda é uma propriedade atribuída a um pixel individual, e é extraída do comportamento da função da imagem na vizinhança daquele pixel. É um vetor variável com dois componentes, magnitude e direção. A magnitude da borda é a magnitude do gradiente, e a direção θ da borda se encontra girada em -90 graus com relação à direção do gradiente φ . A direção do gradiente retorna a direção de crescimento máximo da função, por exemplo, de preto (valor 0) para branco (valor 255), (SONKA; HLAVAC; BOYLE, 2007).

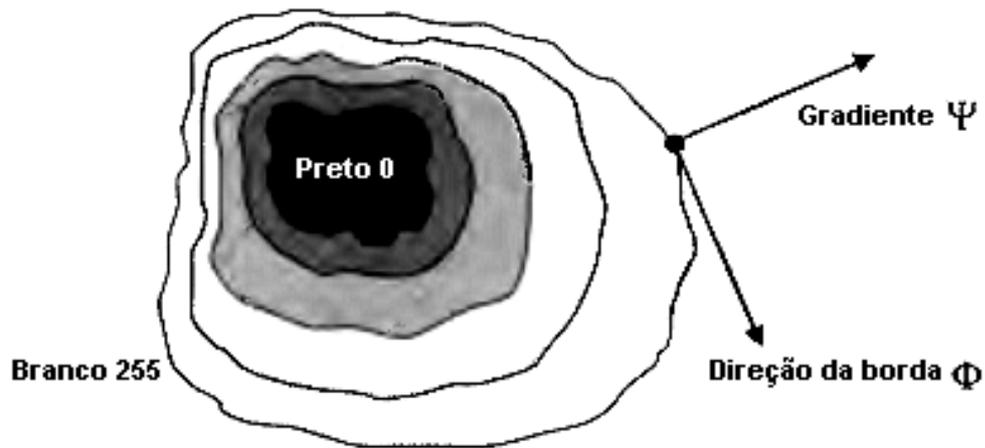


Figura 2.20: Direção do gradiente e direção da borda (SONKA; HLAVAC; BOYLE, 2007).

Bordas são comumente utilizadas para encontrar limites de regiões. Se a região procurada tem luminosidade homogênea, seus limites se encontram nos pixels onde a função da imagem varia, e assim no caso ideal sem ruído os limites serão constituídos dos pixels com alta magnitude de borda. Pode-se reparar que os limites e suas partes (bordas) são perpendiculares à direção do gradiente (SONKA; HLAVAC; BOYLE, 2007).

A magnitude do gradiente $|\text{grad } g(x, y)|$ e a direção φ do mesmo são funções contínuas da imagem e são calculadas através das seguintes equações:

$$|\text{grad } g(x, y)| = \sqrt{\left(\frac{\partial g}{\partial x}\right)^2 + \left(\frac{\partial g}{\partial y}\right)^2} \quad \text{Equação 2.13}$$

$$\psi = \arg\left(\frac{\partial g}{\partial x}, \frac{\partial g}{\partial y}\right) \quad \text{Equação 2.14}$$

Onde $\arg(x, y)$ é o ângulo (em radianos) formado pelo eixo horizontal absoluto da imagem e o ponto (x, y) . No caso de procurar somente as magnitudes das bordas, sem importar sua orientação, é possível utilizar o operador linear diferencial Laplaciano. O Laplaciano possui as mesmas propriedades em todas as direções e é consequentemente invariante a rotação na imagem.

É definido como (SONKA; HLAVAC; BOYLE, 2007):

$$\nabla^2 g(x, y) = \frac{\partial^2 g(x, y)}{\partial x^2} + \frac{\partial^2 g(x, y)}{\partial y^2}. \quad \text{Equação 2. 15}$$

Para enfatizar as bordas (*sharpening*) de uma imagem g obtendo como resultado uma imagem f , utiliza-se a seguinte equação (SONKA; HLAVAC; BOYLE, 2007):

$$f(i, j) = g(i, j) - C S(i, j) \quad \text{Equação 2. 16}$$

Onde C é um coeficiente positivo que indica a força que enfatiza as bordas e $S(i, j)$ é calculado utilizando o operador gradiente. O Laplaciano é muito utilizado para este propósito. As categorias de operadores do gradiente mais utilizados são:

- Operadores aproximando derivadas da função da imagem utilizando diferenças. Alguns deles são invariantes à rotação (como, por exemplo, o Laplaciano), e são calculados através de uma única máscara. Outros, que aproximam primeiras derivadas, utilizam várias máscaras. A orientação é estimada na base do emparelhamento de vários padrões simples (SONKA; HLAVAC; BOYLE, 2007).
- Operadores baseados nos pontos de zero da derivada segunda da função da imagem (como, por exemplo, o detector de Canny).

Os operadores individuais que examinam pequenas vizinhanças locais (primeira categoria) são na realidade convoluções, e podem ser expressas através de máscaras. Os operadores capazes de reconhecer a direção das bordas são representados por várias máscaras, cada uma correspondente a uma direção (SONKA; HLAVAC; BOYLE, 2007).

2.6.2.4.1 Operador de Roberts

O operador de Roberts é um dos operadores mais antigos. Utiliza a vizinhança 2x2 do pixel. Suas máscaras de convolução são:

$$h_1 = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}, \quad h_2 = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}$$

Figura 2.21. Máscaras do operador de Roberts

Assim a magnitude da borda é calculada:

$$|g(i, j) - g(i+1, j+1)| + |g(i, j+1) - g(i+1, j)| \quad \text{Equação 2. 17}$$

A principal desvantagem do operador de Roberts é sua alta sensibilidade a ruídos, porque poucos pixels são utilizados para aproximar o gradiente.

2.6.2.4.2 O operador de Laplace

Este operador (denotado por ∇^2) é um operador que aproxima a derivada segunda, que fornece somente a magnitude do gradiente. O Laplaciano é aproximado através de uma convolução. Uma máscara 3 x 3 h é comumente utilizada. Para a 4-vizinhança a máscara é definida como (SONKA; HLAVAC; BOYLE, 2007):

$$h = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

Figura 2.22. Operador Laplaciano

O operador Laplaciano tem a desvantagem de responder em dobro para alguns eixos na imagem.

2.6.2.4.3 Operador de Prewitt

O operador de Prewitt aproxima a derivada primeira. O gradiente é estimado em oito possíveis direções (para máscaras de convolução de 3 x 3), e o resultado da convolução de

maior magnitude indica a direção do gradiente. As máscaras de convolução de Prewitt mais utilizadas são (SONKA; HLAVAC; BOYLE, 2007):

$$h_1 = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}$$

Figura 2.23. Máscaras de Prewitt.

A direção do gradiente é dada pela máscara que retorne a resposta máxima. Este é o caso para todos os operadores que aproximam a derivada primeira.

2.6.2.4.4 Operador de Sobel

De forma semelhante ao operador de Prewitt, aproxima a derivada primeira. As máscaras de convolução mais utilizadas do operador de Sobel são:

$$h_1 = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$$

Figura 2.24. Máscaras de Sobel

O operador de Sobel é frequentemente utilizado como um detector de bordas verticais e horizontais. Se a resposta de h_1 é y e a resposta de h_2 é x é possível derivar a magnitude da borda como (SONKA; HLAVAC; BOYLE, 2007):

$$\sqrt{x^2 + y^2} \text{ ou } |x| + |y|$$

Equação 2.18

E a direção da borda é igual a: $\arctan(y/x)$.

A seguir serão descritos os operadores baseados nos pontos de zero da derivada segunda (segunda categoria de operadores de bordas). Os operadores da primeira categoria estavam baseados na convolução de vizinhanças muito pequenas e funcionavam bem somente para imagens específicas. A maior desvantagem destes detectores de bordas é sua

dependência do tamanho do objeto e sensibilidade a ruído (SONKA; HLAVAC; BOYLE, 2007).

Uma técnica baseada nos pontos de zero da derivada segunda explora o fato que uma borda corresponde a uma mudança abrupta na função da imagem. Nesse ponto a derivada primeira deverá ter um ponto de máximo/mínimo e derivada segunda será zero (Figura 2.25). Contudo é mais fácil e preciso um ponto de zero do que um ponto de máximo/mínimo. Esta é a grande vantagem destes operadores com relação aos operadores que utilizam a derivada primeira (SONKA; HLAVAC; BOYLE, 2007).

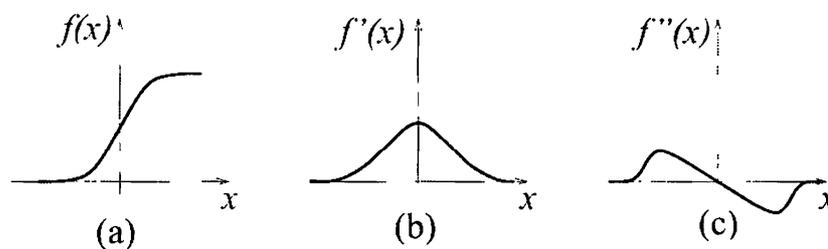


Figura 2.25: Exemplificação do comportamento das derivadas da função da imagem. A) Função da imagem. B) Derivada primeira da função. C) Derivada segunda

2.6.2.4.5 Detecção de bordas de Canny

Canny propôs uma abordagem para detecção de bordas que é ótima para bordas corrompidas com ruído branco. A otimização deste detector está relacionada a três critérios (SONKA; HLAVAC; BOYLE, 2007):

- a) O critério de detecção: bordas importantes não devem ser perdidas e não deve devolver respostas defeituosas.
- b) O critério de localização: a distância entre a posição real e a posição localizada da borda deve de ser mínima.
- c) O critério de resposta: minimização de respostas múltiplas para uma borda somente.

No operador de Canny o primeiro passo consiste em filtrar a imagem com um operador gaussiano para reduzir a interferência do ruído nas bordas detectadas, como por exemplo:

$$\frac{1}{115} \begin{bmatrix} 2 & 4 & 5 & 4 & 2 \\ 4 & 9 & 12 & 9 & 4 \\ 5 & 12 & 15 & 12 & 5 \\ 4 & 9 & 12 & 9 & 4 \\ 2 & 4 & 5 & 4 & 2 \end{bmatrix}$$

Depois da filtragem o gradiente é calculado através da soma dos módulos GX e GY, obtidos através dos operadores de Sobel (Figura 2.24) e as bordas são obtidas através de um limiar. Depois de obtidas as bordas, o operador de Canny executa uma supressão de não máximos com o objetivo de afinar a borda encontrada, selecionando apenas o valor máximo do gradiente. Para evitar que as bordas contínuas sejam rompidas por problemas de ruído, o operador de Canny faz uso de dois limiares T1 e T2, onde $T2 > T1$. Como o valor do limiar T2 é maior, isto indica menor probabilidade de falsas detecções, mas maior ocorrência de bordas quebradas. Dessa forma o algoritmo busca nas detecções de limiar T1, bordas que sejam capazes de religar conexões nas bordas de limiar T2. Estas modificações permitem ao operador de Canny uma grande eficiência e imunidade ao ruído na detecção de bordas. Em contrapartida é necessário um maior tempo computacional (MOUTINHO; THOMÉ, 2005).

2.6.2.5 Utilização do movimento para segmentação

Movimento é uma dica utilizada por humanos e animais para extrair objetos de interesse de um fundo com detalhes irrelevantes. Em aplicações de imagem o movimento aparece de um deslocamento relativo entre o sensor e a cena que está sendo visualizada.

Existem técnicas especiais para segmentação. A abordagem mais simples para detectar mudanças entre duas imagens $f(x, y, t_i)$ e $f(x, y, t_j)$, extraídas nos instantes t_i e t_j consiste em

comparar ambas as imagens pixel a pixel. Uma maneira de realizar isto é através da subtração de um quadro de referência (que contém somente componentes estacionárias) de um quadro subsequente da mesma cena (que contém um objeto em movimento) (GONZALEZ; WOODS, 2002).

A diferença entre duas imagens extraídas nos instantes t_i e t_j pode ser definida como:

$$d_{ij}(x, y) = \begin{cases} 1 & \text{se } |f(x, y, t_i) - f(x, y, t_j)| > T \\ 0 & \text{caso contrário} \end{cases} \quad \text{Equação 2.19}$$

Onde T é um limiar pré-estabelecido.

2.6.2.6 Limiarização (Binarização)

Limiarização é um tipo especial de corte no contraste de imagens em tons de cinza. Determina-se um limite no mapa de valores dos tons de cinza obtendo como resultado uma imagem binária (em preto e branco). Este método é muito simples, porém muito utilizado por ser uma operação muito rápida que consegue destacar regiões de interesse de problemas simples (Figura 2.26). A grande dificuldade deste método é a escolha de um valor para o limiar, que seja o mais genérico possível para todas as imagens do problema. A função utilizada para a limiarização é mostrada na Figura 2.27.



Figura 2.26: Limiarização de uma Imagem para destacar suas características principais

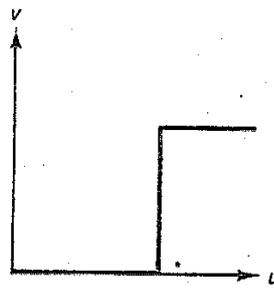


Figura 2.27: Função de limiarização

2.6.3 Extração de características

Após a segmentação da imagem o resultado é frequentemente representado e descrito em uma forma apropriada para o próximo passo no processamento. Basicamente representar uma região envolve duas possibilidades: 1) Representar as regiões em termos de suas características externas (limites), ou 2) representá-las em termos de suas características internas (os pixels que compõem a imagem). No entanto, a escolha do método de representação é somente uma parte da tarefa de tornar os dados utilizáveis para um computador. A seguinte tarefa é descrever a região baseada na representação escolhida. Por exemplo, uma região pode ser representada por sua borda, e a borda descrita por características como seu comprimento, a orientação de uma linha reta que junta seus pontos extremos ou o a quantidade de concavidades que apresenta.

Uma representação externa é escolhida quando o foco principal se encontra em suas características de forma. Uma representação interna é selecionada quando o alvo é uma propriedade regional como, por exemplo, cor ou textura. Algumas vezes é necessário utilizar ambos os tipos de representação. De qualquer forma as características selecionadas como descritores devem ser o menos sensível possível as variações de tamanho, translação e rotação. Os descritores aqui apresentados tentam cumprir uma ou mais destas propriedades de invariância (GONZÁLES; WOODS, 2002).

2.6.3.1 Descritores de forma

Apresenta-se a seguir alguns descritores de forma (BATCHELOR; WHELAN, 2002):

- Distância entre o ponto mais distante da borda e o centróide do objeto;
- Distância entre o ponto mais próximo da borda e o centróide do objeto;
- A quantidade de furos do objeto;
- As distâncias de pontos na borda do objeto desde o centróide em função de posição angular. Isto descreve a silhueta em termos de coordenadas polares;
- A circularidade, que é obtida utilizando a fórmula: $\text{área} / \text{perímetro}^2$. Esta proporção tende a zero para formas irregulares com margens irregulares e tem valor máximo igual a $1/4\pi$.

2.6.4 Análise da Imagem (Interpretação/Classificação)

Para alguns aplicativos as características extraídas da imagem são tudo o que é requerido. Porém, muitas vezes é necessário efetuar um passo extra após a extração de características: a interpretação/classificação.

Uma operação simples de interpretação é a conversão de unidades. Raramente pixels ou nível de cinza serão unidades apropriadas para um aplicativo industrial.

Além das operações simples de interpretação, existem métodos de classificação mais complexos, como, por exemplo, o reconhecimento de padrões.

2.6.4.1 Reconhecimento de padrões

O reconhecimento de padrões tem como um objetivo o reconhecimento de regiões de imagens individuais (padrões). Um padrão é caracterizado por seus descritores. Dentre os métodos mais utilizados no reconhecimento de padrões podem ser citadas os classificadores de distância mínima, classificadores estatísticos e as redes neurais.

O termo reconhecimento engloba uma grande quantidade de problemas de processamento de informação de alta relevância prática, como, por exemplo, reconhecimento de voz, classificação de caracteres manuscritos e diagnóstico médico. Esses problemas são facilmente resolvidos por pessoas. No entanto, a solução deles usando computadores, em muitos casos, provou ter uma alta complexidade. A forma mais genérica de resolver problemas de reconhecimento de padrões é o método estatístico. As redes neurais são uma extensão das técnicas convencionais de reconhecimento de padrões estatístico (BISHOP, 1995).

Um exemplo simples é o reconhecimento de duas classes de objetos, cada uma com uma característica única que as diferencia uma do outra. Ambas as classes serão divididas através desta característica. Esta divisão é realizada através de uma fronteira de decisão, que deverá ser obtida através de algum método de reconhecimento de padrões. Este conceito é mostrado graficamente na Figura 2.28. Este problema hipotético de classificação envolve as características x_1 e x_2 . As circunferências denotam os padrões da classe C_1 e as cruces denotam os padrões da classe C_2 . A fronteira de decisão (representada pela reta na Figura 2.28) determina uma boa separação das classes, apesar de ter alguns padrões que são classificados incorretamente (BISHOP, 1995).

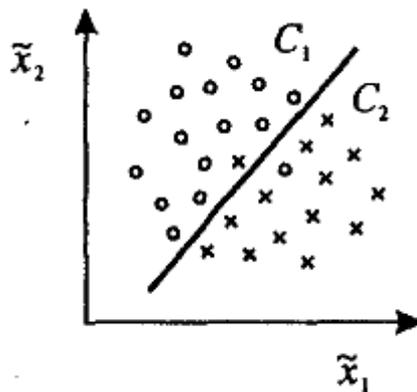


Figura 2.28. Classificação de dois objetos, (BISHOP, 1995).

Um exemplo prático do reconhecimento de padrões é o reconhecimento de caracteres manuscritos. Um exemplo das pesquisas nesta área é o trabalho realizado por (SILVA; THOMÉ, 2002). Outro exemplo de pesquisas práticas é o trabalho de (TAMBERLINI; THOMÉ, 2007), que pertence à área de reconhecimento de impressões digitais.

Uma descrição mais aprofundada sobre reconhecimento de padrões utilizando redes neurais pode ser encontrada em (HAYKIN, 1999).

3 PROCESSAMENTO DE IMAGENS E A ATIVIDADE INDUSTRIAL

3.1 Introdução

Trata-se de uma tecnologia que tem muito a oferecer para a indústria, melhorando, por exemplo, a qualidade dos produtos, aumentando o nível da segurança, e a eficiência dos processos (BATCHELOR; WHELAN, 2002).

Devido ao grande potencial de uso das técnicas de processamento de imagens na indústria foi criada uma subárea específica para este tema dentro das pesquisas de visão por computador: a Visão de Máquina (Machine Vision). Esta área visa resolver os problemas industriais através de qualquer tipo de sensor visual, como por exemplo, os raios X. Isto a diferencia das pesquisas que tentam emular a visão humana que restringem o uso de sensores para câmeras.

Hoje em dia é possível encontrar tecnologia baseada na visão de máquina em diversas áreas na indústria. O maior setor consumidor desta tecnologia é a indústria eletrônica, realizando inspeções em todo o processo de fabricação de circuitos integrados. Nos setores que fabricam produtos em esteiras, como papel, plásticos e têxteis, a visão de máquina está sendo utilizada para inspecionar a integridade do produto. Nos produtos onde é aplicado algum tipo de cobertura (tempero), como, por exemplo, salgados, a visão de máquina é utilizada para verificar a qualidade da cobertura realizada. Na indústria alimentícia a visão de máquina é utilizada para separar produtos defeituosos, verificar forma e tamanho. É possível encontrar aplicações para verificação de etiquetas. No setor farmacêutico têm-se aplicativos que verificam os caracteres das datas de validade dos produtos. Na indústria automotiva existem aplicativos, por exemplo, para verificar a qualidade da pintura e verificação da correta montagem dos veículos (ZUECH, 2000).

As diferentes formas de aplicação de processamento de imagens na área industrial podem ser analisadas segundo uma visão técnica, dada pelo tipo de processo em que atuam, ou segundo uma visão econômica, dado pelo segmento da indústria a que pertencem.

3.2 Classificação quanto ao processo dos aplicativos de visão de máquina

As aplicações são organizadas segundo o objetivo a que se propõem dentro do processo industrial. Neste sentido sua classificação é:

- Monitoração de Processos;
- Controle de Processos;
- Controle de Qualidade.

3.2.1 Monitoração de Processos

Envolve o processamento das informações visuais tendo como objetivo a geração e o envio de sinais ou dados para uma unidade gerenciadora externa. Esta unidade externa é a encarregada de realizar alguma operação (armazenamento, tomada de decisões, entre outras) com base nos dados enviados pelo sistema de monitoração. Como exemplo desta classe de aplicativos tem-se a Monitoração da Queda da Primeira Gota de uma Unidade de Destilação de Petróleo em Batelada (LIMA; THOMÉ, 2004). Nesse estudo de caso o alvo é detectar o momento exato do desprendimento da primeira gota da primeira fração de petróleo obtida na destilação. A queda da primeira gota representa o começo do processo de destilação e demora entre uma e duas horas para se formar. A não detecção deste evento ocasionaria o fracasso da destilação, sendo necessário recomençar o processo do zero, perdendo tempo e recursos. O sistema de monitoramento envia um sinal toda vez que acontecer a queda da gota, sem que seja necessário que o aplicativo realize outra operação, pois será uma unidade de controle externa a que efetuará a tomada de decisões.

Na Figura 3.1 A mostra-se queda de uma gota de um subproduto de petróleo e o resultado da detecção do sistema na Figura 3.1 B.

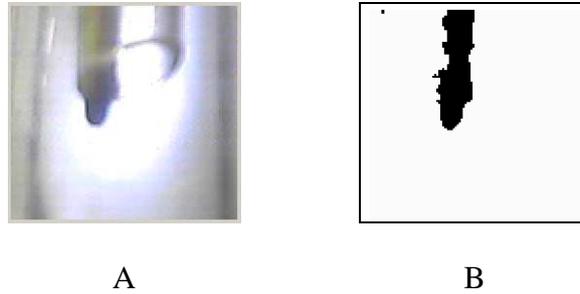


Figura 3.1: Queda da primeira Gota em uma destilação de petróleo em batelada.

3.2.2 Controle de Processos

Aqui o alvo não é somente analisar alguma imagem e enviar dados para uma unidade externa. Neste caso é o próprio sistema que toma as decisões e que será realimentado a cada ciclo do processo de produção. Como exemplo pode-se citar o trabalho de (HONGLU; MACGREGOR, 2004) que descreve o controle da chama de aquecedores industriais (Figura 3.2). A quantidade de combustível fornecida para o aquecedor é controlada pelo estado da chama. O objetivo é otimizar a utilização do combustível, poupando recursos. Na Figura 3.3 mostram-se alguns dos estados da chama extraídos no estudo.

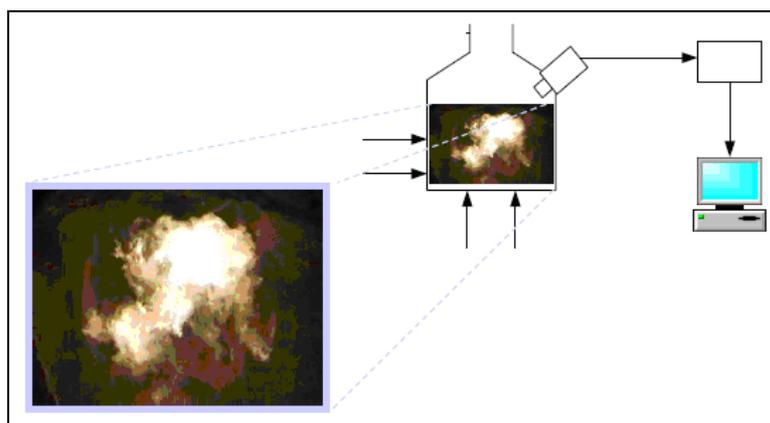


Figura 3.2: Sistema de controle da chama de aquecedores industriais (HONGLU; MACGREGOR, 2004)

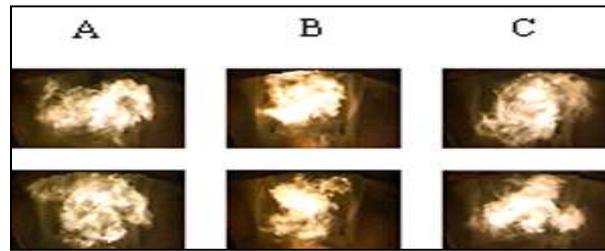


Figura 3.3: Estados possíveis da chama dos aquecedores (HONGLU; MACGREGOR, 2004)

3.2.3 Controle de Qualidade

Nesta classe o sistema pode ter algum tipo de “inteligência” visando analisar e decidir se o produto satisfaz aos padrões estabelecidos para a produção. Um exemplo deste tipo de sistema é a detecção de defeitos em texturas de tecidos. Como exemplo pode-se citar um aplicativo que controla a quantidade de tempero que deve ser aplicada a salgados (HONGLU et al., 2003). Neste aplicativo os dados extraídos da monitoração são repassados para um modelo de regressão parcial de mínimos quadrados. Este modelo é comumente utilizado na quimiometria, que é definida como a ciência relacionada a medidas realizadas em um sistema ou processo químico, obtendo informações sobre o estado do sistema através da aplicação de métodos matemáticos ou estatísticos. Através desta regressão são diagnosticados problemas no processo de revestimento dos salgados.

Na Figura 3.4 apresentam-se algumas das amostras utilizadas para o controle de qualidade dos salgados

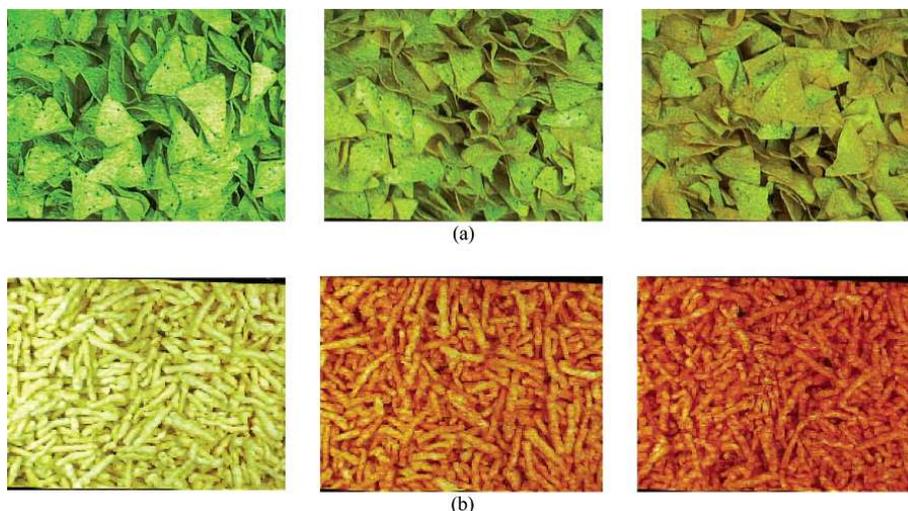


Figura 3.4: Salgados. (a) Produto A. (b) Produto B (HONGLU et al., 2003).

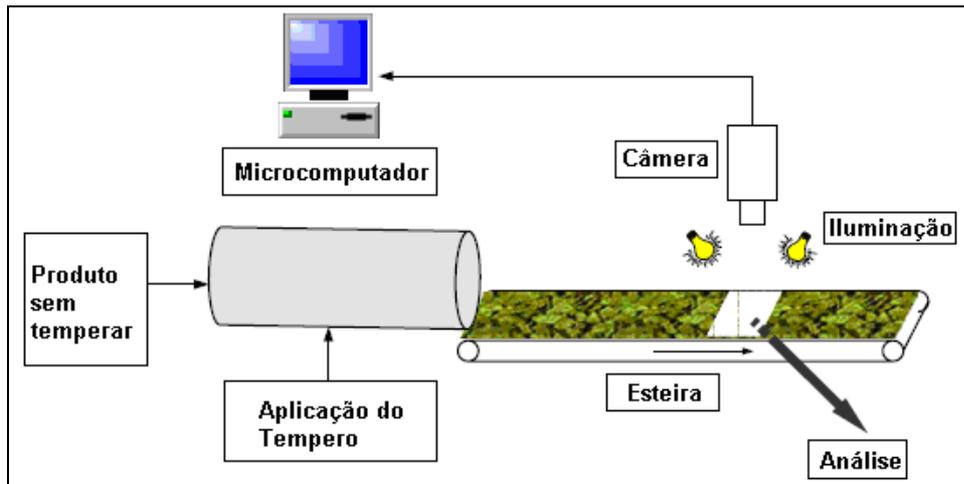


Figura 3.5: Sistema de controle de qualidade de salgados (HONGLU et al., 2003).

3.3 Classificação quanto ao Segmento Econômico

Dependendo do segmento econômico a demanda pode ser maior e mais específica. Os principais segmentos descritos na literatura são:

3.3.1 Indústria Petrolífera

Na indústria de monitoração petrolífera existem alguns aplicativos desenvolvidos utilizando técnicas de processamento de imagens. Como exemplo destes aplicativos pode-se citar o trabalho desenvolvido por (BREKKE; SOLBERG, 2005). Nesse trabalho foi realizada uma revisão dos trabalhos desenvolvidos para efetuar a detecção automática de derramamentos de petróleo através de imagens recebidas por satélites. Sensores de microondas, como o radar de abertura sintética (RAS), capturam imagens bidimensionais. O brilho da imagem é uma reflexão da radiação das microondas na superfície. Os sensores instalados em satélites têm a vantagem de cobrir áreas amplas e conservar a qualidade das imagens geradas não importando as condições climatológicas da área examinada.

As manchas de petróleo suprimem as ondas Bragg (comprimento de onda de poucos centímetros) na superfície do oceano e reduzem o coeficiente de radiação do radar. Conseqüentemente são obtidas regiões escuras nas imagens geradas pelos RAS.



Figura 3.6. Imagem extraída do satélite RADARSAT-1 através de um sensor RAS contendo derramamentos de petróleo (BREKKE; SOLBERG, 2005).

A Figura 3.7 contém o arcabouço proposto para detecção de derramamentos de petróleo. É facilmente identificável que este arcabouço é uma simplificação dos modelos tradicionais utilizados na visão de máquina apresentados na seção 2.5.

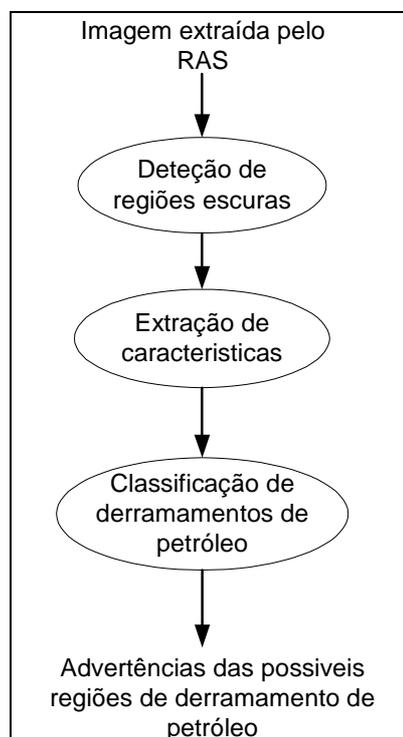


Figura 3.7. Arcabouço para algoritmos de detecção de derramamentos de petróleo (BREKKE; SOLBERG, 2005).

A segmentação é realizada através de limiarização devido ao alto contraste das regiões que representam derramamentos de petróleo na imagem. Um filtro de mediana é aplicado para suavizar as bordas das manchas de petróleo.

A extração de características é realizada analisando a geometria, a forma, e o perímetro da região segmentada. Outra possível característica identificável é o momento estatístico de Hu entre muitos outros. Para a etapa de classificação foram propostos métodos como redes neurais do tipo MLP e o classificador de Mahalanobis (BREKKE; SOLBERG, 2005).

3.3.2 Indústria Automotiva

Dentre as aplicações para a indústria automotiva, pode-se citar como principais exemplos a detecção de defeitos nas peças (prévia à montagem do automóvel); a inspeção dos instrumentos do veículo como o tacômetro (calibragem, revisão das etiquetas); a inspeção da montagem de cintos de segurança; a inspeção na montagem do tanque de gasolina; verificação da aparência e detalhes visuais, como a falta de um furo na carroceria (HAGENIERS, 2001).

Um exemplo comercial é o aplicativo WG-AutoLux-1.0 (Figura 3.8) que opera como um analisador de faróis de carros. Uma imagem da iluminação gerada pelos faróis do carro é capturada em tons de cinza e avaliada pelo sistema, o que resulta em uma série de relatórios do estado dos faróis. É possível também fazer uma simulação do desempenho dos faróis em estradas virtuais, sendo assim possível para um inspetor humano avaliar o desempenho sem ter que fazer um percurso real com o automóvel.

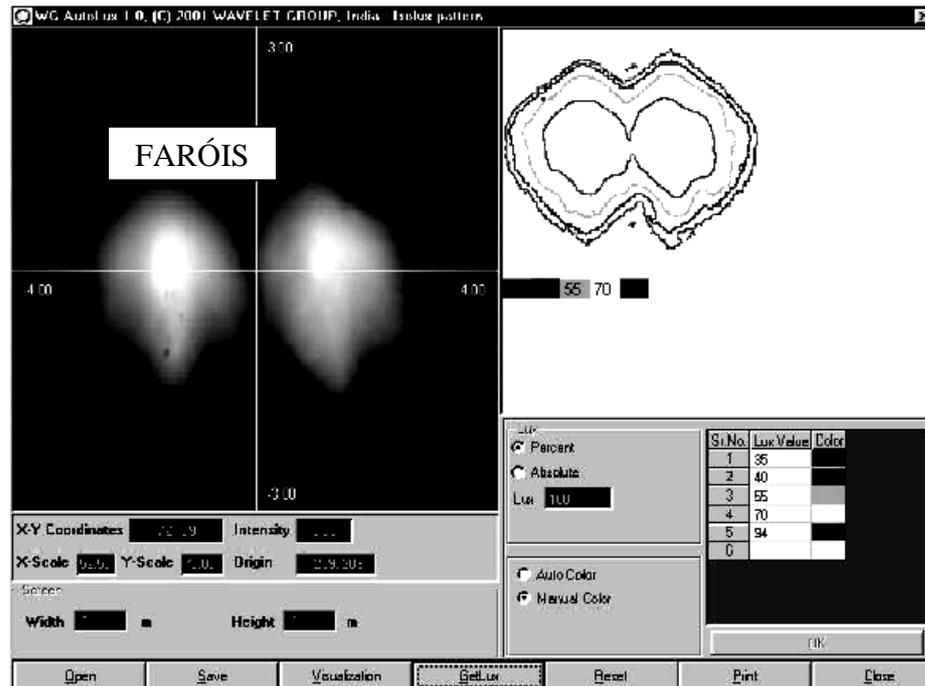


Figura 3.8: Imagem da Aplicação analisadora de faróis de carros WG-AutoLux

Em (BLACKWELL, 1989) foi feita uma revisão de aplicativos para o controle de qualidade de pneus. É apresentada uma divisão do tipo de aplicativos orientados à indústria dos pneus: medição sem contato, verificação de processos e identificação de produtos. Todos estes tipos de aplicativo envolvem a aquisição de uma imagem de uma câmera, análise da imagem e comunicação dos resultados. As principais diferenças entre estes aplicativos são a configuração e posicionamento da câmera, as lentes, iluminação e os métodos de análise das imagens.

Através da medição sem contato as dimensões de um produto podem ser revisadas, como por exemplo, a espessura do mesmo. Esta revisão antigamente não era realizada em tempo real, ocasionando que a correção do processo seja efetuada depois que o produto defeituoso tivesse sido terminado (BLACKWELL, 1989).

A segunda grande área de aplicação da visão de máquina é a verificação. Esta consiste em conferir o correto funcionamento da linha de montagem. A diferença com relação aos aplicativos de medição sem contato é que a verificação é realizada no começo do processo (BLACKWELL, 1989).

A terceira categoria de aplicativos está relacionada com a classificação de produtos. A visão de máquina tem maior sucesso nas aplicações onde a classificação é baseada em medidas dimensionais como, por exemplo, altura ou raio.

A saída esperada destes sistemas varia desde a aceitação ou rejeição de peças, a identificação de códigos ou as medidas do produto.

A Figura 3.9 apresenta um exemplo de aplicativo que verifica a superfície de pneus.

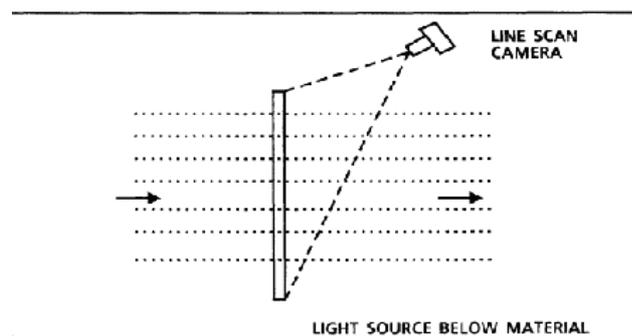


Figura 3.9: Verificação da superfície do pneu (BLACKWELL, 1989).

3.3.3 Indústria Eletrônica

Na área da inspeção automatizada de fábricas de montagem de peças eletrônicas, um dos interesses está em analisar imagens de produtos com o objetivo de determinar a presença ou ausência de anomalias específicas, como componentes faltantes ou conexões quebradas (GONZÁLES; WOODS; EDDINS, 2004)

Outro exemplo é a inspeção de placas eletrônicas. Aqui é controlada a correta montagem das peças na placa (Figura 3.10). Para realizar esta inspeção é utilizada a abordagem de molde universal (Golden Template). O usuário guia a câmera do sistema manualmente e indica os lugares onde a imagem tem que ser extraída. Além disso, os componentes (resistores, capacitores) também são marcados. Com essa informação o sistema gera o molde universal para a placa.

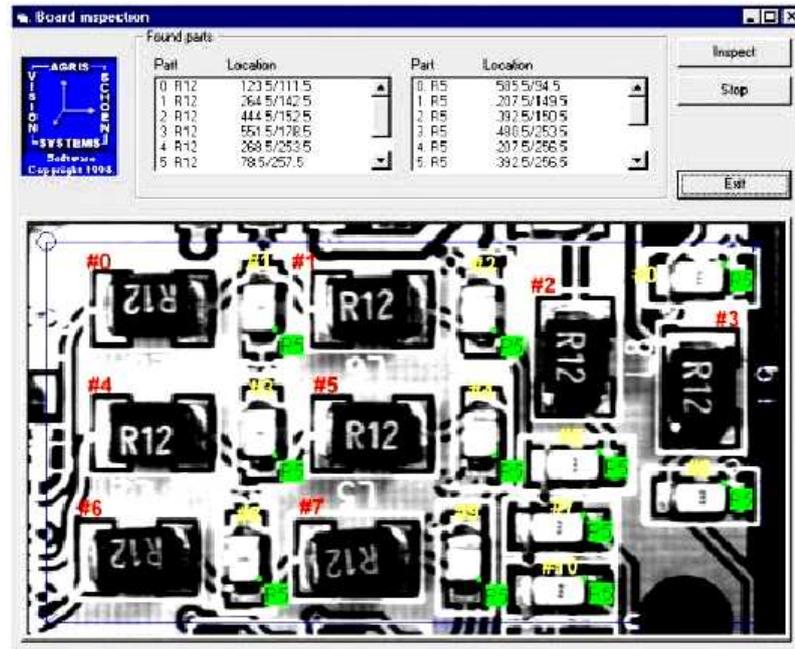


Figura 3.10: Sistema de Inspeção de Placas Eletrônicas

Em (EDWARDS, 1990) mostrou-se um aplicativo de inspeção de placas de circuito integrado (PCI) durante a montagem. Os sistemas de visão de máquina são uma alternativa viável para automatizar processos de fabricação de produtos eletrônicos, tanto para monitoração como para controle dos processos.

Realinhamento de posicionamento de componentes. Um aplicativo comum é a correção do alinhamento de componentes nas placas de circuitos integrados. A correção espacial nos eixos x e y é conseguida ajustando a posição da placa do circuito integrado, e a correção do ângulo é obtida girando a cabeça que posiciona os circuitos. Estes sistemas são implementados frequentemente utilizando técnicas de captura de imagens binárias utilizando um limiar que produza a silhueta de cada dispositivo inspecionado (Figura 3.11), (EDWARDS, 1990).

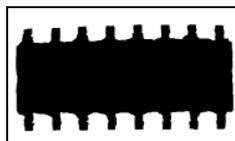


Figura 3.11: Imagem binária de um componente eletrônico

Esta imagem binária é processada para identificar componentes danificados, por exemplo.

3.3.4 Indústria de alimentos e bebidas

Em (ALEIXOS et al., 2000) é apresentado um sistema para classificar a qualidade de cítricos (tangerina, limão, entre outros) segundo seu aspecto externo. As características reconhecidas pelo sistema são: tamanho, forma, e cor. Os algoritmos utilizados são processados em paralelo para aumentar o desempenho do sistema. Foi projetada uma câmera multi-espectral (combinando os espectros RGB e infravermelho) para adquirir as imagens. A detecção do tamanho é realizada utilizando o espectro infravermelho, devido a que o fundo das cenas quase não reflete a luz infravermelha. Portanto, utilizando limiarização é possível segmentar a fruta. Em seguida é aplicado um detector de bordas. São depois calculadas as seguintes informações: o centróide, diâmetro máximo e mínimo, superfície, perímetro e circularidade.

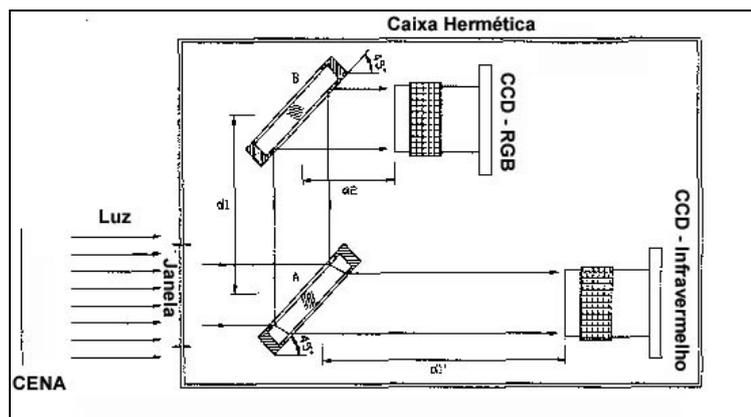


Figura 3.12: Câmera multi-espectral

Os frutos giram enquanto são obtidas as imagens. A cada certo intervalo de tempo são obtidas imagens da região central do fruto girando todas as imagens obtidas são juntadas em uma faixa uma acima da outra (Figura 3.13 A).

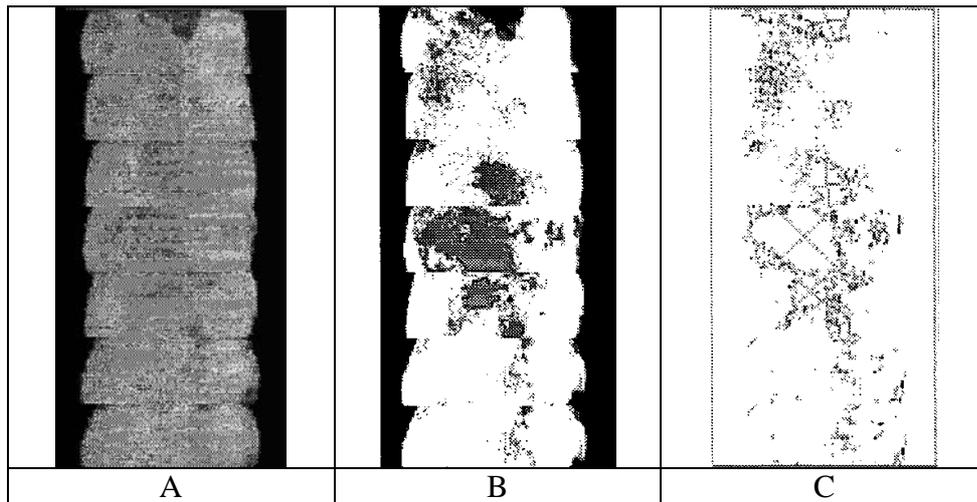


Figura 3.13: A) Faixa que junta imagens da região central do fruto girando. B) Imagem Segmentada. C) Deformidades detectadas

Antes de realizar a detecção, o sistema deve de ser treinado manualmente. Um operário seleciona diferentes janelas representando classes pré-estabelecidas (como fundo, cor primária, cor secundária, deformidades). Um modelo bayesiano discriminatório é gerado com as bandas RGB como variáveis independentes e são contados o número de pixels das classes cor primaria e secundaria. Os mesmos algoritmos utilizados para descrever as características do fruto são empregados para descrever as deformidades.

3.3.5 Indústria Farmacêutica

O sistema apresentado em (DERGANC et al., 2003) efetua a inspeção de comprimidos dentro de cartelas transparentes. As cartelas são verificadas, detectando a ausência de comprimidos e, a existência comprimidos quebrados. A cor, o tamanho e forma dos comprimidos são verificados também. O sistema tem dois modos de operação: treinamento e inspeção.

Na etapa de treinamento é empregada uma imagem da cartela sem defeitos para extrair um modelo dela, que é composto da função de correção de não uniformidade de cor espacial, posição das cartelas, posição dos comprimidos nas cartelas, função de etiquetagem de cor, posição, tamanho e forma de cada comprimido e suas correspondentes tolerâncias pré-estabelecidas.

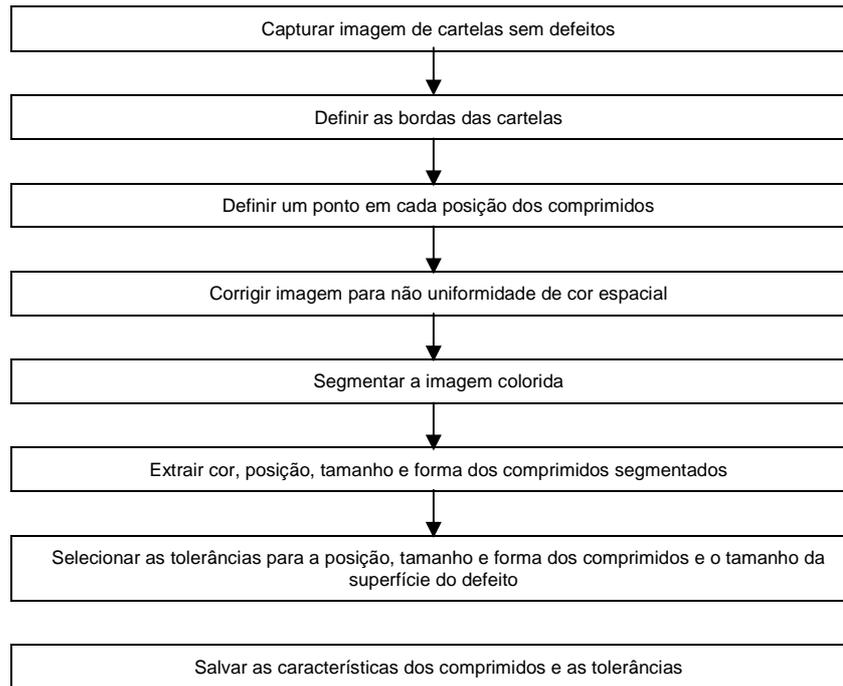


Figura 3.14: Fluxograma da fase de treinamento do sistema (DERGANC et al., 2003)

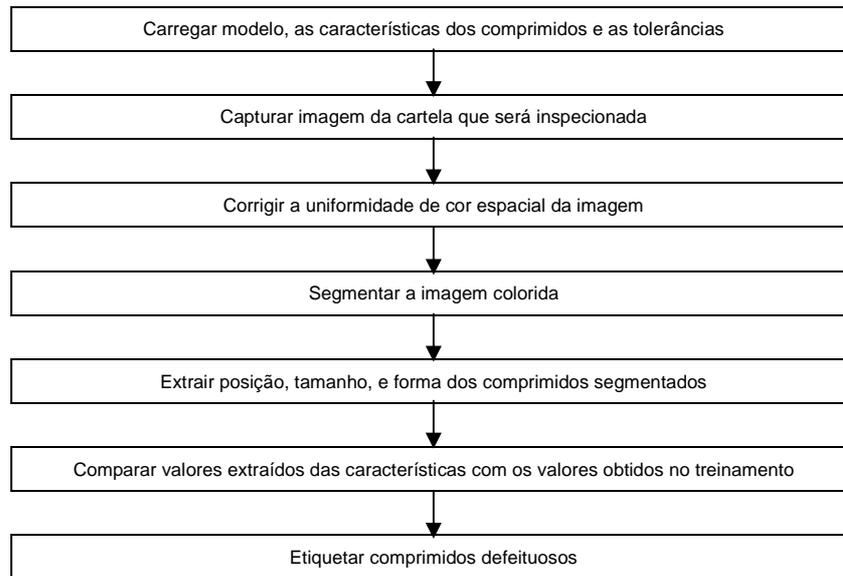


Figura 3.15: Fluxograma da fase de inspeção (DERGANC et. al., 2003)

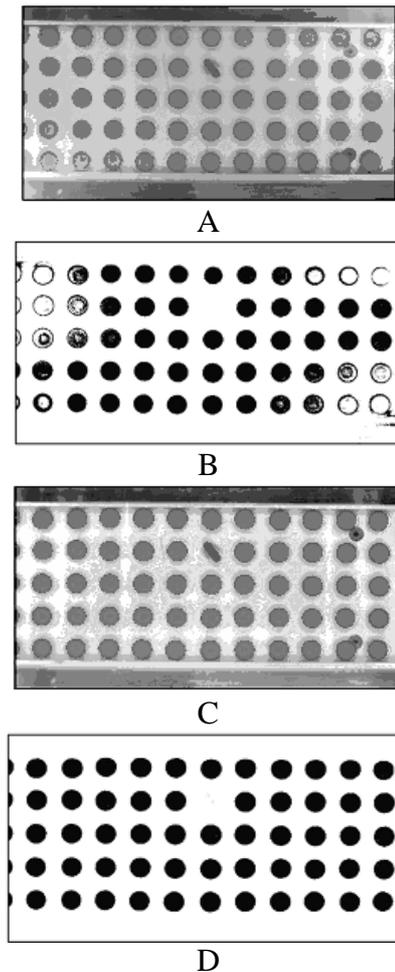


Figura 3.16: A) Imagem com não uniformidade de cor. B) Imagem segmentada. C) Imagem com correção de cor. D) Imagem segmentada correspondente à imagem com correção de cor

3.3.6 Segurança e Biometria

Com relação aos aplicativos de segurança tem-se o trabalho de (LIMA; THOMÉ, 2004) de controle anti-furto de objetos. Nesse estudo o objetivo é monitorar um objeto específico localizado no interior de uma sala e detectar a retirada do mesmo. O estudo é uma primeira tentativa de modelar um problema de alta complexidade, portanto o ambiente foi controlado para realizar testes iniciais.

As pré-condições do ambiente definidas no estudo foram:

- O conjunto de objetos que não estão sendo vigiados presentes no recinto é invariável.

- Considerou-se apenas a situação em que uma pessoa entra na sala.
- A pessoa que adentrar no recinto pode mover todos os objetos presentes.
- Todos os objetos são menores em área na imagem do que qualquer pessoa que venha adentrar na sala.
- O objeto a ser monitorado deve ter uma cor consideravelmente predominante.

A seguir apresenta-se os passos da abordagem proposta para o estudo anti-furto:

- Amostragem do Objeto, que envolve a obtenção de imagens contendo objeto em diferentes posições e ângulos em um fundo neutro.
- Determinação dos Intervalos de Cor, marcando manualmente regiões onde a cor do objeto monitorado varia (devido a iluminação, reflexo etc.).
- Construção do Módulo de Reconhecimento, que utiliza descritores de *fourier* para a extração de características.
- Detecção de Movimento no recinto, através de subtração de imagens.
- Localização do objeto, utilizando rotulação de componentes conexos. O resultado da rotulação será enviado para o módulo de reconhecimento.

Outro tema bastante pesquisado na área de segurança e biometria é o reconhecimento e detecção de faces. Reconhecimento significa descobrir a identidade da pessoa à qual pertence a face. Detecção implica descobrir a posição espacial da face na imagem. Em (MOUTINHO; THOMÉ, 2005) foi proposta a detecção de faces utilizando a cor da pele como descritor principal. No que se refere ao reconhecimento de padrões foram utilizadas redes neurais artificiais. Na Figura 2.29 estão mostrados os resultados gerados pelo sistema de detecção de faces.

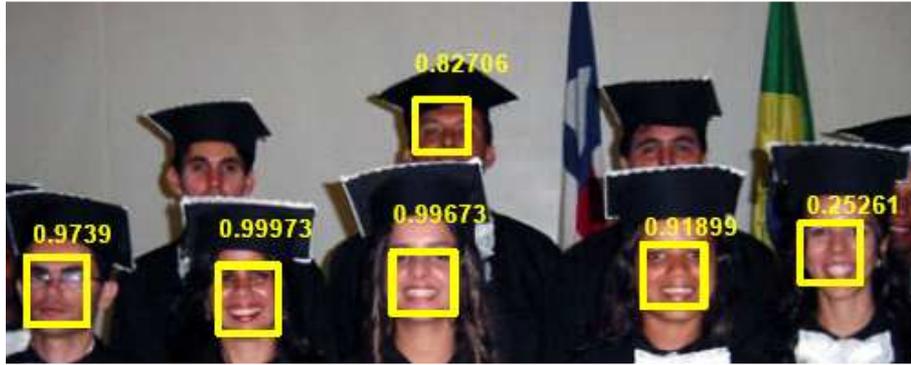


Figura 3.17. Resultados obtidos pelo sistema de detecção de faces proposto em (MOUTINHO; THOMÉ, 2005).

3.3.7 Indústria Têxtil

Em (COHEN; ZHIGANG; ATTALI, 1991) é atacado o problema de detecção e localização de vários tipos de defeitos que podem ser encontradas nas texturas dos tecidos produzidos. São utilizados Campos Aleatórios Gaussianos de Markov (Gaussian Markov Random Field - CAGM) para modelar amostras de texturas de tecido sem defeito. O CAGM é um modelo estocástico que é descrito através de um conjunto pequeno de parâmetros.

A imagem a ser inspecionada é dividida em janelas de tamanho $N \times N$ não sobrepostas uma da outra. Cada janela é classificada como defeituosa (D) ou não defeituosa (ND) baseado na semelhança α . Para efetuar esta classificação é calculada uma avaliação da semelhança máxima do modelo de parâmetros em cada janela.

O processo de inspeção foi dividido em dois passos: 1) treinamento do sistema, 2) inspeção.

O treinamento é efetuado utilizando amostras com texturas livres de defeitos. Estas amostras foram obtidas em condições pré-determinadas de iluminação e de posicionamento da câmera. Para cada imagem é ajustado um modelo CAGM. O treinamento é do tipo off-line (acontece antes do processo de inspeção).

A inspeção é realizada sob as mesmas condições (iluminação e posicionamento da câmera) do treinamento. Uma imagem é analisada para detectar a presença e localização de um defeito.

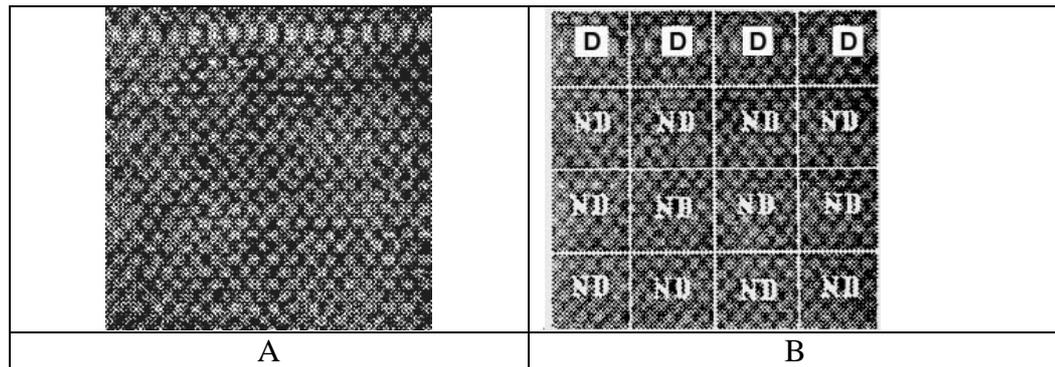


Figura 3.18: A. Imagem apresentada para o sistema. B. Resultado da detecção de defeitos, onde as janelas marcadas com a letra D foram detectadas como sendo regiões defeituosas (COHEN; ZHIGANG; ATTALI, 1991)

O artigo de (CONCI; BELMIRO, 2002) também apresenta um sistema desenvolvido para detecção de defeitos em tecidos. Foram utilizadas câmeras CCD para a aquisição das imagens. O controle acontece no final do processo de manufatura. Os passos seguidos pelo sistema são: 1) Segmentação para obter como resultado uma imagem binária, onde serão utilizadas técnicas de limiarização e detecção de bordas, obtendo como resultado uma imagem binária, 2) Identificar padrões que não contenham defeitos para usá-las como moldes, 3) Utilizar reconhecimento de padrões para comparar os moldes com as texturas dos tecidos que serão avaliados como defeituosos ou não, 4) Determinar o tipo de defeito acontecido.



Figura 3.19: Tecido com defeito em forma de linha horizontal na parte superior da imagem

3.3.8 Indústria Madeireira

Um aplicativo para a inspeção de madeira serrada é apresentado em (CHO; CONNERS, 1991). O propósito deste sistema é o de localizar e identificar defeitos na superfície da madeira. O sistema detecta quatro tipos comuns de defeito: nós, furos, declínios e rachaduras. A saída do sistema é utilizada como entrada de um programa que determinará a qualidade da madeira. A classificação defeito é realizada por uma rede neural.

Para a segmentação foi utilizada a limiarização com múltiplos pontos de corte, baseada no histograma da imagem. São encontrados os pontos de vale do histograma de tons de cinza da imagem, e com isto são obtidos os melhores pontos de corte para aplicar a limiarização. Esta limiarização retorna como resultado várias regiões segmentadas.

Após a segmentação é extraído um vetor de características (área, centro de massa, perímetro, entre outros) de cada região.

O seguinte passo é o reconhecimento dos defeitos da madeira. Cada região será avaliada na procura destes defeitos.

Para cada região é obtido um vetor de confiança, baseado nas propriedades calculadas pelo módulo de segmentação. Cada componente de um vetor de confiança de uma região representa a confiança que se tem de que aquela região em particular pode conter um defeito. Esta avaliação é realizada através de lógica nebulosa. As características de cada defeito são descritas utilizando qualificadores e operadores lingüísticos. A cada qualificador é atribuída uma função de pertinência nebulosa. Então é calculado o vetor de confiança.

Uma vez que todas as regiões tenham seus vetores iniciais de confiança calculados, os procedimentos de detecção de defeitos são aplicados. Cada defeito tem um detector de defeitos específico associado a ele. Os possíveis defeitos detectados através do vetor de confiança são repassados para o detector específico. Cada detector executa dois passos: 1) Etiqueta as regiões que têm grande probabilidade de corresponder com o tipo de defeito que o

detector identifica. Este passo é modelado através de regras que codificam conhecimento a priori do defeito. 2) Verificação das etiquetas. Este passo verifica se um único defeito se encontra fragmentado em várias regiões. A verificação é realizada através de duas abordagens: a primeira baseada em regras, a segunda utilizando uma rede neural MLP (multi layer perceptron) com três camadas. Como entradas da rede neural são extraídas novas características da região como, por exemplo, medidas de textura.

O passo final é resolver as regiões que foram etiquetadas como pertencendo a mais do que uma classe de defeito. Para isto simplesmente é escolhida a etiqueta que tenha maior grau de confiança.

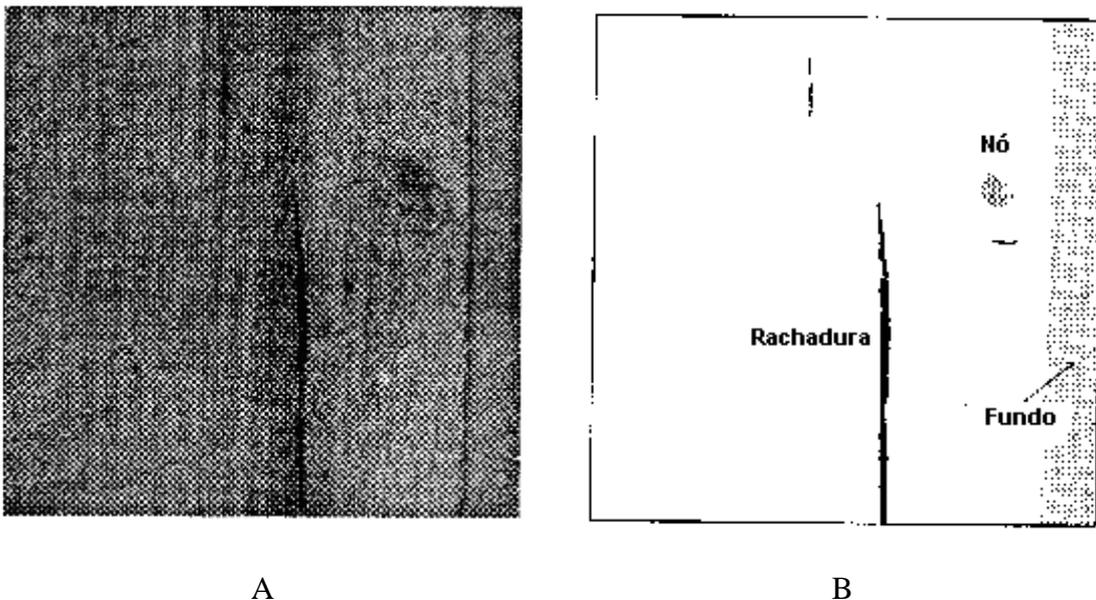


Figura 3.20: A) amostra de madeira. B) Defeitos encontrados pelo sistema (CHO; CONNERS, 1991)

4 Modelo proposto para Medição do Nível na Destilação de Petróleo em Batelada

4.1 Introdução

O estudo de caso é focado na monitoração de processos e refere-se à medição do nível de um subproduto de petróleo em uma garrafa de vidro transparente (Figura 4.1). Este processo faz parte da destilação em batelada de petróleo e é de vital importância para o sucesso desta destilação.

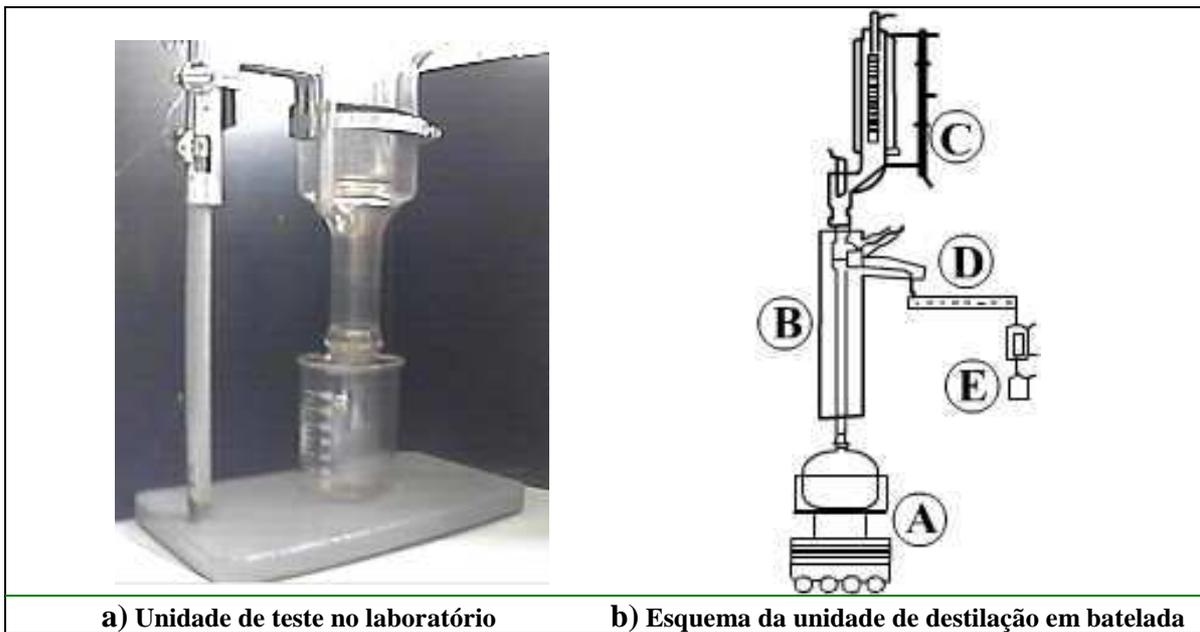
4.2 Descrição do Processo de destilação em Batelada

A destilação em batelada de petróleo consiste em separar as diferentes frações do petróleo em garrafas coletoras localizadas em um carrossel na parte inferior da unidade de destilação. As frações são coletadas em faixas de temperatura predeterminadas a partir do instante em que se desprende a primeira gota, a qual indica o começo do processo de destilação. O carrossel sofre um movimento de rotação a cada mudança de faixa de temperatura, ou quando a fração que está sendo coletada está próxima de ultrapassar a capacidade da garrafa. Para cada fração de petróleo faz-se necessário medir o nível do líquido em tempo real. Toda vez que o líquido alcance um incremento constante predeterminado Δh de altura, é enviado um sinal para o sistema supervisor do processo.



Figura 4.1: Medição do Nível

O equipamento de destilação em batelada utilizado no laboratório é construído totalmente em vidro (Figura 4.2a). A unidade de destilação real (Figura 4.2b) é composta de um balão fervedor (A) com volume que se situa no intervalo de 5 a 50 litros, uma torre de destilação (B), que pode ter de um a dois metros de altura, um condensador de topo (refluxo) (C), um condensador de saída lateral (D) e um dispositivo de coleta das frações (E).



a) Unidade de teste no laboratório

b) Esquema da unidade de destilação em batelada

Figura 4.2: Unidade de destilação

Através da medição da altura do menisco formado pelo nível do líquido, será calculado o volume do mesmo na unidade supervisora, com base nas dimensões da garrafa. Dentre algumas das dificuldades a serem enfrentadas neste estudo de caso pode-se citar: o reflexo do vidro, transparência e baixo contraste de algumas frações, diferenças de viscosidade, densidade e de velocidade da queda do líquido.

4.3 Tipos de petróleo

Existem centenas de componentes químicos no petróleo. Cada um destes componentes possui uma temperatura de ebulição diferente. Ao começar o processo de destilação são

obtidos inicialmente os componentes mais leves (de estrutura química simples e baixo peso molecular). Quanto mais aumenta a temperatura, componentes mais pesados são obtidos.

As curvas de destilação TBP (true boiling point, temperatura de ebulição real) diferenciam os tipos de petróleo e definem o rendimento que será obtido dos produtos.

Os tipos aceitos internacionalmente são: Extra pesado, Pesado, Mediano, Ligeiro, Super Ligeiro. Quanto mais ligeiro o petróleo, mais alto seu valor no mercado.

A grande importância da destilação em batelada é que ela determina o tipo de petróleo existente em cada poço petrolífero, e conseqüentemente ajuda a tomar decisões na hora de realizar investimentos.

4.4 O cenário

Na Figura 4.3 é apresentado um esquema com o posicionamento da câmera, do fundo, da garrafa e do código de barras.

A distância focal da câmera e a área útil possível de ser monitorada estão diretamente relacionadas, bem como o nível de distorção e a precisão na leitura. Nos testes realizados observou-se que esta distância não deve ser superior a 30 cm para obter uma imagem com o nível bem definido como também devido ao espaço reduzido disponível na unidade de destilação. Por causa da pouca liberdade para o posicionamento da câmera, está sendo utilizada uma lente grande angular para cobrir a maior área possível sem ter que afastar a câmera da garrafa. Este tipo de lente ocasiona uma distorção na imagem. A região próxima ao eixo focal da câmera é a que proporciona menor distorção e, conseqüentemente, maior precisão para leitura. O eixo focal da câmera estará alinhado acima da base da garrafa coletora, formando um ângulo alfa com esta base. Este ângulo alfa será o mínimo ângulo possível que permita distinguir a elipse do fundo da garrafa e ao mesmo tempo possibilite ter uma maior precisão na medição de líquidos com volume pequeno. O código de barras cumpre a função de identificar unicamente cada garrafa. É através deste código que é possível saber

qual fração se encontra em qual garrafa no término da destilação. Com a finalidade de não interferir com a visualização do líquido, o código de barra foi posicionado em um fundo falso na garrafa. A capacidade máxima da garrafa será de um litro

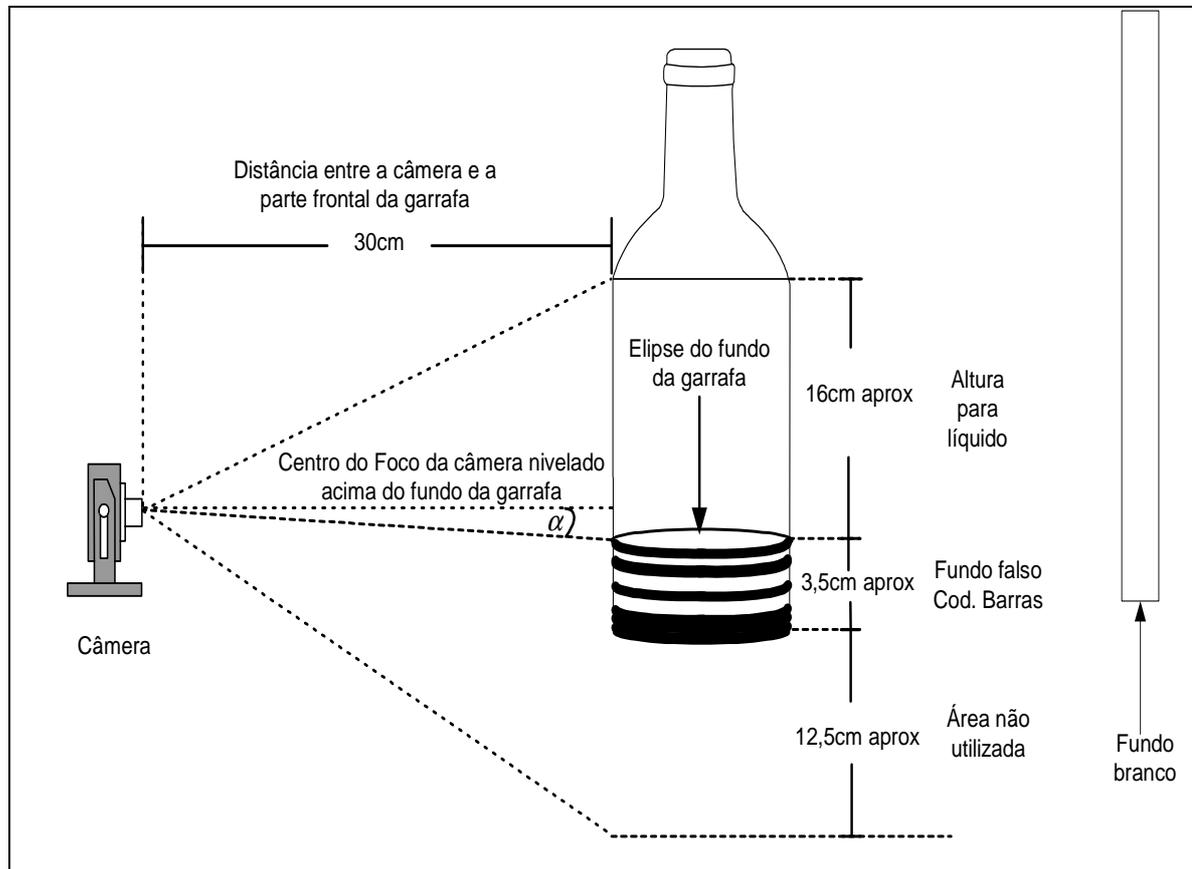


Figura 4.3: Esquema da área de Trabalho

Está sendo realizado um controle do ambiente (Figura 4.4), tanto em termos de iluminação como de interferência de outros objetos (cenário).

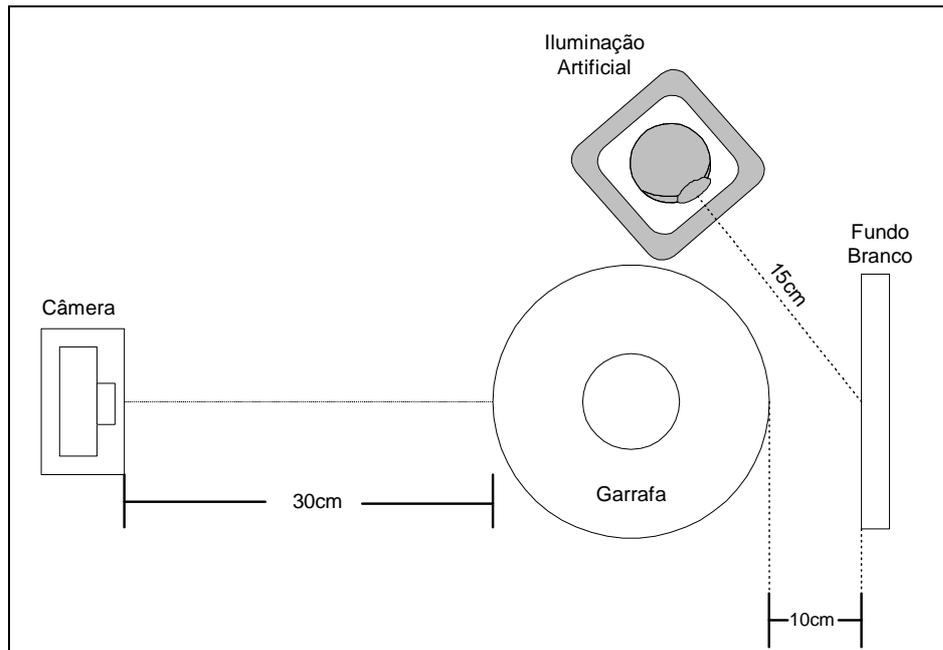


Figura 4.4: Esquema do posicionamento dos equipamentos do sistema de monitoração do nível.

É necessário aplicar-se uma iluminação artificial (Figura 4.5) que reduza a influência de fontes de luz externas e ressalte o contraste dos aspectos desejados para a monitoração. Esta iluminação deve ser direcionada de forma a destacar o nível e ser segura quanto ao risco que possa representar para o processo de destilação. Foram escolhidos LED's de alta luminância para este fim, que são seguros para trabalhar em áreas com materiais inflamáveis. Outras características importantes dos LED são sua durabilidade e baixo custo de manutenção.

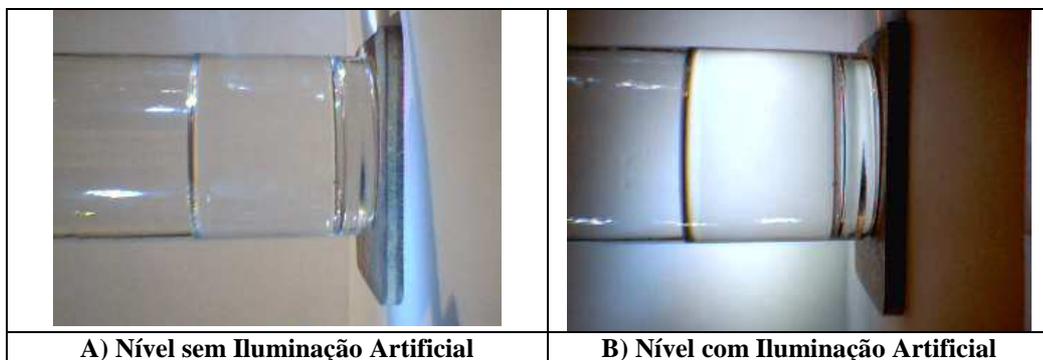


Figura 4.5: Iluminação Artificial

4.5 Ambiente de Simulação

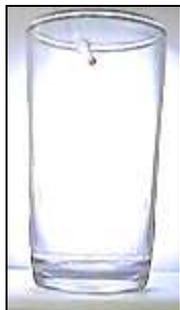
Para o trabalho em laboratório foram utilizados os materiais apresentados na Figura 4.6.



A) Microcâmera



B) Lanternas com LED's de alta luminância



C. Copos de Vidro transparente



D. Equipamento de Destilação

Figura 4.6: Material utilizado no ambiente de simulação

As dimensões do copo de vidro utilizado são: 11,7 cm de altura total, 3,3 cm de raio superior, 1 cm de altura do fundo, e 2,5 cm de raio inferior. Isto significa que se tem 10,7 cm de altura utilizável para o líquido.

4.6 Dificuldades encontradas

4.6.1 Ângulo e posicionamento da Câmera

A escolha do ângulo e do posicionamento da câmera são fatores fundamentais para efetuar o reconhecimento do nível com sucesso. O aumento da distância entre a câmera e a unidade coletora implica uma perda de contraste (nitidez) das bordas da região de interesse. Inversamente, ao aproximar muito a câmera, diminui muito a área que poderá ser visualizada.

Outra dificuldade no posicionamento da câmera é o espaço reduzido da unidade de destilação, o que obrigou o uso de uma câmera com uma lente grande angular.

4.6.2 Baixo contraste nos líquidos transparentes

Para o caso de frações de petróleo transparentes o contraste observado entre o líquido e o fundo é muito baixo, o que dificulta a identificação do nível. Como é mostrado na Figura 4.7, o contraste gerado pelas frações escuras é maior facilitando a localização da linha do nível.

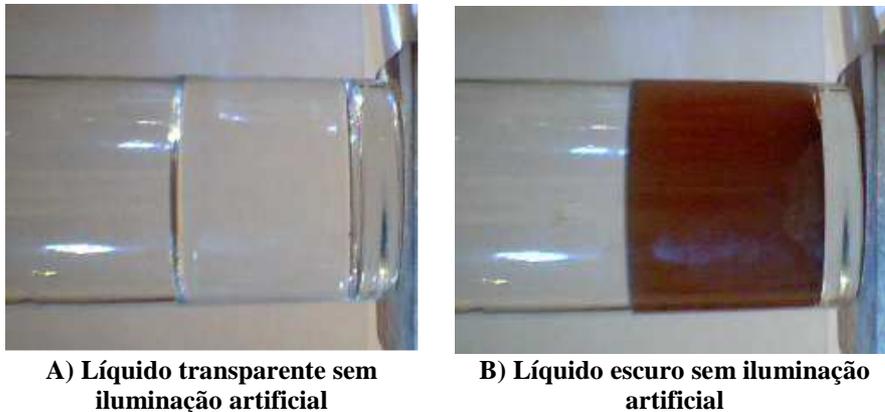


Figura 4.7: Contraste gerado pelas frações de petróleo

4.6.3 Distorções Geométricas da Imagem

Estas distorções reduzem a fidelidade geométrica da imagem e resultam na variação da magnitude da imagem com relação à distância do eixo focal das lentes. Dois tipos de distorção comum são a distorção em almofada (Figura 4.8 A) e a distorção em barril (Figura 4.8 B). Na distorção em almofada, esta se incrementa quanto maior é a distância com relação ao centro. Na distorção em barril a magnitude diminui com relação ao centro da imagem (ZUECH, 2000).

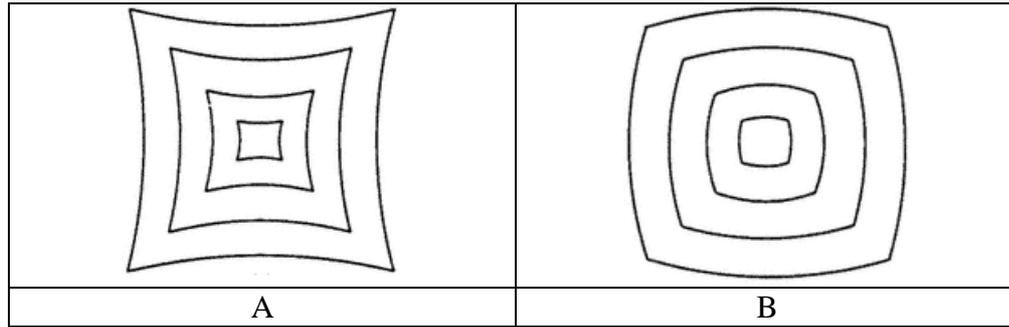


Figura 4. 8: Distorções geométricas das imagens

A lente grande angular da câmera utilizada no estudo de caso ocasiona uma distorção em barril na imagem (Figura 4.9).

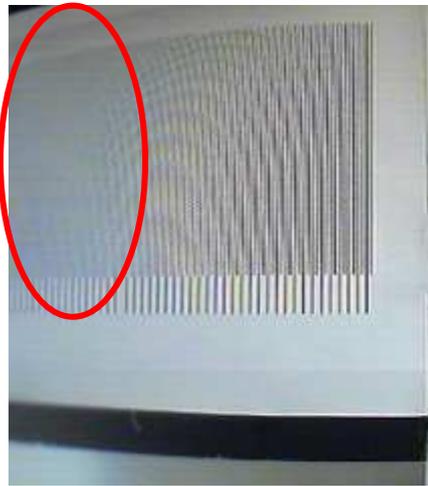


Figura 4.9: Distorção gerada pela lente grande angular da câmera

4.6.4 Reflexo do vidro

É sabido que o vidro é um material que reflete a luz dos objetos que se encontram à sua frente (efeito espelho). Isto ocasiona com que objetos que passam na frente da garrafa ou alguma fonte de luz externa, como uma lâmpada, possam gerar reflexos indesejados que introduzam dificuldades para os algoritmos que realizam a análise da imagem (Figura 4.10).

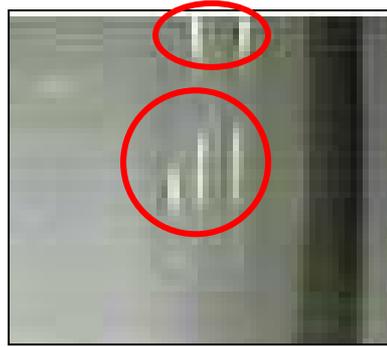


Figura 4.10: Reflexos indesejados na superfície da garrafa delimitados pelas elipses.

4.6.5 Mínimo volume detectável requerido

O mínimo volume detectável requerido pelas especificações da unidade de destilação é 10ml. Isto significa que o deslocamento detectado pelo sistema deve ser pequeno suficiente para cumprir este requisito.

4.7 Arquitetura do sistema de Monitoração através de Imagem

4.7.1 Modularização do sistema de monitoração

O sistema de monitoração através de imagem compõe-se de diversos módulos (Figura 4.11) que serão descritos brevemente nesta seção.

Cabe ressaltar que os módulos apresentados nesta seção ainda não foram implementados, mas é mostrada sua modelagem para contextualizar melhor o problema. A única implementação (em forma de protótipo) realizada neste trabalho é a do modelo proposto na seção 4.8, que se encaixa no submódulo de *análise e detecção da garrafa* que pertencem ao módulo *detecção do nível*.

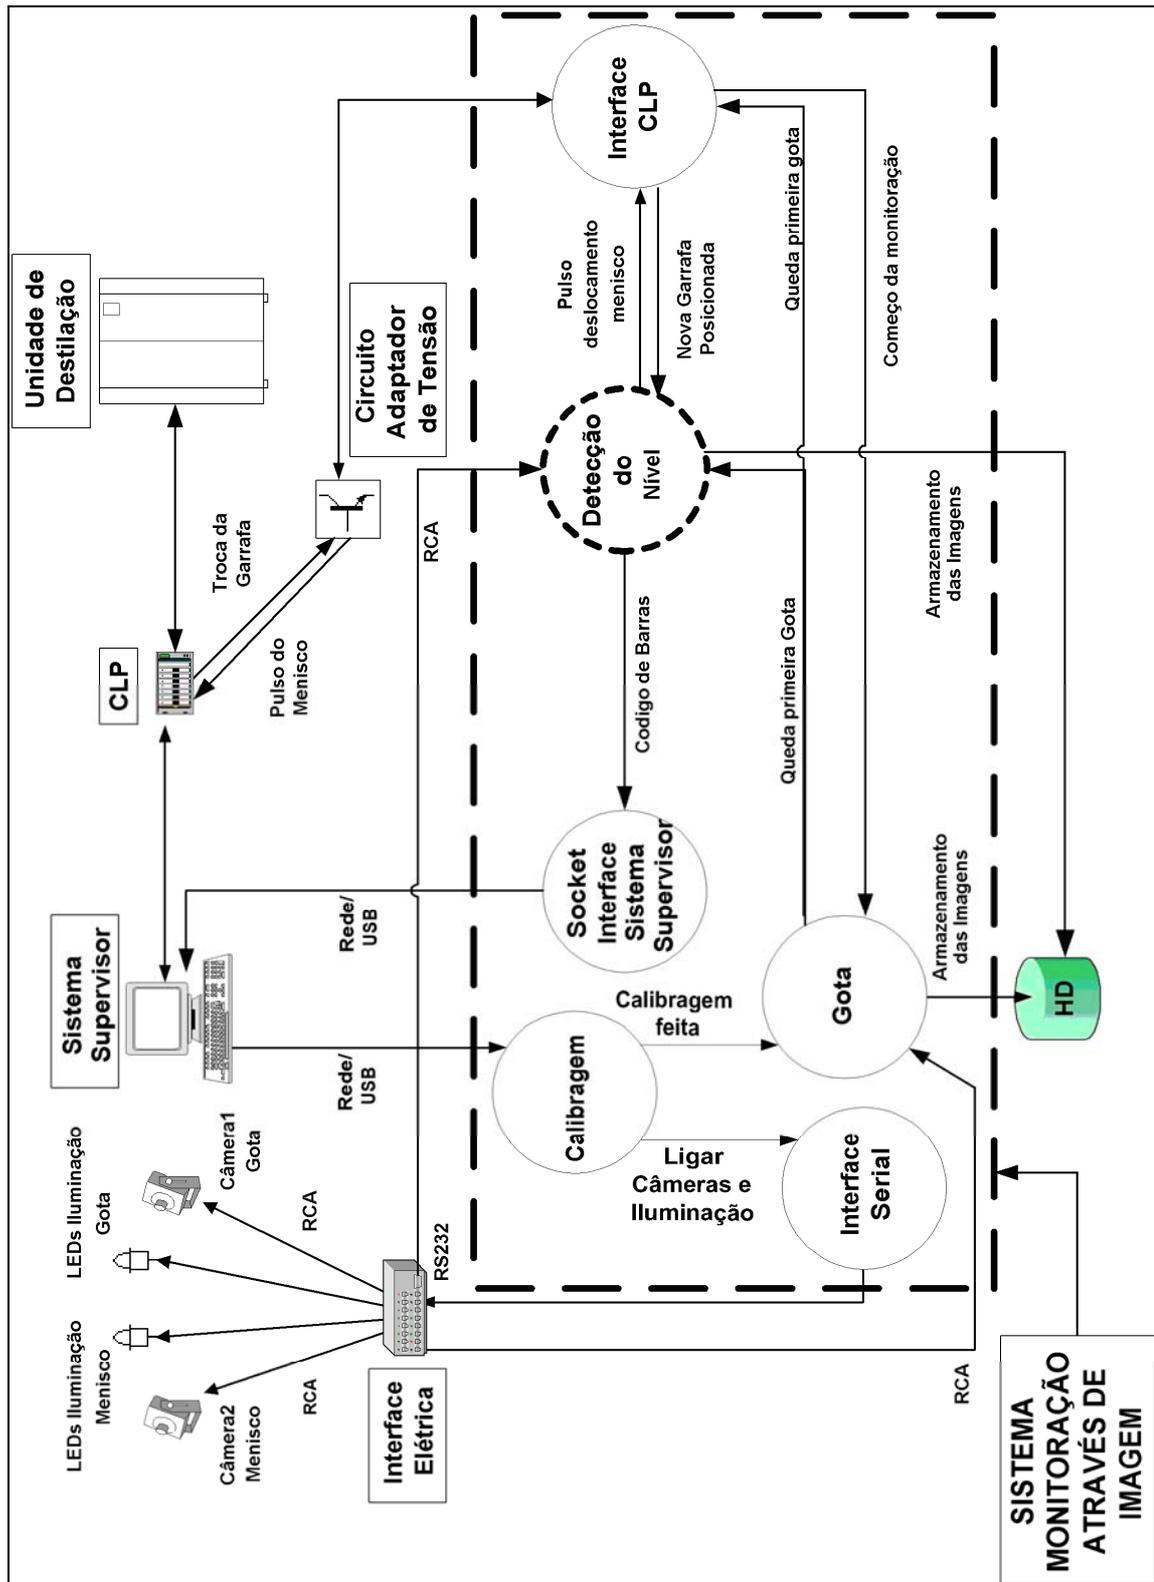


Figura 4.11: Módulos de Monitoração da Unidade de Destilação

O *sistema supervisor* é o encarregado de processar todos os dados coletados pelos sensores do processo de destilação. Com estes dados o *sistema supervisor* controla a destilação, alterando variáveis como, por exemplo, temperatura segundo a necessidade. Este

o sistema é executado em um computador exclusivo para não ser sobrecarregado e que se dedicará somente ao controle do processo de destilação.

Os sensores não interagem diretamente com o supervisor, mas sim com um *controlador lógico programável (CLP)* através de uma rede do tipo FieldBus. O *CLP* faz o papel de servidor central na rede FieldBus, controlando o tráfego das informações, repassando-as depois para o *sistema supervisor*. Os sensores da destilação podem ser vistos como os clientes desta rede. Devido a que o sistema de monitoração é considerado como sendo mais um sensor da unidade, este também se conectará com o *CLP*. Esta comunicação será efetuada através da porta paralela do computador onde será executando o sistema de monitoração por imagem (computador diferente ao do sistema supervisor). Devido a que a porta paralela reconhece e envia sinais elétricos de 5 volts e o *CLP* trabalha com sinais de 24 volts foi projetado um circuito adaptador de tensão. Este adaptador eleva ou diminui o sinal elétrico para a correta comunicação entre o *CLP* e o computador do sistema de monitoração por imagem.

Além do adaptador de tensão foi projetada uma interface elétrica que recebe sinais da porta serial do computador do sistema de monitoração. O módulo encarregado desta comunicação serial é a interface serial. Esta interface serial será a encarregada de receber o sinal para ligar as câmeras e a iluminação através de LED.

O passo prévio ao início da destilação é a calibragem, controlada pelo módulo com o mesmo nome. Esta calibragem será realizada desde o sistema supervisor, que acessará remotamente o módulo, pedindo inicialmente a ativação das câmeras e dos LED. A *calibragem* consiste em marcar a região que delimita o bico da unidade de destilação, onde será monitorada a queda da primeira gota. Uma vez feita esta *calibragem* o sistema se encontra pronto para dar início à destilação. Será o *sistema supervisor* que dará o sinal de iniciar para o *módulo de detecção da gota*. Este módulo monitorará a região do bico até a gota

cair, enviando um sinal do acontecimento da queda para o *CLP* através da *interface CLP* e também para o *módulo de detecção do nível*. Com este sinal o *módulo de detecção do nível* ficará em espera para começar a monitoração das garrafas coletoras. O sinal de garrafa posicionada, que será enviado desde o *sistema supervisor* para a *detecção do nível*, será o evento que iniciará a monitoração do nível.

O *módulo de detecção do nível* será o único descrito com maior detalhe na seguinte seção, por ser este o módulo onde será utilizado o modelo proposto neste trabalho.

4.7.2 Módulo de detecção do Nível

Este módulo tem como objetivo realizar a detecção do nível. Está composto por vários submódulos (Figura 4.12):

- *Localização Garrafa*
- *Leitura do código de Barras*
- *Captura*
- *Log*
- *Análise*

Os submódulos de localização da garrafa e de análise são os mais importantes para o estudo de caso devido a que será neles onde serão utilizados os modelos propostos na seção 4.8.

Após receber os sinais de *queda da gota* do *módulo de detecção da gota*, e o de *garrafa posicionada* do *sistema supervisor* (através da *interface CLP*), será ativado o *módulo de captura*. O primeiro quadro válido capturado será enviado tanto para o *módulo de leitura do código de barras* como para o *módulo de localização da garrafa*. Os quadros capturados subsequentemente serão inseridos em uma fila de tamanho limitado na memória para posterior análise.

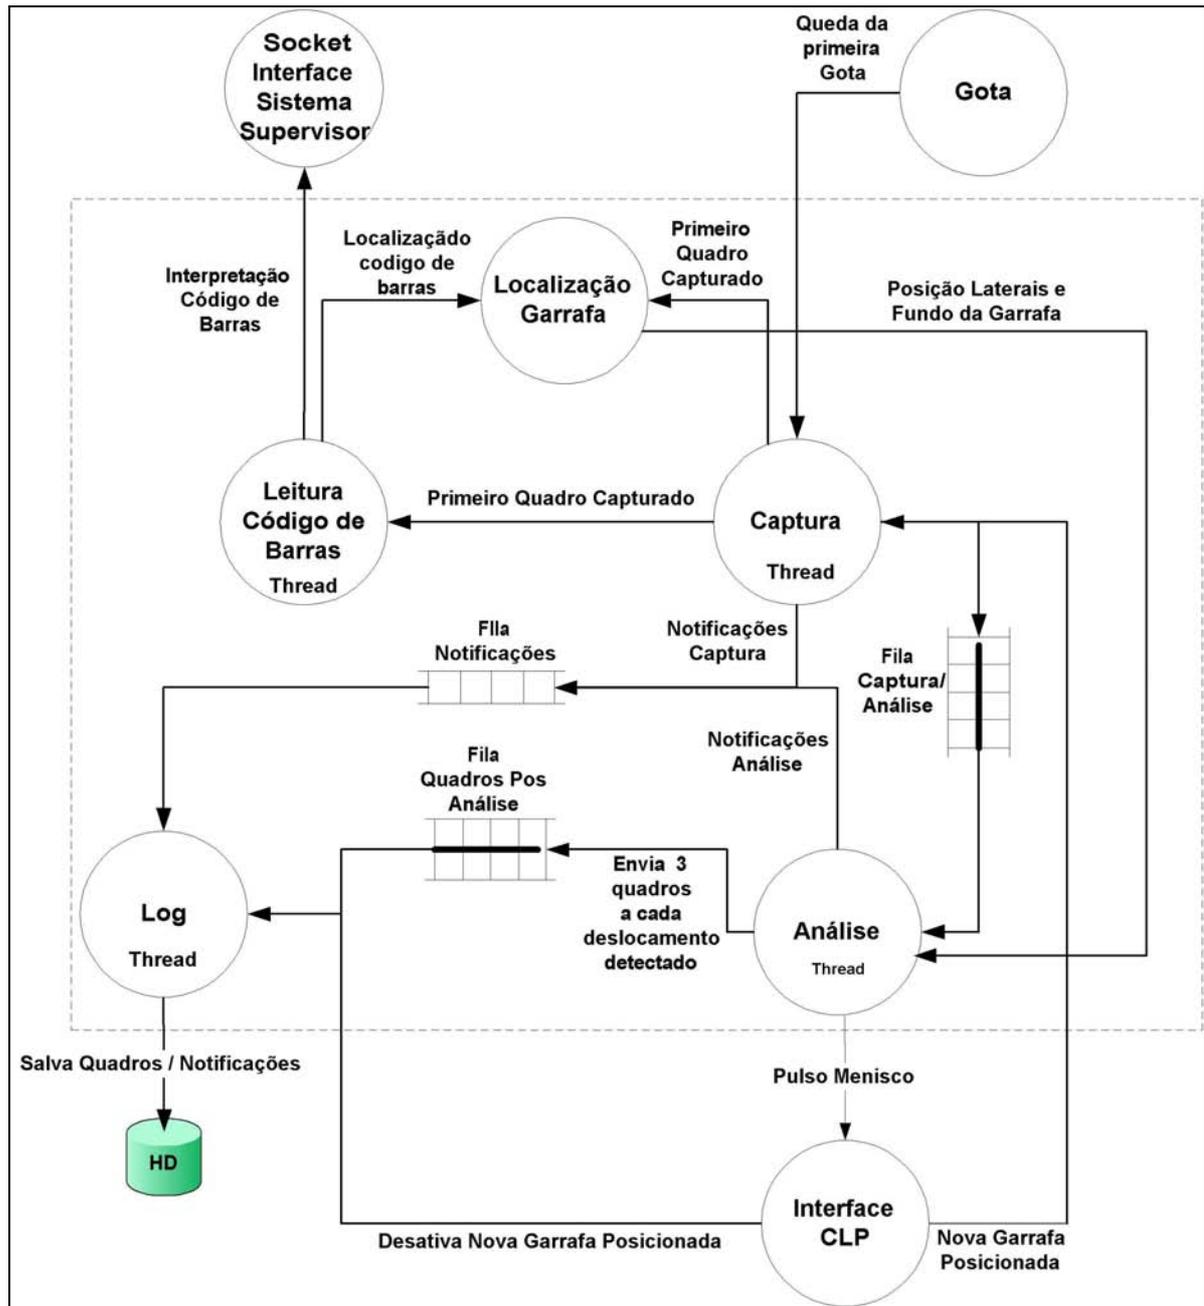


Figura 4.12: Submódulos do módulo de detecção do nível

O módulo de leitura código de barras detectará a posição do código de barras e o interpretará. A interpretação será enviada diretamente ao sistema supervisor através de uma conexão via o módulo socket de interface com o sistema supervisor (rede LAN). A posição do código de barras será enviada para o módulo de localização da garrafa em conjunto com a ordem de começar a localização. Os métodos empregados para a localização das laterais, e fundo da garrafa serão descritos nas seções 4.8.1 e 4.8.2 respectivamente. Uma vez finalizada

a localização do fundo e das laterais da garrafa, serão repassadas suas respectivas posições para o *módulo de análise*. Com esta informação o *módulo análise* começará a avaliar os quadros (utilizando a abordagem 4 detalhada na seção 4.8.3) tentando detectar a posição do nível. Toda vez que a posição do nível atinja um deslocamento Δh em centímetros será enviado um sinal para o *sistema supervisor* através do *módulo interface CLP* e serão armazenados 3 quadros na *fila quadros pos análise* na memória. Estes quadros correspondem ao instante no qual foi detectado o deslocamento procurado e o quadro anterior e posterior a este evento. A garrafa coletora será trocada toda vez que atingir seu limite máximo de armazenamento ou quando o *sistema supervisor* determinar o começo da coleta de uma nova subfração de petróleo. É no momento em que a garrafa está sendo posicionada que o *módulo de análise* para seu funcionamento, e o módulo de Log começa a funcionar. O Log é o encarregado de salvar os quadros que se encontram na fila quadros pos análise na memória permanente do computador e de processar as exceções ou mensagens que possam ter sido geradas durante a execução da detecção do nível. Quando o sistema supervisor envia o sinal indicando que a nova garrafa se encontra posicionada, o módulo de Log é detido e o processo se repetirá desde o primeiro passo indefinidamente, até o sistema supervisor enviar o sinal de final da destilação.

4.7.3 Lógica de comunicação entre o Sistema Supervisor e o Sistema de Monitoração por imagem

A comunicação entre o sistema de monitoração (SM) e o sistema supervisor (SS) é realizada através da interface CLP que ativa o envio e recepção de sinais através da porta paralela do computador do SM. A tensão destes sinais é devidamente amplificada ou diminuída pelo adaptador de tensão e repassada para o CLP, que será quem finalmente enviará o sinal para o SS.

Esta troca de sinais foi modelada como mostrado na Figura 4.13. As regiões na cor cinza representam o estado 1 do sinal elétrico que representa esse evento. Regiões com cor branca representam o estado 0 do sinal.

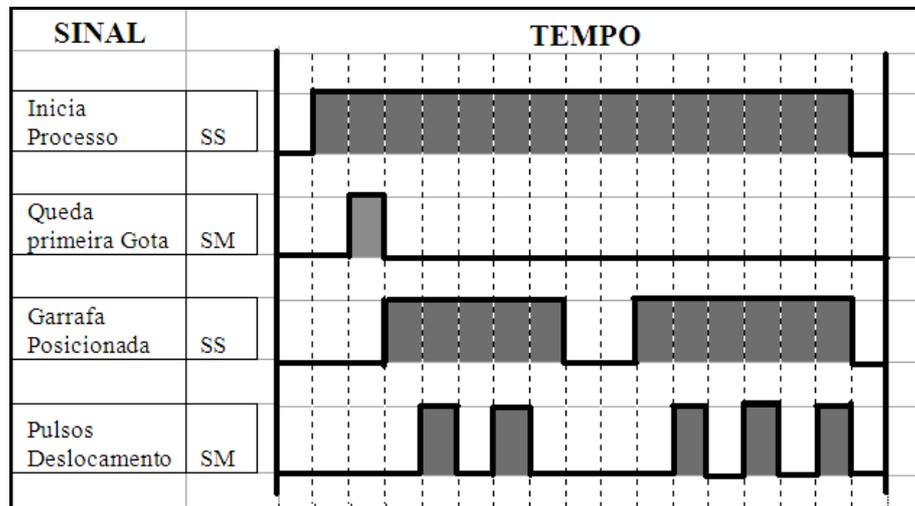


Figura 4.13: Protocolo de comunicação de sinais entre o SS e o SM

4.8 Modelo Proposto para a Medição do Nível em Destilação de Petróleo em Batelada

Antes de iniciar o detalhamento do método proposto para detecção do nível, cabe ressaltar que as imagens para os testes foram capturadas utilizando uma câmera com sensor CCD de 1/4" com resolução de 320 x 240 pixels, virada 90 graus contra o sentido horário. Isto para fazer com que o maior comprimento do quadro capturado pela câmera corresponda com a maior dimensão da garrafa (Figura 4.14).



Figura 4.14: Imagens Capturadas com a câmera

A detecção do nível foi dividida em quatro etapas:

- 1^a. A detecção das laterais da garrafa, que permite diminuir a área de busca, fazendo uma primeira segmentação da região de interesse.
- 2^a. A detecção do fundo da garrafa, que gera como resultado o ponto inicial para realizar a medição do nível e refina a segmentação gerada no passo anterior.
- 3^a. A detecção do nível e determinação da altura em pixels
- 4^a. Correção da deformação em barril da imagem e obtenção da altura em centímetros

4.8.1 Detecção das laterais da Garrafa

O marcador escolhido para esta etapa do reconhecimento foi o código de barras localizado no fundo falso da garrafa. A posição do código de barras será entregue por um módulo externo ao sistema de reconhecimento do nível¹. Sabendo a posição do código de barras de antemão, serão procuradas as laterais da garrafa como sendo as linhas horizontais mais próximas à projeção horizontal do ponto meio da largura do código de barras, demarcada pela linha pontilhada na Figura 4.15.

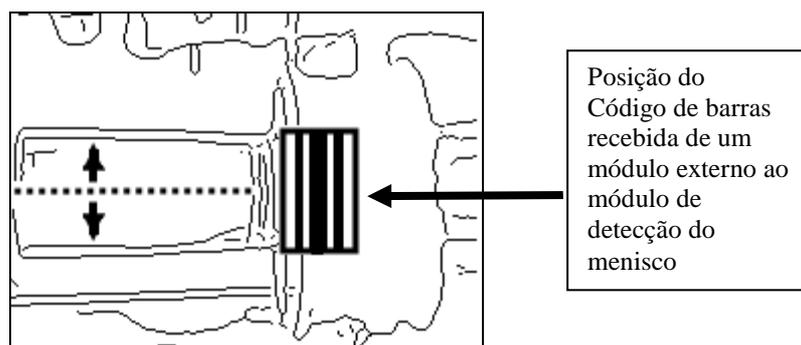


Figura 4.15: Proposta para encontrar as laterais da Garrafa

¹ A garrafa real, que será utilizada na unidade de destilação, não estava pronta quando os testes foram realizados. Por este motivo utilizou-se um copo de vidro para os testes, que não tem fundo falso com código de barras. Para realizar os testes do método proposto foi marcada manualmente a posição onde ele deveria estar. Isto não interfere com os testes porque para o módulo de detecção do menisco não interessa se o código de barras se encontra fisicamente na imagem, mas sim a posição deste na imagem.

Detalhamento do método proposto:

As linhas que definem as laterais da garrafa são parte das bordas da garrafa. Devido a este fato foram utilizados filtros convenientes para destacar altas frequências na imagem (que comumente representam bordas de objetos). Como visto na seção 2.6.2 subitem d, existem filtros passa alta com máscaras horizontais e verticais, como por exemplo, o filtro de Sobel. Em uma primeira tentativa foi aplicada a componente horizontal do filtro de Sobel diretamente na imagem inicial, devido a que estão sendo procuradas as laterais da garrafa (que são linhas horizontais na imagem). Obteve-se como resultado bordas com muito ruído e pouco definidas (Figura 4.16 A). Na tentativa diminuir o ruído da imagem foi aplicado um filtro de medianas, porém esta operação só piorou a definição das bordas (Figura 4.16 B).

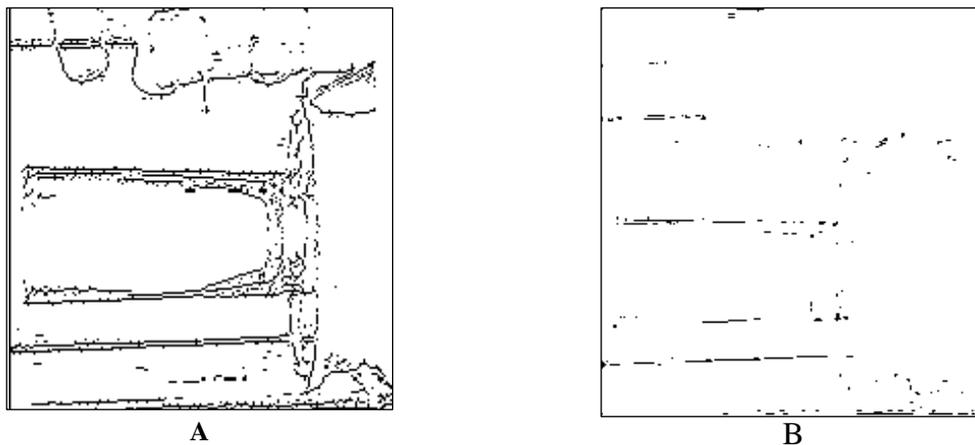


Figura 4.16: Detecção de bordas horizontais aplicando unicamente o filtro de Sobel

Na segunda tentativa (Algoritmo 4. 1) foi aplicado inicialmente o filtro de bordas de Canny na imagem (Figura 4.17 B). Com isto foram obtidas bordas bem definidas de todos os objetos na imagem. Devido a que o detector de Canny não possui máscaras diferenciadas para detecção de bordas verticais ou horizontais, faz-se necessário um segundo processamento para detecção das linhas horizontais. Decidiu-se aplicar a componente horizontal do filtro de Sobel sobre o resultado obtido do detector de Canny (Figura 4.17 C). Esta combinação de filtros mostrou-se robusta suficiente nos testes, extraindo bordas horizontais bem definidas. Como

passo seguinte foi aplicado um filtro de medianas para reduzir o ruído na imagem (Figura 4.17 D).

Algoritmo 4. 1 Detecção das laterais da garrafa	
1	Captura de uma imagem inicial
2	Extração das bordas da imagem através do filtro de Canny
3	Extração das bordas horizontais da imagem gerada no passo 2 através do filtro de Sobel
4	Diminuição do ruído utilizando um filtro de medianas
5	Seleção das bordas horizontais utilizando o método de detecção de linhas através de janelas
6	Cálculo das retas com equação $X = \text{mediaPontosLateral}$, onde $\text{mediaPontosLateral}$ representa a média das coordenadas X dos pontos que pertencem a borda da lateral da garrafa
7	Segmentação da imagem cortando as regiões que se encontram à direita/esquerda das retas calculadas no passo 6.

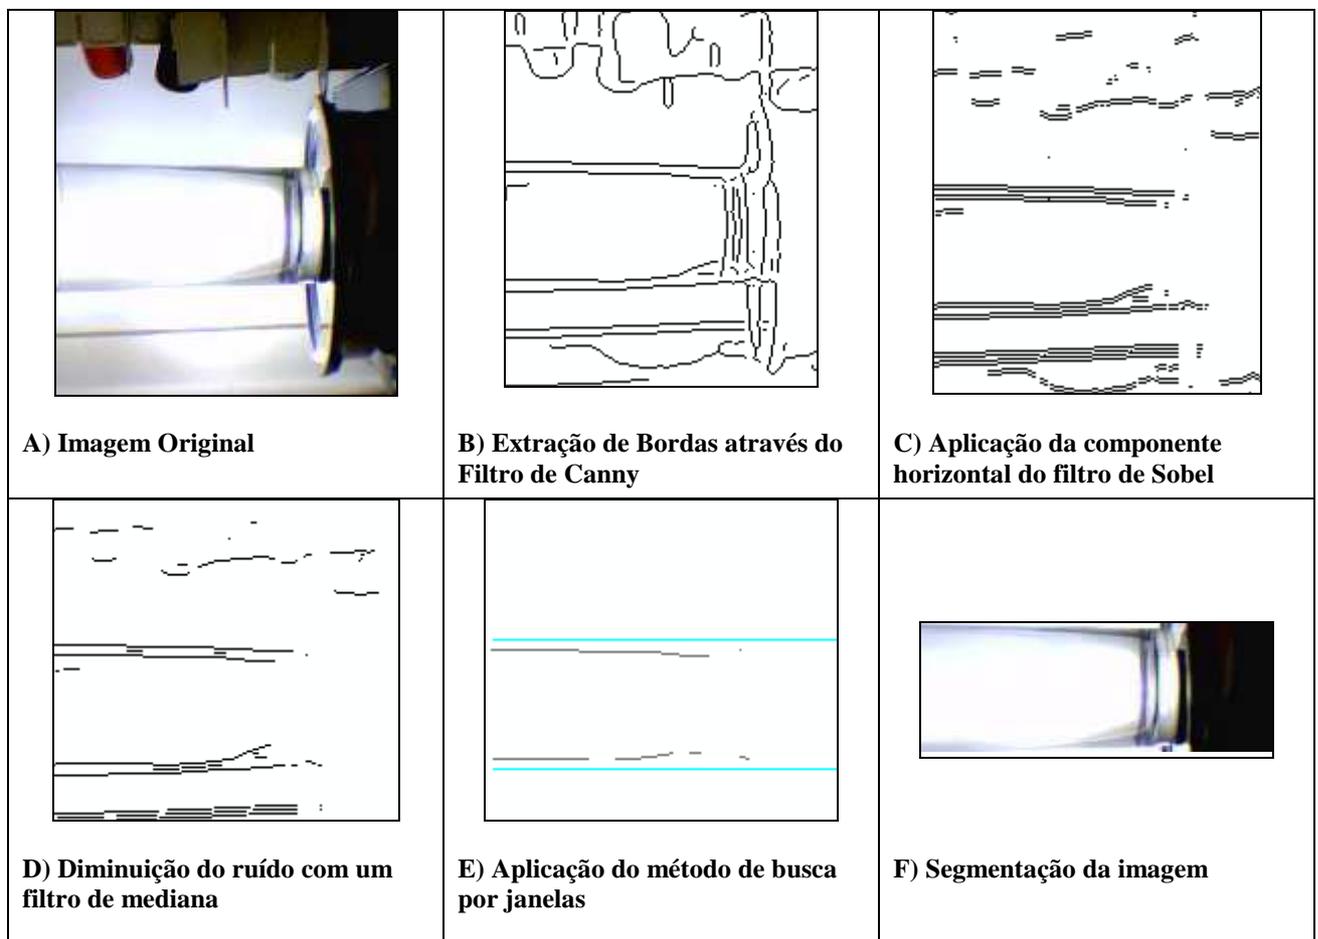


Figura 4.17: Algoritmos utilizados para a detecção das laterais da Garrafa

O resultado da aplicação dos filtros é uma imagem que contém somente linhas horizontais. Sabendo de antemão a dimensão aproximada da garrafa, é possível aplicar um método simples para descobrir a linha horizontal mais próxima da projeção horizontal do

ponto médio da largura do código de barras, que possua a dimensão procurada. Neste método imagina-se que existe uma janela na imagem (retângulo pontilhado da Figura 4.18 B), que se movimenta verticalmente através dela, com um deslocamento de um pixel a cada vez. No estudo foram escolhidos 3 pixels de largura e 160 pixels de altura (correspondentes aproximadamente a metade da altura da imagem, começando a partir do código de barras) como dimensões desta janela. Dentro deste retângulo são contados os pixels nele contidos (somatório das projeções horizontais das filas contidas na janela). Se este somatório se encontra acima de um limiar mínimo predefinido, a região é considerada como sendo uma lateral da garrafa. Caso contrário o retângulo imaginário é deslocado uma fila para cima/baixo (dependendo da lateral que esta sendo procurada) e o total de pixels dentro da janela é comparado novamente com o limiar. Para os testes este limiar foi escolhido como sendo de 160 pixels (o que aproximadamente equivale a uma linha reta de 16 centímetros de altura e 1 milímetro de largura, valor próximo as dimensões das laterais da garrafa). Este método de busca de linhas (busca de linhas através de janelas) é descrito a seguir (Algoritmo 4. 2):

Algoritmo 4. 2 Método de busca de linhas através de janelas	
1	Calcular as projeções horizontais da metade superior da imagem (acima do código de barras)
2	Somar as N projeções horizontais adjacentes correspondentes à largura da janela atual e armazenar o resultado em SomaProjAtual
3	Se SomaProjAtual \geq MinPixelsProj parar. Senão deslocar a janela atual em uma unidade à direita/esquerda e voltar para o passo 2. MinPixelsProj é o limiar que determina o valor mínimo das projeções para estas serem consideradas como a reta procurada

A aplicação da combinação de filtros de Sobel e Canny em conjunto com o método de busca através de janelas é um método simples, porém efetivo, para detectar linhas de tamanho e orientação predefinidos. Este método tem como grande vantagem o fato de permitir a detecção de linhas que não sejam retas perfeitas (Figura 4.18 A). Outros métodos de detecção de retas detectam somente retas quase perfeitas, como é o caso da transformada de Hough para retas, e com um custo computacional maior ao algoritmo proposto. A grande

desvantagem do algoritmo de busca através de janelas é a necessidade de saber de antemão as dimensões aproximadas da reta que está sendo procurada para definir corretamente o limiar `MinPixelsProj`, e se deve de ter uma área restrita para procurar a reta. Estas informações estão disponíveis devido ao ambiente controlado do presente estudo de caso, mas poucas vezes são conhecidas em outros problemas com ambientes que não estejam fortemente controlados.

Após encontrar as linhas que representam as laterais da garrafa (aproximando as retas através de mínimos quadrados), procede-se à remoção das regiões da imagem que se encontram acima e embaixo das laterais da garrafa detectadas pelo sistema (Figura 4.17 F). Assim é reduzida a área de busca do nível e conseqüentemente o processamento necessário para encontrá-lo será menor.

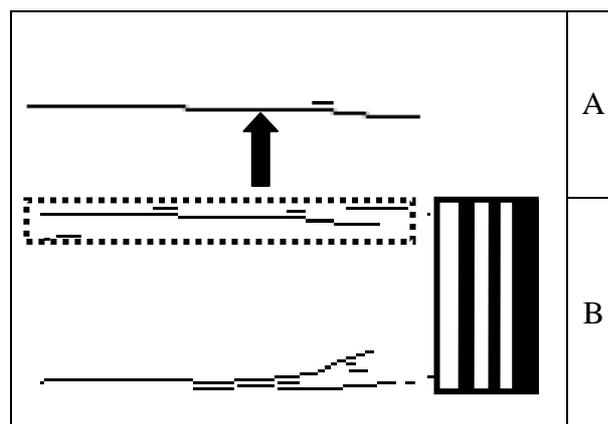


Figura 4.18. Método de busca por janelas

4.8.2 Detecção do fundo da garrafa

O fundo da garrafa é circular, mas devido ao ângulo da câmera ele é visualizado como sendo uma elipse. É possível realizar a detecção de elipses através da transformada de Hough para elipses, porém esta transformada tem um custo computacional muito alto. Em vista que a elipse é regular e o ângulo da câmera é conhecido, é possível realizar um pré-processamento na imagem para fazer com que a elipse se torne uma circunferência, e seguidamente aplicar a

transformada de Hough para circunferências (com um custo computacional muito menor ao da transformada para elipses).

A transformada de Hough para circunferências possui três parâmetros a serem avaliados. Para utilizar o algoritmo de Hough para circunferências, a imagem foi esticada no seu eixo X e diminuída no eixo Y (Figura 4.19 B) utilizando interpolação bilinear, assemelhando a elipse com uma circunferência. Isto é possível porque se sabe que a elipse que será visualizada no fundo da garrafa será regular e terá seus eixos paralelos com os eixos X e Y da imagem.

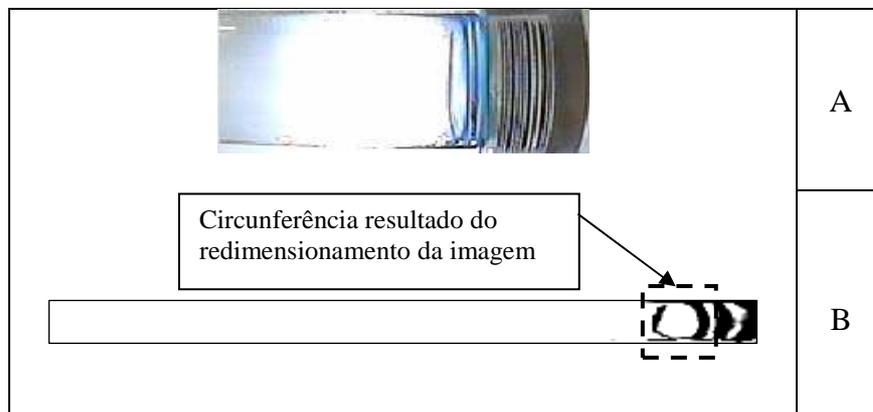


Figura 4.19 A) Figura Original. B) Figura redimensionada com a elipse assemelhando uma circunferência

Após redimensionar a imagem, aplica-se o filtro de Canny na mesma para obter as bordas (Figura 4.19 B). Nesta imagem é aplicado o algoritmo para detecção de circunferências de Hough explicado na seção 3.4.3. Utilizando esta transformada são obtidas regiões candidatas a circunferências. O seguinte passo é escolher a região com maior probabilidade de ser o centro da circunferência procurada, isto através do valor do acumulador da transformada. Os maiores valores do gradiente se encontram nas regiões claras da Figura 4.20 A e indicam as possíveis circunferências (Figura 4.20 B).

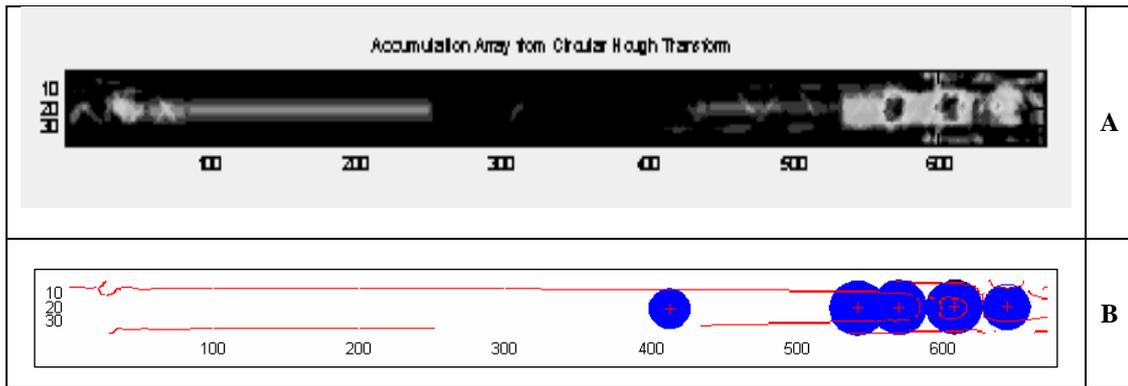


Figura 4.20: A) Acumulador da transformada de Hough. B) Possíveis circunferências detectados

Após a detecção do fundo, a imagem foi recortada novamente obtendo como resultado a Figura 4.21. As linhas verticais representam o topo e o fundo da elipse. O fundo da garrafa será considerado como uma linha vertical que passa no ponto central da elipse e será a partir deste ponto que o nível será monitorado.

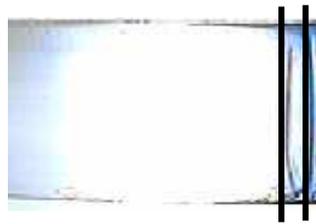


Figura 4.21: Resultado após detecção do fundo

4.8.3 A detecção do nível

A necessidade nesta etapa é segmentar a linha que representa o nível (menisco). Para atender esta necessidade foram projetadas quatro abordagens, misturando algoritmos diferentes em cada caso. As primeiras três tentativas (Abordagens 1, 2 e 3) apresentaram deficiências quando testadas com as amostras. A quarta abordagem é a mais robusta conseguindo a menor taxa de erro nos testes e uma velocidade de resposta aceitável para o estudo de caso.

A seguir serão descritas todas as abordagens em conjunto com suas vantagens e deficiências.

4.8.3.1 Abordagem 1

A primeira abordagem baseou-se no método proposto para a detecção das laterais da garrafa exposto na seção 4.8.1. O conjunto de detectores de bordas de Canny e Sobel é novamente utilizado, sendo que desta vez é utilizada a máscara vertical de Sobel (o nível é uma linha vertical na imagem) ao invés da máscara horizontal. Como passo final foi aplicado o método de busca de linhas através de janelas (Algoritmo 4. 2), modificado para detecção de linhas verticais. O algoritmo desta primeira abordagem é descrito a seguir:

Algoritmo abordagem 1:

- Aplicação do filtro de Canny para extração das bordas da imagem (Figura 4.22 B).
- Aplicação da componente vertical do filtro de Sobel para extração das linhas verticais (Figura 4.22 C).
- Aplicação de um filtro de medianas para diminuir o ruído da imagem (Figura 4.22 D).
- Detecção e segmentação da linha do nível utilizando a busca de linhas através de janelas (utilizando o Algoritmo 4. 2 modificado para procurar linhas verticais ao invés de horizontais)

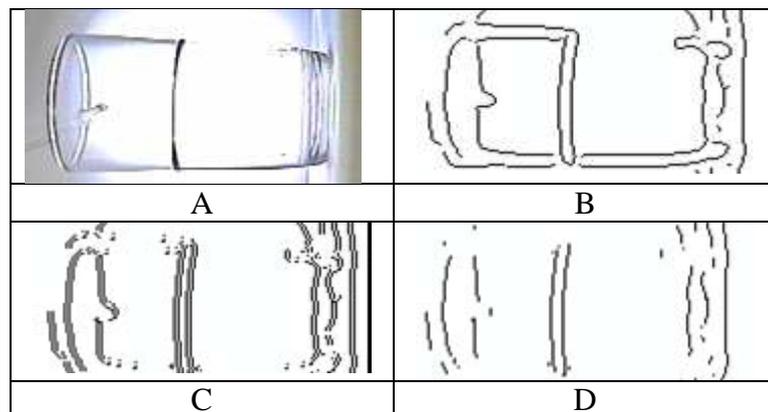


Figura 4.22. Primeira tentativa de detecção do nível

Vantagens

Este método é muito veloz devido aos algoritmos de Canny, Sobel e a busca de linhas através de janelas que não são muito exigentes computacionalmente. A implementação desses algoritmos é simples.

Desvantagens

A utilização consecutiva de dois detectores de bordas aumenta o ruído na extração das mesmas, fazendo necessária a utilização de um filtro de medianas. Isto faz com que o resultado final seja uma aproximação do nível o que diminui a precisão do método.

A taxa de erro é alta e existem quadros onde o nível não foi detectado como será mostrado na seção de resultados.

4.8.3.2 Abordagem 2

A segunda abordagem foi projetada para tentar melhorar as falências da primeira. Devido a que na abordagem 1 a altura do nível não foi detectada em alguns quadros, perdendo-se a posição da linha do nível, decidiu-se utilizar vários quadros em conjunto para a detecção da mesma. A cada 30 quadros (aproximadamente dois segundos de vídeo com a taxa aproximada de captura utilizada de 16 quadros por segundo) foram extraídos seis quadros (significando que a cada $2/6$ de segundo é extraído um quadro) para o cálculo do nível. A média das alturas dos níveis detectados em cada um dos seis quadros foi considerada como o nível real. Se em algum quadro o nível não fosse detectado com sucesso, este não será considerado na média. A utilização de equalização de histograma visa aumentar o contraste da imagem destacando o nível. Foi utilizada também a subtração entre o quadro corrente e um quadro de referência (primeiro quadro capturado com a garrafa vazia) esperando retirar elementos estáticos da imagem (fundo), que poderiam interferir a detecção do nível.

Algoritmo:

- Capturar quadro de fundo (primeiro quadro válido recebido da câmera).
- Transformar imagens RGB (quadro de fundo e quadro atual) em imagens em tons de cinza (Figura 4.23 A e B)
- Aplicar equalização de histograma nas imagens (quadro de fundo e quadro corrente, Figura 4.23 C e D)
- Subtrair o quadro atual com o quadro de fundo e binarizar o resultado da subtração (Figura 4.23 D).
- Detectar e segmentar a linha do nível utilizando a busca de linhas através de janelas (Algoritmo 4. 2).

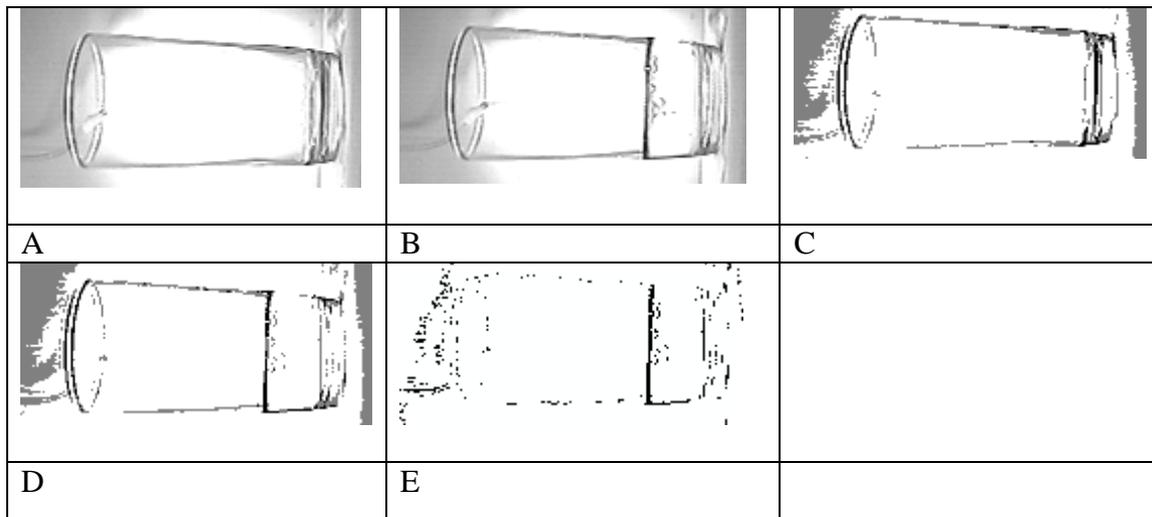


Figura 4.23. Abordagem 2 para detecção do nível. (As cores da imagem E foram invertidas para melhor visualização do resultado)

Vantagens

Primeira abordagem onde vários quadros são utilizados para obter uma medida única do nível. Não é tão veloz quanto o método utilizado na primeira abordagem, mas mesmo assim é bastante rápido e não requer de muito esforço computacional.

Desvantagens

Utilizando-se o primeiro quadro como único quadro de referência o erro na detecção aumenta; quanto maior seja a distância temporal entre o quadro atual e o de referência, maior será o ruído produzido pela subtração. Apesar das melhoras que deveriam acrescentar a taxa de acerto, isto não aconteceu. Existem quadros onde o nível não é detectado. A equalização do histograma não melhorou o contraste das imagens tanto como era esperado.

4.8.3.3 Abordagem 3

Nesta abordagem é utilizada novamente a subtração com um quadro de referência (quadro de fundo). Na imagem resultante da subtração é aplicado um método, proposto neste trabalho, para diminuição de pixels não relevantes na segmentação do nível (com tom de cinza alto, próximo do branco). Para remover os pixels menos relevantes da imagem, foi utilizado o conceito estatístico do desvio padrão. É considerado nesta proposta que os valores de luminância menos relevantes se encontram dentro dos limites da média ± 2 vezes o desvio padrão (conceito extraído do comportamento estatístico de populações normais). Os pixels mais relevantes são os valores mais próximos dos extremos do histograma. Os pixels com valor próximo de 0 (preto) são os mais relevantes para a linha do nível. Na Figura 4.24A mostra-se a imagem original em tons de cinza. Na Figura 4.24B exibe-se o resultado da remoção de pixels menos relevantes.

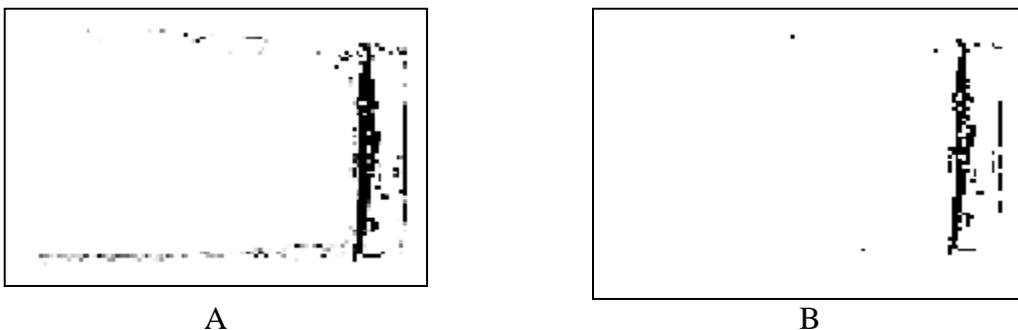


Figura 4.24. Remoção de pixels menos relevantes

A linha do nível pode ficar fragmentada após a extração de alguns pixels que foram qualificados equivocadamente como sendo não relevantes. Para juntar estes fragmentos é aplicado o algoritmo de fechamento (algoritmo apresentado na seção 2.6.1). Seguidamente é aplicado o detector de bordas de Canny e finalmente o método de busca através de janelas para segmentar a linha que representa o nível (Algoritmo 4. 2).

Algoritmo

- Capturar quadro de fundo (primeiro quadro recebido da câmera)
- Transformar imagens RGB (quadro de fundo e quadro atual) em imagem em tons de cinza (Figura 4.25 A e B).
- Subtrair o quadro atual com o quadro de fundo (Figura 4.25 C).
- Procurar os pixels mais relevantes utilizando a condição:

$$\text{luminância} < \text{média} + 2 * \text{desvio padrão}$$

Os pixels que não cumprirem esta condição receberão o valor 255 (branco). O restante de pixels terá o valor 0 (preto). O resultado final é uma imagem binária (Figura 4.25 D).

- Aplicação do operador de fechamento para juntar os pedaços do nível que podem estar separados. Este passo é necessário antes da extração do ruído porque a linha que determina o nível muitas vezes é formada por pixels que podem ser confundidos com ruído (Figura 4.25 E).
- Extração do ruído através da avaliação dos vizinhos de 8 de cada pixel. Se um pixel tiver menos vizinhos de cor preta do que um limiar pré-estabelecido, será considerado como ruído e eliminado da imagem (Figura 4.25 F).
- Aplicação do filtro de Canny para extração de bordas (Figura 4.25 G).
- Detecção e segmentação da linha do nível utilizando a busca de linhas através de janelas (Algoritmo 4. 2).

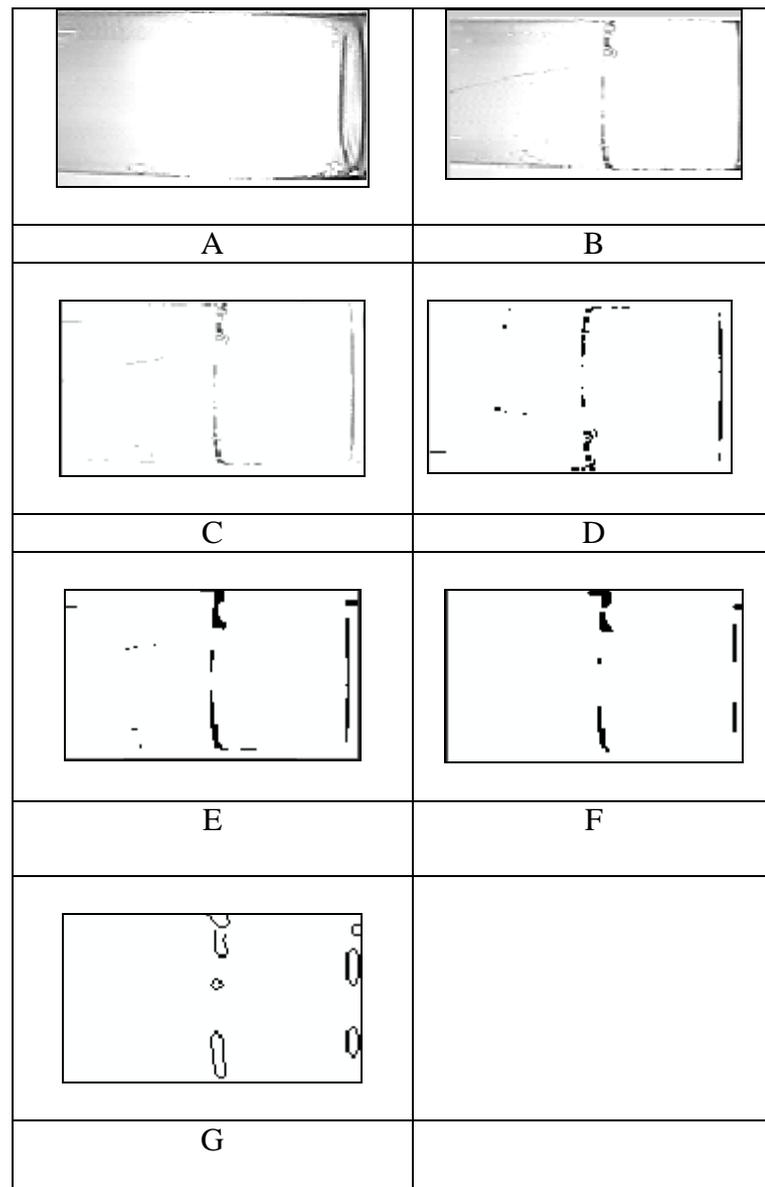


Figura 4.25: Abordagem 3 para detecção do nível

Vantagens

O resultado obtido com esta abordagem supera por muito os resultados das primeiras duas abordagens. É a primeira abordagem que não possui quadros onde a detecção do nível não foi conseguida. Utiliza vários quadros para calcular uma média do nível.

Desvantagens

Esta é a abordagem que utiliza mais algoritmos em conjunto e, portanto tem o maior custo computacional de todas as apresentadas no estudo. O cálculo do fechamento é uma operação muito pesada.

4.8.3.4 Abordagem 4

O problema encontrado nas abordagens anteriores é a pouca espessura da linha obtida como resultado final do processamento (que representa o nível do líquido). Esta linha é muito fina e alguns dos pixels que a compõem não têm um nível de cinza muito alto, gerando pouco contraste na imagem e conseqüentemente dificultando sua detecção.

Solução proposta: pelos testes feitos com as primeiras três abordagens, uma única imagem do vídeo contém poucos pixels com valores de cinza suficientemente relevantes como para detectar o nível. Devido a este fator foi projetada uma solução que pudesse levar em consideração a mistura de vários quadros consecutivos para facilitar a detecção do nível. A idéia principal consiste em somar os valores de tom de cinza dos pixels de imagens consecutivas no vídeo, na procura dos elementos que aparecem repetidamente nesta seqüência. Estes pixels serão considerados como sendo mais confiáveis, não representando ruído ou alguma perturbação aleatória na imagem. Isto significa que os pixels que aparecem repetidamente com um valor aproximadamente constante em uma seqüência de vídeo curta tendem a representar melhor as bordas dos objetos nela contidos (objetos de fundo ou objetos que tem um movimento constante e restrito em curtos intervalos de tempo, como é o caso do nível). Existem métodos na bibliografia que levam em consideração o movimento para realizar a segmentação de objetos, como a proposta feita em (GONZÁLES; WOODS, 2002), mas devido à velocidade requerida no problema em questão e à vantagem de ter um ambiente controlado, foi projetado neste trabalho um algoritmo mais simples e veloz.

Pode-se utilizar a seguinte analogia para exemplificar o raciocínio que levou a projeção deste método. Se fosse necessário calcular a posição da terra no dia 10 de janeiro deste ano poder-se-ia realizar os cálculos levando em consideração sua posição em um instante desse dia (o que não seria 100% correto, pois a terra se encontra em um movimento “aproximadamente constante”. Levar em consideração somente o cálculo de uma posição

poderia nos levar a erros devido a falhas no equipamento de medição ou ruídos). Outra maneira de calcular a posição da terra seria escolher um conjunto de posições do planeta em vários horários desse dia e fazer uma média, o que daria como resultado a posição aproximada da terra no dia inteiro e descartaria ruídos ou erros na aquisição dos dados.

Os passos da quarta abordagem são enumerados no Algoritmo 4. 3.

Algoritmo 4. 3: Abordagem 4 para detecção do Nível	
1	Acumular um número N de imagens em uma matriz somatório, <i>matrizSoma</i> .
2	Normalizar a matriz somatório para fazer com que ela esteja no intervalo 0-255 (tons de cinza) $matrizSomaNormalizada = (matrizSoma/elementoMaiorSoma) * 255$
3	Aplicar filtro de medianas com uma máscara 3x3 na matriz somatório para tirar o ruído
4	Na matriz resultante do passo 3 saturar os pixels mais altos e cortar os mais baixos (1% em cada caso) da imagem para aumentar o contraste da mesma.
5	Binarizar imagem resultante do passo 4
6	Aplicar filtro de Canny
7	Aplicar algoritmo de busca de linhas através de janelas (para detecção de linhas horizontais) para detecção dos segmentos de linha do nível que intersectam com as laterais da garrafa

A seguir serão descritos os resultados de cada passo do algoritmo.

Na Figura 4.26 A é mostrada a imagem resultante da aplicação do primeiro passo do algoritmo. Pode-se observar na Figura 4.26 B um quadro simples, que não leva em consideração o somatório. A Figura 4.26 B possui mais ruído do que a figura A, e a linha que representa o nível não se encontra bem definida.

Nas Figura 4.26 C e D mostram-se as linhas que representam o nível correspondente as Figura 4.26 A e B respectivamente. Nas Figura 4.26 C e D o nível foi segmentado manualmente (para mostrar o resultado deste passo, mas isto não faz parte do algoritmo) e ambas foram binarizadas com o mesmo limiar e seu tamanho duplicado através do método do vizinho mais próximo para facilitar a visualização. A segmentação automática do nível será efetuada nos passos seguintes do algoritmo.

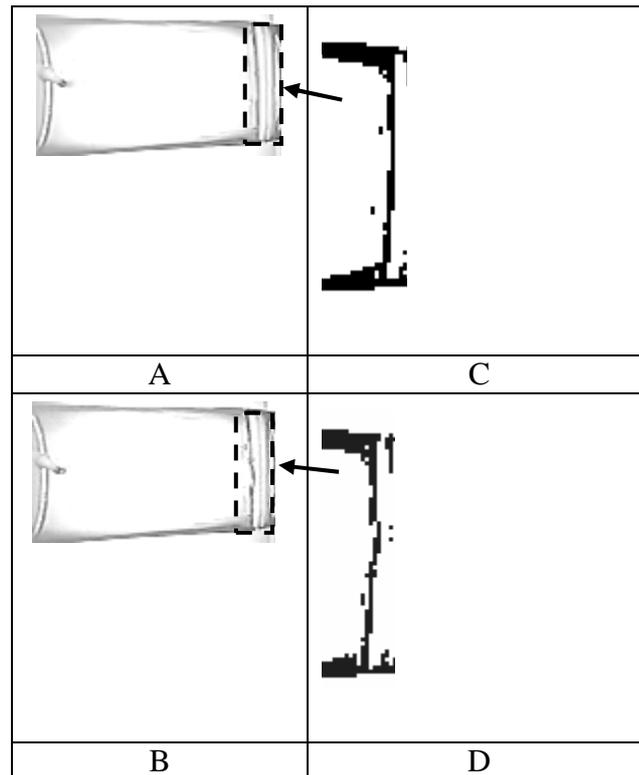


Figura 4.26: Comparativo entre imagens com e sem somatório

A normalização realizada no passo 2, faz com que a matriz somatório esteja no intervalo $[0, 255]$ e possa ser utilizada como uma imagem em tons de cinza. A normalização faz com que os pixels menos relevantes (que apareceram em menor quantidade na seqüência de imagens acumulada na matriz somatório) tenham um valor de cinza pequeno e possam ser descartados facilmente posteriormente.

Ao somar os quadros e armazená-los na matriz somatório fazemos com que cada valor de luminância é considerado como um peso na mesma (acumulador). Conseguem-se assim definir melhor os valores dos pixels em um intervalo curto de tempo e reduzir a influência de ruídos nas imagens. Um método semelhante é descrito em (GONZALES; WOODS, 2002) para sua utilização em imagens estáticas. No presente estudo o método foi utilizado na seqüência de vídeo com objetos que se encontram em um movimento constante.

Exemplificando, pode-se supor que o valor de luminância que deveria ter sido atribuído para um pixel “p” na imagem deveria ter sido de 240 (próximo do branco). Porém, ruído aleatório na hora da digitalização, fez com que “p” ficasse com valor de 10 (próximo do

preto). Isto aumenta a dificuldade na procura do nível que é formado por pixels próximos a esta cor. O ruído apareceu no pixel “p” em 5 quadros consecutivos. Nos seguintes 25 quadros o ruído desaparece e o valor do pixel muda para o valor real, 240. Ao somar estes valores na matriz somatório o valor do pixel “p” será 6050 (conta feita multiplicando os valores de luminância do pixel pelo número de quadros, $5 * 10 + 240 * 25$). O valor máximo de um dos elementos da matriz somatório no caso pior é de $255 * 30 = 7650$ (255 é o maior valor em tons de cinza possível para este exemplo e 30 o número de quadros total utilizados no somatório). Ao ser aplicada a normalização o pixel “p” passará a ter o valor $6050 / 7650 * 255 = 202$ (valor final arredondado para não conter parte decimal). Pode-se apreciar que o pixel ficou com um valor muito mais próximo do branco (valor real) sendo eliminada grande parte da influencia do ruído no processo.

Cabe ressaltar que este método considera a utilização de equipamentos com taxa de captura alta suficiente para fornecer uma quantidade razoável de quadros (N) a serem acumulados na matriz somatório e que a posição do objeto monitorado seja “aproximadamente constante” neste intervalo. Esta taxa de captura depende do problema a ser resolvido.

No presente estudo foi utilizada uma câmera com taxa de captura de 16 quadros por segundo e o objeto de estudo (o nível) mostrou-se constante suficiente em intervalos de 1 segundo mesmo com o líquido caindo com uma velocidade de aproximadamente 43 ml/min.

No passo 3 é aplicado um filtro de medianas na matriz somatório para reduzir o ruído que poderia ter ultrapassado os passos 1 e 2 do algoritmo.

No passo 4 são saturados os pixels mais representativos da imagem. Isto significa que os pixels de menor valor serão arredondados para zero e os de maior valor para 255. A escolha dos pixels mais representativos é realizada extraíndo 1% dos pixels mais próximos

dos limites inferior e superior de luminância da imagem. Isto aumenta o contraste sem ter um custo computacional muito alto.

No passo 5 é aplicada uma binarização com um limiar fixo de 0.5 (valor obtido empiricamente). A escolha do limiar é mais fácil depois de aplicar o corte e saturação na imagem, pois os pixels mais representativos foram afastados um do outro deixando uma margem ampla no meio do histograma para posicionar o limiar da binarização.

No passo 6 é aplicado o filtro de Canny para deixar a imagem somente com as bordas.

No passo 7 é aplicado novamente o algoritmo de busca de linhas através de janelas, mas desta vez para procurar segmentos de linha verticais. Os segmentos procurados são as interseções do nível com as laterais da garrafa (Figura 4.27)

Posteriormente ambas as interseções achadas terão calculada a média da reta que passa por todos seus pixels obtendo como resultado uma altura para cada linha. Finalmente será aplicada uma média entre ambas as linhas para detectar o nível (Figura 4.27 C).

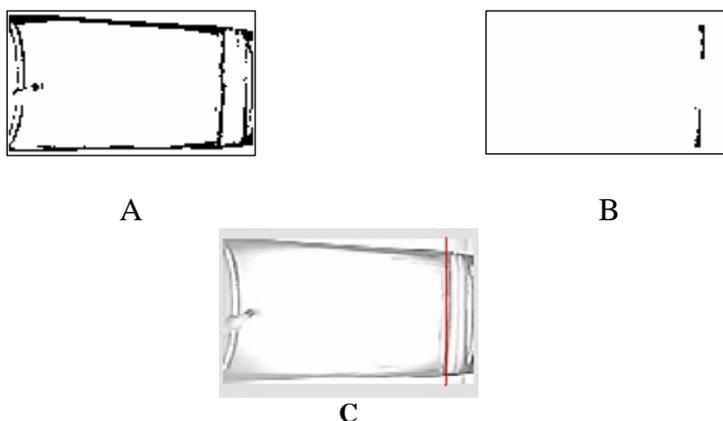


Figura 4.27: Detecção das interseções do nível com as laterais da garrafa

Vantagens

Utiliza muitos mais quadros do que as abordagens anteriores para extrair uma média do nível em um tempo semelhante ao da abordagem 3. Isto significa que a medição do nível é baseada em mais quadros e, portanto é mais confiável. Isto é confirmado pelos resultados nos

testes. Com esta abordagem foram obtidos os resultados mais robustos e com menor média do erro e menor desvio padrão.

A matriz somatório ocupa simplesmente o valor de um quadro na memória. No estudo de caso do nível seria uma matriz de 320 x 240. Esta vantagem é muito importante, devido a que não é necessário salvar muitos quadros na memória, que poderia ser facilmente esgotada devido à alta taxa de captura.

A normalização utilizada é um cálculo rápido e simples que não tem um custo computacional alto.

Desvantagens

A média extraída deve ter quadros consecutivos com pouca alteração na altura do nível. Isto significa que pode ser necessário aumentar a taxa de captura (atualmente de 16 quadros por segundo) para líquidos com maior velocidade de queda do que a velocidade máxima testada. Para o caso do gotejamento da destilação em batelada a taxa de captura atual é suficiente, como será mostrado na seção de resultados.

4.8.4 Correção da deformação em barril da imagem e obtenção da altura em centímetros

A imagem capturada sofre uma deformação em barril ocasionada pela lente utilizada na câmera. Este problema foi resolvido através da correção de imagem utilizando mapeamento de pontos com posição conhecida com o aplicativo da Figura 4.28. Para isto foi digitalizada uma imagem de uma quadrícula com linhas horizontais e verticais espaçadas com o valor constante de 1 centímetro entre elas. Tendo o eixo focal da câmera calibrado com o ponto central da quadrícula, foram marcadas uma a uma as interseções das retas e armazenadas suas correspondentes coordenadas.

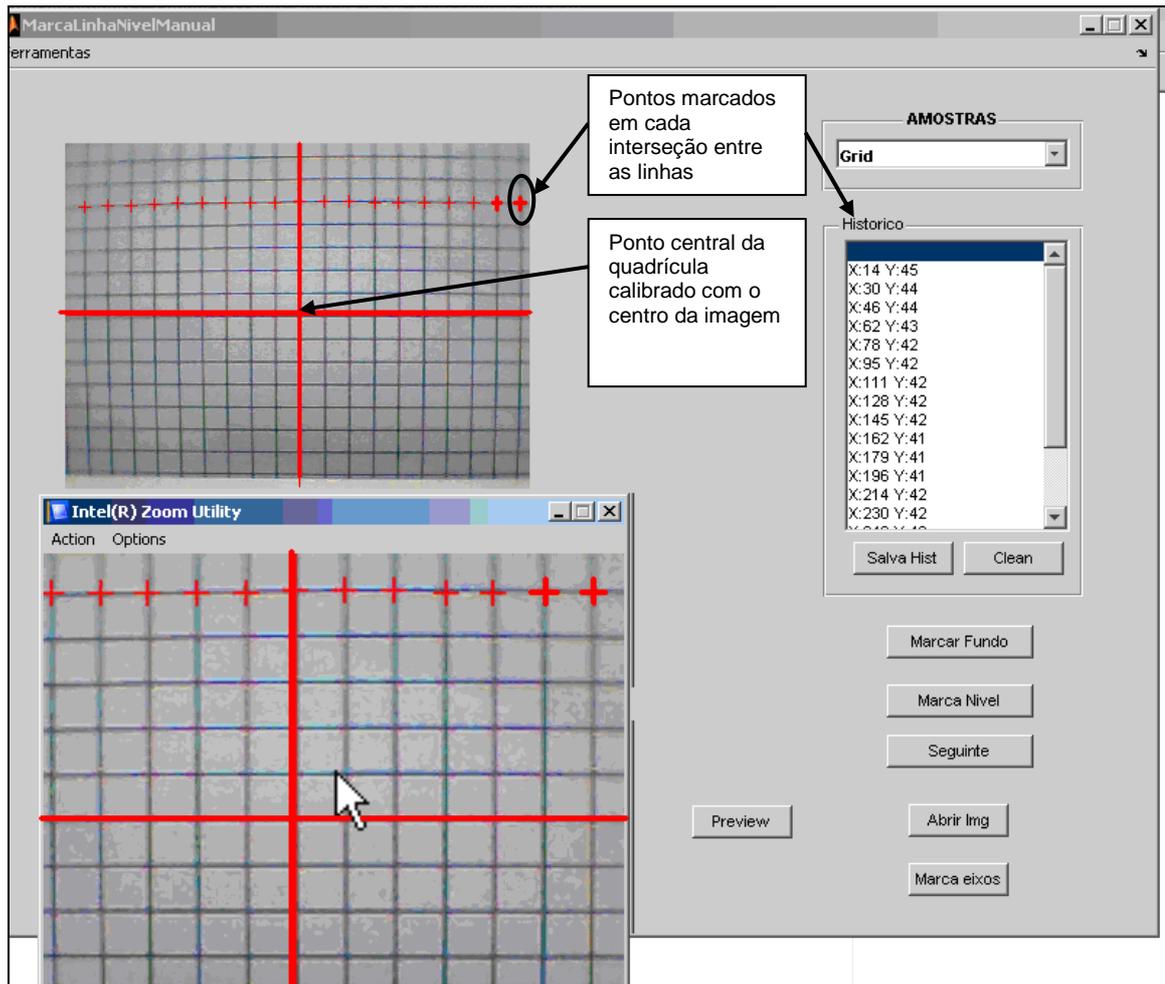


Figura 4.28: Mapeamento dos pixels

Para esclarecer mais este processo de mapeamento apresenta-se a seguir um exemplo do mesmo:

Cada interseção das linhas horizontais e verticais é marcada manualmente, obtendo assim as coordenadas (X, Y) (em pixels, com deformação) de cada uma delas com relação ao centro da malha. Com estas coordenadas é montada uma matriz de pares (Tabela 4. 1). Cada elemento da matriz terá calculada a altura h do ponto marcado com relação à linha vertical central da imagem. Para o exemplo simplificou-se a malha como sendo uma quadrícula de 4 x 4 quadrados, com um total de 25 interseções (Figura 4.29). A deformidade da malha do exemplo foi exagerada deliberadamente para melhor visualização do processo. Para a interseção do elemento $m(1,1)$ da esquina superior esquerda da malha tem-se uma altura $h(1,1)$ em centímetros (que é a altura real, sem deformação) com relação à linha horizontal

central pontilhada, que será armazenada na matriz de alturas H . Estas alturas são facilmente calculadas devido a que cada linha se encontra posicionada a 1 centímetro com relação às vizinhas. Para o exemplo a altura $h(1,1)$ é igual a 2 centímetros.

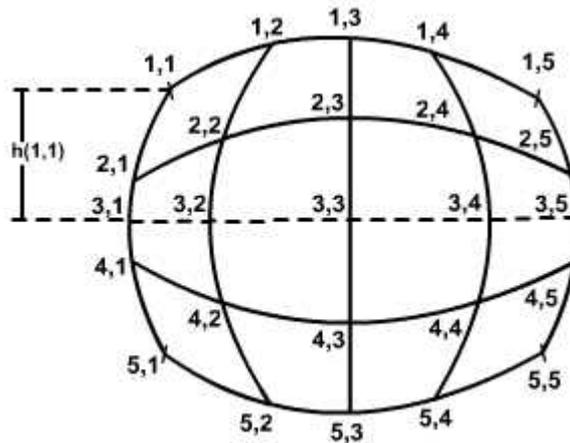


Figura 4.29: Exemplo de malha utilizada para o mapeamento da relação pixels – centímetros (distorção do tipo barril apresentada pela câmera utilizada)

Tabela 4. 1: Matriz m de posições das interseções da malha (em pixels, com deformação)

(-9, 7)	(-4, 9)	(0, 9)	(4, 9)	(9, 7)
(-10, 2)	(-6, 4)	(0, 5)	(6, 4)	(10, 2)
(-11, 0)	(-7, 0)	(0, 0)	(7, 0)	(11, 0)
(-10, -2)	(-6, -4)	(0, -5)	(6, -4)	(10, -2)
(-9, -7)	(-4, -9)	(0, -9)	(4, -9)	(9, -7)

Tabela 4. 2: Alturas em centímetros de cada interseção da malha

2	2	2	2	2
1	1	1	1	1
0	0	0	0	0
-1	-1	-1	-1	-1
-2	-2	-2	-2	-2

Pode-se observar que cada elemento da tabela 4.1 representa as coordenadas deformadas de uma interseção e que o elemento da tabela 4.2 com mesmo subíndice corresponde à altura real (sem deformação) em centímetros deste elemento. Através destas matrizes é possível obter a relação entre coordenadas deformadas e altura não deformada na imagem para distâncias de 1 centímetro. Isto é insuficiente para ter uma boa aproximação na hora de calcular a altura em centímetros do nível.

A primeira sugestão para melhorar esta aproximação seria a de reduzir a distância entre as linhas da malha, porém isto aumentaria muito o número de interseções a serem marcadas manualmente. A câmera utilizada consegue capturar um quadro de aproximadamente 34 centímetros de altura x 25 centímetros de largura considerando que se encontra a 30 centímetros da garrafa. Para realizar o mapeamento total dessa imagem, com linhas a um centímetro de distância uma da outra, é necessário realizar $34 \times 24 = 816$ marcações manuais. Reduzindo a distância entre as linhas da malha para 1mm seria necessário efetuar $340 * 240 = 81600$ marcações. Para otimizar este processo de mapeamento decidiu-se conservar a distância de 1 cm entre as linhas da malha e utilizar interpolação para calcular as alturas intermediárias entre as linhas.

A função $H = \text{mapeia}(x, y)$ representa a relação entre a posição de um ponto (x, y) em pixels com a altura do mesmo em centímetros.

Graficamente o valor absoluto da função H é apresentado na Figura 4.30.

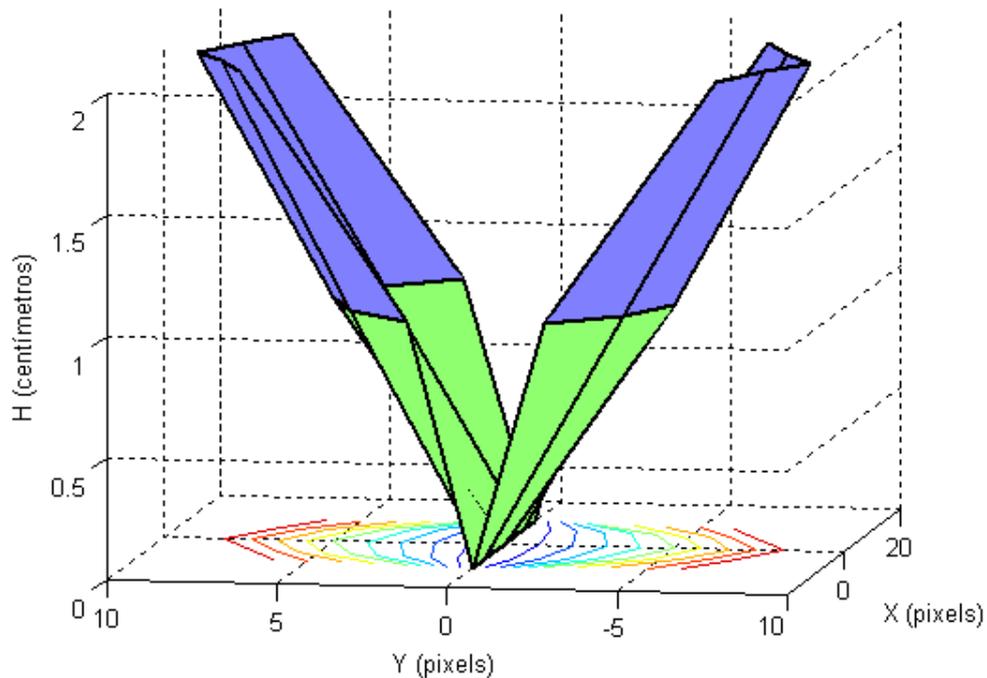


Figura 4.30: Resultado da função mapeia

A interpolação foi realizada através da triangulação de Delaunay (apresentada na seção 4.8.5) utilizando polinômios de terceiro grau e o resultado é mostrado na Figura 4.31. Os resultados foram salvos em na matriz H' . Enquanto as distâncias entre a câmera e a garrafa não mudarem, não será necessário calcular novamente esta matriz. Para o exemplo a matriz será de 18 x 22. Para o caso real esta matriz resultante terá como dimensões 320x240 (que corresponde à resolução dos quadros capturados), e conterà a altura do ponto indicado pelos subíndices da própria matriz.

O resultado da função será acessado depois de receber o resultado da altura em pixels do nível de um quadro por parte de alguma das abordagens projetadas para a detecção do nível apresentadas na seção 4.8.3.

Para saber a altura de um pixel com coordenadas (x', y') em centímetros com relação à linha central da imagem bastará com extrair o valor da matriz H' com coordenadas (x', y') .

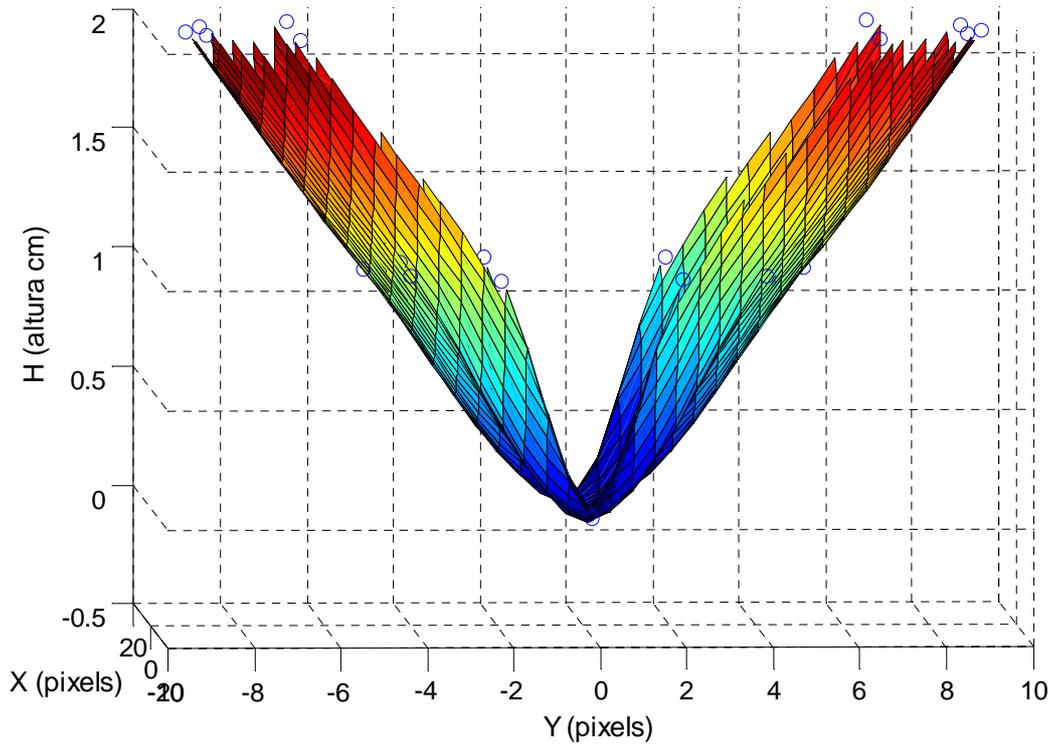


Figura 4.31: Função interpolada com o mapeamento pixels X centímetros

Esta altura extraída da matriz não será diretamente equivalente à altura do nível. O sistema verificará a posição do fundo da garrafa antes de efetuar o cálculo (Figura 4.32). A altura do nível h_n será calculada como:

$$h_n = h + \text{abs}(h_f) \quad \text{Equação 4. 1}$$

Onde h representa a altura do nível obtida, e h_f representa a altura do fundo da garrafa, ambas em centímetros e extraídas da matriz H' .

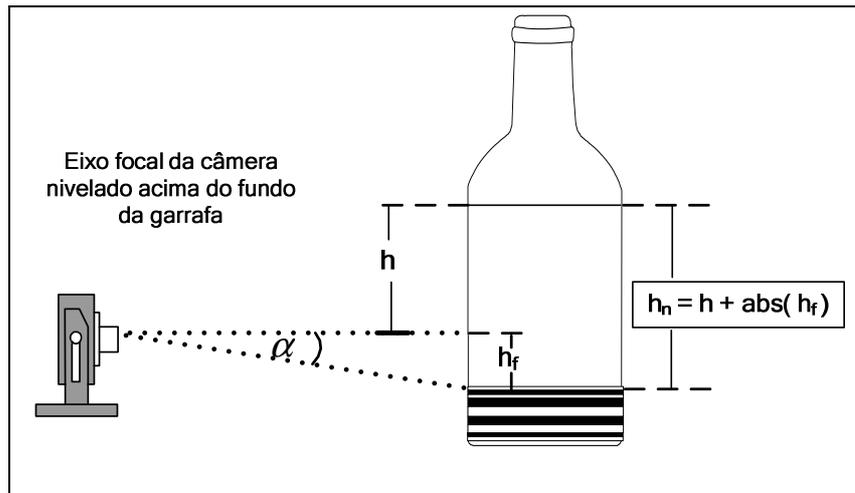


Figura 4.32: Cálculo da altura do nível (h_n)

4.8.5 Interpolação altimétrica através de polinômios de terceiro grau utilizando triangulação de Delaunay

A modelagem matemática de superfícies pode ser definida como sendo um conjunto de pontos amostrados da superfície real, com coordenadas espaciais (XYZ) determinadas em um referencial dado, e algoritmos que possibilitem construir um modelo matemático que reproduza da melhor maneira possível o comportamento altimétrico da superfície real.

O processo envolve três etapas básicas de trabalho:

- Obtenção de informações da superfície real que possibilitem a caracterização matemática do modelo.
- Elaboração do modelo matemático, composto por estruturas de dados e funções de interpolação que simulem o comportamento da superfície real.
- Utilização do modelo em substituição à superfície real.

4.8.3.5 Obtenção das informações da superfície real

A obtenção das informações da superfície real para fins de modelagem matemática de superfícies, consiste em levantar, utilizando uma técnica de amostragem, um certo número de pontos com coordenadas espaciais (X,Y,Z), (MITISHITA; TREVIZAN, 2001).

A elaboração do modelo matemático de uma superfície consiste no agrupamento dos pontos que descrevem a superfície real, em unidades lógicas denominadas de estruturas de dados, e na determinação de funções de interpolação, de forma que todo o conjunto simule de modo idealizado o comportamento da superfície original. (MITISHITA; TREVIZAN, 2001).

Existem vários processos na elaboração de modelos digitais. De forma geral, os pontos amostrados são interligados formando polígonos e estes por sua vez formando um poliedro. Desta maneira, a superfície é aproximada por um modelo que é um poliedro cujos vértices são os pontos amostrados. É possível ter diferentes classes de poliedros, sendo a triangulação o método mais empregado para a geração dos mesmos (MITISHITA; TREVIZAN, 2001).

4.8.3.6 Triangulação

É o modelo digital mais empregado na representação matemática de superfícies. Consiste em montar poliedro de faces triangulares, onde os vértices dos triângulos são os pontos amostrados na superfície. Estes pontos são classificados como pontos interiores quando são totalmente rodeados por triângulos e pontos exteriores quando são unidos dois a dois formando uma linha poligonal fechada que delimita a área a ser modelada (região de interesse), conforme mostrado na Figura 4.33, (MITISHITA; TREVIZAN, 2001).

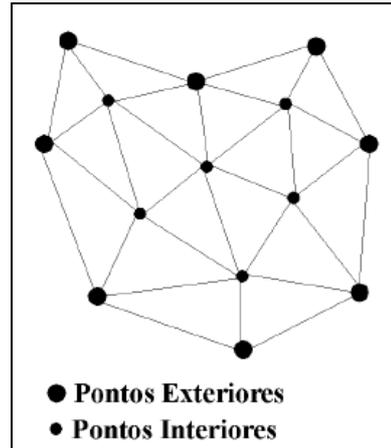


Figura 4.33: Pontos Amostrados na superfície (MITISHITA; TREVIZAN, 2001)

O primeiro procedimento na construção de uma triangulação é delimitar a região de interesse. Verifica-se que esta fronteira não é única, pois existe um número elevado de possíveis regiões de interesse. De todas as possíveis regiões de interesse, existirá somente uma que define um polígono convexo. Esta fronteira convexa é a que é empregada para delimitar a triangulação (MITISHITA; TREVIZAN, 2001).

O segundo procedimento é a realização da triangulação propriamente dita. Consiste na união dos pontos amostrados, dois a dois, formando triângulos. Verifica-se que uma triangulação não é única.

Nem todas as triangulações possíveis prestam-se bem para a tarefa de modelagem de superfícies. Deve-se escolher uma onde não haja abundância de triângulos excessivamente longos e afinados Pettinati (apud. MITISHITA; TREVIZAN, 2001). De todas as diferentes triangulações de um mesmo conjunto de pontos, existe uma que satisfaz a exigência apresentada anteriormente. Esta triangulação é conhecida como triangulação de Delaunay.

O procedimento para a geração da triangulação de Delaunay está baseado na propriedade do circuncírculo Pettinati (apud. MITISHITA; TREVIZAN, 2001).

Seja $P = \{p_i(X_i, Y_i), i = 1, n\}$ um conjunto de pontos amostrados e $T = \{\Delta p_i, p_j, p_k \mid p_i, p_j, p_k \in P\}$ uma triangulação qualquer. T será uma triangulação de Delaunay de P se e somente se em cada triângulo $\Delta p_i, p_j, p_k \in T$ não existirem pontos

internos ao circuncírculo p_i, p_j, p_k ou ao círculo definido pelos pontos p_i, p_j, p_k . Na Figura 4.34 é mostrada esta propriedade (MITISHITA; TREVIZAN, 2001).

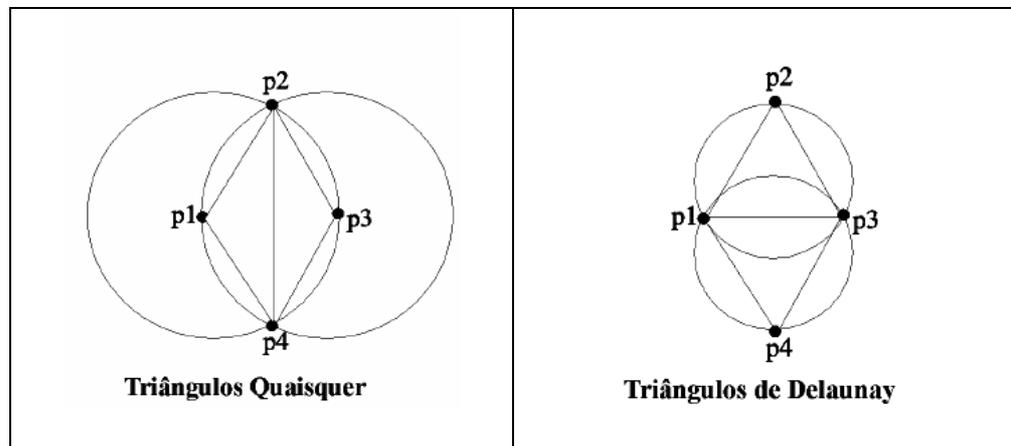


Figura 4.34: Propriedade do circuncírculo na definição de triângulos de Delaunay (MITISHITA; TREVIZAN, 2001)

A modelagem matemática de superfícies não consiste somente na construção de um modelo digital poliédrico. O sistema deverá possuir algoritmos de interpolação de valores de “alturas”, em posições não correspondentes aos pontos amostrados. Os algoritmos de interpolação devem conter certas condições de contorno, baseadas no princípio de que o comportamento de uma superfície contínua possa ser derivado do comportamento conhecido de posições próximas, Pettinati (apud. MITISHITA; TREVIZAN, 2001).

4.8.3.7 Superfície triangular de 3º grau contínua

Geralmente, é empregado nos processos de interpolação um conjunto limitado de pontos que é conhecido como vizinhança local. Este procedimento parte de uma triangulação e o ponto a ser interpolado encontra-se no interior de um dos triângulos (Figura 4.35).

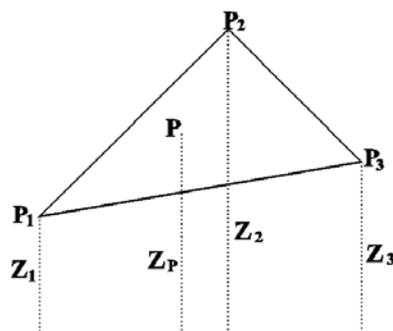


Figura 4.35 Superfície de referência (MITISHITA; TREVIZAN, 2001)

Considera-se que a superfície interna do domínio triangular possa ser aproximada por um polinômio bivariado de 3º grau completo:

$$Z(x, y) = a_1 + a_2x + a_3y + a_4xy + a_5x^2 + a_6y^2 + a_7x^2y + a_8y^2x + a_9y^3 + a_{10}x^3$$

Este polinômio possui dez coeficientes que devem ser determinados com as informações contidas no triângulo. Desta forma, para cada vértice do triângulo têm-se as seguintes condições:

- 1) Coordenada altimétrica Z ;
- 2) As derivadas parciais de 1ª ordem:

$$\frac{\partial Z}{\partial x} = a_2 + a_4y + 2a_5x + 2a_7xy + a_8y^2 + 3a_{10}x^2 \quad \text{Equação 4.2}$$

$$\frac{\partial Z}{\partial y} = a_3 + a_4x + 2a_6y + a_7x^2 + 2a_8xy + 3a_9y^2 \quad \text{Equação 4.3}$$

- 3) As derivadas parciais de 2ª ordem:

$$\frac{\partial^2 Z}{\partial x^2} = 2a_5x + 2a_7y + 6a_{10}x \quad \text{Equação 4.4}$$

$$\frac{\partial^2 Z}{\partial y^2} = 2a_6 + 2a_8x + 6a_9y \quad \text{Equação 4.5}$$

$$\frac{\partial^2 Z}{\partial xy} = a_4 + 2a_7x + 2a_8y \quad \text{Equação 4.6}$$

Aplicando-se estas condições para os três vértices do triângulo, resulta um sistema com dezoito equações e dez parâmetros, possibilitando a determinação dos coeficientes com ajustamento do método de mínimos quadrados (M.M.Q.). A dificuldade deste procedimento se encontra na forma que serão estimadas as derivadas parciais em cada vértice do triângulo,

pois os valores das derivadas exercem grande influência nos valores dos coeficientes da função $Z(x, y)$, (MITISHITA; TREVIZAN, 2001).

Para a determinação das derivadas parciais em cada ponto do triângulo, utiliza-se uma superfície quádrlica do tipo (MITISHITA; TREVIZAN, 2001):

$$Z(x, y) = a_1 + a_2x + a_3y + a_4xy + a_5x^2 + a_6y^2 \quad \text{Equação 4.7}$$

A superfície quádrlica é determinada por ajustamento M.M.Q. em uma região de domínio restrito, definida pelo vértice e seus nove pontos mais próximos. O cálculo das derivadas parciais pode ser dado por (MITISHITA; TREVIZAN, 2001):

$$\frac{\partial Z}{\partial x} = a_2 + a_4y + 2a_5x \quad \text{Equação 4.8}$$

$$\frac{\partial Z}{\partial y} = a_3 + a_4x + 2a_6y \quad \text{Equação 4.9}$$

$$\frac{\partial^2 Z}{\partial x^2} = 2a_5 \quad \text{Equação 4.10}$$

$$\frac{\partial^2 Z}{\partial y^2} = 2a_6 \quad \text{Equação 4.11}$$

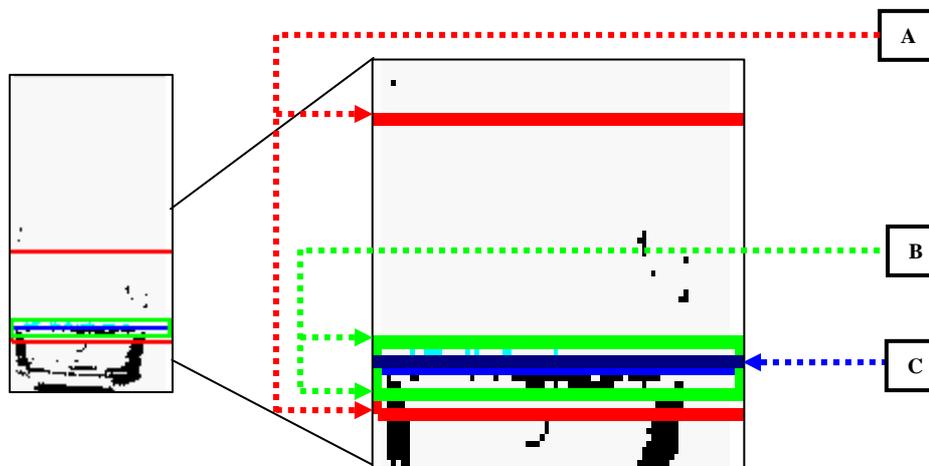
$$\frac{\partial^2 Z}{\partial xy} = a_4 \quad \text{Equação 4.12}$$

Onde x_v , y_v e z_v são coordenadas planimétricas do vértice do triângulo.

Ajustando-se uma quádrlica para cada vértice do triângulo, e admitindo-se as derivadas da quádrlica como sendo iguais as do polinômio de 3º grau, têm-se as informações necessárias para a determinação dos coeficientes da função de interpolação por ajustamento M.M.Q. Trata-se de um procedimento matemático que apresenta resultados ótimos na interpolação altimétrica de pontos (MITISHITA; TREVIZAN, 2001).

4.8.6 Região de segurança para detecção do nível

Para diminuir a região de busca do nível, foi proposto limitá-la com a informação que se tem da última posição detectada do nível, no instante t_1 . Espera-se que a seguinte posição do nível no instante t_2 não se encontre muito distante da anterior, então se delimitou a área de busca como mostrado na Figura 4.36. Como a altura do nível tem um movimento ascendente, é considerada na busca somente a região acima do nível detectado no instante t_1 .



- A. Representa o limite para busca do nível
- B. Representam a Janela utilizada para detecção de regiões candidatas de linhas
- C. Representa o nível detectado

Figura 4.36: Região de segurança de detecção do nível

4.9 Restrições do Modelo Proposto

4.9.1 Precisão na medição do Nível

Devido que as distorções nos objetos aumentam à medida que o pixel se afasta do eixo focal da câmera, a precisão de qualquer medida dependerá tanto da distância entre a câmera e o objeto como da distância do pixel de interesse ao eixo focal.

Para determinar a precisão máxima possível de ser tratada pelo sistema, considerando as condições expostas na Figura 4.3, foram tiradas fotos de papéis de cor branca com linhas horizontais pretas traçadas com uma distância constante x entre elas, como mostrado na Figura 4.32.

Como se pode apreciar na Figura 4.37A é possível ainda distinguir um espaço em branco entre as linhas. No entanto podemos observar que quanto mais longe ficam as linhas do eixo focal da imagem, menor fica a distância entre elas, o que demonstra uma perda da precisão nas regiões mais distantes.

Nos testes realizados com 1mm de distância entre as linhas não conseguiu-se mais observar o espaço em branco entre as mesmas, o que indica que a precisão máxima que o sistema poderá fornecer se encontra ente 1 e 2mm. O espaço entre as linhas fica mais difícil de observar na parte superior da imagem. Na Figura 4.37B é mostrado o mesmo teste com distância de 4 mm entre as linhas.

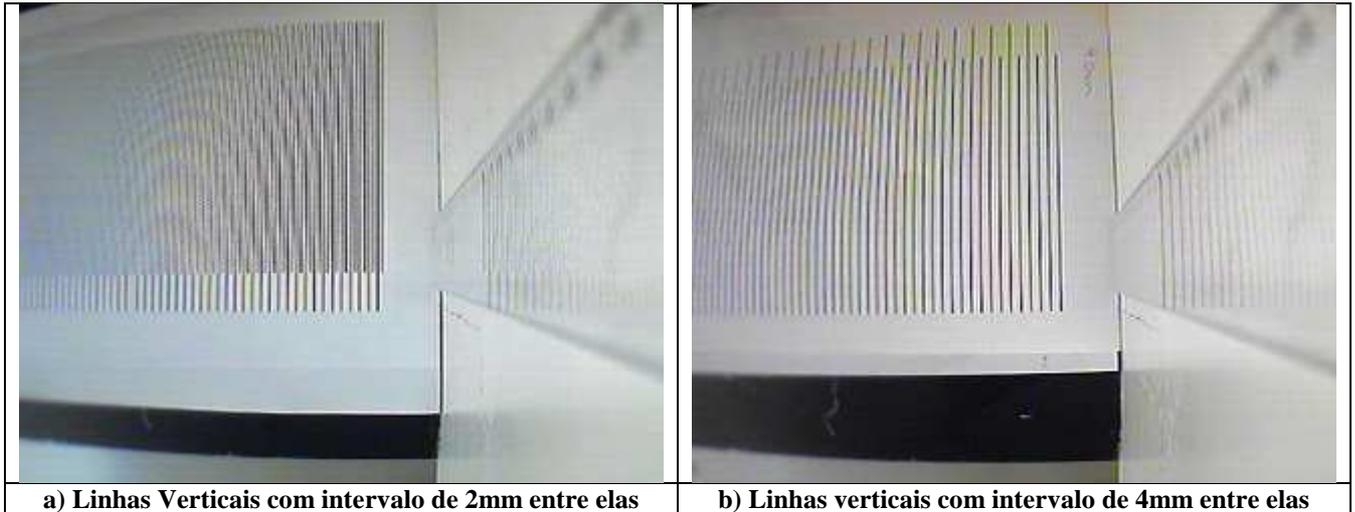


Figura 4.37. Testes para achar a altura mínima H_{min} que o sistema será capaz de calcular

4.9.2 Formato e dimensões da garrafa

A Tabela 4.3 apresenta a relação entre a dimensão do raio, do volume e da altura disponível para visualização de líquido (h_{UTIL}) na garrafa, calculada através da equação do volume de cilindros. Esta altura para visualização de líquido representa a altura da parte perfeitamente cilíndrica da garrafa (sem contar a parte onde as laterais da mesma convergem para formar o bico), (Figura 4.38).

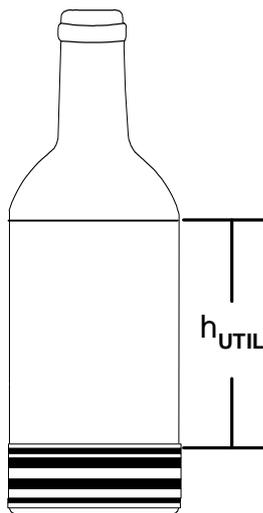


Figura 4.38: Altura utilizável para detecção do nível (h_{UTIL})

Por exemplo, para uma garrafa com raio de 4.7 cm e volume de 1000ml tem-se que a altura disponível para visualização de líquido é 14,41 cm.

A proposta atual está destacada em negrito e corresponde a uma garrafa de 4,5 cm de raio e 12,24 cm de altura. Como pode ser visto na Figura 4.3, existem um total de aproximadamente 16 cm utilizáveis.

Tabela 4. 3: Relação Raio (r) – Volume (v)- Altura do Líquido (h_{UTIL})

Raio (cm)	Volume (ml)	Altura (cm)
4.3	1000	17.22
4.4	1000	16.44
4.5	1000	15.72
4.6	1000	15.04
4.7	1000	14.41
4.8	1000	13.82
4.9	1000	13.26

4.9.3 Comportamento do líquido

Para uma correta detecção do nível visualmente, o líquido a ser monitorado deve ser “bem comportado”. Isto significa que não se espera uma queda semelhante a uma torneira aberta, mas sim um gotejamento do líquido. Pelas características da destilação espera-se este tipo de comportamento. A queda muito volumosa do líquido pode ocasionar com que o mesmo se espalhe pelo contorno da garrafa o que pode gerar uma detecção do nível acima da verdadeira posição. Para o caso de líquidos viscosos e com cores escuras o problema é mais grave ainda, porque o líquido ficaria grudado nas paredes da garrafa impossibilitando uma correta medição visual.

4.10 Obtenção e avaliação dos Resultados

Para avaliar o desempenho do sistema é necessária uma medida de comparação com o resultado obtido. Com esta finalidade foi feita uma marcação manual da posição do nível que será descrita a seguir.

4.10.1 Marcação manual do nível

Foi desenvolvida uma ferramenta para realizar uma marcação manual do nível para poder realizar o cálculo do erro do sistema (Figura 4.39). A cada 30 quadros (aproximadamente 2 segundos de vídeo) foi marcada manualmente a posição do nível.

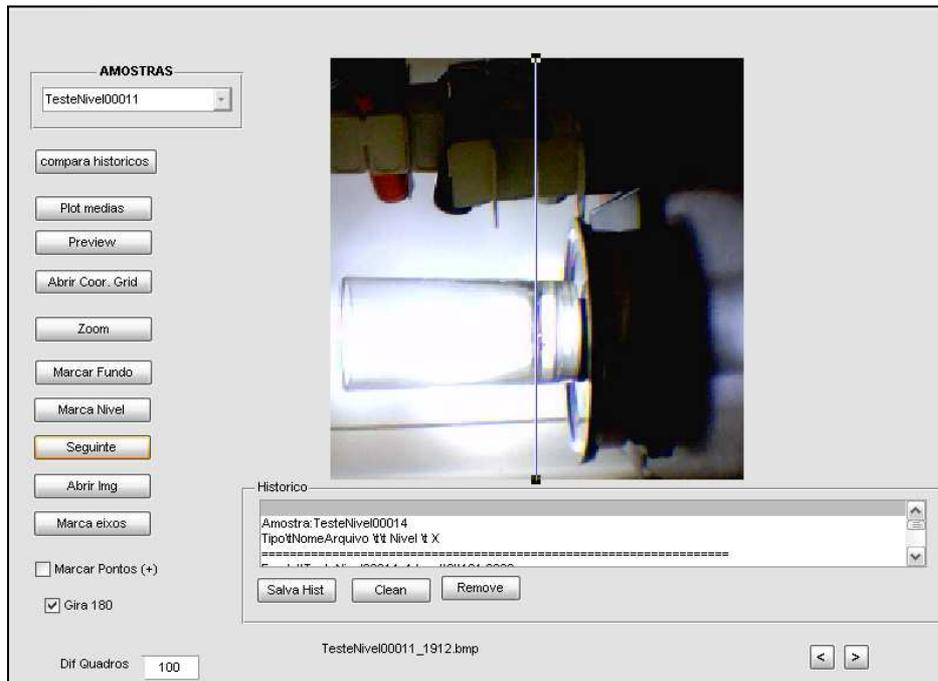


Figura 4.39: Marcação manual do nível

4.10.2 Resultados

O erro do protótipo foi calculado da seguinte forma: $\text{Erro} = \text{ValorNivelSistema} - \text{ValorNivelReal}$.

Isto significa que caso o sistema tenha detectado o nível acima da marcação manual o erro será positivo. Caso contrário o erro será negativo. Cabe ressaltar que para o cálculo da média do erro foi utilizado o valor absoluto dos erros individuais.

Fazendo uma média na função de conversão de distância em pixels e centímetros pode-se aproximar cada pixel com 0,1 centímetros (1 mm). Cabe ressaltar que a precisão desta equivalência depende da posição onde se encontra o nível.

O equipamento utilizado para os testes foi um computador Pentium M de 1.5 Ghz e 1GB de memória RAM.

Tabela 4. 4: Amostras utilizadas nos testes de laboratório

Número amostra	Total Quadros Amostra	Tempo aprox. aquisição amostra (min)	Medias avaliadas (*)	Velocidade aprox. do líquido (ml/min)
1	86010	90	2867	2,9
2	30660	33	1022	7,9
3	4980	6	166	43,5

Tabela 4. 5: Parâmetros utilizados para cada abordagem

Abordagem	Distancia entre quadros utilizados para media (*)	Quadros utilizados para calculo da media
1	30	--
2	5	6
3	5	6
4	1	30

(*) Na abordagem 1 não é calculada a média, é utilizado o valor do nível de um único quadro.

Tabela 4. 6: Resultados dos testes aplicando todas as abordagens (Cifras arredondadas em 2 casas decimais).

Número amostra	Abord.	Erro Médio (mm)	Erro Médio (ml)	Desvio Padrão	Erro Máximo Superior (mm)	Erro Máximo inferior (mm)	Tempo de proc. (min)	Pontos onde nível não foi encontrado
1	1	2,3	7.87	0,84	5	-5	8	10
1	2	5,5	18.81	12,84	90	-3	17	8
1	3	2,69	9.20	0,92	5	-5	34	0
1	4	0,57	1.95	0,66	3	-1	37	0
2	1	2,98	10.19	3,63	5	-84	3	3
2	2	2,02	6.91	2,98	64	-3	5	6
2	3	1,34	4.58	0,88	3	-5	9	0
2	4	0,69	2.36	1,12	2	-7	10	0
3	1	2,79	9.54	1,03	5	-2	1	1
3	2	2,26	7.73	4,25	48	0	1	5
3	3	2,05	7.01	0,87	4	-3	2	0
3	4	0,58	1.98	0,69	2	-2	2	0

Nota: O erro médio em ml foi calculado utilizando o maior raio do copo (caso pior).

A quantidade de médias avaliadas é igual para todas as abordagens, porém a quantidade de pontos utilizada para extrair a média é de 6 quadros para o caso da abordagens 2 e 3 e de 30 quadros para a abordagem 4. Isto significa que a abordagem 4 processa mais

quadros para a obtenção da média em um tempo semelhante ao da abordagem 3, mas devido ao maior número de quadros tem maior precisão na hora de detectar o nível.

Da altura total do copo (10,7 cm) foram utilizados somente 10 cm para as amostras. O volume total de líquido com esta altura é de aproximadamente 261 ml.

Para a abordagem 4 o deslocamento Δh máximo detectado entre dois pontos de avaliação foi de aproximadamente 1mm. Levando em consideração o raio maior do copo (3,3 cm), o volume mínimo detectável é 3,4 ml. Para o caso do copo real, com raio 4,5 cm, o volume mínimo detectável é aproximadamente 6,4 ml.

5 CONCLUSÕES E TRABALHOS FUTUROS

5.1 Cumprimento dos objetivos

Acreditamos que o objetivo principal da pesquisa tenha sido atingido, através do desenvolvimento do modelo computacional (baseado na quarta abordagem) que consegue monitorar um deslocamento Δh mínimo pequeno suficiente para detectar mudanças menores que 10 ml (mínimo volume requerido pelo sistema).

Foi desenvolvido um protótipo com as quatro abordagens (primeiro objetivo secundário), e os desempenhos de cada abordagem foram avaliados e comparados (segundo objetivo secundário).

5.2 Conclusões sobre o estudo de caso

O problema de detecção do nível é um problema não trivial. Foi necessário o desenvolvimento de quatro abordagens para conseguir resolver esse problema e atingir uma taxa de erro médio menor a 1mm (abordagem 4). A detecção do nível não é um problema que tenha sido atacado anteriormente através de processamento de imagens, é por este motivo que decidiu-se utilizar a prototipagem evolutiva para projetar um modelo computacional que resolva o problema.

A primeira abordagem demonstrou ser a mais veloz de todas. Os algoritmos utilizados nessa abordagem são os mais simples do estudo. Porém, esta abordagem obteve as menores taxas de acerto dentre as quatro projetadas.

Na segunda abordagem a complexidade dos algoritmos utilizados para a detecção do nível foi aumentada. Essa abordagem tenta corrigir as deficiências encontradas na primeira abordagem, no entanto os resultados não foram satisfatórios. Foi proposto utilizar mais do que um quadro para determinar a posição do nível. É mais lenta que a primeira abordagem devido aos algoritmos utilizados, que são mais exigentes computacionalmente.

Na terceira abordagem a complexidade dos algoritmos foi aumentada com relação às primeiras duas. Isto determinou uma queda no desempenho do protótipo. Em compensação a taxa de acerto foi muito superior em comparação com as abordagens anteriores. Apesar da queda do desempenho, o tempo de processamento da terceira abordagem não ultrapassou um terço do tempo total da aquisição das amostras.

Na quarta abordagem tentou-se diminuir a carga computacional retirando os algoritmos mais pesados como, por exemplo, o fechamento. Apesar de que o tempo de processamento dessa abordagem é semelhante ao tempo utilizado pela terceira abordagem, a diferença se encontra no número de quadros utilizados para extrair a média. Na terceira abordagem são utilizados seis quadros para a obtenção da média. Na quarta abordagem são utilizados trinta quadros para a obtenção da média, o que significa que são processados mais quadros no mesmo intervalo de tempo utilizado pela terceira abordagem. Este fator contribui para ter um cálculo mais preciso da média, o que aumenta a taxa de acerto da última abordagem com relação à terceira.

É uma boa estratégia aumentar gradativamente a complexidade dos algoritmos utilizados para resolver o problema. Na primeira tentativa de detecção do nível foram utilizados algoritmos muito simples com o intuito de conhecer melhor o problema.

O algoritmo de detecção de linhas através de janelas é um método simples, porém efetivo para reconhecimento de linhas verticais e horizontais em ambientes fortemente controlados.

O método proposto na abordagem 4 para cálculo de imagens “médias” resultou em um incremento na taxa de acerto do protótipo.

A transformada de Hough mostrou ser um método eficiente para detecção de figuras geométricas representadas por equações com poucos parâmetros.

Os problemas de visão de máquina frequentemente têm sido muito específicos. A melhor estratégia parece ser a de fechar o contexto do problema e não ter a pretensão de criar um sistema muito genérico. É necessário levar em consideração a alta velocidade de processamento requerida pelas linhas industriais. De nada serve um algoritmo que resolve o problema com taxas de erro satisfatórias, se não é possível utilizá-lo na prática por ser muito lento.

Todo conhecimento prévio do problema deve ser utilizado para tentar diminuir a carga de processamento do sistema de visão de máquina. No presente estudo foi utilizado o conhecimento prévio das dimensões aproximadas da garrafa para redimensionar a circunferência do fundo. Isto possibilitou a utilização do algoritmo de Hough circular, ao invés do algoritmo de Hough para elipses, que é muito mais exigente computacionalmente.

A projeção de um sistema de visão de máquina envolve não somente a concepção de software, mas envolve também a consideração de fatores de engenharia. Embora o modelo computacional seja a maior contribuição da pesquisa, a projeção do ambiente de trabalho (iluminação indireta, ambiente de testes, projeção de uma garrafa com fundo falso, interação com o CLP) teve uma grande influência na consecução de resultados positivos na detecção do nível. A evolução nas abordagens propostas para a solução do problema mostra o processo de amadurecimento que os sistemas de visão de máquina requerem.

A iluminação artificial é um fator importante a ser levado em consideração sempre nos modelos que pretendam resolver problemas industriais, onde comumente o ambiente é controlado. A projeção desta iluminação artificial deve ser cuidadosa e bem valorizada. No estudo de caso desenvolvido nesta dissertação a projeção da iluminação indireta como sendo a melhor escolha foi um processo demorado porque não é citada como método tradicional na bibliografia da área. Vários testes tiveram que ser realizados antes de conseguir a melhor configuração para esta iluminação.

A projeção de um sistema de visão de máquina requer um conhecimento aprofundado de técnicas de processamento de imagens, e, na maioria dos casos, os algoritmos clássicos devem ser modificados para atingir resultados ótimos. Além do conhecimento de processamento de imagens, é fundamental estudar a bibliografia dedicada exclusivamente à área de visão de máquina, pois facilita a concepção de novos modelos.

É necessário ressaltar também que a projeção de um sistema de visão de máquina não implica somente a aplicação direta de algoritmos de processamento de imagens, mas requer um árduo trabalho de pesquisa a ser desenvolvido. Como mostrado no presente trabalho, a resolução do estudo de caso precisou de uma pesquisa bibliográfica ampla e da projeção de diferentes abordagens.

Os sistemas de visão de máquina, e em geral todo sistema de visão, possuem dois módulos básicos: o módulo de captura e o módulo de análise. Esses módulos podem trabalhar separadamente um do outro, mas compartilhando os dados. Isto faz com que este tipo de sistemas seja candidato indiscutível para ser implementado utilizando métodos de programação paralela. Com a aparição dos processadores de baixo custo com mais de um núcleo (*core*), deve ser possível melhorar muito o desempenho dos sistemas de visão comerciais.

É importante levar em consideração possíveis deformações na imagem ocasionadas pelos equipamentos utilizados na captura. O método aqui utilizado para a correção da deformação da câmera é um método simples e que pode ser estendido para corrigir ambas as coordenadas dos pixels, e não somente para correção da coordenada vertical como feito aqui.

5.3 Contribuições da pesquisa

A monitoração de níveis de líquidos bem comportados com densidades e cores variáveis é um problema que não foi resolvido utilizando as ferramentas disponíveis

atualmente no mercado, sendo assim este trabalho poderia ser visto como uma contribuição significativa para a indústria.

A terceira abordagem apresenta um método novo para determinar os pixels mais relevantes em uma imagem em tons de cinza dinamicamente. Em outras palavras, um limiar de binarização é obtido dinamicamente. Este método foi projetado levando em consideração o conceito estatístico da média e o desvio padrão em distribuições normais.

O método para cálculo das médias e normalização de imagens utilizado na quarta abordagem é um método que pode ser explorado para melhorar a definição de bordas em cenas de vídeo.

Esta pesquisa reúne referências bibliográficas como, por exemplo, (BATCHELOR; WHELAN, 2002), (LIMA; THOMÉ, 2004), (EJIRI, 1990), (ZUECH, 2000) dedicadas exclusivamente à área de visão de máquina. Através da bibliografia aqui compilada é possível ter uma visão diferenciada da área de visão de máquina e que futuros pesquisadores possuam uma visão mais abrangente da projeção de sistemas para esta área. Um erro comumente cometido por pesquisadores pouco experientes na área é o de considerar somente a bibliografia padrão de processamento de imagens. Embora esta bibliografia padrão seja muito útil e boa para a aprendizagem dos conceitos fundamentais da área de processamento de imagens, eles carecem de conceitos importantes para a área de visão de máquina como técnicas de iluminação artificial e estudo de técnicas diretamente aplicadas à indústria.

5.4 Trabalhos Futuros

Experimentar utilizando a média de quadros proposta na abordagem 4 com sobreposição dos quadros utilizados para diferentes médias. No presente estudo uma média foi calculada a cada trinta quadros, como mostrado na Figura 5.1. Na Figura 5.2 é mostrado o cálculo de médias com sobreposição o que possibilitara diminuir a distância entre uma média e outra. Isto pode levar a ter uma maior precisão na monitoração do nível.

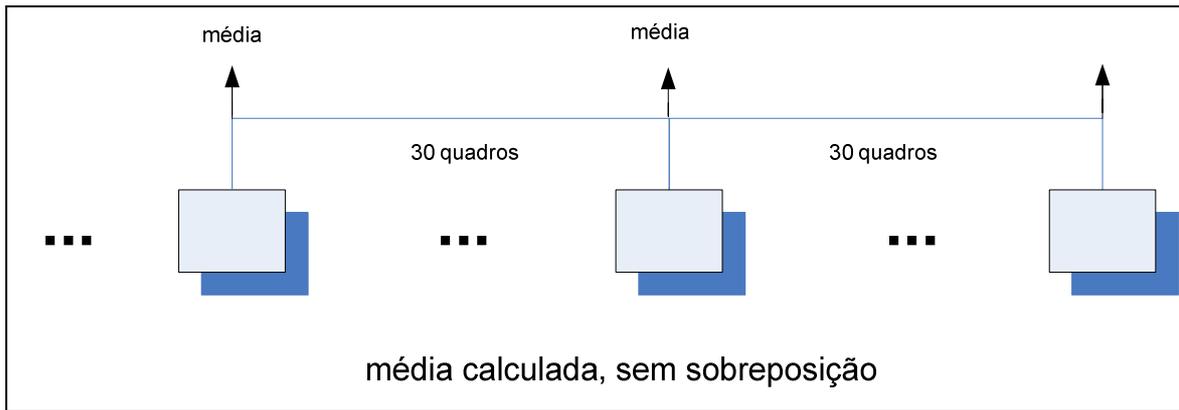


Figura 5.1. Cálculo das médias utilizando sobreposição

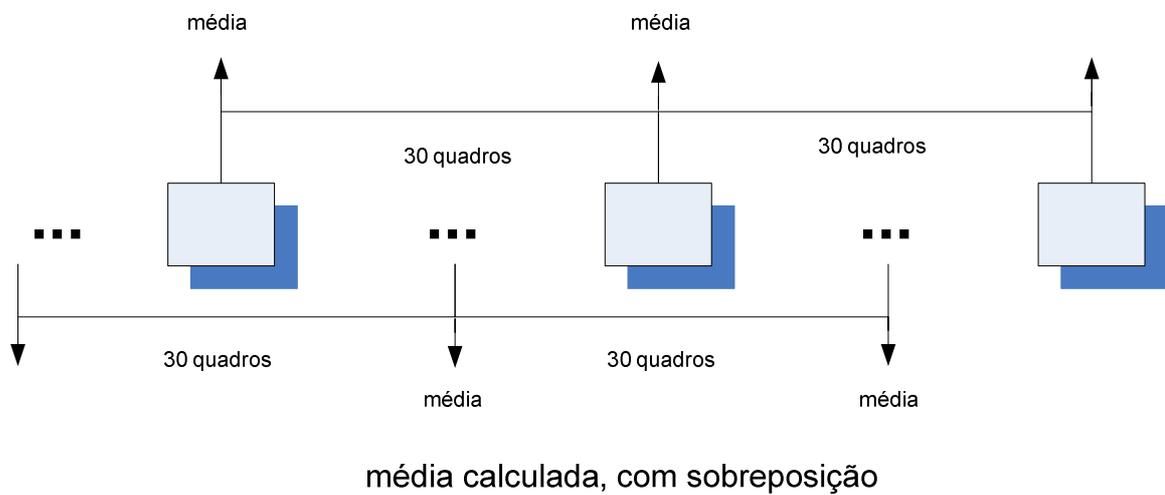


Figura 5.2. Cálculo das médias com sobreposição

Experimentalizar utilizando a remoção de pixels não relevantes projetada na abordagem 3 de detecção do nível. O método foi proposto levando em consideração o comportamento de distribuições normais. É possível procurar outra distribuição que se adapte melhor ao estudo de caso.

Programação do protótipo em uma linguagem de programação que seja compilada, como, por exemplo, C++. O MATLAB possui uma linguagem de programação interpretada, o que diminui o desempenho aplicativo gerado. Dentro da nova implementação cabe também a utilização de técnicas de processamento paralelo, como threads. Será utilizada a modelagem proposta na seção 4.7.2.

Experimentar utilizando o método de cálculo de médias proposto na abordagem 4 em outros cenários, para testar sua capacidade de definição de bordas e possíveis novos usos e limitações. O método pode ser utilizado também para a criação de um quadro de fundo para segmentar os objetos estáticos em uma sequência de vídeo.

Gostaríamos de ter chegado a realizar testes com a garrafa real utilizada na unidade da destilação em batelada. Teria sido desejável também contar com amostras extraídas da unidade de destilação real (na dissertação foi utilizado um ambiente de simulação para extrair as amostras), mas esta não se encontrava pronta na época em que os testes foram realizados.

Referências Bibliográficas

ALEIXOS, N.; BLASCO, J.; MOLTÓ, E.; NAVARRON, F. **Assessment of citrus fruit quality using a real-time machine vision system.** Proceedings. 15th International Conference on Pattern Recognition, 2000. Volume 1, 3-7 Set. 2000 Pag(s):482 - 485 vol.1.

BATCHELOR, Bruce G.; WHELAN, Paul F. **Intelligent Vision Systems for Industry.** London: Springer-Verlag, 2002.

BISHOP, Christopher M. **Neural Networks for Pattern Recognition.** CLARENDON PRESS. OXFORD, 1995.

BLACKWELL, G. F. **Machine vision in the tire industry.** Electrical Engineering Problems in the Rubber and Plastics Industries, 1989., IEEE Conference Record of 1989 Forty-First Annual Conference of Volume , Issue , 10-11 Abril 1989 Pag: 67 – 79

BREKKE, Camilla; SOLBERG, Anne H. S. **Oil spill detection by satellite remote sensing.** Remote Sensing of Environment, Volume 95, Issue 1, 15 Março 2005, Pag. 1-13.

CHIN, Roland T.; DYER, Charles R. **Model-Based Recognition in Robot Vision.** ACM Computer Surveys, Vol. 18, No 1, Março 1986.

CHAN, J. P; PALMER, G. S. **Machine Vision – Applications in Industry.** IEEE Colloquium on Application of Machine Vision. 24 Maio 1995. London, UK.

CHO, Tai Hoon; CONNERS, Richard W. **A neural network approach to Machine Vision Systems for automated industrial inspection.** International Joint Conference on Neural Networks, 1991. IJCNN-91-Seattle Volume i, Issue , 8-14 Jul 1991 Pag:205 - 210 vol.1

COHEN, Fernand S.; FAN, Zhigang; ATTALI, Stephane. **Automated Inspection of Textile Fabrics using Textural Models.** IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 13, No. 8. Agosto 1991.

CONCI, Aura; BELMIRO, Claudia P. **A System for Real-Time Fabric Inspection and Industrial Decision.** Proceedings of the Fourteenth International Conference on Software Engineering and Knowledge Engineering, p. 707 - 714. Jul 2002.

DERGANČ, Joze; LIKAR, Bostjan; BERNARD, Rok; TOMAZEVIC, Dejan; PERNUS, Franjo. **Real-time automated visual inspection of color tablets in pharmaceutical blisters**. Real-Time Imaging Volume 9, Issue 2, Abril 2003, Pág. 113-124

EDWARDS H. **Machine Vision and its integration with CIM systems in the electronics manufacturing industry**, Computer-Aided Engineering Journal, Editora IEEE, p12, 1990.

EJIRI M. **Machine vision technology: past, present and future**. Intelligent Robots and Systems '90. 'Towards a New Frontier of Applications', Proceedings. IROS '90. IEEE International Workshop. Jul 1990

GONZALEZ, Rafael C.; WOODS, Richard E. **Digital Image Processing**, Prentice Hall, 2002.

GONZALEZ, Rafael C.; WOODS, Richard E.; EDDINS, Steven L. **Digital Image Processing Using Matlab**. Prentice Hall, 2004.

HAGENIERS, Omer L. **Advantages of 100% In-Line Inspection In Automotive Body Assembly**,

Acessado via internet em março de 2007 através do endereço:

<http://www.inf.ufsc.br/~visao/2000/Hough/index.html>

HARMS, Toni M. **Machine Vision: What can it do for you**. Electrical Engineering Problems in the Rubber and Plastics Industries, 1992., IEEE Conference Record of 1992 Forty-Fourth Annual Conference of 13-14 April 1992 Page(s):30 – 34

HAYKIN, Simon. **Neural Networks: A comprehensive Foundation**. Prentice Hall. Singapore, 1999.

HONGLU, Yu; MACGREGOR, John F.; HAARSMA, Gabe; BOURG Wilfred. **Digital imaging for on-line monitoring and control of industrial snack food processes**. Industrial Engineering and Chemistry Research. 2003

HONGLU, Yu; MACGREGOR, John F. **Monitoring flames in an industrial boiler using multivariate image analysis**, AIChE Journal, 2004.

JAIN, Anil K. **Fundamentals of Digital image Processing**. Prentice Hall. New Jersey,. 1989

JAMUNDÁ, Teobaldo. **Reconhecimento de Formas: A Transformada de Hough**, Seminário Visão Computacional . CPGCC/UFSC – 2000.

Acessado via internet em março de 2007 através do endereço:

<http://www.inf.ufsc.br/~visao/2000/Hough/index.html>

LIMA, Jorge; THOMÉ, Antonio Carlos. **Processamento de Imagens Aplicado á monitoração de Processos**. Rio de Janeiro 2004. Dissertação de Mestrado em Informática. Universidade Federal de Rio de Janeiro 2004.

MITISHITA, Edson A.; TREVIZAN, Sérgio J. **Técnicas de Interpolação Altimétrica Baseadas numa Estrutura de Dados Triangular (Triangulação)**. II COLÓQUIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS, 2001, Curitiba. 30 anos da Pós-Graduação em Ciências Geodésicas no Brasil. 2001. v. 1 p. 1-15.

MOUTINHO, Adriano; THOMÉ, Antonio Carlos. **Identificação de Padrões Faciais Usando Redes Neurais Artificiais**. Dissertação de Mestrado em Informática. PPGI – UFRJ. 2005

PENG, Tao, **Detect circles with various radii in grayscale image via Hough Transform**.

Acessado via internet em junho de 2007 através do endereço:

<http://www.mathworks.com/matlabcentral/fileexchange/loadFile.do?objectId=9168&objectType=file>

PISTORI, J.; PISTORI, H.; COSTA, E. R. **Hough-Circles: Um Módulo de Detecção de Circunferências para o ImageJ**. VI Workshop Software Livre 2005 - WSL2005, 2005, Porto Alegre, 2005.

SILVA, Eugênio; THOMÉ, Antonio Carlos G. **Reconhecimento Inteligente de Caracteres Manuscritos**. Dissertação (Mestrado em Sistemas e Computação). IME - Instituto Militar de Engenharia. Rio de Janeiro, 2002.

SONKA, Mylan; HLAVAC, Vaclav; BOYLE, Roger. **Image Processing, Analysis, and Machine Vision, International Student Edition** , 2007, THOMSON , Ontário.

TAMBERLINI, Fernando A.; THOMÉ, Antonio Carlos G. **Estudo de técnicas utilizadas no reconhecimento de identidade por impressões digitais**. Dissertação (Mestrado em Informática). Universidade Federal do Rio de Janeiro. PPGI. Rio de Janeiro, 2007.

ZUECH, Nello. **Understanding and Applying Machine Vision**. Second Edition, Revised and Expanded. Vision Systems International. Yardley, Pennsylvania, 2000. Editora: Marcel Dekker

APÊNDICE I

Gráficos com o detalhamento dos resultados obtidos com cada uma das abordagens. O eixo horizontal representa o número da imagem avaliada. O eixo vertical representa o erro individual obtido nessa imagem.

a) AMOSTRA 1

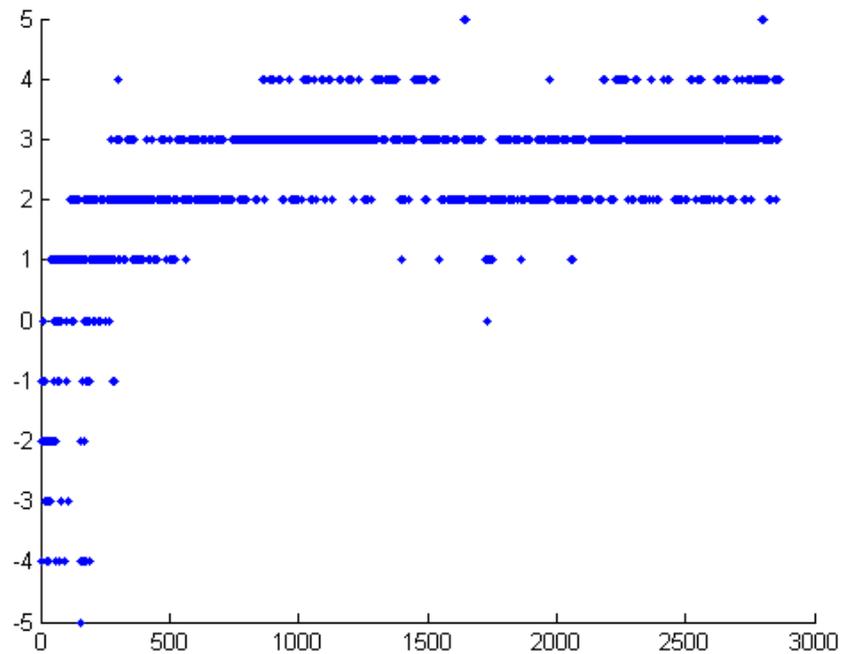


Figura A. 1: Erro da abordagem 1 aplicada na amostra 1

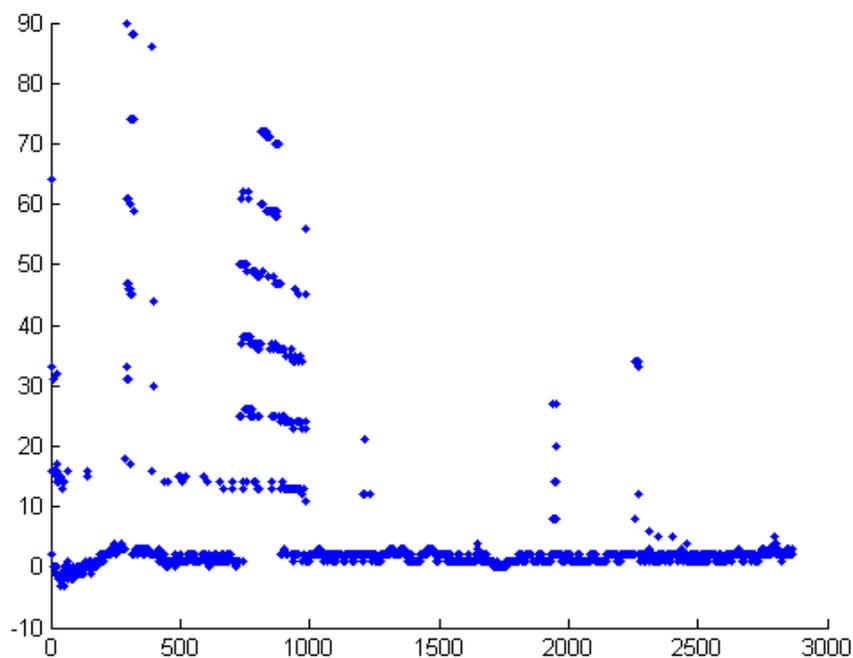


Figura A.2: Erro da abordagem 2 aplicada na amostra 1

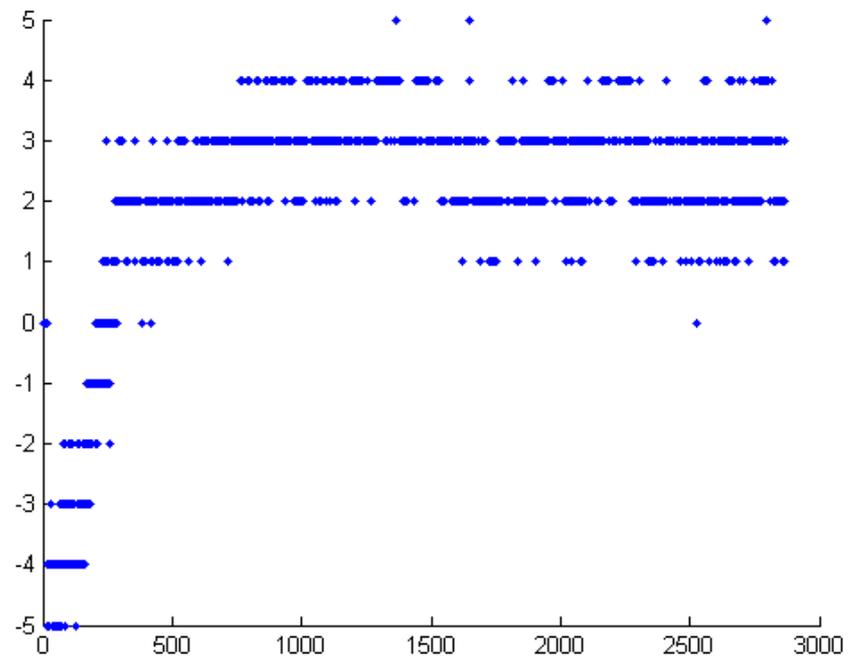


Figura A. 3: Erro da abordagem 3 aplicada na amostra 1

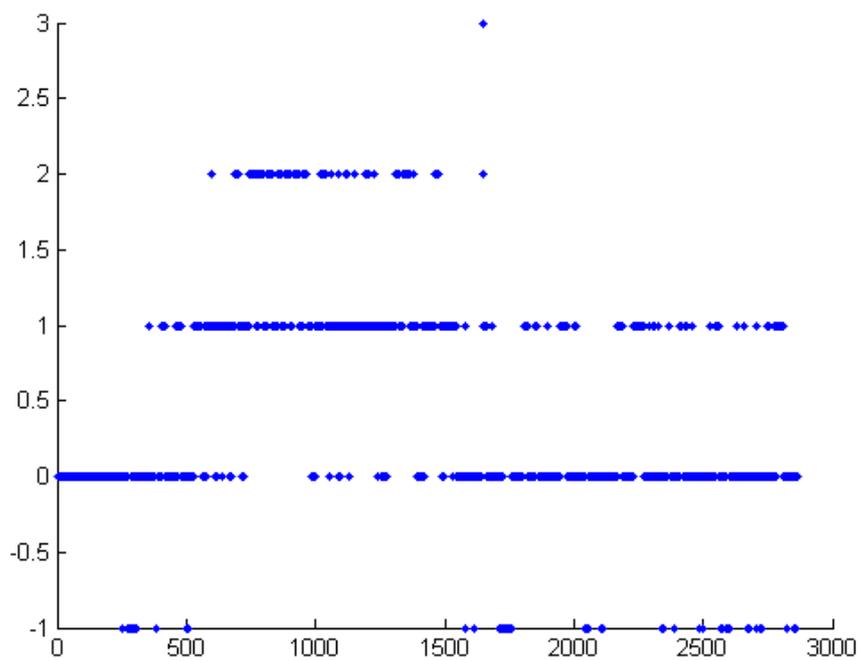


Figura A.4: Erro da abordagem 4 aplicada na amostra 1

b) AMOSTRA 2

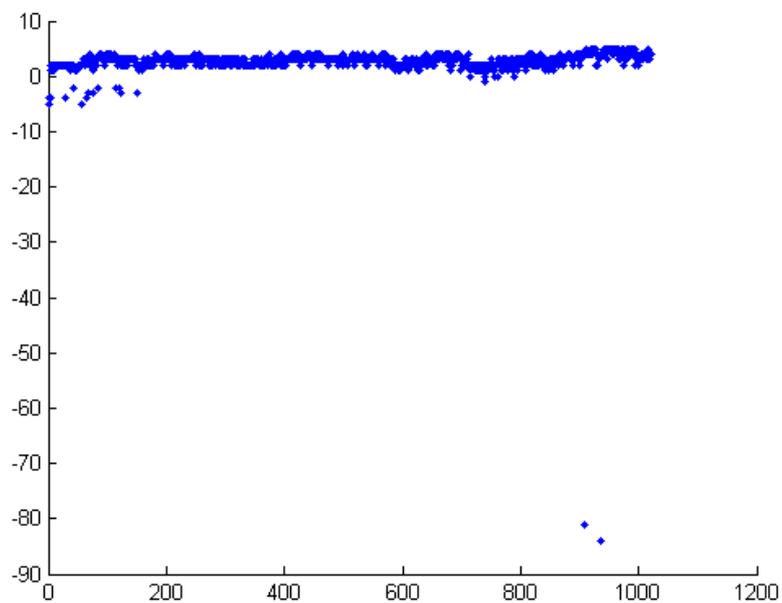


Figura A.5: Erro da abordagem 1 aplicada na amostra 2

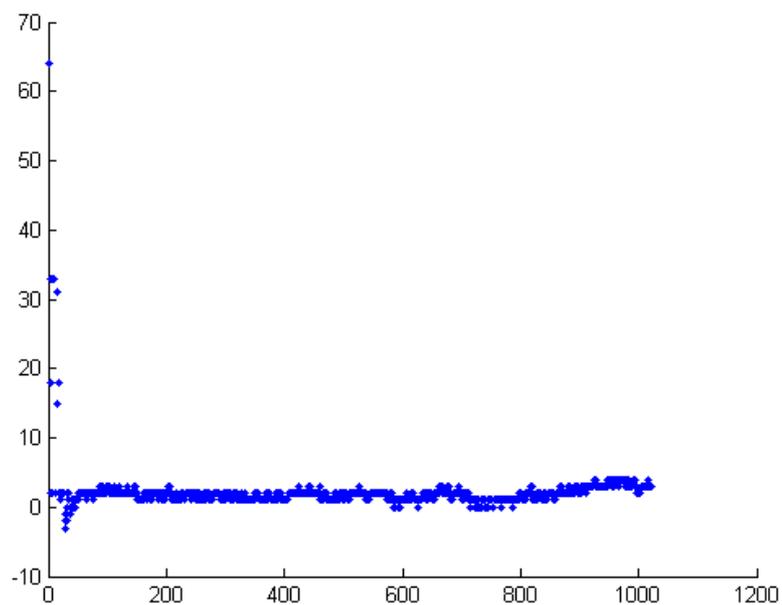


Figura A.6: Erro da abordagem 2 aplicada na amostra 2

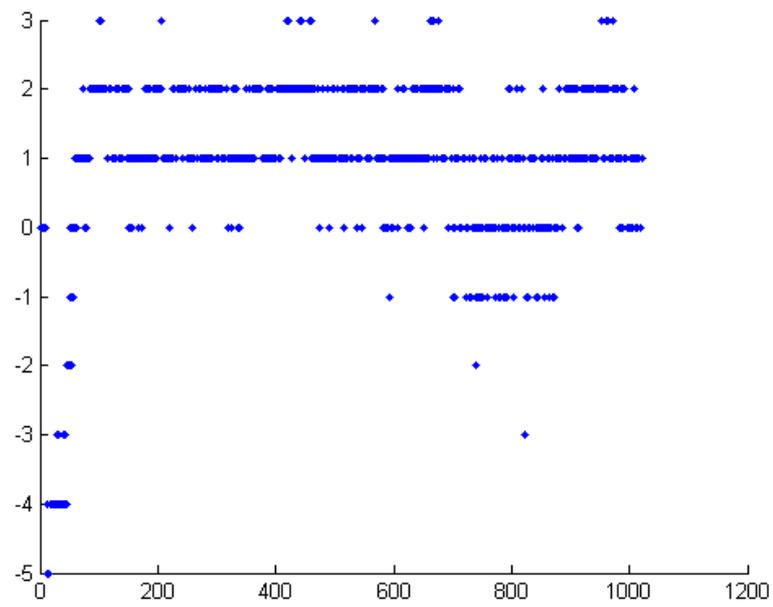


Figura A.7: Erro da abordagem 3 aplicada na amostra 2

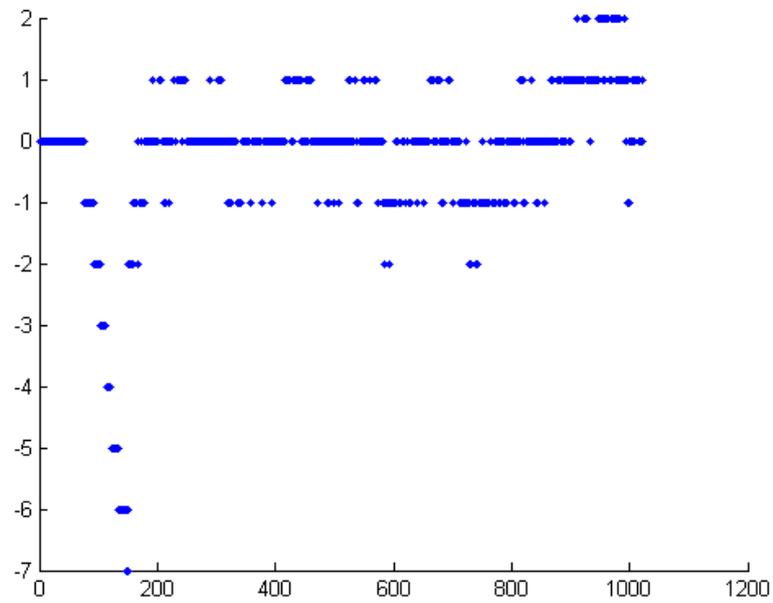


Figura A.8: Erro da abordagem 4 aplicada na amostra 2

c) AMOSTRA 3

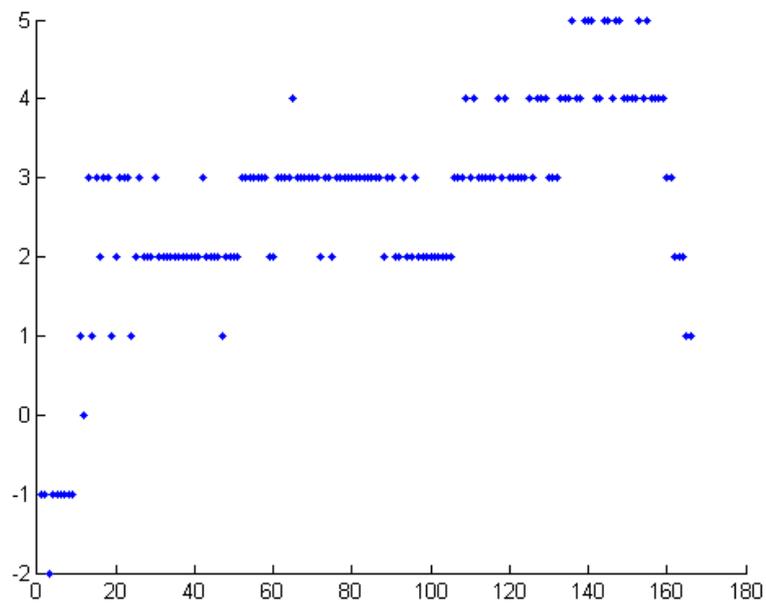


Figura A.9: Erro da abordagem 1 aplicada na amostra 3

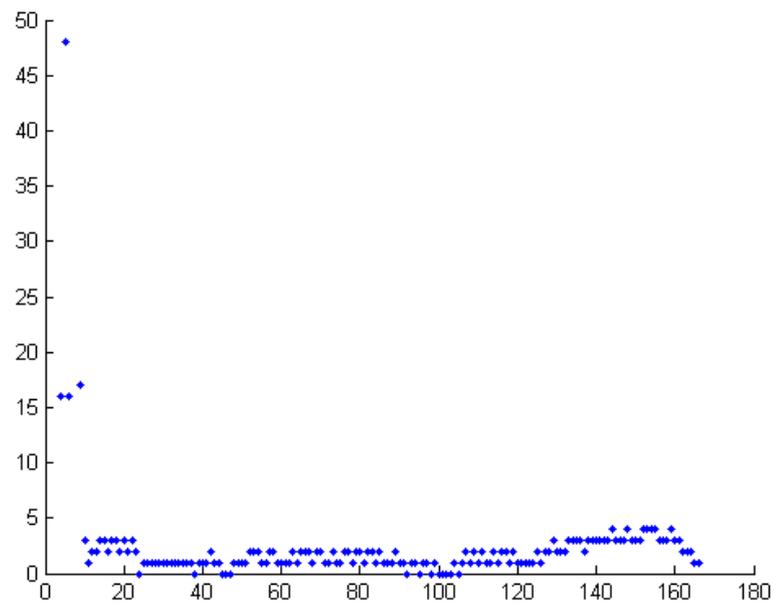


Figura A.10: Erro da abordagem 2 aplicada na amostra 3

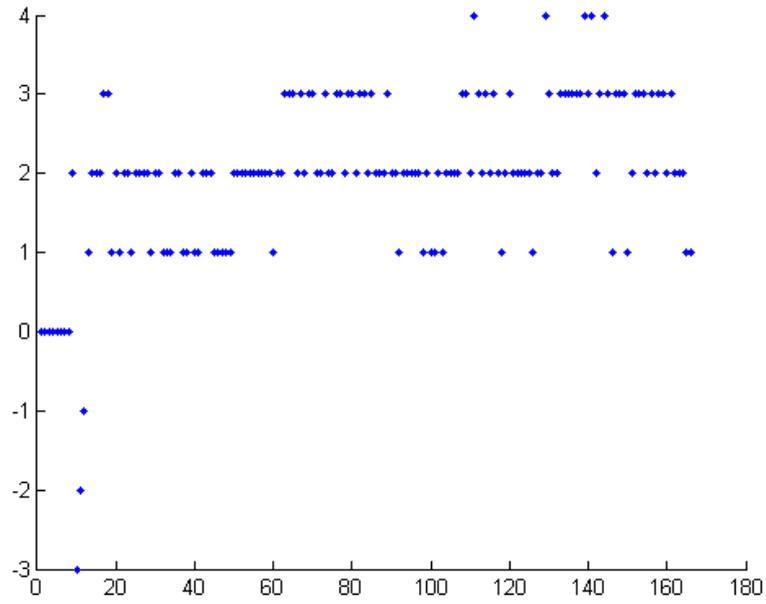


Figura A.11: Erro da abordagem 3 aplicada na amostra 3

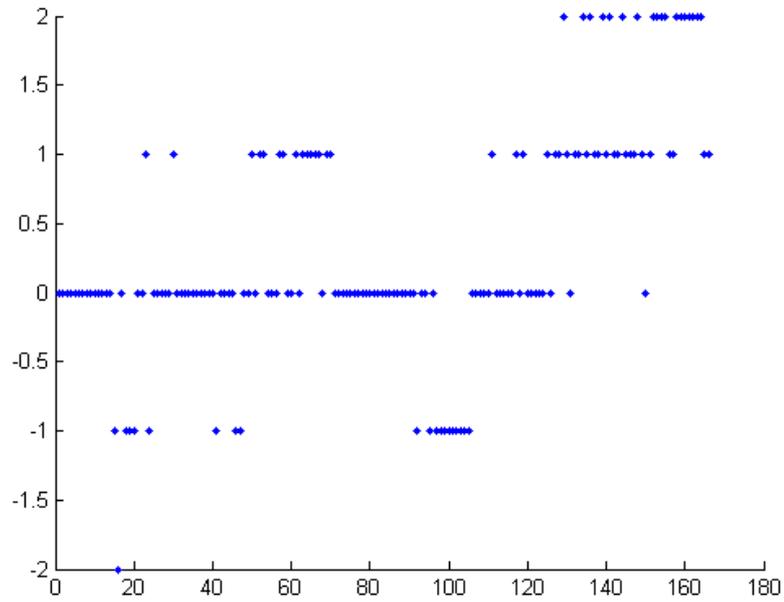


Figura A.12: Erro da abordagem 4 aplicada na amostra 3

APÊNDICE II

O Protótipo

Foi desenvolvido um protótipo para este estudo de caso. A plataforma de desenvolvimento escolhida foi o MATLAB versão 7. Esta ferramenta foi escolhida devido a que possui ampla variedade de algoritmos de processamento de imagens disponíveis. O manual detalhando o funcionamento do protótipo se encontra no DVD que acompanha esta dissertação.

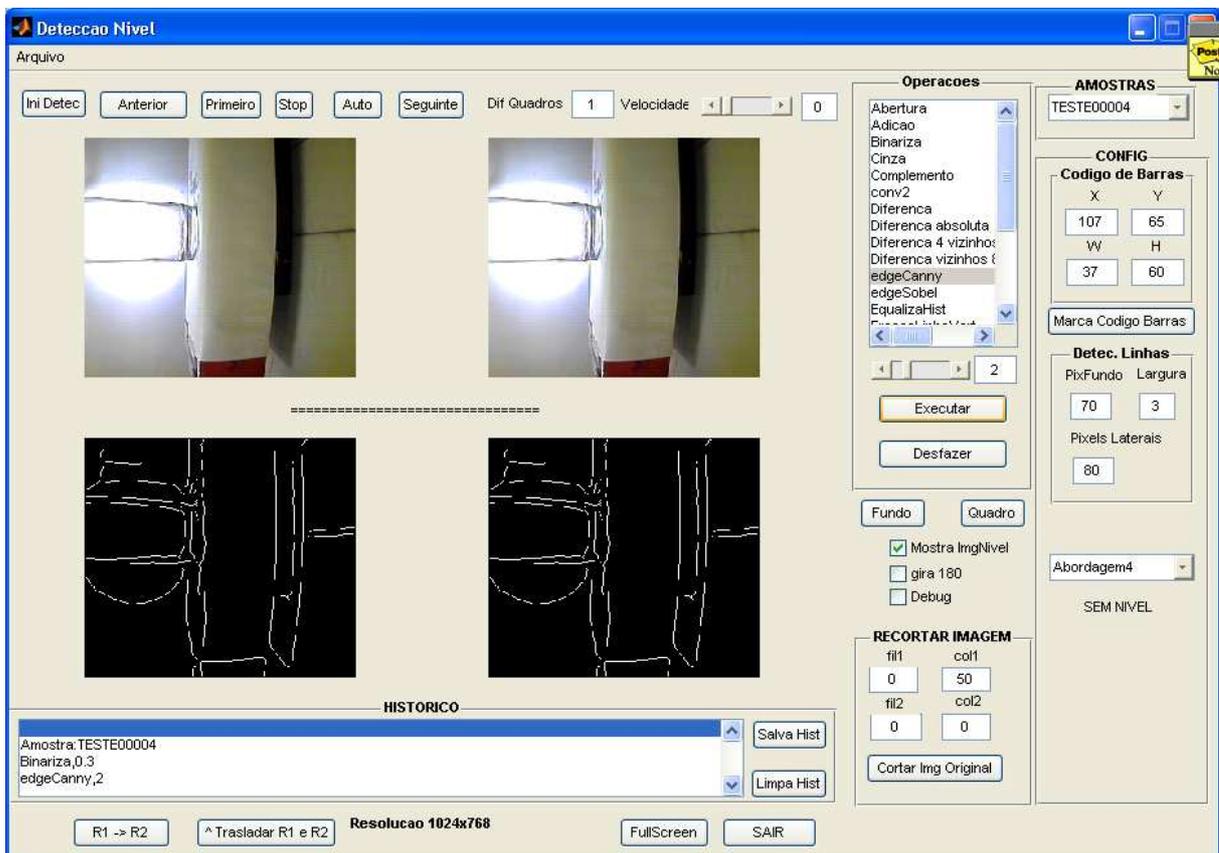


Figura A.13: Protótipo para detecção do nível