

SAULO VARGAS

**DESENVOLVIMENTO DE UM SISTEMA DE INSPEÇÃO AUTOMÁTICA DE TECIDO DE
MALHA**

FLORIANÓPOLIS, 2016

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E
TECNOLOGIA DE SANTA CATARINA
CAMPUS FLORIANÓPOLIS
DEPARTAMENTO ACADÊMICO DE METAL-MECÂNICA
MESTRADO PROFISSIONAL EM MECATRÔNICA**

SAULO VARGAS

**DESENVOLVIMENTO DE UM SISTEMA DE INSPEÇÃO AUTOMÁTICA DE TECIDO DE
MALHA**

**Dissertação submetida ao Instituto
Federal de Educação, Ciência e
Tecnologia de Santa Catarina como parte
dos requisitos de obtenção do título de
Mestre em Mecatrônica.**

**Professor Orientador:
Maurício Edgar Stivanello, Dr. Eng.
Coorientador:
Mário Lucio Rollof, Dr. Eng.**

FLORIANÓPOLIS, 2016

V297d Vargas, Saulo

Desenvolvimento de um sistema de inspeção automática de tecido de malha / Saulo Vargas ; orientador, Maurício Edgar Stivanello ; coorientador, Mário Lucio Rollof. – Florianópolis, 2016.

84 p.

Dissertação (mestrado) – Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina. Programa de Pós-graduação em Mecatrônica.

Inclui referências

1. Fabricação têxtil. 2. Inspeção automatizada. 3. Tecido de malha. 4. Visão computacional. I. Stivanello, Maurício Edgar. II. Rollof, Mário Lucio. III. Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina. Programa de Pós-graduação em Mecatrônica. IV. Título.

CDD 677

Ficha catalográfica elaborada por Cláudia Kautzmann, CRB 14/1214

DESENVOLVIMENTO DE UM SISTEMA DE INSPEÇÃO AUTOMÁTICA DE TECIDO DE MALHA

SAULO VARGAS


Esta dissertação foi julgada adequada para obtenção do Título de Mestre em Mecatrônica e aprovada na sua forma final pela banca examinadora do Programa de Pós-Graduação em Mecatrônica do Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina.

Florianópolis, 18 de março de 2016.


Banca Examinadora:



Prof. Maurício Edgar Stivanello, Dr. Eng. - Orientador



Prof. André Roberto de Sousa, Dr. Eng. - Membro Interno ao Programa



Prof. Marcelo Ricardo Stemmer, Dr. Eng. - Membro Externo a Instituição

À esposa Daiane Formento
Vargas e ao filho Lucas
Formento Vargas, que são
minha fonte de inspiração.

AGRADECIMENTOS

Gostaria de compartilhar os resultados desta dissertação com todos aqueles que contribuíram das mais diferentes formas, para sua realização.

Deixo aqui meus sinceros agradecimentos: a Deus, pela força que me sustenta.

Ao professor, Maurício Edgar Stivanello, de quem foi um privilégio receber orientação, pela confiança e estímulo durante a realização da pesquisa.

À minha esposa Daiane, sempre incentivadora, com quem compartilhei minhas dificuldades e conquistas enquanto realizava o estudo.

Aos meus pais, Nilton Sebastião Vargas (sempre presente) e Salma Maria da Silva Vargas e meus irmãos, Nilton César Vargas e Claudia Maria da Silva Vargas pelos incentivos e carinhos.

A todos os professores e colegas do PPGM que de alguma forma contribuíram para a minha formação.

Enfim, a todos que, de alguma forma, contribuíram para esta construção.

RESUMO

O atual processo de produção do tecido de malha conta com equipamentos de alto nível tecnológico. Porém, em algumas etapas deste processo existem atividades repetitivas que são realizadas por operadores humanos e que podem ser automatizadas, contribuindo assim com o aumento da produtividade e competitividade do negócio. O foco do presente trabalho é a atividade de inspeção do rolo de tecido de malha, que ocorre logo após o processo de tricotagem pelos teares. Como esta atividade ainda é realizada por meio de inspeção visual do operador humano, o mesmo pode cometer erros devido à incapacidade do ser humano de manter a atenção necessária em atividades repetitivas durante longa jornada de trabalho. Dessa forma, neste trabalho é apresentado o desenvolvimento de um sistema para inspeção automática de tecidos de malha crua lisa, através de técnicas de visão computacional. A partir das especificidades do sistema tradicional de inspeção definiu-se como requisitos funcionais que o sistema deva ser capaz de contar, classificar e marcar a posição do defeito, além de calcular a área total defeituosa e classificar o rolo de tecido quanto ao grau de qualidade, seguindo normas da ABNT sobre a inspeção de tecido de malha. Para isso, um estudo de técnicas de visão computacional se fez necessário para prover ao sistema a capacidade de inspecionar os rolos de malha de forma autônoma. Neste contexto, são avaliados e propostos métodos e soluções para problemas como sincronização de imagens, calibração de câmeras e detecção e classificação de diferentes tipos de defeitos encontrados em tecido de malha. O sistema proposto foi avaliado a partir de uma série de testes usando uma base de dados de imagem criada a partir de rolos fornecidos pela indústria e imagens obtidas em tempo real. Os resultados encontrados indicam a possibilidade de desenvolver e empregar um sistema de inspeção automatizada de malha que atenda a maioria dos requisitos existentes, de modo que auxilie o controle de qualidade na indústria têxtil.

Palavras-chave: Fabricação Têxtil. Inspeção Automatizada. Tecido de Malha. Visão Computacional.

ABSTRACT

High technological equipments are currently used in the knitted fabric production process. However, there are activity tasks that still being performed by human operators in some stages of this process and that can be automated, contributing to increased productivity and competitiveness of the business. The focus of this work is the inspection activity of knitted rolls, which occurs immediately after the process of knitting by looms. As this activity is still performed by visual inspection of the human operator, mistakes can occur due to human inability to maintain necessary attention during long working hours in repetitive activities. In this work, the development of a system that employs computer vision techniques for automated inspection of knitted fabric in raw and flat state is presented. From the specifics of the traditional inspection system, it was defined as the main functional requirements that the system should be able to count, to classify and to mark the position of the defect. Also, it is important for the system the ability to calculate the defective total area and to classify the fabric roll as the degree of quality, following norms of ABNT related to inspection of knitted fabric. For this, a study of computer vision techniques was made necessary to provide the system the capacity to inspect of way autonomous the knitted rolls. In this context, methods and solutions for problems such as synchronization of images, calibration of camera and detection and classification of different types of defects found in knitted fabric were implemented and evaluated. The developed system was evaluated in a series of tests using a image database created from rolls supplied by the industry and images obtained in real time. Final results indicate the possibility of developing and employing a fabric automated inspection system that meets most existing requirements, in order to assist the quality control in the textile industry.

Keywords: Automated Inspection. Computer Vision. Knitted Fabrics. Textile Manufacturing.

LISTA DE FIGURAS

Figura 1: Amostras de defeitos.....	15
Figura 2: Sistema tradicional de inspeção.....	16
Figura 3: Arquitetura sistema de visão.....	21
Figura 4: Transformação entre planos.....	22
Figura 5: (a) imagem representada como matriz de intensidade visual.....	25
Figura 6: Histograma de intensidades.....	26
Figura 7: (a) adjacência-4. (b) adjacência-8.....	27
Figura 8: Posição dos vizinhos de z.....	28
Figura 9: Máscaras 3 x3 para suavização.....	29
Figura 10: (a) Pixels sobre uma máscara 3 x 3. (b) e (c) máscaras de Sobel.....	32
Figura 11: Exemplos de elementos estruturantes.....	33
Figura 12: Ilustração da transformada de Hough.....	34
Figura 13: Obtendo uma matriz de co-ocorrência.....	38
Figura 14: Modelo de neurônio artificial.....	41
Figura 15: Exemplos de função de ativação.....	42
Figura 16: Camadas da RNA.....	42
Figura 17: Ilustração do hiperplano, vetores suporte e margem de separação.....	46
Figura 18: Conjunto de dados não linear.....	49
Figura 19: Ilustração do sistema de inspeção.....	51
Figura 20: Amostras de defeitos classificados conforme NBR 13175.....	54
Figura 21: Protótipo máquina revisadeira.....	55
Figura 22: Sistema de inspeção.....	56
Figura 23: Fluxograma das etapas de processamento.....	58
Figura 24: Gabarito de calibração.....	59
Figura 25: Fronteira ampliada.....	60
Figura 26: Configurações de subjanelas adjacentes com alta variabilidade.....	61
Figura 27: Número de janelas x fronteiras circunscritas.....	64
Figura 28: Gráfico comparativo entre os desvios padrão e o limiar.....	65
Figura 29: Ilustração do método de detecção.....	66
Figura 30: Identificação dos artefatos região contígua e linha.....	68
Figura 31: Intensidades da borda.....	68
Figura 32: Identificação região defeituosa.....	69
Figura 33: Amostras de defeitos do tipo linha horizontal.....	75
Figura 34: Amostra defeito tipo linha vertical.....	76
Figura 35: Defeito região contígua ampliado.....	76
Figura 36: Cálculo do comprimento do defeito.....	77

LISTA DE TABELAS

Tabela 1: Tabela de pontuação por defeito	18
Tabela 2: Funções Kernel.....	50
Tabela 3: Agrupamento dos defeitos.....	53
Tabela 4: Especificação do encoder.....	56
Tabela 5: Especificação da câmara.....	56
Tabela 6: Especificação da lente.....	57
Tabela 7: Especificação do computador.....	57
Tabela 8: Defeitos presentes no banco de imagens.....	63
Tabela 9: Média dos Resultados da detecção.....	66
Tabela 10: Matriz de confusão	70
Tabela 11: Matriz de confusão - Método baseado na forma.....	71
Tabela 12: Matriz de confusão – RNA imagem inteira	71
Tabela 13: Matriz de confusão – RNA região defeituosa	71
Tabela 14: Matriz de confusão – SVM imagem inteira	72
Tabela 15: Matriz de confusão – SVM região defeituosa	72
Tabela 16: Medidas e tempo de execução por método.....	72
Tabela 17: Relatório de inspeção	74
Tabela 18: Defeitos presentes no rolo inspecionado.....	74
Tabela 19: Relatório detecção.....	75
Tabela 20: Matriz de confusão - Método baseado na forma.....	78
Tabela 21: Matriz de confusão - RNA região defeituosa	78
Tabela 22: Precisão global e coeficiente Kappa.....	79

SUMMARY

1	INTRODUCTION	11
1.1	Objectives	12
1.1.1	General objective	12
1.1.2	Specific objective	12
1.2	Justification	12
1.3	Work structure	13
2	FABRIC INSPECTION	14
2.1	Defects found in the production of knitted	14
2.2	Traditional inspection	15
2.3	Automated inspection	18
3	COMPUTER VISION	21
3.1	Image acquisition	21
3.1.1	Camera calibration	22
3.1.2	Homography	23
3.2	Image processing	24
3.2.1	Monochrome digital image	24
3.2.1.1	Intensity histogram	25
3.2.1.2	Extraction of connected components	27
3.2.2	Pre-processing	28
3.2.2.1	Smoothing spatial filters	28
3.2.3	Segmentation	30
3.2.3.1	Thresholding	30
3.2.3.2	Edge detectors	31
3.2.3.3	Morphological operations	33
3.2.3.4	Edge link	34
3.2.4	Description	35
3.2.4.1	Geometric descriptors	35
3.2.4.2	Texture descriptors	37
3.2.5	Interpretation	40
3.2.5.1	Artificial neural networks	41
3.2.5.1.1	Multilayer feedforward neural network	43
3.2.5.2	Support vector machine	45
3.2.5.2.1	SVMs nonlinear	48
3.2.5.2.2	Multiclass classification	50
4	INSPECTION SYSTEM DEVELOPMENT	51
4.1	System description	51
4.2	Defects categorization	53
4.3	Experimental apparatus	54
4.4	Software module	57
4.4.1	Calibration of the acquisition system	59
4.4.2	Defect detection	59

4.4.3	Descriptors calculation	61
4.4.4	Defect classification	62
5	RESULTS.....	63
5.1	Inspection results offline using images of base	63
5.1.1	Results of the detection method.....	63
5.1.2	Results of the classification method.....	67
5.1.3	Evaluation of the computacional cost.....	73
5.2	Inspection results online	73
6	CONCLUSIONS AND FUTURE PROSPECTS.....	80
	BIBLIOGRAPHIC REFERENCES	82

1 INTRODUÇÃO

A indústria têxtil utiliza equipamentos de alto nível tecnológico em toda a sua cadeia produtiva. Da produção do fio, passando pela produção da malha até a confecção do artefato final, são necessárias diferentes etapas de manufatura que combinam esforços de máquinas automatizadas com atividades realizadas por operadores humanos, antes do produto acabado chegar ao consumidor final.

Para o caso específico da produção do tecido de malha, são utilizadas máquinas que possuem um grande número de alimentadores de fios chamadas teares. Apesar de todo o aparato tecnológico embarcado nos teares, estes não estão livres de produzir regiões do tecido com defeitos, devido a problemas eletromecânicos, mecânicos ou de qualidade da matéria prima.

Após a tarefa realizada pelos teares, é necessária uma etapa de inspeção dos rolos de malha produzidos para classificá-los quanto ao grau de qualidade e retroalimentar o processo de produção, evitando que defeitos com origem conhecida continuem ocorrendo. A eficiência na classificação dessa matéria-prima aumenta o rendimento dos processos subsequentes e reduz a geração de resíduos têxteis.

Atualmente, o procedimento de inspeção é realizado visualmente por um operador humano, com o auxílio de uma máquina revisadeira que possui uma luz de fundo (*backlight*) na área de inspeção e um sistema de desbobinamento e bobinamento do tecido. Ocorre que fatores como habilidades individuais do operador humano, ambiente de trabalho, tempo de inspeção, caracterização de defeitos, número de defeitos ocorrendo simultaneamente e experiência do operador podem influenciar na qualidade da atividade de inspeção (PINHEIRO, 2007).

A dificuldade de concentração, por exemplo, causada por motivos intrínsecos ou extrínsecos, pode prejudicar o processo de percepção humana, fazendo com que o operador tenha reduzida a sua capacidade de detectar defeitos. Por outro lado, inspeções repetitivas por um longo período podem tornar o processo de percepção hipnótico, prejudicando a sensibilidade visual do operador humano e fazendo com que deixe de perceber defeitos que ocorrem com menos frequência (PINHEIRO, 2007).

A adoção de novas tecnologias que utilizem sistemas automatizados pode ser uma ótima estratégia para empresas que pretendem minimizar os erros de inspeção decorrentes de falha humana e que precisem aumentar a produtividade e a competitividade do seu negócio para enfrentar o mercado têxtil globalizado. Sistemas que empregam técnicas de análise de imagens estão sendo utilizados em diversas aplicações, abrangendo áreas como

saúde, agrícola, segurança, controle de qualidade em linhas de produção e muitas outras (MARQUES FILHO, VIEIRA NETO, 1999; NEVES, VIEIRA NETO, GONZAGA, 2012).

Várias pesquisas têm sido desenvolvidas no sentido de propor abordagens para a inspeção de tecido baseadas em técnicas de visão computacional (KUMAR, 2008; NGAN, PANG, YUNG, 2011). Apesar dos progressos significativos nos últimos anos, o problema de inspeção de tecido automatizado ainda apresenta desafios e demanda atenção dos pesquisadores em relação a avaliação dos sistemas propostos em cenários de inspeção em tempo real.

Devido à carência de tecnologias presentes na etapa de inspeção de tecidos e dada a relevância regional da indústria têxtil, a elaboração deste trabalho foi direcionada para o desenvolvimento de um sistema de inspeção automática de tecidos de malha. Para isso, foram estudadas, implementadas e avaliadas diversas técnicas de visão computacional para tratar dos diferentes defeitos encontrados na produção do tecido de malha.

1.1 Objetivos

1.1.1 Objetivo geral

O objetivo geral do presente trabalho foi desenvolver um sistema para inspeção automática de tecidos de malha por trama em estado cru e liso, usando técnicas de visão computacional.

1.1.2 Objetivos específicos

- a) Estudar e implementar técnicas de visão computacional que possibilitem a identificação automática de diferentes tipos de defeitos em tecidos de malha;
- b) Desenvolver um software para aquisição, processamento e transmissão de dados;
- c) Integrar o software com um sistema de supervisão e aquisição de dados em uma máquina revisadeira;
- d) Transferir conhecimento acadêmico-científico na área de visão computacional para a indústria têxtil.

1.2 Justificativa

Assim como no resto do país, o setor têxtil e do vestuário local enfrenta uma barreira de competitividade provocada pela abertura internacional de mercado, principalmente pelo

crescimento de produtos asiáticos no mercado mundial (GOMES, MACHADO, ALEGRE, 2014). Mais bem preparados tecnologicamente e mais agressivos mercadologicamente, os competidores internacionais oferecem produtos com preço e qualidade competitivos para o mercado nacional.

Para as empresas desse segmento sobreviverem no mercado mundial competitivo é necessário reduzir aos mais baixos níveis, os custos de produção (COSTA, ROCHA, 2009). Estima-se que o preço do tecido é reduzido em torno de 55% devido à presença de defeitos (SRINIVASAN, 1992; ZHANG, 2011). O cenário mundial exige que se aumente a eficiência, com linhas de produção mais ágeis, redução ao mínimo da criação de refugos e melhor qualidade de formação.

A adoção de novas tecnologias que utilizem sistemas de informação e de automação é uma ótima estratégia para as empresas do setor têxtil e do vestuário manterem os níveis de competitividade de produção, qualidade e preço, frente às ameaças de grandes produtores mundiais como China e Índia.

O desenvolvimento deste trabalho é de grande relevância, dada a importância econômica do setor têxtil e do vestuário para nosso estado. Santa Catarina tem o segundo maior polo têxtil e do vestuário do Brasil, e o Vale do Itajaí é o principal responsável pela posição nacional. Em todo o estado o setor acumula 10.223 indústrias (2013), 174,4 mil trabalhadores (2013), representa 17,8% do Valor da Transformação Industrial de SC (2012) e é responsável por 3% das exportações de SC, US\$ 177 milhões (2013) (FIESC, 2014).

1.3 Estrutura do trabalho

No capítulo 2 são apresentados o cenário de inspeção de tecido tradicional, os defeitos encontrados na produção da malha, bem como as abordagens que estão sendo adotadas em trabalhos correlatos. No capítulo 3 é realizada uma revisão bibliográfica de diversos temas de visão computacional que fundamentam o desenvolvimento deste trabalho. No capítulo 4 são apresentadas as etapas do desenvolvimento do sistema de inspeção como levantamento dos requisitos funcionais e não-funcionais, análise, projeto e implementação do aparato experimental. No capítulo 5 são apresentados e discutidos os resultados alcançados na avaliação do sistema empregando imagens de amostras de tecidos adquiridas junto à indústria e em tempo real a partir de imagens capturadas de uma máquina revisadeira. No capítulo 6, são apresentadas as conclusões e perspectivas para trabalhos futuros.

2 INSPEÇÃO DE TECIDOS

Em função dos defeitos que podem surgir na produção do tecido de malha, é necessária uma inspeção prévia dos rolos produzidos para avaliar a qualidade do tecido produzido em relação a um padrão de qualidade especificado. A eficiência dessa tarefa possibilita maior rendimento das etapas subsequentes da cadeia produtiva têxtil, evitando retrabalho e geração de resíduos têxteis, além de permitir que tendências de defeitos sejam transmitidas à etapa anterior a fim de evitar novas ocorrências.

No presente capítulo são apresentados os defeitos encontrados na produção de malha, uma descrição do método tradicional de inspeção e as abordagens utilizadas para automatizar a tarefa de inspeção de tecido em trabalhos correlatos.

2.1 Defeitos encontrados na produção de malha

“Defeito é uma característica produzida involuntariamente durante o processo de fabricação, originando uma falha que reduz a qualidade desejada” (NBR 13175, 1994, p. 1). O tecido de malha por trama é formado por um conjunto de fios em cursos sucessivos na direção horizontal que se ligam por laçadas ao longo do comprimento do tecido (SISSONS, 2012). As máquinas utilizadas nessa tarefa de tricotagem, teares circulares ou retilíneos, não estão livres de produzir tecidos com regiões defeituosas. Além da qualidade do fio, fatores como quebra de agulhas, irregularidades de ajustagem, desgastes e alimentação incorreta interferem na qualidade do tecido de malha, provocando diferentes tipos de defeitos (ARAÚJO, 1988; SILVA, 1999; SMITH 1986).

A Associação Brasileira de Normas Técnicas - ABNT, através da norma NBR 13175 (1994), define 19 tipos de defeitos observáveis no tecido de malha por trama em estado cru. Defeitos imperceptíveis a olho nu, como irregularidade de gramatura, que afetam a qualidade da malha, podem ser observados somente em laboratório com equipamentos apropriados.

Na Figura 1 são apresentadas algumas amostras de defeitos observáveis com sua respectiva classificação pela NBR 13175.

Os defeitos *a* e *b* são dois tipos de furos que se diferenciam por suas dimensões. Um furo de pequena dimensão é definido como *Buraco* e de maior dimensão como *Rasgo*. Esses defeitos são causados principalmente por rompimento do fio ou por danos na lingueta da agulha ou platina do tear. Os defeitos *c* e *d* se caracterizam por linhas verticais no sentido longitudinal do rolo de tecido. O defeito *Malha corrida* pode ser causado por agulhas

com gancho quebrado e o defeito *Afastamento irregular da coluna* pode estar associado a agulhas e/ou platina tortas ou canaletas sujos ou desgastadas.




Figura 1: Amostras de defeitos

Os defeitos *e* e *f* se caracterizam por linhas horizontais no sentido latitudinal do rolo de tecido. O defeito *Barramento* apresenta a aparência de listras horizontais, definidas por diferenças entre um ou mais cursos, que são causadas por problemas de alimentação como fio estranho, falta de fio, fio com título diferente ou fio sujo. A linha horizontal que formou o defeito *f* é composta por um conjunto de colunas que não se entrelaçaram provenientes de pequenas malhas corridas.

2.2 Inspeção tradicional

A inspeção dos rolos de tecido de malha ocorre logo após o processo de tricotagem. A amostragem dos rolos que serão inspecionados ocorre conforme acordo firmado entre vendedor e comprador. No Brasil, na ausência deste acordo, deve ser observada a norma técnica NBR 5426 (1985).

O procedimento tradicional de inspeção de tecidos é realizado por um inspetor humano, com o auxílio de uma máquina revisadeira, como ilustra Figura 2. Esta máquina possui uma área de inspeção com sistema de iluminação (*backlight*) e sistema de

desbobinamento e bobinamento do tecido que opera com velocidade constante entre 8 e 20 m/s (KUMAR, 2008). Estima-se que a precisão da inspeção manual fique em torno de 70%, sendo altamente influenciada pela fadiga do operador humano (NGAN, PANG, YUNG, 2011; ISLAM, AKHTER, MURSALIN, 2008).




Figura 2: Sistema tradicional de inspeção (GÜVEN ÇELIK MAKINA, 2015)

Segundo a NBR 13461 (1995) o inspetor humano deve proceder a inspeção da seguinte forma:

1. Determinar a largura mínima (L) do rolo de tecido com a trena, em metros e com duas casas decimais.
2. Na ocorrência de defeito, o inspetor deve:
 - a. Marcar o início e término do defeito, no sentido do comprimento do rolo.
 - b. Determinar o comprimento defeituoso individual, em metros, medindo a distância entre as marcas de início e término. O comprimento defeituoso individual mínimo é arbitrado em 0,40 m. Para comprimentos que excederem 0,40 m, o comprimento defeituoso individual é o próprio comprimento medido.
 - c. Registra o valor do comprimento defeituoso individual (CDI).
3. Determinar o comprimento (C) do rolo tecido em metros e com duas casas decimais.
4. Classificar os defeitos observáveis de acordo com as especificações da NBR 13175.

Para cada rolo inspecionado são geradas estatísticas, a partir das seguintes fórmulas (NBR 13461, 1995):

$$AT = L \cdot C \quad (1)$$

$$ADT = L \cdot \sum CDI \quad (2)$$

$$D = \frac{ADT \cdot 100}{AT} \quad (3)$$

Onde:

AT: área total, em m²

L: largura do rolo de tecido, em m

C: comprimento do rolo de tecido, em m

ADT: área defeituosa total

CDI: comprimento defeituoso individual, em m

D: percentual da área defeituosa

Ao final da inspeção é gerado um relatório, onde constam as seguintes informações (NBR 13461, 1995):

1. Declaração de que o ensaio foi conduzido de acordo com a norma NBR 13461.
2. Número de rolos inspecionados e plano de amostragem.
3. Para cada rolo inspecionado deve conter:
 - a. Identificação do rolo de tecido.
 - b. Comprimento, em metros e com duas casas decimais.
 - c. Largura, em metros e com duas casas decimais.
 - d. Área total, em metros quadrados e com duas casas decimais.
 - e. Área total defeituosa, em metros quadrados e com duas casas decimais.
 - f. Percentual de área defeituosa, com duas casas decimais.
4. Qualquer desvio da norma NBR 13461.

Como não há uma norma técnica para classificação final do rolo de tecido de malha quanto ao seu nível de qualidade, algumas malharias definem com seus clientes métodos próprios de classificação. Entre os métodos encontrados em pesquisas de campo, há o método baseado na quantidade e tipo de defeito por rolo e o método baseado na inspeção por pontuação de defeitos.

No primeiro método, o rolo é classificado como de primeira ou segunda qualidade, de acordo com a quantidade de defeitos e a gravidade dos defeitos presentes no rolo de tecido

inspecionado. A quantidade e a gravidade dos rolos são fatores acordados entre vendedor e comprador.

O método baseado na inspeção por pontuação de defeito é uma adaptação da norma técnica NBR 13484 (2004) que apresenta método de inspeção por pontuação de defeito exclusivamente para tecido plano. Neste método, cada defeito recebe uma pontuação conforme o valor do comprimento defeituoso. A Tabela 1 apresenta um método de pontuação utilizado por uma determinada empresa.

Tabela 1: Tabela de pontuação por defeito

Comprimento defeituoso	Pontuação
0 a 15 cm	2
15,1 a 23 cm	3
23,1 cm ou mais	4

A pontuação total atribuída por rolo de tecido é dada em função da soma dos pontos, comprimento e da largura do rolo de tecido, segundo a fórmula:

$$Pontos/100m^2 = \frac{Soma\ dos\ pontos \cdot 100}{L \cdot C} \quad (4)$$

A pontuação máxima admissível por rolo inspecionado para ser classificado como de primeira qualidade depende do acordo entre comprador e vendedor.

2.3 Inspeção automatizada

Para o caso de inspeção automática de tecidos, várias pesquisas têm sido desenvolvidas no sentido de propor sistemas baseados em visão computacional. As abordagens para inspeção de tecidos utilizadas em sistemas comerciais não são relatadas na literatura, devido às restrições de propriedade intelectual. Atualmente estão disponíveis no mercado alguns sistemas automáticos de inspeção de tecido, porém com um custo elevado. Não há registro de utilização por empresas brasileiras e alguns desses sistemas estão resumidos em Dockery (2001).

Os sistemas de inspeção de tecido apresentados na literatura estão orientados para a tarefa de detecção e/ou classificação de defeitos de forma automática. A detecção do defeito é uma tarefa importante no processo de produção da malha, pois evita que regiões críticas do tecido sejam enviadas às etapas subsequentes da cadeia produtiva, reduzindo assim a geração de resíduos e aumentando a produtividade. A classificação do defeito

também é uma tarefa essencial neste processo, uma vez que essa informação é útil para realização de diagnósticos de falhas e prevenção das reincidências de defeitos por causas conhecidas.

A arquitetura típica dos sistemas de inspeção propostos na literatura é composta por câmeras em paralelo para cobrir a largura do tecido, sistema de iluminação de fundo (*backlight*) para realçar o defeito e computador para processar os dados de entrada (KUMAR, 2008).

Os métodos de detecção utilizados em sistemas de inspeção automática de tecido descritos na literatura variam de acordo com as características do tecido e são classificados em função da abordagem utilizada para analisar a textura do tecido (NGAN, PANG, YUNG, 2011; KUMAR, 2008; MAHAJAN. KOLHE, PATIL, 2009). As abordagens adotadas são comumente classificadas em três categorias: estatística, espectral e baseada em modelo.

Considerando que as regiões do tecido sem defeito são de alguma forma estacionárias, as abordagens estatísticas detectam como defeitos as regiões com comportamento estatístico diferente. A distribuição espacial dos níveis de intensidade nessa abordagem é definida por representações como matrizes de co-ocorrência, dimensão fractal, correlação cruzada e morfologia matemática.

Imagens de tecidos com textura uniforme, compostas por repetições padronizadas de primitivas de textura, são mais facilmente avaliadas no domínio da frequência. Nessa abordagem espectral, as características primitivas de textura podem ser definidas por Transformadas de Fourier, Filtro de Gabor e Transformada de Wavelet. Alterações espectrais são utilizadas para detectar o defeito na imagem inspecionada.

As abordagens baseadas em modelos são particularmente mais adequadas para imagens de tecido com textura aleatória. Nesse caso, as texturas são modeladas por um processo estocástico como Modelos Autoregressivos e Campos Aleatórios de Markov. Assim, a detecção de defeitos torna-se um problema de testes de hipóteses estatísticas do modelo.

Conforme a taxonomia de métodos de detecção automatizada de tecidos organizada por Ngan, Pang e Yung (2011), as taxas de acerto variam entre 54,13% e 98,30% para os métodos da abordagem estatística, entre 82,86% e 98% para os métodos da abordagem espectral, e de até 100% para os métodos que se enquadram na abordagem baseada em modelos.

Além da detecção, a classificação do defeito quanto a sua natureza ou quanto a categorias de defeitos diferentes da classificação binária (tem ou não defeito) é uma tarefa primordial para o controle de qualidade do tecido. Essa informação, além de ser útil para prevenir reincidências de defeitos por causas conhecidas, pode também ser usada para

classificar o rolo de tecido quanto ao seu grau de qualidade. Para a realização automática dessa tarefa, são empregados métodos de classificação baseados em rede neural (HABIB, 2014), lógica Fuzzy (KUMAR, RAGUPATHY, 2012), máquina de vetor suporte (SVM) (DONGLI, 2013), sendo a maioria baseado em redes neurais, segundo Habib (2014).

A seleção dos descritores que compõem os vetores de características que representam os diferentes tipos ou categorias de defeitos tem grande influência no desempenho do classificador (GONZALEZ, WOODS, 2010). Diferentes descritores têm sido utilizados como entrada para classificadores de defeitos em tecidos. Descritores geométricas como centroide, altura, largura e área da região defeituosa, e descritores de textura baseados em histograma e matriz de co-ocorrência como homogeneidade, entropia e contraste, são exemplos de descritores utilizados como componentes do vetor de características.

São diversos os tipos de defeitos que podem surgir na produção do tecido, porém, os pesquisadores têm trabalho com categorias de defeitos. Entre as categorias de defeitos definidas temos: buraco, mancha de óleo, fio de cor, fio ausente vertical, fio ausente horizontal, outro tipo de defeito, além da categoria sem defeito, nos sistemas que não realizam uma etapa prévia de detecção do defeito e o classificador avalia todas as imagens inspecionadas.

Para avaliar o desempenho dos classificadores o critério comumente empregado entre os pesquisadores é a precisão global de classificação, que corresponde a probabilidade de uma imagem qualquer (ou defeito) ser classificada corretamente entre as categorias de saída. Segundo o estudo comparativo de classificadores baseados em redes neurais, organizado por Habib (2014), as precisões globais desses classificadores variam de 76,5% a 100%. O classificador baseado em lógica fuzzy teve precisão global de 96,55% (KUMAR, RAGUPATHY, 2012) e o classificador baseado em SVM 94% (DONGLI, 2013).

Contudo, é importante observar que os métodos propostos na literatura são muitas vezes avaliados empregando um número reduzido de amostras ou ainda empregando imagens adquiridas em condições de operação muito distantes da encontrada na indústria (HABIB, 2014; NGAN, PANG, YUNG, 2011; KUMAR, 2008; MAHAJAN. KOLHE, PATIL, 2009).

3 VISÃO COMPUTACIONAL

A partir de informações visuais o ser humano pode fazer inferências como reconhecer e localizar pessoas, animais, lugares e objetos, distinguir cores, texturas e formas, utilizando informações obtidas pelos olhos e processadas pelo cérebro. Segundo Vernon (1991), a visão computacional tenta fazer o mesmo, exceto que o meio pelo qual o conhecimento é adquirido é um instrumento computacional em vez de um cérebro humano. Para isso, ela “procura integrar as áreas de processamento de imagens e inteligência artificial, tendo como objetivo a obtenção de algoritmos [sistemas] capazes de interpretar o conteúdo visual de imagens.” (NEVES, VIEIRA NETO, GONZAGA, 2012, p.5).

Um sistema de visão computacional é formado, basicamente, por um módulo de aquisição de imagens e por um módulo de processamento, como ilustrado na Figura 3. O módulo de aquisição de imagens é responsável por fornecer dados sensoriais da cena observada ao módulo de processamento, que por sua vez, processa esses dados e fornece parâmetros necessários ao sistema atuador.

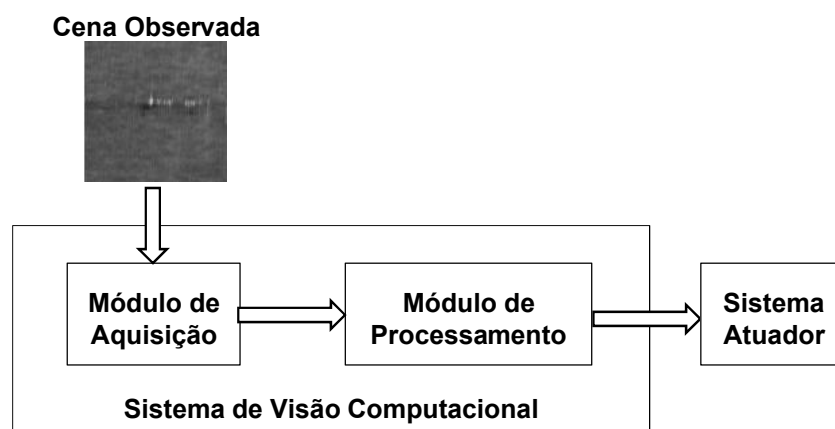


Figura 3: Arquitetura sistema de visão

No presente capítulo é apresentada uma descrição dos módulos relacionados a um sistema de visão computacional.

3.1 Aquisição de imagens

A aquisição de uma imagem é o processo de conversão de uma cena real em uma imagem, na qual é a entrada principal de um sistema de visão computacional (MARQUES FILHO, VIEIRA NETO, 1999). Em um sistema de aquisição de imagens são utilizados equipamentos como câmeras, lentes e fontes de iluminação.

A câmera possui uma matriz de sensores sensíveis a luz onde, para cada elemento da matriz, é armazenada carga elétrica proporcional a intensidade de luz que incide naquele ponto. Circuitos eletrônicos específicos realizam uma varredura e convertem esse sinal elétrico em sinal analógico, que é então digitalizado por outro componente, formando a imagem digital, a qual serve de entrada para o módulo de processamento. Nas câmeras digitais o sinal analógico é digitalizado na eletrônica da própria câmera, o que reduz a suscetibilidade a ruídos e aumenta a resolução da câmera.

A iluminação é um fator importante em um projeto de sistema de aquisição, pois a câmera captura a luz refletida sobre a cena observada. Luz natural, luz fluorescentes, LEDs, emissores infra-vermelhos, luz negra e fibra óptica são alguns exemplos de fontes de iluminação que podem ser empregadas, com diferentes configurações, em sistemas de visão. As configurações de iluminação comumente empregados em sistemas de inspeção visual são: frontal, fundo e estruturada. A iluminação frontal consiste em posicionar a fonte de luz na frente do objeto, de modo que os feixes luminosos sejam refletidos na direção do sensor da câmera. Na iluminação de fundo a fonte luz é posicionada atrás do objeto, emitindo luz na direção da câmera. Na iluminação estruturada a fonte de luz se move sobre a superfície do objeto. A luz de fundo (*backlighting*) elimina sombra e os efeitos de brilho e é muito usada em sistemas de inspeção de tecido (KUMAR, 2008).

3.1.1 Calibração de câmera

Imperfeições no sistema óptico da câmera provocam distorções das características geométricas da imagem capturada. Para recuperar as características geométricas são aplicados métodos de calibração da câmera (ZHANG, 2000; BENVENUTI, 2001; STIVANELLO, 2008; FRANÇA J., STEMMER, FRANÇA M., 2007), na qual se obtém uma matriz de projeção P , que relaciona os pontos de um gabarito no plano do mundo 3-D com seus respectivos pontos no plano da imagem 2-D, como ilustra a Figura 4.




Figura 4: Transformação entre planos

De forma geral, para calibração da câmera são necessárias uma imagem do gabarito e as coordenadas de pontos do gabarito no sistema de coordenadas do mundo. São necessários ao menos 6 pontos para calcular a matriz de projeção (STIVANELLO, 2008). Empregando técnicas para a extração de características da imagem, como vértices e contornos, são identificados os pontos candidatos às projeções de pontos do gabarito. A partir da ordenação dos pontos extraídos, faz-se a relação entre cada ponto 3-D do gabarito com o respectivo ponto 2-D da imagem. Como resultado desta etapa obtém-se n pares formados por pontos do mundo $\{(X_i, Y_i, Z_i) | i = 1, 2, \dots, n\}$ e suas respectivas projeções no plano de imagem $\{(x_i, y_i) | i = 1, 2, \dots, n\}$. Dessa forma, a matriz de projeção P é obtida a partir do sistema:

$$\begin{bmatrix} \lambda x_i \\ \lambda y_i \\ \lambda \end{bmatrix} = \begin{bmatrix} p_{11} & p_{12} & p_{13} & p_{14} \\ p_{21} & p_{22} & p_{23} & p_{24} \\ p_{31} & p_{31} & p_{32} & p_{34} \end{bmatrix} \begin{bmatrix} X_i \\ Y_i \\ Z_i \\ 1 \end{bmatrix} \quad (5)$$

onde λ é um fator de escala da matriz de projeção. É importante lembrar, que P carrega parâmetros intrínsecos da câmera como distância focal, coordenadas do sistema de coordenadas da imagem e tamanho dos pixels, e parâmetros extrínsecos que descrevem a transformação entre o sistema de coordenadas da câmera e o sistema de coordenadas do mundo conhecido, como matriz de rotação e vetor de translação.

Segundo Stivanello (2008), o método descrito acima apresenta o inconveniente de que a informação de calibração somente será válida no entorno da posição dos pontos pertencentes ao gabarito de calibração. Por esta razão, Zhang (2000) propõe um método de calibração onde pontos do gabarito no mundo e de suas correspondentes projeções na imagem são tomados em diferentes orientações. O método consiste nas seguintes etapas:

1. Tomar algumas imagens do gabarito sob diferentes orientações e movendo o gabarito ou a câmera;
2. Detectar os pontos característicos nas imagens;
3. Estimar os parâmetros intrínsecos e extrínsecos;
4. Estimar os coeficientes da distorção radial;
5. Definir todos os parâmetros através da minimização do erro de projeção dos pontos.

3.1.2 Homografia

A fim de obter informações como posição e comprimento real do defeito detectado, é necessário converter as coordenadas em pixels no plano da imagem para coordenadas métricas, segundo um sistema de coordenadas do plano do objeto, ou no caso, do tecido observado. A conversão de coordenadas entre os sistemas envolvidos é realizada através da estimação da transformação projetiva planar, ou homografia, que relaciona os dois planos (TRUCCO, VERRI, 2003).

O método para se obter a matriz de homografia é semelhante ao método de calibração, porém como todos os pontos são coplanares, a coordenada z do mundo real é igual a zero. A partir dessa condição, o sistema (5) pode ser simplificado para:

$$\begin{bmatrix} \lambda x_i \\ \lambda y_i \\ \lambda \end{bmatrix} = \begin{bmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & h_{33} \end{bmatrix} \begin{bmatrix} X_i \\ Y_i \\ 1 \end{bmatrix} \quad (6)$$

Para se obter a matriz de homografia a partir de (6), são necessários no mínimo 4 pontos do sistema de coordenadas do mundo e as respectivas coordenadas de suas projeções no sistema de coordenadas da imagem.

3.2 Processamento de imagens

O processamento de imagens corresponde a uma etapa fundamental de um sistema de inspeção visual automatizado. A partir do emprego de diversas técnicas de processamento de imagens é possível melhorar a qualidade da imagem e extrair características, como forma e textura, necessárias à interpretação dos elementos da imagem.

Nesta seção serão apresentados conceitos e descritas algumas das técnicas utilizadas em sistema de visão computacional.

3.2.1 Imagem digital monocromática

Uma imagem é um função bidimensional $f(x, y)$, em que x e y são coordenadas espaciais, e a amplitude de f em qualquer ponto (x, y) é chamada de intensidade ou nível de cinza da imagem nesse ponto (GONZALES, WOODS, 2010, p. 1). Em imagens digitais, x , y e os valores de intensidade f são quantidades finitas e discretas. A Figura 5 mostra duas formas de representar uma imagem $f(x, y)$.

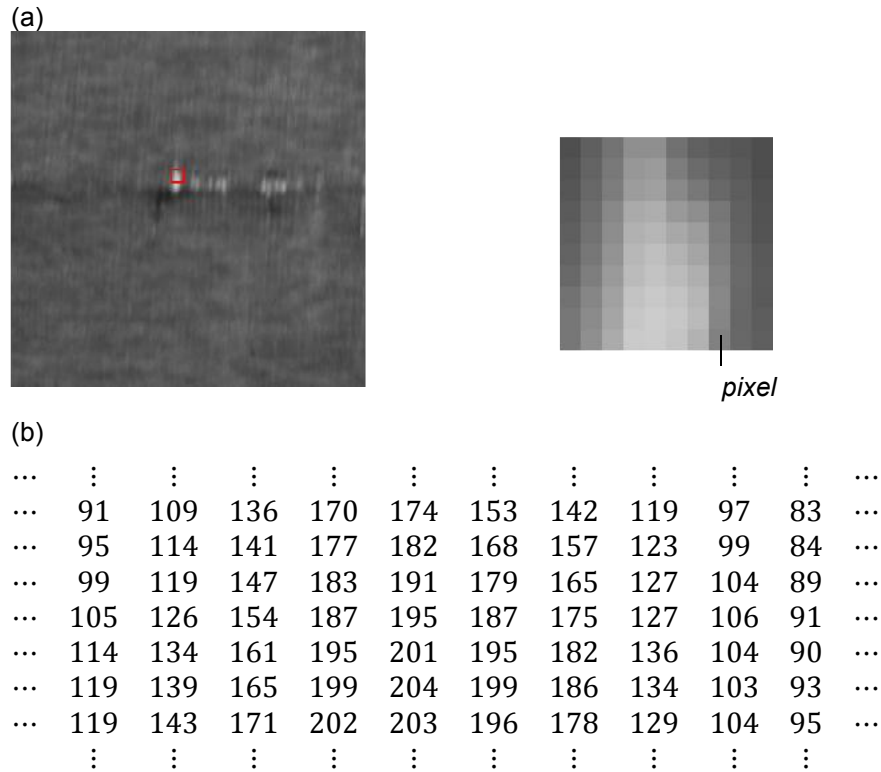


Figura 5: (a) imagem representada como matriz de intensidade visual.
(b) imagem representada como matriz numérica

A Figura 5a mostra $f(x, y)$ como uma matriz de intensidade visual. Nesse caso, cada ponto da imagem, denominado de *pixel*, corresponde a um nível de cinza da imagem. Na Figura 5b $f(x, y)$ é representada por uma matriz numérica, onde cada elemento da matriz, corresponde ao valor do nível de cinza de um pixel.

Apesar da representação por matriz de intensidade visual permitir uma rápida compreensão da cena capturada, é a representação por matriz numérica a utilizada para processamento de imagens. Na forma de equação, a representação de uma matriz numérica $M \times N$ é dada por:

$$f(x, y) = \begin{bmatrix} f(0, 0) & f(0, 1) & \dots & f(0, N - 1) \\ f(1, 0) & f(1, 1) & \dots & f(1, N - 1) \\ \vdots & \vdots & & \vdots \\ f(M - 1, 0) & f(M - 1, 1) & \dots & f(M - 1, N - 1) \end{bmatrix} \quad (7)$$

3.2.1.1 Histograma de intensidades

O histograma de uma imagem digital é uma forma de representar a distribuição dos níveis de cinza de uma imagem. O histograma de uma imagem com L níveis de intensidade é uma função discreta $h(z_i) = n(z_i)$, onde z_i é o valor de intensidade i no intervalo $[0, L -$

1] e $n(z_i)$ é o número de pixels da imagem com intensidade z_i . A Figura 6 ilustra a representação gráfica do histograma da imagem monocromática f com 256 níveis de intensidade.

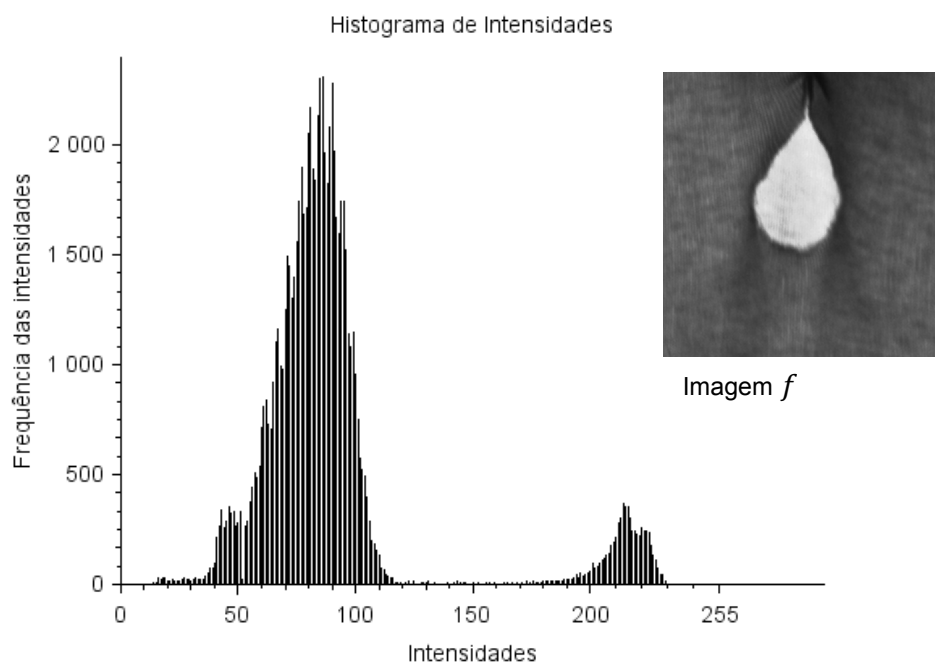


Figura 6: Histograma de intensidades

Em muitos casos é útil normalizar o histograma pelo número total de pixels da imagem. Dessa forma, um histograma normalizado é dado por:

$$p(z_i) = \frac{n(z_i)}{M \cdot N} \quad (8)$$

onde:

$$i = 0, 1, 2, \dots, L - 1$$

z_i : é a intensidade i da imagem

$n(z_i)$: é o número de pixels com intensidade z_i

$M \cdot N$: é o número total de pixels da imagem

$p(z_i)$: é a probabilidade de ocorrência do nível de cinza z_i

$$p(z_i) \geq 0$$

$$\sum_{i=0}^{L-1} p(z_i) = 1$$

Histogramas de intensidades são empregados em várias técnicas de processamento de imagem no domínio espacial (GONZALES, WOODS, 2010). Além de serem úteis em aplicações de segmentação e realce de imagens, são usados para o cálculo de estatísticas sobre a textura da imagem.

3.2.1.2 Rotulação de componentes conexos

Um subconjunto S de pixels que gozam de uma propriedade de intensidade P forma um componente conexo de uma imagem, quando, para todo pixel pertencente a S , existir um caminho para os demais pixels de S (GONZALES, WOODS, 2010). O caminho entre dois pixels é a sequência de pixels que estão conectados por algum tipo de adjacência especificada.

Considerando dois tipos de adjacências, temos:

Adjacência-4. Dois pixels z_i e z_j , com $i \neq j$, que gozam de uma propriedade de intensidade P , são adjacentes-4 se z_i estiver no conjunto de vizinhança z_j , formado pelos vizinhos horizontais e verticais cujas coordenadas são $(x - 1, y)$, $(x, y - 1)$, $(x + 1, y)$ e $(x, y + 1)$.

Adjacência-8. Dois pixels z_i e z_j , com $i \neq j$, que gozam de uma propriedade de intensidade P , são adjacentes-8 se z_i e z_j são adjacentes-4 ou z_i estiver no conjunto de vizinhança z_j , formado pelos vizinhos diagonais cujas coordenadas são $(x - 1, y - 1)$, $(x + 1, y - 1)$, $(x + 1, y + 1)$ e $(x - 1, y + 1)$.

A Figura 7 ilustra os dois tipos de adjacências do parágrafo anterior. Na Figura 7a, qualquer pixel v_i , é adjacente-4 a z , e na Figura 7b, qualquer pixel v_i ou d_i é adjacente-8 a z .




Figura 7: (a) adjacência-4. (b) adjacência-8

Para o caso de uma imagem binária, o procedimento para rotulação de componentes conexos utilizando adjacência-8, é apresentado por Gonzales e Woods (2000) conforme descrito a seguir. Considere que a imagem binária $g(x, y)$ seja percorrida em todas suas posições, a partir da origem $(0, 0)$, da esquerda para direita e de cima para baixo. Definindo z como o valor do pixel em qualquer posição (x, y) , e q , r , s e t como os valores de seus

vizinhos, posicionados como ilustrado na Figura 8, os componentes conexos são rotulados seguindo os passos abaixo.

1. Ler o valor de z ;
2. Se for 0, mova-se para a próxima posição e volte ao passo 1. Se for 1, ler o valor dos vizinhos q, r, s e t ;
3. Se todos os vizinhos forem 0, atribua a z um novo rótulo. Se apenas um dos vizinhos for 1, atribua a z o seu rótulo. Se dois ou mais vizinhos forem 1, atribua um dos rótulos a z e anote as equivalências.
4. Mova-se para a próxima posição e volte ao passo 1.




Figura 8: Posição dos vizinhos de z

Este algoritmo é muito importante em processamento de imagem, pois permite associar agrupamentos de pixels relacionados a objetos presentes na imagem e, desta forma, possibilita extrair informações como quantidade, posição, tamanho, dentre outras informações dos objetos presentes na cena observada.

3.2.2 Pré-processamento

Devido a falhas no sistema de aquisição e transmissão as imagens capturadas podem conter imperfeições que dificultam o processamento subsequente. Dessa forma, é necessário realizar um pré-processamento para melhorar a qualidade da imagem a ser inspecionada.

3.2.2.1 Filtros Espaciais de Suavização

Para remoção de pequenos detalhes e redução de ruídos em imagens digitais é empregada uma técnica de filtragem espacial de suavização (GONZALES, WOODS, 2010). Nessa técnica as operações são realizadas diretamente sobre os valores dos *pixels*.

Dada uma imagem de entrada $f(x, y)$ e um filtro T definido sobre alguma vizinhança centrada em (x, y) , a imagem filtrada $g(x, y)$ é expressa pela função:

$$g(x, y) = T[f(x, y)] \quad (9)$$

T corresponde a uma máscara, com tamanho arbitrário, que percorre todas as posições (x, y) de f para obter cada elemento de g na posição correspondente, a partir de um operador predefinido ϕ . Dada uma máscara de tamanho $m \times m$ e denotando por z_1, z_2, \dots, z_m os valores dos níveis de cinza dos pixels sob a máscara em qualquer posição (x, y) de f , temos que:

$$g(x, y) = \phi(z_1, z_2, \dots, z_m) \quad (10)$$

O operador ϕ define o tipo de filtragem espacial de suavização. Se o operador corresponder a uma soma de produtos, trata-se de um filtro linear de suavização. Caso contrário, trata-se de um filtro de estatística de ordem ou não linear.

Nos filtros lineares deve-se especificar os pesos da máscara $m \times m$ de acordo com o objetivo do filtro. Nesse caso, cada elemento de $g(x, y)$ recebe a média dos pixels de $f(x, y)$ contidos na vizinhança da máscara de filtragem. Denotando por w_1, w_2, \dots, w_m os pesos de uma máscara com tamanho $m \times m$ e por z_1, z_2, \dots, z_m os níveis de cinza dos pixels sob a máscara em qualquer posição (x, y) de f , temos que:

$$g(x, y) = w_1 z_1 + w_2 z_2 + \dots + w_m z_m \quad (11)$$

A Figura 9 mostra dois filtros de suavização com máscaras de tamanho 3×3 . O filtro (a) retorna a média aritmética dos pixels sob a máscara. Neste caso, todos os pesos w_i recebem o mesmo valor $1/9$. O filtro (b) retorna a média ponderada dos pixels sob a máscara. Neste caso, os pesos são diferentes e os pixels correspondentes aos maiores pesos tem maior contribuição no valor da média.

(a)		
$\frac{1}{9} \times$		
1	1	1
1	1	1
1	1	1

(b)		
$\frac{1}{16} \times$		
1	2	1
2	4	2
1	2	1

Figura 9: Máscaras 3 x3 para suavização

Nos filtros de estatística de ordem o operador ϕ se baseia na ordenação dos pixels contidos na vizinhança da máscara. Cada elemento de $g(x, y)$ recebe o valor do pixel de uma posição predefinida. O filtro mais comum desse grupo é o filtro da mediana. Dada uma máscara de tamanho $m \times m$ e denotando por z_1, z_2, \dots, z_m os valores dos níveis de cinza dos pixels sob a máscara em qualquer posição (x, y) de f , temos que:

$$g(x, y) = \text{med}(z_1, z_2, \dots, z_m) \quad (12)$$

A mediana med de um conjunto de valores ordenados é o valor que ocupa a posição central. Os valores abaixo da mediana são menores do que ela e os acima são maiores. Em uma máscara de tamanho 3×3 , por exemplo, a mediana é o quinto maior valor entre os pixels contidos na vizinhança máscara.

3.2.3 Segmentação

A segmentação tem como objetivo separar o objeto de interesse do fundo da imagem observada. A saída da etapa de segmentação é uma imagem binária, em que os pixels do objeto segmentado têm intensidade 1 e do fundo 0. A maioria das técnicas de segmentação baseia-se na descontinuidade ou similaridade dos valores de níveis de cinza (GONZALES, WOODS, 2010). Para detecção de descontinuidades podem ser empregados detectores de bordas como Sobel e Canny. Para a detecção de regiões similares podem ser empregadas técnicas de limiarização.

3.2.3.1 Limiarização

Em imagens onde o objeto de interesse se destaca do fundo devido a diferenças de intensidades, a segmentação pode ser feita por um simples processo de limiarização com limiar global. Dessa forma, dada uma imagem de entrada $f(x, y)$ e um limiar K que separa a fase correspondente ao objeto da fase correspondente ao fundo da imagem, a imagem segmentada $g(x, y)$ é dada por:

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) > K \\ 0 & \text{se } f(x, y) \leq K \end{cases} \quad (13)$$

O valor do limiar K pode ser obtido a partir do histograma de intensidade da imagem. Nos casos onde os objetos de interesse possuem intensidades distantes do resto da

imagem, o histograma corresponderá a dois agrupamentos diferentes de níveis de cinza. Assim, se obtém o limiar selecionando um valor K que separe estes agrupamentos.

Contudo, há a possibilidade de determinar automaticamente o valor do limiar por métodos iterativos. No método de Otsu (OTSU, 1979), inicialmente é feita a normalização do histograma de intensidades como descrito na seção 3.2.1.1. Na sequência, o método separa os níveis de cinza de uma imagem em classes, através de limiares pertencentes a L , de modo a maximizar a variância entre as classes. Para o caso de separar os níveis de cinza em duas classes, o método de Otsu seleciona um limiar k , com $k \in L$ que maximiza a função variância entre classes:

$$\sigma^2(k) = \frac{[\mu(z) \cdot \omega(k) - \mu(k)]^2}{\omega(k)[1 - \omega(k)]} \quad (14)$$

em que:

$$\mu(z) = \sum_{i=0}^{L-1} z_i \cdot p(z_i)$$

$$\omega(k) = \sum_{i=0}^k p(z_i)$$

$$\mu(k) = \sum_{i=0}^k z_i \cdot p(z_i)$$

$\mu(z)$ corresponde à média das intensidades da imagem, $\omega(k)$ corresponde a probabilidade de ocorrer a classe com níveis de cinza menores ou iguais a k , e $\mu(k)$ corresponde à média dos pixels da classe com níveis de cinza menores ou iguais a k .

3.2.3.2 Detectores de bordas

Sobel

No método de Sobel as variações abruptas de intensidades são detectadas pelas derivadas parciais em todos os pontos da imagem $f(x, y)$. Sejam z_1, z_2, \dots, z_9 valores de níveis de cinza, posicionados como ilustrado na Figura 10a, dos pixels sob uma máscara de tamanho 3×3 em qualquer posição (x, y) de f , temos que as derivadas parciais de f nas direções x e y , são dadas por:

$$g_x = \frac{\partial f}{\partial x} = (z_7 + 2z_8 + z_9) - (z_1 + 2z_2 + z_3) \quad (15)$$

$$g_y = \frac{\partial f}{\partial y} = (z_3 + 2z_6 + z_9) - (z_1 + 2z_4 + z_7) \quad (16)$$

(a)		
z ₁	z ₂	z ₃
z ₄	z ₅	z ₆
z ₇	z ₈	z ₉

(b)		
-1	-2	-1
0	0	0
1	2	1
<i>g_y</i>		

(c)		
-1	0	1
-2	0	2
-1	0	1
<i>g_x</i>		

Figura 10: (a) Pixels sobre uma máscara 3 x 3. (b) e (c) máscaras de Sobel.

As Figuras 10b e 10c apresentam as máscaras para implementar o cálculo das derivadas parciais de uma imagem, do mesmo modo como em (11).

Para se obter uma imagem binária ao final desse processo, é necessário empregar uma técnica de limiarização e a partir de um limiar K separar as descontinuidades de intensidade do fundo da imagem, como em (13).

Canny

O detector de bordas Canny visa satisfazer três critérios principais (CANNY, 1986):

1. Baixa taxa de erro. As bordas detectadas devem ser verdadeiras.
2. Boa localização dos pontos de borda. A distância entre os pixels da borda detectada e da borda verdadeira deve ser a menor possível.
3. Resposta mínima. Deve retornar apenas um ponto para cada ponto real da borda.

Para atender esses critérios, a imagem de entrada é suavizada com um filtro Gaussiano. Na sequência, obtém-se o vetor gradiente para cada ponto (x, y) da imagem f . O vetor gradiente é formado pelas derivadas parciais de f , através das fórmulas (15) e (16), e é utilizado para determinar a força e a direção da borda em um ponto (x, y) . A força é determinada pela magnitude $M(x, y)$ do vetor gradiente, fórmula (17), e a direção da borda $\alpha(x, y)$ é perpendicular à direção do vetor gradiente, na qual é calculada pela fórmula (18).

$$M(x, y) = \sqrt{g_x^2 + g_y^2} \quad (17)$$

$$\alpha(x, y) = \operatorname{tg}^{-1}\left(\frac{g_y}{g_x}\right) \quad (18)$$

Para evitar bordas largas em torno de máximos locais, as direções das bordas são discretizadas para 0° , 45° , 90° ou 135° . Por último, é realizada uma operação de limiarização por histerese combinada com uma análise de conectividade para reduzir falsos pontos da borda.

3.2.3.3 Operações morfológicas

Após a aplicação das técnicas de segmentação descritas, podem persistir na imagem de saída pequenos componentes que não correspondem ao objeto de interesse. Esses componentes normalmente estão associados a presença de ruídos na imagem inspecionada. Para eliminá-los, são empregadas sobre a imagem segmentada operações morfológicas de erosão e dilatação.

Os operadores morfológicos utilizam elementos estruturantes para percorrer todas as posições (x, y) de uma imagem f . Esses elementos são pequenas janelas usadas para examinar uma imagem buscando propriedades de interesse (GONZALES, WOODS, 2010), como ilustrado na Figura 11.




Figura 11: Exemplos de elementos estruturantes

Na erosão, o elemento estruturante percorre toda as posições (x, y) da imagem segmentada g e, se o elemento estruturante estiver contido no objeto segmentado, $g(x, y) = 1$, caso contrário $g(x, y) = 0$. Esse procedimento afina ou diminui o tamanho do objeto segmentado.

Na dilatação, o elemento estruturante percorre toda as posições (x, y) da imagem segmentada g e, se pelo menos um elemento do elemento estruturante pertencer ao objeto segmentado, $g(x, y) = 1$, caso contrário $g(x, y) = 0$. Esse procedimento engrossa ou aumenta o tamanho do objeto segmentado.

3.2.3.4 Ligação de bordas

A ligação de bordas é um procedimento adotado para recuperar os pixels de borda, na fronteira do objeto, que não foram detectados por causa de problemas como ruídos e quebras de bordas por problemas de iluminação não uniforme (GONZALES, WOODS, 2010). Uma abordagem para ligação de bordas consiste em determinar as bordas significativas do objeto a partir de propriedades globais do objeto predefinidas, como por exemplo, se ela pertence ou não a uma curva estabelecida.

A transformada de Hough é um método para ligação de bordas que podem ser parametrizadas como retas e círculos. A ideia desse método é aplicar uma transformação que leva todos os pontos de uma curva a um único ponto no espaço de parâmetros da curva procurada (DUDA, HART, 1972).

Para o caso onde o interesse é detectar bordas que tem a forma de uma reta, todos os pontos (x, y) não nulo do plano da imagem (imagem segmentada) são transformados em um curva no espaço de parâmetros, por meio da equação da reta (19), resultando em uma família de curvas senoidais de parâmetros (ρ, θ) , como ilustrado na Figura 12.

$$\rho = x \cos \theta + y \sin \theta \quad (19)$$




Figura 12: Ilustração da transformada de Hough

Cada ponto (x_i, y_i) do plano da imagem corresponde a uma curva no espaço de parâmetros e cada ponto (ρ_i, θ_i) do espaço de parâmetros corresponde a uma reta no plano da imagem. O ponto de intersecção (ρ', θ') no espaço de parâmetros corresponde a reta que passa por um conjunto de pontos de uma borda no plano da imagem.

Para determinar o ponto de intersecção é utilizada uma matriz acumuladora A , onde as linhas correspondem aos valores de θ quantizados no intervalo $0 \leq \theta < \pi$ e as colunas os valores de ρ quantizados no intervalo $(-D \leq \rho \leq D)$, onde D é a medida da diagonal da imagem. Para cada ponto (x_i, y_i) do plano da imagem, θ assume cada valor permitido e o ρ correspondente é calculado por (19), e cada célula $a_{\theta\rho}$ da matriz acumuladora é então incrementada. No final desse processo, a matriz acumuladora é inspecionada para encontrar as células com contagem elevadas. E se a contagem de uma célula $a_{\omega\tau}$ é k , significa que os k pontos de uma borda no plano da imagem pertencem a reta $\tau = x \cos \omega + y \sin \omega$.

3.2.4 Descrição

Como resultado da etapa de segmentação tem-se uma imagem binária, na qual o objeto ou região segmentada corresponde a um agrupamento de pixels a serem analisados. Considerando que uma análise direta sobre esse agrupamento pode ser inapropriada para uma interpretação correta da cena observada, é comum utilizar esquemas de representação dos objetos segmentados que facilitem o cálculo de descritores desses objetos.

A representação pode ser feita basicamente por características internas ou externas do objeto segmentado (GONZALES, WOODS, 2010). As características internas compreendem os pixels que constituem a superfície do objeto. As externas correspondem aos pixels que constituem a fronteira do objeto. A partir dessas representações podem ser calculados diferentes descritores para posterior interpretação dos objetos segmentados.

Nessa seção serão apresentados dois tipos de descritores: geométricos e de textura.

3.2.4.1 Descritores geométricos

Os descritores geométricos são medidas que estão associados tanto a características internas como externas do objeto segmentado.

a. Área

Refere-se ao tamanho da superfície do objeto na imagem. Essa medida é calculada como o número total de pixels do objeto, incluindo os pixels da fronteira.

b. Perímetro

É o comprimento da fronteira do objeto. O número de pixels ao longo da fronteira expressa essa medida.

c. Eixo maior e Eixo menor

O eixo maior é o maior segmento de reta que liga dois pontos da fronteira e o eixo menor é o maior segmento de reta perpendicular ao eixo maior, cuja intersecção dos pontos extremos desses dois eixos com a fronteira do objeto forma uma caixa delimitadora que a envolve completamente. A medida desses eixos é dada pela distância euclidiana de seus pontos extremos.

d. Número de objetos por imagem

Refere-se a quantidade de objetos segmentados em uma imagem. Esse valor é obtido pelo número de rótulos atribuídos na rotulação de componentes conexos, como descrito na seção 3.2.1.2.

Associados aos 3 primeiros descritores acima, podem ser obtidos descritores invariantes a escala ou rotação como excentricidade e circularidade.

e. Excentricidade

Este descritor busca uma relação entre o eixo menor e o maior do objeto segmentado. O valor desse descritor é dado pela fórmula (20). A excentricidade retornará um valor positivo menor ou igual a 1. Valores próximos a zero indicam que o objeto segmentado é mais alongado.

$$E = \frac{\textit{eixo menor}}{\textit{eixo maior}} \quad (20)$$

f. Circularidade

A circularidade é calculada pela fórmula (21) e indica o quão circular é o objeto segmentado. Seu valor é um número positivo menor ou igual a 1, sendo 1 para um objeto circular.

$$C = \frac{4\pi \cdot \textit{Área}}{(\textit{Perímetro})^2} \quad (21)$$

3.2.4.2 Descritores de textura

Os descritores de textura estão associados as características internas do objeto segmentado na imagem original. A textura da superfície de um objeto está relacionada a propriedades como suavidade, rugosidade e regularidade. Uma das abordagens utilizadas para descrever essas propriedades é a abordagem estatística, que utiliza medidas estatísticas locais sobre os pixels do objeto, ou, em alguns casos, da imagem inteira ou da região no entorno do objeto.

Alguns descritores são baseados em histogramas de intensidades. A partir do histograma normalizado $p(z_i)$, como definido na seção 3.2.1.1, de uma imagem ou de uma região, pode-se obter os descritores de textura abaixo.

a. Variância

É uma medida de contraste de nível de cinza e seu valor é expresso por (22). Quanto menor a variância, mais homogêneas são as intensidades da superfície da imagem ou região, e quanto maior, mais rugosa é a superfície. Por ser mais informativo, já que sua resposta é em nível de cinza, é possível utilizar o desvio padrão das intensidades como um descritor de contraste, no qual tem interpretação semelhante à variância. O desvio padrão é calculado por (23).

$$\sigma^2(z) = \sum_{i=0}^{L-1} (z_i - \mu(z))^2 p(z_i) \quad (22)$$

$$\sigma(z) = \sqrt{\sigma^2(z)} \quad (23)$$

b. Uniformidade

Mede a suavidade das intensidades de uma superfície e é calculada por (24). O intervalo de valores é $[0, 1]$, e é máxima para uma superfície com intensidades iguais.

$$U(z) = \sum_{i=0}^{L-1} (p(z_i)^2) \quad (24)$$

c. Entropia do histograma

Mede a variabilidade das intensidades de uma superfície e seu valor é dado por (25). Uma entropia nula significa que as intensidades da superfície são iguais.

$$e(z) = - \sum_{i=0}^{L-1} p(z_i) \log_2(p(z_i)) \quad (25)$$

Os descritores calculados a partir de histogramas não possuem informação sobre a posição dos pixels em relação a outros (GONZALES, WOODS, 2010). Uma maneira de contornar essa situação é calcular descritores sobre os elementos da matriz de co-ocorrência de uma imagem ou região.

Uma matriz de co-ocorrência M é uma tabulação da quantidade de vezes que arranjos dos L níveis de intensidade, tomados 2 a 2, ocorrem em uma imagem, dada uma propriedade P que estabelece uma distância e uma orientação entre os níveis de intensidade arranjados. M será sempre um matriz quadrada de ordem $L \times L$.

A Figura 13, ilustra uma matriz de co-ocorrência para uma imagem com 4 níveis de cinza, a partir de uma propriedade que estabelece uma distância de 1 pixel e orientação de 45° entre os pixels. Cada célula m_{ij} da matriz de co-ocorrência contém o número de transições do nível de cinza z_i , para z_j na imagem f , considerando uma distância de 1 pixel e orientação de 45° .




Figura 13: Obtendo uma matriz de co-ocorrência

A soma S dos elementos de M corresponde ao número de arranjos que satisfazem a propriedade P ($S = 16$ na Figura 13). Então, M pode ser normalizada dividindo cada elemento m_{ij} por S . O valor p_{ij} representa a probabilidade de um arranjo, que satisfaça P , ter as intensidades (z_i, z_j) . Os valores p_{ij} estão no intervalo $[0, 1]$ e sua soma é 1.

$$p_{ij} = \frac{m_{ij}}{S} \quad (26)$$

Definida a matriz de co-ocorrência, vários descritores podem ser calculados para descrever padrões de textura. Haralick (1973) definiu descritores de textura a partir de M normalizada. Abaixo são apresentados alguns desses descritores.

d. Segundo Momento Angular

Mede a uniformidade da textura da superfície e seu cálculo é dado por (27). O intervalo de valores é $[0, 1]$, e é máximo quando as intensidades da imagem são iguais.

$$\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} (p_{ij})^2 \quad (27)$$

e. Contraste

É uma estimativa das variações de intensidades entres pares de pixels da superfície e é calculada por (28). O intervalo de valores é de 0 a $(L - 1)^2$. Valores na diagonal de M representam pouco contraste. A medida que os valores de M se distanciam da diagonal, os pesos $(i - j)^2$ são maiores e ocorre o aumento do contraste.

$$\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} (i - j)^2 p_{ij} \quad (28)$$

f. Entropia

Mede a desordem da textura da superfície e é calculada por (29). Seu valor varia de 0 a $2 \log_2 L$ (quando todos os p_{ij} são iguais). Sendo 0 para superfícies com intensidades iguais.

$$\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p_{ij} \log_2 p_{ij} \quad (29)$$

g. Homogeneidade

Mede a homogeneidade da textura da superfície e é calculado por (30). Seus valores variam de 0 a 1. Sendo máximo quando M é uma matriz diagonal.

$$\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} \frac{p_{ij}}{1 + |i - j|} \quad (30)$$

h. Correlação

Estima o quão um pixel está correlacionado com seu vizinho na superfície inteira. Seu valor é calculado por (31) e varia de -1 a 1.

$$\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} \frac{(i - m_r)(j - m_c)p_{ij}}{\sigma_r \sigma_c} \quad (31)$$

$\sigma_r \neq 0$ e $\sigma_c \neq 0$

em que:

$$m_r = \sum_{i=0}^{L-1} i \sum_{j=0}^{L-1} p_{ij}$$

$$m_c = \sum_{j=0}^{L-1} j \sum_{i=0}^{L-1} p_{ij}$$

e

$$\sigma_r^2 = \sum_{i=0}^{L-1} (i - m_r)^2 \sum_{j=0}^{L-1} p_{ij}$$

$$\sigma_c^2 = \sum_{j=0}^{L-1} (j - m_c)^2 \sum_{i=0}^{L-1} p_{ij}$$

3.2.5 Interpretação

Um sistema de visão computacional deve ser capaz de interpretar vetores de características, formados por descritores como aqueles da seção 3.2.4, de modo a reconhecer classes de padrões que permitam obter informações de alto nível ou atuar sobre os objetos da cena. As técnicas de reconhecimento de classes de padrões podem ser divididas em aprendizagem supervisionada e não supervisionada.

De maneira geral, os algoritmos de reconhecimento recebem vetores de características como entrada e tem como tarefa retornar classes de padrões. Na aprendizagem supervisionada, as classes de padrões são predefinidas e o algoritmo é treinado por um conjunto de pares de treinamento, formado por vetores de características e suas respectivas classes, de forma a retornar saídas corretas para novas entradas não apresentadas previamente.

Na aprendizagem não supervisionada, as classes de padrões não são predefinidas e o algoritmo aprende a encontrá-las a partir de medidas de qualidade. Essa abordagem é utilizada para encontrar padrões ou tendências que auxiliem no entendimento de um conjunto de dados (SOUTO et. al., 2003).

Nesta seção serão apresentadas duas técnicas de reconhecimento de padrões com aprendizagem supervisionadas: Redes Neurais Artificiais (RNA) e Máquina de Vetor Suporte (SVM- Support Vector Machine).

3.2.5.1 Redes neurais artificiais

Segundo Loesch e Sari (1996), RNA são sistemas computacionais que simulam habilidades do sistema nervoso biológico, como extração de informações e reconhecimento de padrões, usando um grande número de neurônios artificiais interconectados. Um neurônio artificial é o elemento básico de uma rede neural e sua função é simular o funcionamento de um neurônio biológico. A Figura 14 mostra o modelo de um neurônio artificial. Os principais elementos de um neurônio artificial são: entradas, pesos, soma ponderada e função de ativação.

A entrada de um neurônio é dada por um vetor $X = [x_0, x_1, \dots, x_n]$, cujos elementos são os estímulos a serem processados pelo neurônio. Cada elemento do vetor de pesos $W = [w_0, w_1, \dots, w_n]$ corresponde ao grau de importância de cada entrada para o neurônio.




Figura 14: Modelo de neurônio artificial

A resposta de um neurônio se baseia na soma ponderada de suas entradas, conforme (32). A função de ativação por limiar $f(s)$ analisa o sinal gerado por $s(X)$ e retorna uma saída para o neurônio.

$$s(X) = \sum_{i=0}^n x_i w_i \quad (32)$$

A função de ativação pode ser definida por diferentes sentenças e depende do modelo de rede utilizado. A Figura 15 ilustra 3 tipos de exemplos de função de ativação.

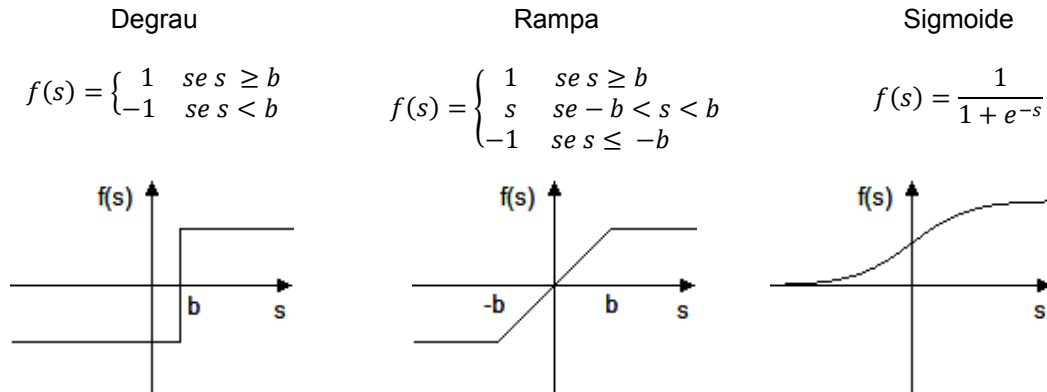


Figura 15: Exemplos de função de ativação

Em uma rede neural artificial os neurônios são organizados em camadas, de modo que a saída de cada neurônio em uma camada alimente a entrada de todos os neurônios da camada seguinte, como ilustrado na Figura 16. O número de neurônios da camada de entrada é dado pela dimensão do vetor de características X , $(n + 1)$, e sua função é armazenar a informação de entrada para repassar aos neurônios da próxima camada. O número de neurônios da camada de saída é igual ao número de classes de padrões M definidas para a rede neural reconhecer.

A propriedade mais importante de uma RNA é a habilidade de aprender a partir de exemplos. O conhecimento adquirido pela rede é armazenado na forma de pesos, que são obtidos na fase de treinamento da rede. Através da variação desses valores a RNA constrói o conhecimento.

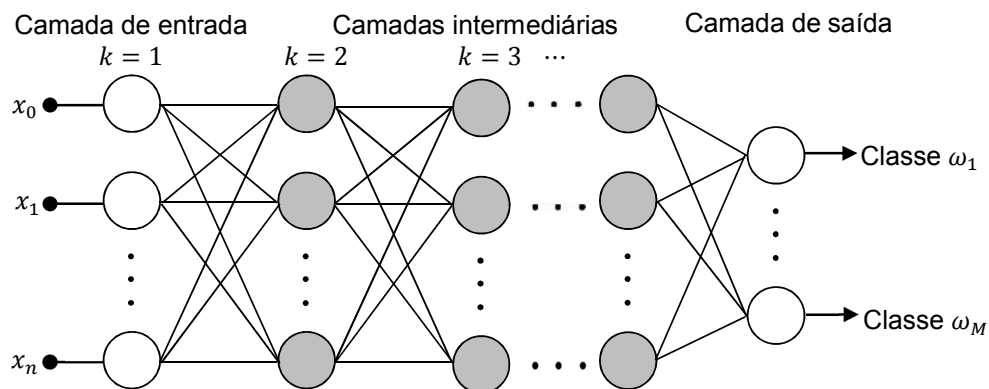


Figura 16: Camadas da RNA

Para uma RNA reconhecer padrões de classes pelo método de aprendizagem supervisionada, é necessário treiná-la a partir de um conjunto de treinamento de pares de vetores de características e classes de padrões, de modo a obter vetores de pesos que minimize o erro entre a saída obtida e a saída desejada.

Para cada vetor de características apresentado a RNA, verifica-se se a classe de padrão obtida corresponde à classe de padrão desejada. Caso sejam iguais, apresenta-se o par seguinte à rede. Caso as classes sejam diferentes, deve ocorrer um ajuste nos pesos dos neurônios. Este procedimento deve-se repetir para todos os pares do conjunto de treinamento, até se obter um erro admissível.

Terminada a fase de treinamento, a RNA está pronta para reconhecer a classe padrão de vetores de características que não foram previamente utilizados.

3.2.5.1.1 Rede neural multicamadas feedforward

Os modelos de RNA se diferenciam por aspectos estruturais como quantidade de camadas, quantidade de neurônios por camadas e tipo de conexão entre as camadas e seus neurônios (LOESCH, SARI, 1996). Segundo esses autores, o modelo de RNA multicamadas *feedforward* é o mais utilizado para reconhecimento de classes de padrões devido a sua capacidade de abstração e de generalização.

A Figura 16 ilustra o tipo de arquitetura de uma RNA multicamadas *feedforward*. Nesse tipo de rede há uma ou mais camadas ocultas e a função de ativação é não linear e diferenciável ao longo de todos os caminhos da RNA para que seja possível desenvolver uma regra de treinamento por retropropagação (GONZALES, WOODS, 2010). A rede reconhece um vetor de características X como pertencente à classe de padrões ω_i , se a i -ésima saída da rede é “alta”, enquanto as outras saídas são “baixas”.

O fluxo de processamento inicia na camada de entrada e vai até a camada de saída. Dessa forma a entrada da função de ativação de cada neurônio j da camada k , $k > 1$, é dada pela soma ponderada (33).

$$s_j^{(k)} = \sum_{i=0}^n x_i^{(k-1)} \cdot w_{ji}^{(k)} \quad (33)$$

onde:

$s_j^{(k)}$: soma ponderada do neurônio j da camada k

$x_i^{(k-1)}$: saída da função de ativação do neurônio i da camada $k - 1$

$w_{ji}^{(k)}$: Peso na entrada do neurônio j , da conexão i , da camada k

Para atender o critério de diferenciabilidade, a função de ativação normalmente empregada nas RNA multicamadas são do tipo sigmoide. A função (34) é um exemplo que atende esse critério.

$$f(s_j^{(k)}) = \frac{1}{1 + e^{(-s_j^{(k)} + b)}} \quad (34)$$

onde $f(s_j^{(k)})$ corresponde a saída da função de ativação do neurônio j da camada k e b é um fator de compensação. A derivada $f'(s_j^{(k)})$ pode ser obtida pela expressão (35).

$$f'(x) = f(x) \cdot (1 - f(x)) \quad (35)$$

O treinamento de uma RNA multicamadas *feedforward* segue o mesmo princípio de treinamento descrito anteriormente. Ao se apresentar um vetor de característica, o fluxo de processamento é alimentado para frente, passando por todas as camadas. A classe de padrão obtida é comparada com a saída desejada, e no caso de o erro ser maior que o admissível, ocorre um ajuste dos pesos proporcional à derivada parcial do erro quadrático total em relação aos pesos. Esse ajuste ocorre da camada de saída para a primeira camada oculta.

Seja o erro quadrático total na última camada da RNA dado por:

$$\varepsilon^2 = \sum_{j=0}^n (\varepsilon_j)^2 \quad (36)$$

onde:

$$\varepsilon_j = d_j - o_j$$

d_j : saída desejada do neurônio j da última camada

o_j : saída obtida no neurônio j da última camada

n : número de neurônios da última camada

Considerando os neurônios j da camada k , e utilizando o método do gradiente descendente, o ajuste dos pesos no instante de iteração t é dado por:

$$W_j^{(k)}(t+1) = W_j^{(k)}(t) - \alpha \nabla_j^{(k)} \varepsilon^2(t) \quad (37)$$

onde:

α : taxa de treinamento, controla a estabilidade da rede

$\nabla_j^{(k)} \varepsilon^2(t)$: gradiente do erro quadrático em relação aos pesos do neurônio j da camada k , na iteração t .

$W_j^{(k)}(t)$: vetor dos pesos do neurônio j , da camada k , na iteração t . ($W_j = w_{j0}, w_{j1}, \dots, w_{jn}$).

$W_j^{(k)}(t + 1)$: vetor dos pesos do neurônio j , da camada k , na iteração $t + 1$.

Para o caso em que função de ativação é do tipo sigmoide, como em (34), o ajuste dos pesos é dado por (38), onde os pesos iniciais são normalmente adotados como números aleatórios próximos a zero.

$$W_j^{(k)}(t + 1) = W_j^{(k)}(t) + \alpha \delta_j^{(k)} X_j^{(k)} \quad (38)$$

onde:

$X_j^{(k)}$: é o vetor de entradas do neurônio j da camada k

Se j for a camada de saída da rede, $\delta_j^{(k)}$ é dado por:

$$\delta_j^{(k)} = (d_j - o_j) f'(s_j^{(k)}) \quad (39)$$

Se j for uma camada intermediária interna e p for a próxima camada à direita com $n + 1$ neurônios, $\delta_j^{(k)}$ é dado por:

$$\delta_j^{(k)} = f'(s_j^{(k)}) \sum_{p=0}^n \delta_p^{(k)} w_{jp}^{(k)} \quad (40)$$

3.2.5.2 Máquina de vetor suporte

SVM é um método de classificação de dados que busca encontrar um hiperplano ótimo como função de decisão a partir de um conjunto de pares treinamento, de modo que a margem de separação dos dados seja máxima (DONGLI et al., 2013). Dessa forma, a

função de decisão pode ser aplicada a um novo conjunto de dados oriundos do mesmo domínio dos dados de treinamento.

A margem de separação λ é dada pela distância entre o hiperplano e os vetores mais próximos, denominados de vetores suporte, como ilustrado na Figura 17. Nessa figura, os vetores suporte estão sobre as linhas pontilhadas e o hiperplano entre elas.




Figura 17: Ilustração do hiperplano, vetores suporte e margem de separação

Dado um conjunto de pares de treinamento linearmente separáveis, formado por n vetores de características X_i e suas respectivas classes de padrões $\omega_i \in \{-1, +1\}$, $i = 1, 2, \dots, n$, a equação expressa por (41) define um hiperplano que separa os dados em duas regiões. O que permite classificar o vetor de características X_i na classe $+1$ se $f(X_i) > 0$ ou -1 se $f(X_i) < 0$.

$$f(X) = W^T X + b = 0 \quad (41)$$

onde:

W : vetor de pesos

b : termo independente

Para encontrar os parâmetros W e b do hiperplano ótimo, com a maior margem de separação, define-se o hiperplano canônico de modo que os vetores mais próximos ao hiperplano $W^T X + b = 0$ satisfaçam (42) (LORENA, CARVALHO, 2007).

$$|W^T X_i + b| = 1 \quad (42)$$

Essa restrição garante que não há nenhum vetor entre $W^T X + b = 0$ e $W^T X + b = \pm 1$ e implica na restrição (43) para todos os pares do conjunto de treinamento.

$$\omega_i(W^T X_i + b) \geq 1 \quad (43)$$

Dados dois vetores suporte X_i e X_j pertencentes a classes diferentes, podemos obter a margem de separação λ pela soma da distância euclidiana de cada vetor ao hiperplano (44).

$$\lambda = \frac{|(W^T X_i + b)|}{\|W\|} + \frac{|(W^T X_j + b)|}{\|W\|} \quad (44)$$

Levando em conta a restrição imposta em (42), temos que a margem de separação λ é dada por:

$$\lambda = \frac{2}{\|W\|} \quad (45)$$

Dessa forma, para obter os parâmetros W e b do hiperplano ótimo que maximiza a margem de separação λ , basta minimizar $\|W\|$, considerando a restrição (43). Que pode ser escrito na forma de um problema de otimização dado por (46).

$$\begin{aligned} & \underset{W, b}{\text{Minimizar}} && \frac{1}{2} \|W\|^2 \\ & \text{Sujeito a} && \omega_i(W^T X_i + b) \geq 1 \\ & && \forall i = 1, 2, \dots, n \end{aligned} \quad (46)$$

Fatores como a presença de ruído ou pontos discrepantes fazem com que os dados de certas aplicações não sejam perfeitamente linearmente separáveis. Para resolver essa situação, acrescenta-se uma variável de folga $\xi > 0$ à restrição (43) para relaxar a restrição do problema de otimização (46). Esse procedimento suaviza as margens do classificador, permitindo que alguns vetores fiquem entre os vetores suporte e a ocorrência de alguns erros de classificação. Dessa forma, o problema de otimização (46) é reescrito como:

$$\begin{aligned}
& \underset{W,b}{\text{Minimizar}} \quad \frac{1}{2} \|W\|^2 + C \sum_{i=1}^n \xi_i \\
& \text{Sujeito a} \quad \omega_i (W^T X_i + b) \geq 1 - \xi_i \\
& \quad \quad \quad \xi_i \geq 0 \\
& \quad \quad \quad \forall i = 1, 2, \dots, n
\end{aligned} \tag{47}$$

O termo $\sum_{i=1}^n \xi_i$ na função objetivo de (47) é uma forma de minimizar os erros marginais e $C > 0$ é um termo de regularização do erro.

Para resolver o problema (47) pode ser introduzida a função Lagrangiana, que engloba as restrições à função objetivo, associadas a parâmetros α denominados de multiplicadores de Lagrange, e tornando suas derivadas parciais nulas (LORENA, CARVALHO, 2007). O resultado da função Lagrangiana é o seguinte problema dual:

$$\begin{aligned}
& \underset{\alpha}{\text{maximizar}} \quad \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j \omega_i \omega_j X_i^T X_j \\
& \text{Sujeito a} \quad 0 \leq \alpha_i \leq C, \quad \forall i = 1, 2, \dots, n \\
& \quad \quad \quad \sum_{i=1}^n \alpha_i \omega_i = 0
\end{aligned} \tag{48}$$

A forma dual possui restrições mais simples e o produto $X_i^T X_j$ será útil para a solução de problemas com dados não linearmente separáveis.

3.2.5.2.1 SVMs não lineares

Inicialmente a SVM foi definida para problemas linearmente separáveis ou que possuíam uma distribuição aproximadamente linear. No entanto há situação em que não é possível separar os dados do conjunto de treinamento por um hiperplano, como ilustra a Figura 18.

Nesses casos, adota-se uma função $\Phi(X)$ para mapear os dados de entrada para um espaço de alta dimensão. Segundo o teorema de Cover, um problema não linear tem maior probabilidade de ser linearmente separável em um espaço de alta dimensão (LORENA, CARVALHO, 2007).




Figura 18: Conjunto de dados não linear

O hiperplano ótimo de decisão, agora é definido como em (49). E para a classificação de um novo vetor de características é necessário mapeá-lo antes para o espaço de alta dimensão através de $\Phi(X)$.

$$f(X) = W^T \Phi(X) + b = 0 \quad (49)$$

A partir da transformação dos dados de treinamento por $\Phi(X)$, a única modificação no problema de otimização (48) é utilizar $\Phi(X_i)$ no lugar de X_i .

$$\underset{\alpha}{\text{maximizar}} \sum_{i=0}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j \omega_i \omega_j \Phi(X_i^T) \Phi(X_j)$$

$$\text{Sujeito a } 0 \leq \alpha_i \leq C, \quad \forall i = 1, 2, \dots, n \quad (49)$$

$$\sum_{i=1}^n \alpha_i \omega_i = 0$$

Como o cálculo de $\Phi(X_i)$ pode ser muito custoso devido à alta dimensão do novo espaço, utiliza-se um função *kernel* para calcular $\Phi(X_i^T) \Phi(X_j)$. Uma função *kernel* recebe dois vetores de características X_i e X_j do conjunto de entrada e calcula o produto $\Phi(X_i^T) \Phi(X_j)$ direto no espaço de alta dimensão. Tem-se então:

$$k(X_i, X_j) = \Phi(X_i^T) \Phi(X_j) \quad (50)$$

A Tabela 2 mostra algumas funções *kernel* (HSU, CHANG, LIN, 2010) que são implementadas no método SVM. A última coluna apresenta os parâmetros que devem ser informados pelo usuário.

Tabela 2: Funções *Kernel*

Tipo de <i>Kernel</i>	Função	Parâmetros
Linear	$k(X_i, X_j) = X_i^T X_j$	-
Polinomial	$k(X_i, X_j) = (\gamma X_i^T X_j + r)^d, \gamma > 0$	γ, r, d
RBF – Radial basis function	$k(X_i, X_j) = e^{-\gamma \ X_i - X_j\ ^2}, \gamma > 0$	γ
Sigmoidal	$k(X_i, X_j) = \tanh(\gamma X_i^T X_j + r)$	γ, r

3.2.5.2.2 Classificação multiclases

Para o caso em que há mais de duas classes de padrões para classificação, pode-se recorrer a decomposição do problema multiclases em subproblemas binários de SVMs.

Dado um conjunto de pares de treinamento, formado por n vetores de características X_i e suas respectivas classes de padrões $\omega_i \in \{\omega_1, \omega_2, \dots, \omega_n\}$, com $i = 1, 2, \dots, n$ e $k > 2$, onde k é o número de classes de padrões, a decomposição em subproblemas binários pode ser feita empregando abordagens como um-contra-um ou um-contra-todos (HSU, LIN, 2002).

Na abordagem um-contra-todos são definidos k classificadores binários com o conjunto de treinamento, onde cada classificador $f_k(X)$ tem a função de classificar uma classe k das demais. Para um novo vetor de característica X_j , a classe à qual X_i pertence é a classe representada pelo classificador k que obteve o maior valor $f_k(X_j)$.

Na abordagem um-contra-um as classes de padrões são comparadas duas a duas, o que leva a um total de $\frac{k(k-1)}{2}$ classificadores binários. Um novo vetor de característica X_j é classificado na classe k na qual teve o maior número de indicações pelos $\frac{k(k-1)}{2}$ classificadores.

4 DESENVOLVIMENTO DO SISTEMA DE INSPEÇÃO

4.1 Descrição do sistema

O presente trabalho foi orientado para o desenvolvimento de um sistema de inspeção automática de rolos de tecido em tempo real. Devido aos diferentes tipos de tecidos e suas texturas, este trabalho limitar-se-á à inspeção de tecidos do tipo malha crua lisa, ou seja, onde o tecido ainda não foi beneficiado e a sua cor é homogênea.

A inspeção do sistema proposto será realizada a partir de imagens da superfície do tecido, adquiridas durante o desbobinamento do rolo de tecido em uma máquina revisadeira. Como a presença dos defeitos a serem identificados provoca alterações visuais na superfície do tecido, a atividade de inspeção será automatizada através do uso de um sistema de inspeção óptico. Para tal, foi construída uma estrutura composta por um sistema de processamento, baseado em técnicas de visão computacional, e de aquisição, conforme ilustrado na Figura 19.




Figura 19: Ilustração do sistema de inspeção

Com objetivo de compreender o domínio do problema de inspeção de tecido de malha, foram visitadas indústrias do segmento de malharia de Blumenau e de Jaraguá do Sul e realizadas entrevistas com especialistas da área têxtil *in loco*. Com base nessas entrevistas e em pesquisas bibliográficas em normas técnicas (NBR 5426, 1985, NBR 13461, 1995, NBR 13175, 1994, NBR 13484, 2004) e referências (SILVA, 1999, SMITH, 1986 e ARAÚJO, 1988) que tratam do controle de qualidade do tecido de malha, foram elaborados os requisitos funcionais e não funcionais para o sistema de inspeção proposto.

Requisitos funcionais

1. O sistema deve ser capaz de detectar e classificar os defeitos presentes em rolos de tecido de malha de acordo com grupos de defeitos previamente definidos.
2. O sistema deve destacar a região defeituosa com algum tipo de marcação.
3. O sistema deve calcular a quantidade de defeitos.
4. O sistema deve calcular a área total inspecionada, a área defeituosa total e o percentual de área defeituosa conforme NBR 13461 (1995).
5. O sistema deve emitir um relatório com os dados obtidos na inspeção, bem como a classificação do rolo de tecido quanto a sua qualidade.

Os requisitos 1, 2, 3 e 5 descritos acima fazem parte da tarefa básica de inspeção realizada pelo operador humano. O operador detecta e classifica os defeitos com base em um histórico de defeitos conhecidos. Essa informação é útil para retroalimentar o processo de produção da malha e evitar reincidências de defeitos. O operador destaca o defeito no rolo a partir de uma marcação com uma caneta especial para que no processo subsequente a região defeituosa seja eliminada ou tratada. Um relatório final com a quantidade e os tipos de defeitos é utilizado para classificar o rolo de tecido quanto à sua qualidade.

O requisito 4 atualmente não é atendido pelos sistemas de inspeção tradicionais, pois o cálculo de área é de difícil realização pelo operador humano devido à falta de instrumentos adequados para realizar medições com a máquina em operação. Com a inclusão dessa funcionalidade, além de atender a NBR 13461 (1995), essa informação será útil para definir parâmetros mais criteriosos de classificação do rolo de tecido.

Requisitos não funcionais

1. O sistema deve possuir interface simples.
2. O sistema deve empregar tecnologias multiplataforma.
3. Utilizar ferramentas ou componentes livres.
4. O sistema deve permitir customizações.

O requisito de interface simples foi levantado para facilitar a interação dos usuários que trabalharão direto com o sistema na inspeção dos rolos de tecido. O segundo requisito visa atender empresas com diferentes sistemas operacionais, ampliando o alcance do sistema de inspeção. O requisito 3 visa reduzir o custo do sistema com a utilização de componentes e ferramentas livres. Como não existe uma norma para orientar a classificação dos rolos de tecido de malha, o requisito 4 possibilita a empresa customizar

os critérios de classificação dos rolos de tecido conforme padrão acordado com seus clientes.

4.2 Categorização dos defeitos

A classificação automática dos defeitos visíveis não é uma tarefa simples, pois alguns grupos de defeitos produzem artefatos semelhantes em imagens de tecido de regiões defeituosas. Este fato, somado à ausência de uma categorização de defeitos em tecido de malha na literatura que considere as características topológicas do defeito, levou à criação de uma proposta própria de categorização, validada junto a profissionais da indústria têxtil.

Na Figura 20 são apresentadas amostras de defeitos com sua respectiva classificação conforme NBR 13175 (1994). Nas amostras *a* e *b* é possível observar que os defeitos provocam na imagem uma região circular que denominamos de região contígua. Os defeitos presentes nas amostras *c* e *d* se caracterizam por linhas no sentido vertical e as amostras *e* e *f* por linhas no sentido horizontal. As amostras *g* e *h* se diferenciam das outras por conterem mais de um tipo de defeito na mesma imagem inspecionada.

Devido à similaridade dos artefatos gerados por certos grupos de defeitos observáveis, em imagens de regiões defeituosas, foram criadas quatro categorias para agrupá-los de acordo com o tipo de artefato. Na Tabela 3 são apresentadas as quatro categorias de defeitos, bem como os tipos de defeitos definidos pela norma técnica NBR 13175 (1994) agrupados por categoria. A última coluna dessa tabela traz uma descrição do artefato gerado por categoria.

Tabela 3: Agrupamento dos defeitos

CATEGORIA	DEFEITOS AGRUPADOS	ARTEFATO GERADO
Defeito Região Contígua	Buraco, Rasgo, Pé de Galinha, Bucha, Mancha de óleo, Tecido sujo, Fibras Estranhas	Região contígua
Defeito Linha Horizontal	Barramento, Malha corrida, Mancha de Óleo, Fio Irregular, Fio Duplo, Falta de Fio, Fio Estranho, Fio Puxado, Alimentação Negativa, Título Diferente, Fio Sujo, Fibras Estranhas	Linha no sentido da largura do tecido
Defeito Linha Vertical	Malha corrida, Óleo, Vincos, Afastamento Irregular da Coluna, Fibras Estranhas	Linha no sentido do comprimento do tecido
Defeito Misto	-	Dois ou mais artefatos dos três supracitados

Essas categorias são utilizadas pelo método de classificação de defeitos do sistema de inspeção proposto.

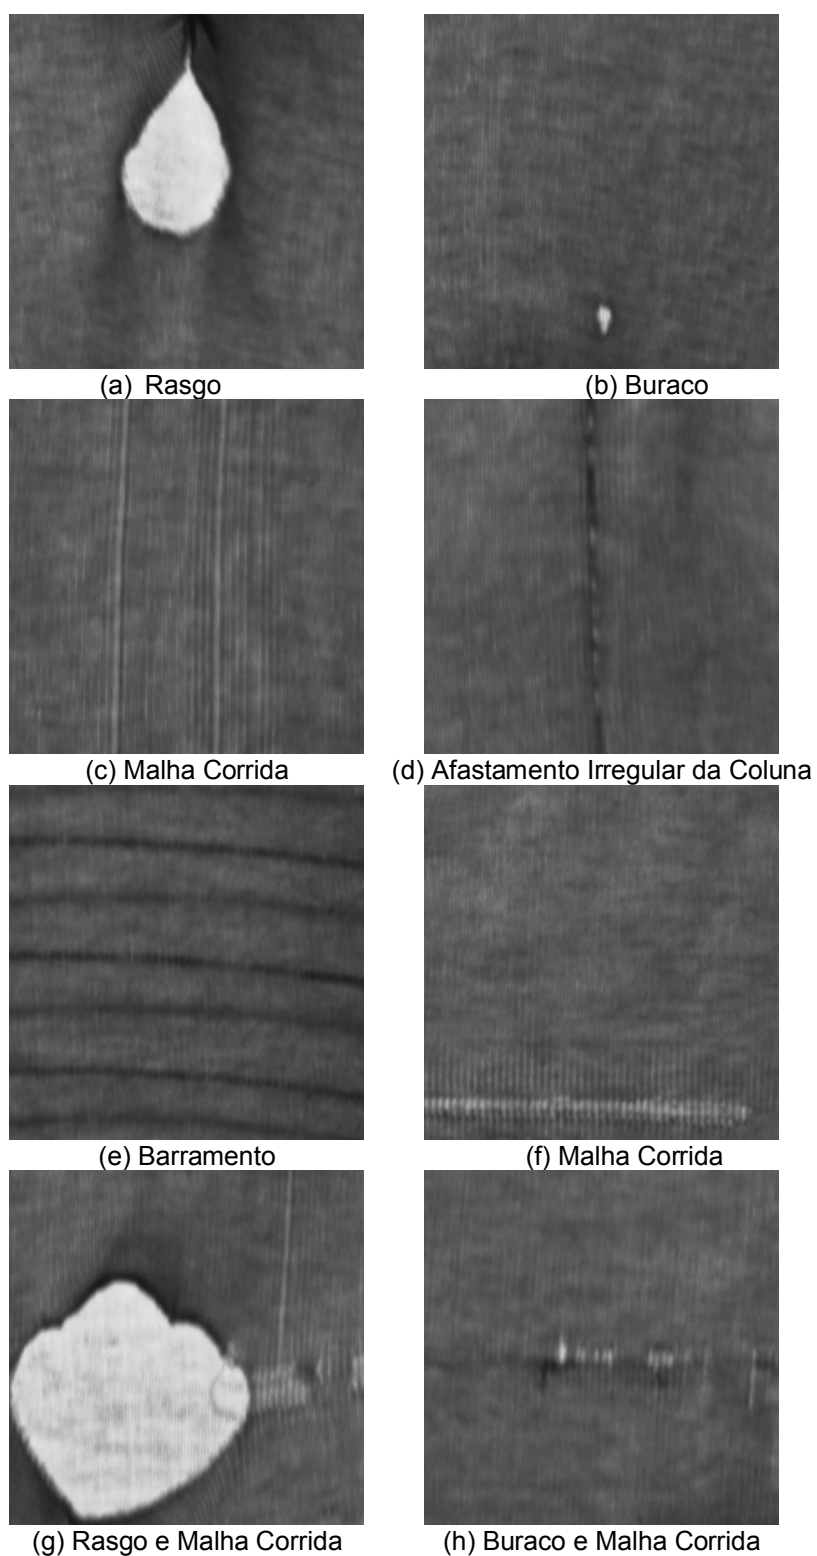


Figura 20: Amostras de defeitos classificados conforme NBR 13175(1994)

4.3 Aparato experimental

Como parte da solução para o problema de inspeção proposto, fez-se necessário o desenvolvimento de um sistema para desbobinar o tecido continuamente e capturar as imagens.

Durante a fase inicial da pesquisa foi desenvolvido um protótipo de uma máquina revisadeira utilizada pela indústria têxtil para realização dessa tarefa, com o objetivo de levantar as demandas para o desenvolvimento de uma máquina revisadeira mais adequada à tarefa de inspeção automática, criar uma base de imagens e avaliar módulos do software de inspeção.

Esse protótipo tem como base um sistema de desbobinamento e bobinamento do tecido com uma luz de fundo e um sistema de aquisição e processamento, formados por câmera, lente e um computador, conforme ilustrado na Figura 21.





Figura 21: Protótipo máquina revisadeira

Para a fase final da pesquisa foi projetado e desenvolvido, em parceria com a empresa de automação industrial Mgalteck¹, uma máquina revisadeira que pode trabalhar com rolos de até 1,30 metros de largura, semelhante a empregada na indústria têxtil, porém com um sistema para computar a quantidade de tecido inspecionada, controlar a velocidade e adquirir e processar as imagens, conforme ilustrado na Figura 22.


Para calcular a quantidade de tecido inspecionada e acionar a câmera, foi instalado na máquina revisadeira um encoder incremental cujas especificações encontram-se na Tabela 4. Para uma resolução espacial adequada das imagens capturadas o suporte da câmera permite ajustar manualmente a distância da câmera até o plano do tecido. As

¹ <http://www.mgalteck.com.br>

especificações da câmera, lente e computador usados no sistema de aquisição e processamento são apresentadas na Tabela 5, Tabela 6 e Tabela 7 respectivamente.



Projeto da máquina



Máquina desenvolvida

Figura 22: Sistema de inspeção

Para calcular a quantidade de tecido inspecionada e acionar a câmera, foi instalado na máquina revisadeira um encoder incremental cujas especificações encontram-se na Tabela 4.

Tabela 4: Especificação do encoder

Características	Valor
Fabricante	AUTONICS
Modelo	ENC-1-2-T-24
Resolução	1cm/Pulso
Rotação máxima	5000 rpm

Para uma resolução espacial adequada das imagens capturadas o suporte da câmera permite ajustar manualmente a distância da câmera até o plano do tecido. As especificações da câmera, lente e computador usados no sistema de aquisição e processamento são apresentadas na Tabela 5, Tabela 6 e Tabela 7 respectivamente.

Tabela 5: Especificação da câmera

Características	Valor
Fabricante	Basler
Modelo	acA1300-60gm
Sensor	CMOS
Resolução	1282 x 1026 pixels
Dimensões	42,0 x 29,0 x 29,0 mm
Interface	GigE

Tabela 6: Especificação da lente

Características	Valor
Fabricante	TAMRON
Modelo	12VM412ASIR
Distância focal	4 - 12 mm
Tamanho da Imagem	1/2"
Iris	Manual

Tabela 7: Especificação do computador

Características	Valor
Fabricante	DELL
Modelo	Inspiron 14R - 5437
Processador	Intel Core i5 4200U 1.60 GHz
RAM	8 GB
Sistema operacional	Windows 8.1 64 bit

Para a avaliação final do sistema de inspeção foi utilizado um rolo de tecido de meia malha em estado cru e liso, produzido com fio 24/1 *Ne* em tear industrial, com 23,30 m de comprimento e 0,90 m de largura, na qual foi inspecionado por um especialista da área têxtil. O menor defeito presente nesse rolo possui área de 10 mm².

4.4 Módulo de software

O principal requisito funcional que orientou o desenvolvimento do sistema de inspeção proposto foi a detecção e classificação de defeitos de forma automática em imagens da superfície do tecido de malha. A detecção do defeito é uma tarefa importante no processo de produção da malha, pois evita que regiões críticas do tecido sejam enviadas às etapas subsequentes da cadeia produtiva, reduzindo assim a geração de resíduos e aumentando a produtividade. A classificação do defeito também é uma tarefa essencial neste processo, uma vez que essa informação é útil para realização de diagnósticos de falhas e prevenção das reincidências de defeitos por causas conhecidas

Como a presença dos defeitos provoca alterações visuais na superfície do tecido que podem ser descritas pela análise dos níveis de intensidade da imagem, foi utilizada uma abordagem estatística para o desenvolvimento do sistema de processamento.

Na Figura 23 é apresentado o fluxograma das etapas de processamento utilizadas para a realização da tarefa de inspeção. O sistema foi implementado na linguagem C++ utilizando a biblioteca de processamento de imagens OpenCv. Os ambientes de desenvolvimento Eclipse e Visual Studio foram utilizados.

Inicialmente é realizada a calibração do sistema de aquisição para corrigir imperfeições do sistema óptico e obter a matriz de homografia que relaciona o plano da imagem com o plano do tecido. Após essa tarefa, imagens da superfície do tecido são capturadas em linha na máquina revisadeira e processadas na sequência para verificar se possuem alguma região com defeito. A detecção de defeitos é realizada a partir da avaliação da textura de pequenas regiões provenientes da divisão da imagem capturada em partes iguais.

Na ocorrência de defeitos, as imagens passam por uma etapa de classificação de defeitos que definirá em qual categoria de defeito cada imagem inspecionada pertence. Nesta etapa, os defeitos são classificados a partir do emprego de uma técnica de reconhecimento de padrões.

A partir das informações dos defeitos identificados e descritos, são extraídas informações úteis ao processo industrial como total de defeitos por categoria e a área defeituosa, que podem ser usadas para classificação final dos rolos de tecido.

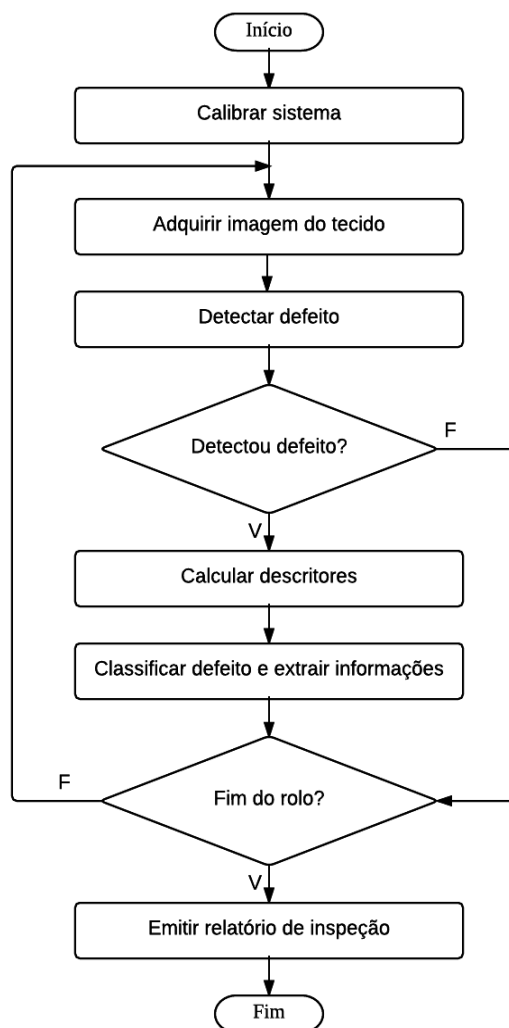


Figura 23: Fluxograma das etapas de processamento

4.4.1 Calibração do sistema de aquisição

A calibração do sistema de aquisição é uma etapa inicial e que antecede as etapas de processamento do sistema de inspeção. Para correção das distorções radiais foi implementado neste trabalho o método de Zhang (2000), descrito na seção 3.1.1.

O padrão do gabarito de calibração é formado por um conjunto de quadrados pretos, dispostos de maneira que os vértices comuns sejam facilmente detectáveis, como ilustra a Figura 24. Para calcular a matriz de projeção P a partir de (5), o gabarito é posicionado em diferentes orientações no plano do tecido até que sejam capturadas 8 imagens.




Figura 24: Gabarito de calibração

Para a homografia foi apresentado um padrão com 4 pontos conhecidos no plano do tecido, que se relacionam com os correspondentes pontos do plano da imagem, a partir de (6), para calcular os elementos da matriz de homografia.

4.4.2 Detecção do defeito

Para a detecção de defeitos é proposto um método baseado em estatística local. O método consiste em dividir a imagem a ser inspecionada em pequenas regiões quadradas, chamadas aqui de subjanelas, e avaliar a textura de cada uma delas.

Esse método parte da premissa de que os pixels no entorno da fronteira de regiões defeituosas apresentam níveis de intensidade muito diferentes. Em imagens de tecido onde existem defeitos que resultem em “maior passagem de luz” na região defeituosa, como é o caso de furos e rasgos, o entorno da fronteira é formado por pixels com níveis de intensidade próximos aos extremos da escala de cinza (0 a 255), além de pixels com os mesmos níveis de intensidade de regiões sem defeitos, como ilustrado na Figura 25a. Nos casos em que os defeitos não são evidenciados pela “alta passagem de luz” por serem mais fechados, o entorno da fronteira é formado por pixels com níveis de intensidade que

variam do mais escuro a níveis presentes em regiões sem defeito, como ilustrado na Figura 25b.




Figura 25: Fronteira ampliada

É possível observar que a textura no entorno da fronteira de regiões defeituosas é pouco suave, indicando alta variabilidade dos níveis de intensidade. Já nas regiões sem a presença de defeitos observa-se o contrário, há menor variabilidade e a textura é mais suave.

Com base nessas observações, para descrever a textura das subjanelas da imagem é usado o desvio padrão do histograma de intensidade de cada subjanela.

Seja $i = \{0, 1, 2, \dots, L - 1\}$ o conjunto dos L níveis de intensidade de uma subjanela e $p(z_i)$ o histograma normalizado $p(z_i)$, como definido na seção 3.2.1.1, o cálculo do desvio padrão é dado pela fórmula (23).

O valor limite do desvio padrão para indicação da presença de defeito pode ser determinado automaticamente, para cada tipo de malha e tamanho de subjanelas, a partir do valor médio dos desvios padrão das subjanelas de uma faixa da imagem sem a presença de defeito, definida pelo usuário.

Para complementar o método e evitar que regiões da imagem sem defeitos sejam falsamente classificadas como defeituosas, foi definida e empregada a regra de vizinhança que determina que: somente as regiões formadas por subjanelas adjacentes e com alta

variabilidade, conforme configurações ilustradas na Figura 26, são classificadas como defeituosas.




Figura 26: Configurações de subjanelas adjacentes com alta variabilidade

A adição dessa regra se faz necessária, pois devido ao processo de tricotagem da malha, algumas subjanelas sem defeito podem conter pixels com níveis de intensidade muito distante da intensidade média da imagem.

4.4.3 Cálculo dos descritores

O cálculo dos descritores é realizado apenas sobre as imagens que foram detectadas como defeituosas. O cálculo dos descritores geométricos é realizado a partir do tipo de artefato presente na imagem defeituosa. Para identificar os artefatos são empregados dois procedimentos em série com o intuito de identificar regiões contíguas e/ou linhas.

Para identificar regiões contíguas, é aplicada inicialmente uma técnica de segmentação que consiste em separar nas imagens a fase correspondente ao artefato de interesse da fase correspondente à textura original da imagem. Para isso, é empregada uma técnica de limiarização, como descrito na seção 3.2.3.1, com um limiar definido para cada tipo de malha. Como resultado dessa etapa é obtida uma imagem binária com os elementos de interesse destacados do fundo. Devido à possível presença de ruídos na imagem inspecionada são empregadas na sequência operações morfológicas, como na seção 3.2.3.3, de erosão e dilatação para eliminar pequenos componentes que não representam defeitos e que devem ser eliminados.

Para descrever os artefatos encontrados na etapa anterior é empregado um algoritmo de rotulação de componentes conexos, como descrito em 3.2.1.2, que permitirá o cálculo dos descritores apresentados na seção 3.2.4.1.

As linhas presentes nas imagens de tecidos de malha com defeito se caracterizam por variações abruptas de intensidade no entorno dos pixels do segmento que representa cada linha. Para identificar linhas, inicialmente é empregada uma etapa de detecção de bordas para separar os pontos pertencentes ao artefato de interesse da textura original da imagem. Para isso, foram empregados os algoritmos de detecção de bordas Canny e Sobel,

seção 3.2.3.2, que apresentam como resultado uma imagem binária com os pontos pertencentes às linhas destacados do fundo.

Para descrever os artefatos destacados pelo detector de bordas, é empregado um algoritmo de ligação de bordas baseado na transformada de Hough, descrito na seção 3.2.3.4, que apresenta como resultado uma lista dos pontos pertencentes a cada segmento correspondente a linha.

O cálculo dos descritores de textura pode ser feito sobre toda a imagem detectada como defeituosa, aplicando as fórmulas apresentadas na seção 3.2.4.2. Contudo, em alguns casos esses descritores podem ser calculados apenas sobre a região no entorno do artefato. Para obter essa região, são empregados os mesmos procedimentos descritos acima para identificar linhas e regiões contíguas. As imagens resultantes desses procedimentos são unidas, formando uma imagem binária com as linhas e/ou regiões contíguas destacadas do fundo, na qual serve de referência para definir o menor retângulo que circunscreve a região defeituosa. Caso nenhum elemento seja destacado, a imagem inteira será definida como região defeituosa.

4.4.4 Classificação do Defeito

Os defeitos serão classificados entre uma das categorias apresentadas na Tabela 3. Dessa forma serão considerados 3 métodos de classificação. No primeiro método a classificação é feita em função do tipo de artefato observado na imagem inspecionada. Para identificar os artefatos, são utilizados os mesmos procedimentos descritos na seção 4.4.3 para o cálculo de descritores geométricos. Os artefatos do tipo região contígua identificados serão classificados como *Defeito Região Contígua*. Para os artefatos identificados como linha, a classificação ocorrerá a partir do valor do comprimento de cada segmento e de sua angulação, sendo desconsideradas aquelas com valor fora da faixa aceitável. Os artefatos do tipo linha com angulação em torno de 90° são classificados como *Defeitos Linha Vertical* e com angulação em torno de 0° como *Defeitos Linha Horizontal*. A classificação na categoria *Defeito Misto* ocorrerá quando forem identificados, na mesma imagem, pelo menos dois dos três tipos de artefatos citados: região contígua, linha vertical e linha horizontal, ou, não forem identificados nenhum desses artefatos.

Os outros dois métodos se baseiam nos reconhecedores de padrão descritos na seção 3.2.5, Rede neural multicamadas feedforward e SVM não linear multiclases, para classificar os defeitos. Como entrada para esses métodos, serão utilizados descritores de textura baseados na matriz de co-ocorrência, descritos na seção 3.2.4.2.

5 RESULTADOS

Neste capítulo serão apresentados os resultados alcançados pelo presente projeto durante a fase de desenvolvimento e após a conclusão do sistema de inspeção. Inicialmente serão apresentados os resultados experimentais dos algoritmos de detecção e classificação para um banco de imagens de amostras de tecido de malha. Na sequência serão apresentados os resultados do sistema de inspeção proposto para imagens obtidas em tempo real em um cenário de inspeção industrial.

5.1 Resultados de inspeção *off-line* empregando da base de imagens

Durante a fase de desenvolvimento do presente trabalho foi criada uma base de imagens com 122 amostras de tecido produzidas em teares industriais, das quais 38 contém algum tipo de defeito. A Tabela 8 apresenta a classificação desses defeitos segundo as categorias descritas na seção 4.2, realizada por um especialista da indústria têxtil, bem como a quantidade por defeito.

Tabela 8: Defeitos presentes no banco de imagens

Categoria de defeito	Quantidade
Região Contígua	5
Linha Horizontal	4
Linha Vertical	11
Misto	18

Estas imagens foram capturadas a partir de rolos de tecido sendo desbobinados no protótipo da máquina revisadeira apresentado na seção 4.3, com o objetivo de reproduzir as condições de operação encontradas na indústria. As imagens produzidas são monocromáticas com dimensões de 760x600 pixels, o que em função da configuração mecânica do sistema resultou em uma resolução espacial de 75 *dpi* do tecido amostrado. Esse banco de imagens está sendo disponibilizado na internet² para que outros pesquisadores possam avaliar e comparar os resultados de seus sistemas.

5.1.1 Resultados do método de detecção

O tamanho das subjanelas e o valor do limiar do desvio padrão para a indicação da presença de defeitos são variáveis importantes para o desempenho do método de

² fabricdataset.gaspar.ifsc.edu.br

detecção. Assim, devem ser definidas de modo a maximizar o número de defeitos detectados e minimizar o tempo de execução. O tamanho das subjanelas deve ser definido de modo a circunscrever as fronteiras de defeitos de diferentes tamanhos.

Como ilustrado na Figura 27, defeitos pequenos não tem apenas suas fronteiras circunscritas por subjanelas grandes, mas sim o defeito por inteiro, o que reduz a quantidade de subjanelas adjacentes com alta variabilidade. Por outro lado, subjanelas menores consomem mais tempo de processamento, deixando o sistema mais lento, o que não é interessante para aplicações que necessitam de respostas rápidas.

Uma análise prévia dos desvios padrão de diferentes tamanhos de subjanelas de uma faixa da imagem sem defeitos e escolhida aleatoriamente foi necessária para o sistema determinar o valor do limiar automaticamente. Para subjanelas de tamanho 3x3 foi utilizado como limiar a média dos desvios padrão das subjanelas de uma faixa da imagem. Nos demais tamanhos, o valor médio dos desvios padrão das subjanelas foi menor devido ao maior número de elementos nas subjanelas. Nesses casos, o uso do valor médio dos desvios padrão como limiar não apresentou resultados satisfatórios para o banco de imagens avaliado.

Para as subjanelas de tamanho 5x5, 15x15 e 20x20 foi definido como limiar o dobro do valor médio dos desvios padrão das subjanelas de uma faixa da imagem sem defeitos. Os desvios padrão das subjanelas 10x10 apresentaram maior variabilidade entre seus valores, o que levou a considerar como limiar o dobro do limite superior do intervalo de confiança da média dos desvios padrão.

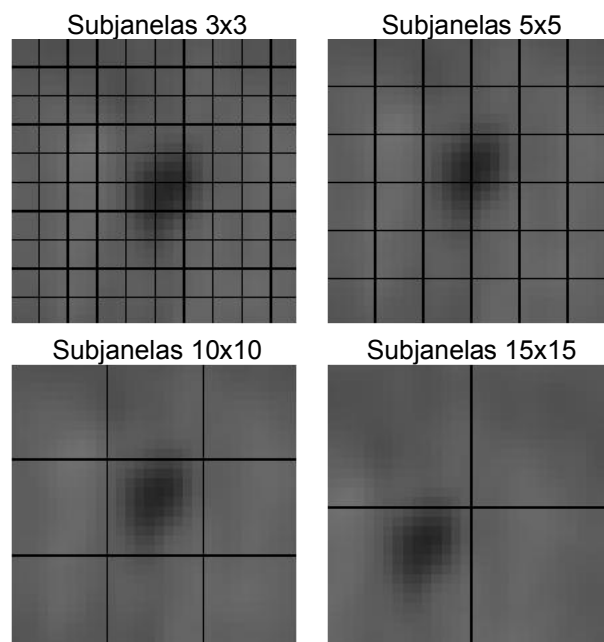


Figura 27: Número de janelas x fronteiras circunscritas

Na Figura 28 é apresentado o gráfico do valor do limiar e dos desvios padrão para uma faixa defeituosa da imagem, para subjanelas 5x5. Os pontos acima do limiar representam os picos de desvio padrão e correspondem a subjanelas que contém fronteiras de regiões defeituosas.

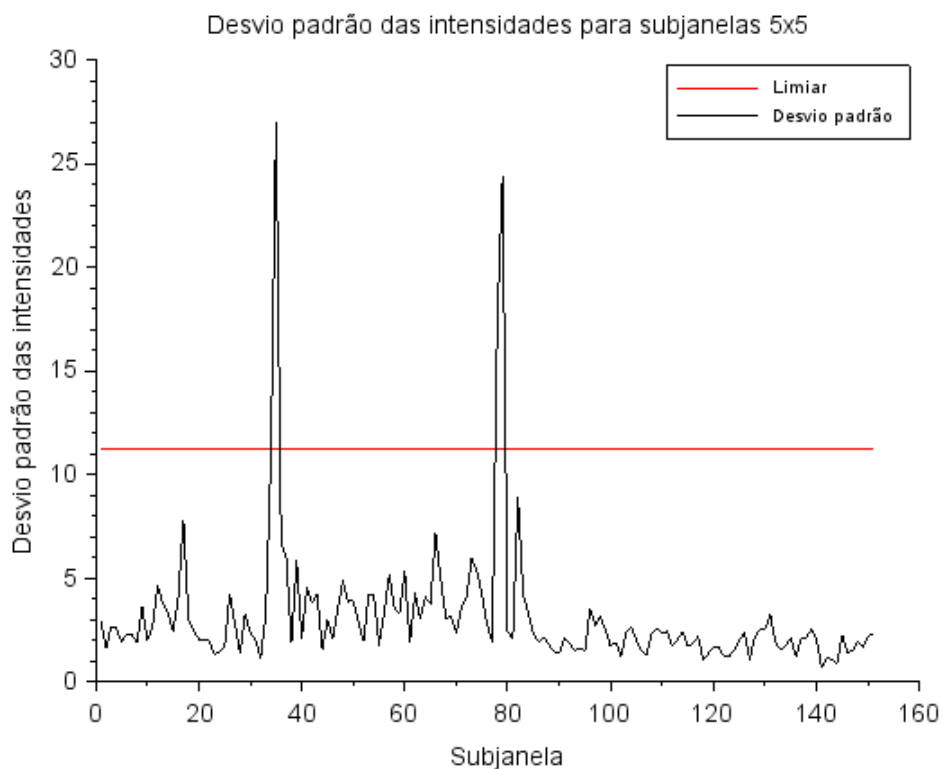


Figura 28: Gráfico comparativo entre os desvios padrão e o limiar

Na Figura 29 é ilustrado o processo de detecção automatizado. Para cada imagem inspecionada foi calculado o desvio padrão das subjanelas. Aquelas com valor acima do limiar são destacadas e, se estiverem conectadas conforme descrito na Figura 26, são consideradas fronteira da região defeituosa, indicando que a imagem inspecionada contém algum defeito.

Na Tabela 9 são apresentados os valores médios de algumas estatísticas obtidas na repetição do experimento de inspeção com a base de imagens 100 vezes, para 5 tamanhos de subjanelas. A coluna “Acertos” indica a taxa média de imagens classificadas corretamente quanto a presença ou não de defeitos e a coluna “Erros” indica a taxa média de imagens classificadas erradamente. A coluna “Falsos positivos” indica a taxa média de imagens classificadas falsamente como defeituosas e a coluna “Falsos negativos” indica a taxa média de imagens detectadas falsamente como boas. A última coluna apresenta o tempo médio necessário para o processamento das etapas de detecção por imagem.

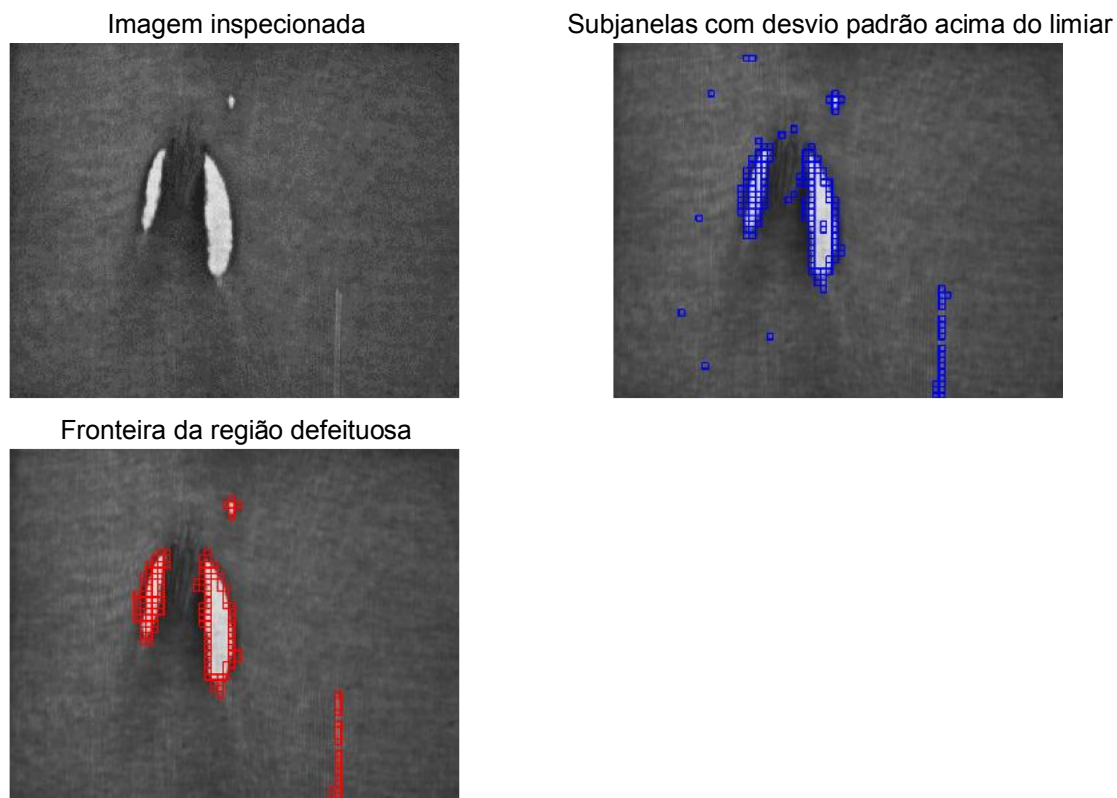


Figura 29: Ilustração do método de detecção

Tabela 9: Média dos Resultados da detecção

Subjanelas	Acertos	Erros	Falsos positivos	Falsos negativos	Tempo execução (ms)
3x3	96,72%	3,28%	0,00%	3,28%	168,89
5x5	96,82%	3,18%	0,93%	2,25%	61,52
10x10	96,97%	3,03%	3,03%	0,00%	16,66
15x15	98,99%	1,01%	1,01%	0,00%	8,18
20x20	99,02%	0,98%	0,13%	0,85%	5,29

De forma geral, o método proposto apresentou para a base de imagens avaliada uma excelente taxa média de acertos para todos os tamanhos de subjanelas testados. A maior taxa média de erros entre as subjanelas, corresponde a apenas 4 imagens do total de amostras avaliadas.

As baixas taxas de falsos negativos das subjanelas de tamanho 10x10, 15x15 e 20x20 indicam que esses tamanhos foram adequados para circunscrever as fronteiras defeituosas das imagens da base avaliada, com destaque para as duas maiores que apresentaram baixas taxas de falsos positivos, mostrando que são mais robustas a variações de intensidade.

O tamanho das subjanelas influenciou no tempo de processamento das etapas do método de detecção. Quanto maior o tamanho das subjanelas menor foi o tempo de

processamento por imagem inspecionada. Além de altas taxas de acertos, o método de detecção apresentou baixos tempos de processamento para subjanelas 15x15 e 20x20, o que torna possível a integração do método à linhas de produção para controle de qualidade de tecido.

Comparando as taxas de acertos do método de detecção proposto com os resultados encontrados na literatura empregando diferentes abordagens (NGAN, PANG, YUNG, 2011), podemos dizer que os resultados alcançados são excelentes, com a vantagem de que os testes foram realizados com um maior conjunto de dados adquiridos em condições de operação mais realistas. Além disso, as taxas de acertos são superiores as taxas obtidas por operadores humanos.

5.1.2 Resultados do método de classificação

Para avaliar os métodos de classificação foram utilizadas as 38 amostras com algum tipo de defeito da base de imagens. Para a classificação baseada na forma do artefato presente na imagem inspecionada, os artefatos foram identificados conforme descrito na seção 4.4.4. Na Figura 30 é ilustrado o resultado do processo de identificação dos artefatos região contígua e linha.

O valor do limiar para segmentação de regiões contíguas é de fácil definição, pois os pixels que formam esse tipo de artefato têm intensidade muito diferente da intensidade média das regiões sem defeito. A identificação do artefato tipo linha se mostrou menos sensível para determinadas imagens, pois nem sempre o artefato foi descrito por completo. Ajustes nos parâmetros das técnicas propostas podem provocar a identificação de falsas linhas na imagem inspecionada.

A utilização dos dois detectores de borda para identificação do artefato do tipo linha se justifica por duas razões: (a) o detector de borda Canny deve ser usado para segmentar bordas suaves, pois estas são eliminadas pela aplicação da limiarização e das operações morfológicas sobre as imagens resultantes do detector de bordas Sobel; (b) o detector de borda Sobel deve ser usado em razão dos limiares utilizados na limiarização por histerese na técnica de Canny. Como as bordas podem ser formadas por intensidades que tendem aos extremos da escala de cinza, como ilustrado na Figura 31, a magnitude do gradiente nos pontos localizados em bordas escuras é menor do que a magnitude do gradiente em bordas claras. Dessa forma, os limiares para histerese devem ser definidos para segmentar uma dessas bordas, sob a pena da outra não ser segmentada ou serem segmentadas falsas bordas.

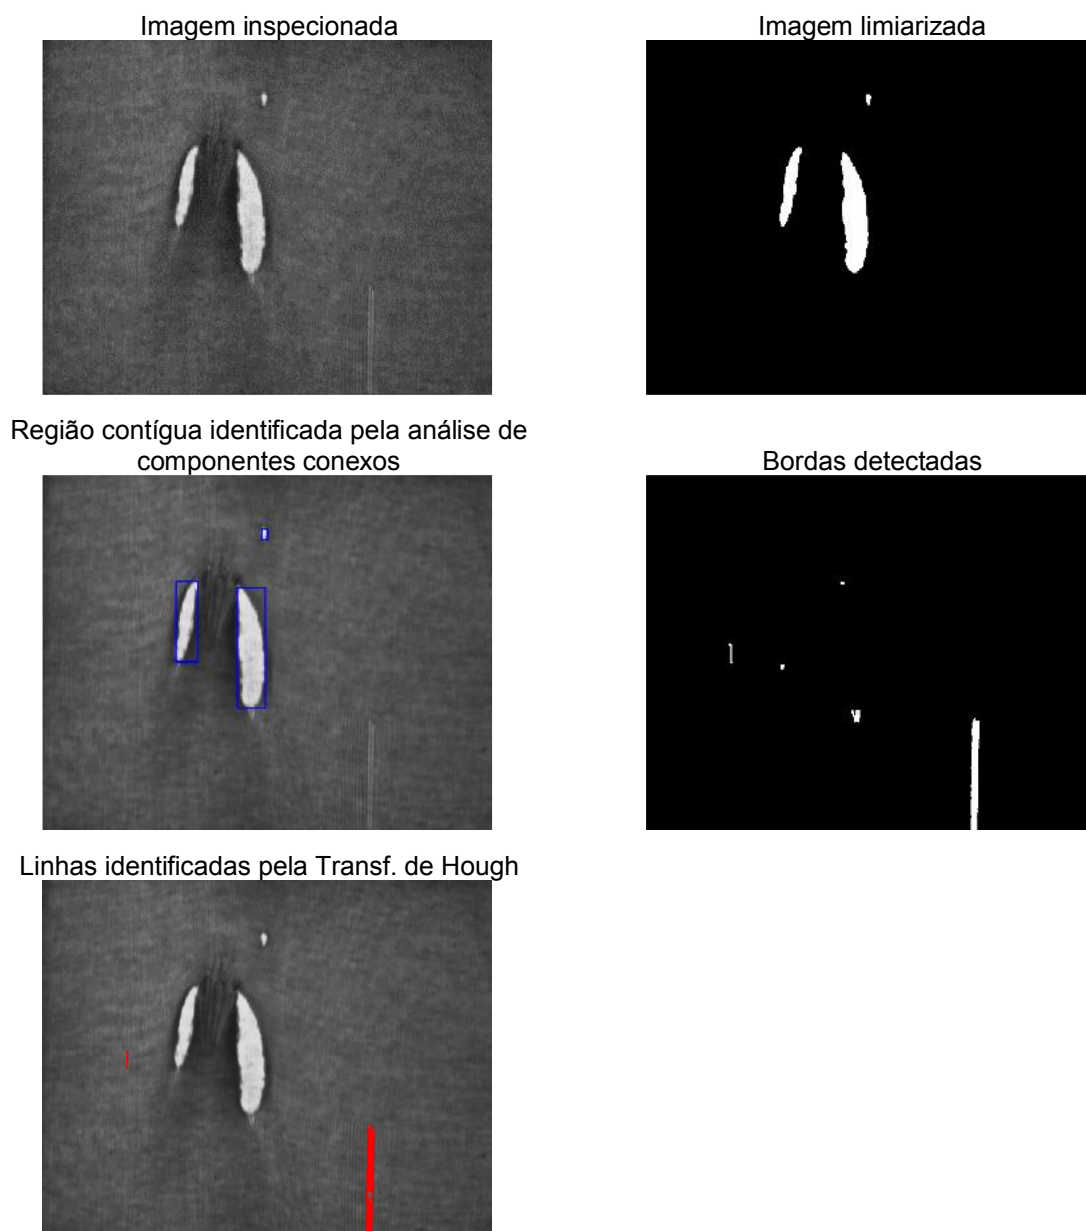


Figura 30: Identificação dos artefatos região contígua e linha




Figura 31: Intensidades da borda

Para a classificação baseada nos reconhecedores de padrão RNA e SVM, foram utilizados descritores de textura como entrada para os reconhecedores de padrões. Para cada imagem defeituosa foram obtidas 4 matrizes de co-ocorrência, com uma distância entre os pixels arranjados de 1 pixel e orientação de 0°, 45°, 90° e 135°. Para cada matriz foram calculados os descritores de textura contraste, uniformidade, homogeneidade, entropia e correlação, como descrito na seção 3.2.4.2, resultando em 20 descritores. Para treinamento da RNA e do SVM foram selecionadas 30 imagens defeituosas diferentes da base de imagens (Região contígua = 7; Misto = 11; Linha vertical = 6; Linha horizontal = 6).

Para o cálculo dos descritores foram consideradas duas situações: (a) sobre toda a imagem, (b) sobre a região defeituosa. Foi definido como região defeituosa, o menor retângulo que circunscribe os defeitos presentes em uma imagem inspecionada. A Figura 32 ilustra resultado do processo de identificação da região defeituosa conforme descrito na seção 4.4.3.




Figura 32: Identificação região defeituosa

Os resultados obtidos pelos métodos de classificação propostos foram comparados com a classificação realizada pelo especialista (Tabela 8). Estes resultados foram organizados por meio de uma matriz de confusão, como ilustrado da Tabela 10. Cada elemento $x_{i,j}$ dessa matriz corresponde ao número de imagens da categoria i (linha)

classificadas na categoria j (coluna). Dessa forma, a diagonal principal corresponde as classificações concordantes.

Tabela 10: Matriz de confusão

Categoria	Linha Horizontal	Linha Vertical	Região Contígua	Misto
Linha Horizontal	$x_{1,1}$	$x_{1,4}$
Linha Vertical	\vdots	\vdots	\vdots	\vdots
Região Contígua	\vdots	\vdots	\vdots	\vdots
Misto	$x_{4,1}$	$x_{4,4}$

Para avaliar os resultados do método proposto, foram utilizadas as seguintes medidas:

$$\text{Precisão por categoria}(k) = \frac{x_{k,k}}{\sum_{i=1}^4 x_{k,i}} \quad (51)$$

$$\text{Precisão global} = \frac{\sum_{i=1}^4 x_{i,i}}{N} \quad (52)$$

$$\text{Coeficiente Kappa} \quad (53)$$

$$= \frac{N \sum_{i=1}^4 x_{i,i} - \sum_{i=1}^4 s_{i,L} s_{i,C}}{N^2 - \sum_{i=1}^4 s_{i,L} s_{i,C}}$$

onde:

N representa a soma dos valores da matriz de confusão: $N = \sum_{i=1}^4 \sum_{j=1}^4 x_{i,j}$

$s_{i,L}$ representa a soma dos valores da linha k : $s_{k,L} = \sum_{i=1}^4 x_{k,i}$

$s_{i,C}$ representa a soma dos valores da coluna k : $s_{k,C} = \sum_{i=1}^4 x_{i,k}$

A primeira medida, precisão por categoria, corresponde à probabilidade de uma imagem da categoria k ser classificada corretamente pelo método. Esta medida permite avaliar a eficiência do método para cada categoria. A precisão global representa a proporção de classificações concordantes em relação ao tamanho do conjunto de imagens, ou seja, representa a probabilidade de uma imagem defeituosa qualquer ser classificada corretamente.

O coeficiente Kappa mede o grau de concordância entre a classificação do especialista e do método, e considera todos os elementos da matriz de confusão ao invés de apenas aqueles que se encontram na diagonal principal. Esta última medida define a eficiência dos métodos propostos. Dessa forma, valores maiores que 0,80 indicarão

excelente concordância, valores menores que 0,4 fraca concordância, e valores intermediários concordância moderada (adaptado de LANDIS, KOCK, 1977).

Os resultados obtidos com as 38 amostras defeituosas da base de imagens para cada método de classificação são apresentados nas Tabelas 11, 12, 13, 14 e 15, onde a última coluna mostra a precisão do classificador em cada categoria. A precisão global, o coeficiente Kappa e o tempo médio de processamento de cada classificador são apresentados na Tabela 16.

Tabela 11: Matriz de confusão - Método baseado na forma

Categoria	Linha Horizontal	Linha Vertical	Região Contígua	Misto	Precisão (%)
Linha Horizontal	4	0	0	0	100%
Linha Vertical	0	11	0	0	100%
Região Contígua	0	0	5	0	100%
Misto	0	0	0	18	100%

Todas as categorias do método de classificação baseado na forma do artefato alcançaram taxa de precisão por categoria máxima, indicando que a probabilidade de classificação dentro de cada categoria é excelente. A identificação do artefato tipo linha é um dos maiores problemas para o método proposto, pois nem sempre é descrito por completo. Ajustes nos parâmetros das técnicas propostas provocam a identificação de falsos artefatos na imagem inspecionada.

Tabela 12: Matriz de confusão – RNA imagem inteira

Categoria	Linha Horizontal	Linha Vertical	Região Contígua	Misto	Precisão (%)
Linha Horizontal	4	0	0	0	100%
Linha Vertical	0	11	0	0	100%
Região Contígua	0	0	3	2	60%
Misto	0	1	0	17	94%

A precisão nas categorias Linha Horizontal, Linha Vertical e Misto atingiram excelentes valores para o método RNA imagem inteira. A confusão maior ocorreu na categoria Região Contígua, o que gerou um valor baixo de precisão para a categoria.

Tabela 13: Matriz de confusão – RNA região defeituosa

Categoria	Linha Horizontal	Linha Vertical	Região Contígua	Misto	Precisão (%)
Linha Horizontal	4	0	0	0	100%
Linha Vertical	0	11	0	0	100%
Região Contígua	0	0	5	0	100%
Misto	0	0	0	18	100%

O método baseado em RNA região defeituosa também alcançou uma taxa de precisão máxima dentro de cada categoria.

Tabela 14: Matriz de confusão – SVM imagem inteira

Categoria	Linha Horizontal	Linha Vertical	Região Contígua	Misto	Precisão (%)
Linha Horizontal	4	0	0	0	100%
Linha Vertical	0	9	1	1	82%
Região Contígua	0	0	3	2	60%
Misto	0	1	0	17	94%

O método baseado em SVM imagem inteira apresentou boas taxas de precisão para as categorias Linha Horizontal, Linha Vertical e Misto, porém o método não se mostrou eficiente na classificação dentro da categoria Região Contígua.

Tabela 15: Matriz de confusão – SVM região defeituosa

Categoria	Linha Horizontal	Linha Vertical	Região Contígua	Misto	Precisão (%)
Linha Horizontal	4	0	0	0	100%
Linha Vertical	2	0	0	9	0%
Região Contígua	0	0	2	3	40%
Misto	3	0	0	15	83%

O método baseado em SVM região defeituosa apresentou as piores taxas de precisão por categoria. As categorias Linha Horizontal e Misto tiveram os melhores resultados.

A extração da região defeituosa é um dos maiores problemas dos métodos que dependem dessa informação (RNA região defeituoso, SV região defeituosa), principalmente para defeitos que provocam na imagem artefatos do tipo linha. Em alguns casos partes das linhas que formam o artefato não são segmentadas, influenciando na definição da região defeituosa.

Tabela 16: Medidas e tempo de execução por método

	Método baseado na forma	RNA imagem inteira	RNA região defeituosa	SVM imagem Inteira	SVM região defeituosa
Precisão global	100%	92%	100%	87%	55%
Coeficiente Kappa	100%	88%	100%	80%	29%
Tempo de execução (ms)	46,58	88,11	90,37	88,66	124,26

Os resultados obtidos pelos métodos de classificação baseado na forma, RNA região defeituosa e RNA imagem inteira estão condizentes com os resultados encontrados na literatura (HABIB, 2014, KUMAR, RAGUPATHY, 2012, DONGLI, 2013). Esses métodos

alcançaram elevadas taxas de precisão global para a base de imagens avaliada, indicando que a probabilidade de classificação correta para qualquer nova imagem é alta. De acordo com o coeficiente Kappa, a concordância observada foi excelente para esses 3 métodos, o que indica que os métodos se mostram eficientes para a classificação de defeitos em tecido de malha, com destaque para os métodos baseados na forma e em RNA região defeituosa que atingiram o valor máximo.

5.1.3 Avaliação do custo computacional

O tempo médio consumido para o processamento do ciclo de operação, considerando o maior tempo de execução dos 3 melhores métodos de classificação e o tempo de execução do método de detecção para subjanelas 10x10, foi de 107,03 ms. Com esse tempo o sistema pode operar a aproximadamente 9 Hz. Considerando a utilização de câmeras em uma configuração cujo campo de visão seja de 20 cm no sentido longitudinal do rolo de tecido sendo inspecionado, temos que o sistema pode inspecionar a uma velocidade de 1,8 metros de tecido por segundo. Isso torna o sistema de inspeção proposto cerca de 5 vezes mais rápido do que o sistema tradicional de inspeção, que é de cerca de 8 a 20 metros por minuto (KUMAR, 2008).

Desta forma, os resultados obtidos permitiriam ainda a utilização de várias câmeras posicionadas no sentido transversal do tecido de modo a cobrir larguras maiores do que o campo de visão de uma única câmera, mantendo ainda a velocidade de inspeção superior à do sistema tradicional. Ainda, é importante observar que no escopo do trabalho não foi realizado um maior esforço com o objetivo de reduzir o custo computacional dos algoritmos implementados. O uso de recursos de paralelismo disponíveis na arquitetura de processadores atuais, ou de processamento empregando a unidade gráfica (GPU), poderia reduzir ainda mais o custo apresentado.

5.2 Resultados de inspeção on-line

Para avaliação final do sistema de inspeção proposto foi utilizado a máquina revisadeira descrita na seção 4.3. Além de controle de velocidade, essa máquina possui um sistema manual de ajuste da posição da câmera, o que permite controlar a distância entre câmera e plano da superfície do tecido conforme sua gramatura, e um sistema para medir o comprimento do tecido e posicionamento das regiões defeituosas.

Para o tecido utilizado nessa fase do trabalho, foi necessário deixar a câmera a uma distância de trabalho de 35 cm do plano do tecido, o que resultou em um campo de visão

de 0,40 m de largura por 0,30 m de altura. Devido a disponibilidade de somente uma câmara para o desenvolvimento deste projeto, a largura do tecido inspecionado será de 0,40 m, 0,20 m para cada lado a partir do centro do tecido.

A tabela 17 apresenta o relatório da inspeção manual de uma face do rolo de tecido empregado. Essa inspeção foi realizada minuciosamente por um especialista da área têxtil, a fim de comparar o resultado do método proposto com o melhor resultado do especialista. O cálculo dos valores foi realizado conforme descrito na seção 2.2.

Tabela 17: Relatório de inspeção

Características	Valor
Comprimento	23,30 m
Largura	0,40m
Área Total Inspeccionada	9,32 m ²
Número de Defeitos	17
Área Total Defeituosa	1,46 m ²
Porcentagem Área Defeituosa	15,66%

Com relação ao tipo de defeito, a Tabela 18 apresenta os tipos de defeitos presentes no rolo de tecido inspecionado, conforme categorização descrita na seção 4.2, bem como as respectivas quantidades.

Tabela 18: Defeitos presentes no rolo inspecionado

Categoria de defeito	Quantidade
Região Contígua	7
Linha Horizontal	3
Linha Vertical	4
Misto	3

Na Tabela 19 é apresentado um relatório do método de detecção do sistema de inspeção em tempo real, para subjanelas de tamanho 8x8, a uma velocidade de 20 m/min. Esse tamanho apresentou o melhor desempenho e foi definido de forma a cobrir toda a área da imagem inspecionada.

O sistema capturou 75 quadros da superfície inspecionada, dos quais 48 são de regiões do tecido livres de defeitos e 27 contêm algum artefato que corresponde a uma falha gerada por algum tipo de defeito. Do total de quadros capturados, o sistema acertou o resultado de classificação de 70 quadros e errou de 5. Para os 48 quadros sem defeitos, o sistema não gerou falsos positivos, ou seja, nenhum quadro sem defeito foi classificado falsamente como defeituoso. Para os 27 quadros com defeitos, o sistema gerou 5 falsos

negativos, ou seja, 5 quadros com defeitos foram classificados falsamente como sem defeitos.

Tabela 19: Relatório detecção

Subjanelas	Acertos	Erros	Falsos positivos	Falsos negativos
8x8	93,33%	6,67%	0%	18,52%

O método de detecção proposto apresentou precisão superior à inspeção manual tradicional que é de aproximadamente 70% (NGAN, PANG, YUNG, 2011; ISLAM, AKHTER, MURSALIN, 2008). Esse resultado também é condizente com os resultados de sistemas de detecção apresentados na literatura, conforme a taxonomia de métodos de detecção automatizada de tecidos organizada por Ngan, Pang e Yung (2011).

Os 22 quadros verdadeiros positivos detectados pelo sistema de inspeção correspondem a 15 defeitos daqueles detectados pelo especialista. Isso se deve ao fato de que alguns defeitos foram capturados por mais de um quadro devido ao seu tamanho. Os 2 defeitos não detectados pelo método correspondem a defeitos do tipo linha horizontal.

O método de detecção proposto não se mostrou robusto na detecção de defeitos do tipo linha horizontal como ilustrados na Figura 33. Nos casos em que esse tipo de defeito foi detectado, a região detectada corresponde a uma pequena parte do defeito.




Figura 33: Amostras de defeitos do tipo linha horizontal

Todos os defeitos do tipo linha vertical foram detectados pelo método proposto, porém para algumas imagens desse tipo de defeito, como ilustrado na Figura 34, o defeito também não foi detectado por completo.

Devido à textura do tecido de malha inspecionado, as intensidades das imagens de alguns defeitos do tipo linha horizontal e vertical são semelhantes às intensidades de regiões sem defeito. Isso se deve a gramatura do fio, que originou um tecido mais fino e

com trama mais aberta em relação ao tecido utilizado para formar a base de imagens avaliada *off-line*.




Figura 34: Amostra defeito tipo linha vertical

A redução ou o aumento do tamanho das subjanelas não influenciou na eficiência do método de detecção para esses dois tipos defeitos. Além de não contribuir para a detecção, a redução deixa o sistema mais lento. O aumento do tamanho das subjanelas reduz o número de subjanelas com desvio padrão maior do que o limiar e prejudica a detecção de pequenos defeitos.

Se o valor do limiar for reduzido para detectar esses dois defeitos, o número de subjanelas "falsos positivos" será maior devido a textura do tecido e prejudicará o desempenho do método de detecção.

Para defeitos que geram na imagem inspecionada um artefato com níveis de cinza diferentes do fundo da imagem, o método detectou todas os defeitos presentes no rolo utilizado, sendo que o menor defeito possui 5 mm de comprimento por 3 mm de largura, como ilustrados na Figura 35.




Figura 35: Defeito região contígua ampliado

Para atender ao requisito de calcular a área total defeituosa, foi utilizada a distância entre as linhas que limitam o defeito detectado, com ilustrado na Figura 36, para determinar o comprimento defeituoso individual.

Considerando somente os quadros verdadeiros positivos, o comprimento total defeituoso determinado pelo sistema de inspeção foi de 1,64 m, o que resulta em uma área total defeituosa de $0,66 \text{ m}^2$ ($1,64 \times 0,4$). Se comparamos esse valor com a área total dos 15 defeitos correspondentes detectados pelo especialista ($1,38 \text{ m}^2$), temos que o sistema calculou somente 48% da área defeituosa gerada por esses defeitos.

Se forem desconsiderados os defeitos do tipo linha horizontal e vertical, pois o sistema não detectou todos esses defeitos por completo, temos que a área defeituosa detectada pelo sistema é de 94% da área defeituosa detectada pelo especialista. Esse número não chegou próximo ao 100% porque um defeito do tipo misto possui uma linha vertical que não foi detectada por completo.




Figura 36: Cálculo do comprimento do defeito

Devido à imprecisão do sistema para calcular o comprimento defeituoso individual para os diferentes tipos de defeitos presentes no rolo de tecido, não foi realizada uma avaliação final do rolo de tecido quanto ao seu grau de qualidade, pois essa informação é essencial para atribuir uma pontuação conforme descrito na seção 2.2.

Para destacar o defeito com algum tipo de marcação, o sistema retorna as coordenadas dos limites do defeito na margem do plano do tecido, a partir da posição das linhas que o limitam no plano da imagem. Essas coordenadas podem ser utilizadas por um atuador para fazer marcações situadas na margem do rolo de tecido, semelhante ao que é feito pelo inspetor humano.

Para classificação do defeito em tempo real foram implementados e avaliados os métodos baseados na forma e em RNA região defeituosa, por apresentarem melhores resultados quando avaliados sobre a base de imagens. Para treinamento da RNA foram utilizadas 5 imagens de cada categoria de defeito capturadas em diferentes posições do plano do tecido. Para cada imagem foram calculados os mesmos 20 descritores utilizados na avaliação *off-line* da base de imagens.

As Tabelas 20 e 21, apresentam a matriz de confusão, com a precisão do classificador por categoria na última coluna. A precisão global e o coeficiente Kappa são apresentados na Tabela 22.

Tabela 20: Matriz de confusão - Método baseado na forma

Categoria	Linha Horizontal	Linha Vertical	Região Contígua	Misto	Precisão (%)
Linha Horizontal	2	0	0	0	100%
Linha Vertical	0	8	0	1	89%
Região Contígua	0	0	6	1	86%
Misto	0	0	1	3	75%

O método baseado na forma apresentou boas taxas de precisão dentro de cada categoria. O defeito Misto, classificado erradamente como Região Contígua, é formado por uma região contígua e uma linha horizontal. O erro ocorreu porque o artefato gerado pela linha não foi identificado pelo método proposto. Os defeitos Linha Vertical e Região Contígua, classificados erradamente como Misto, geraram nas imagens capturadas artefatos com intensidades próximas a do fundo da imagem e por isso não foram identificados, fazendo o sistema classificá-los como Misto. Um refinamento nos parâmetros dos métodos para identificar esses artefatos prejudicaria a eficiência do método de classificação baseado na forma.

Tabela 21: Matriz de confusão - RNA região defeituosa

Categoria	Linha Horizontal	Linha Vertical	Região Contígua	Misto	Precisão (%)
Linha Horizontal	2	0	0	0	100%
Linha Vertical	1	7	1	0	78%
Região Contígua	0	0	7	0	100%
Misto	1	0	1	2	50%

O método baseado em RNA região defeituosa apresentou boas taxas de precisão para as categorias Linha Horizontal, Linha Vertical e Região Contígua, porém o método não se mostrou eficiente na classificação dentro da categoria Misto.

Tabela 22: Precisão global e coeficiente Kappa

	Método baseado na forma	RNA região defeituosa
Precisão global	86%	82%
Coeficiente Kappa	80%	74%

Os métodos de classificação avaliados em tempo real apresentaram taxas de precisão global parecidas, com uma pequena vantagem para o método baseado na forma. A partir dessas taxas pode-se dizer que a probabilidade de classificação correta desses métodos para uma nova imagem fica em torno de 80%.

Comparando os resultados desses métodos de classificação com os resultados encontrados na literatura, temos que as taxas de precisão global ficaram dentro da faixa de precisão dos trabalhos baseados em redes neurais (76,5% a 100%) (HABIBI, 2014). Porém, ficaram um pouco abaixo dos resultados dos métodos baseados em lógica fuzzy (96,55%) (KUMAR, RAGUPATHY, 2012) e SVM (94%) (DONGLI, 2013).

De acordo com o coeficiente Kappa, os métodos de classificação avaliados apresentaram concordância observada moderada, o que indica que os métodos estão suscetíveis a cometer erros na classificação de defeitos em tecido de malha.

Considerando os resultados do sistema de inspeção, podemos dizer que os resultados apresentados para tarefa de detecção e classificação automática de defeitos são satisfatórios, com a vantagem de a inspeção ter sido realizada em tempo real e em um cenário de inspeção semelhante ao da indústria têxtil.

6 CONCLUSÕES E PERSPECTIVAS FUTURAS

O presente trabalho foi orientado para o desenvolvimento de um sistema para inspeção automatizada de malha crua lisa. Diferentes técnicas de visão computacional foram combinadas para compor métodos de detecção e classificação de defeitos.

Diferente de trabalhos encontrados na literatura, o sistema proposto foi avaliado empregando uma base de imagens representativa, composta por um grande número de amostras adquiridas em condições de operação condizentes com as encontradas na indústria. Além dessa avaliação *off-line*, o sistema proposto também foi avaliado em tempo real, a partir de imagens da superfície do tecido de malha capturadas de um rolo de tecido sendo desbobinado por uma máquina revisadeira empregada na indústria têxtil.

Para a base de imagens, o sistema proposto apresentou excelentes taxas de detecção para diferentes tamanhos de subjanelas e de precisão global de classificação, mostrando-se robusto aos diferentes tipos de defeitos. As taxas de detecção ficaram entre 96,72% e 99,02% e a taxa de precisão global de classificação foi de 100% para os métodos baseado na forma e em RNA região defeituosa e 92% para o método baseado em RNA imagem inteira. Devido ao baixo custo computacional para o processamento de um ciclo de operação, 107,03 ms, a utilização desse sistema mostrou-se adequado para a aplicação de inspeção de tecido de malha em tempo real. O sistema proposto pode inspecionar a uma velocidade de 1,8 metros de tecido por segundo.

Os resultados da avaliação do sistema de inspeção em tempo real foram inferiores aos resultados da base de imagens. A taxa de detecção foi de 93,33% para subjanelas de tamanho 8x8 e a taxa de precisão global de classificação foi de 86% para o método baseado na forma e de 82% para o método baseado em RNA região defeituosa. Contudo, a taxa de detecção é superior à do inspetor humano e a taxa de classificação é condizente com os resultados apresentados na literatura para sistemas de classificação de defeitos em tecido baseados em redes neurais.

A detecção de defeitos que formam na imagem um artefato do tipo linha se mostrou como o maior desafio encontrado. A adoção do método de detecção baseado em estatística não se mostrou robusto na detecção desses defeitos por completo, principalmente para os defeitos do tipo linha horizontal, na qual em alguns casos o defeito não foi detectado. No entanto, o método se mostrou robusto na detecção de defeitos que formam na imagem um artefato do tipo região contígua, devido ao contraste desse tipo de defeito em relação ao restante da imagem.

O tipo de malha utilizado na avaliação do sistema mostra-se como uma variável importante na eficiência de um sistema de inspeção automatizada por visão. A gramatura

do fio utilizado na produção do tecido de malha influencia na textura do tecido produzido e, conseqüentemente, na textura das imagens capturadas. Dessa forma, os parâmetros dos métodos de detecção e classificação devem ser definidos em função do tipo de tecido.

O sistema de inspeção proposto atendeu aos requisitos de detecção, classificação e marcação do defeito. Os requisitos cálculo da área defeituoso e classificação final do rolo de tecido inspecionado não foram atendidos pelo sistema proposto. Para atender a esses requisitos é necessário determinar o comprimento defeituoso individual com maior exatidão, principalmente para os defeitos do tipo linha horizontal e vertical.

Como contribuições do trabalho desenvolvido temos a disponibilização de uma estrutura de hardware e software para auxiliar o desenvolvimento de sistemas de inspeção automatizada de tecido por visão. Além disso, também disponibilizamos uma base de imagens para que outros pesquisadores possam realizar testes e comparar seus resultados.

Como perspectivas futuras se pretende inicialmente agrupar mais câmeras ao sistema de aquisição de modo a cobrir toda a largura do rolo de tecido inspecionado e elaborar um procedimento para unir essas imagens sem que ocorra uma sobreposição das laterais comuns das imagens. Na sequência é necessário testar o sistema proposto *in loco* nas malharias do polo têxtil localizado na região de Blumenau. O objetivo será avaliar a eficiência do sistema para uma base maior de rolos de tecido de malha do mesmo tipo e para diferentes tipos de tecidos de malha crua e lisa. Estudar e desenvolver soluções para as deficiências encontradas, de modo a se obter um sistema para inspeção automatizado de tecido de malha que seja capaz de livrar o operador humano da tediosa tarefa de inspeção e que possibilite maior competitividade das empresas de malha do Brasil frente ao mercado internacional

Além disso, pretende-se avaliar a eficiência do sistema proposto em tecidos de malha beneficiados e em tecidos planos, sem estampas e com apenas uma cor.

REFERÊNCIAS BIBLIOGRÁFICAS

- ARAÚJO, Mário de. **Manual das malhas de trama**. Brasília: Direção Geral da Indústria, 1988, v.2.
- ASSOCIAÇÃO BRASILEIRA DE NORMA TÉCNICAS. **NBR 13175**: Defeitos em tecido de malha por trama. Rio de Janeiro, 1994.
- ASSOCIAÇÃO BRASILEIRA DE NORMA TÉCNICAS. **NBR 5426**: Planos de amostragem e procedimentos na inspeção por atributos. Rio de Janeiro, 1985.
- ASSOCIAÇÃO BRASILEIRA DE NORMA TÉCNICAS. **NBR 13461**: Tecido de malha por trama – Determinação do percentual de defeito. Rio de Janeiro, 1995.
- ASSOCIAÇÃO BRASILEIRA DE NORMA TÉCNICAS. **NBR 13484**: Tecidos planos - Método de classificação baseado em inspeção por pontuação de defeitos. Rio de Janeiro, 2004.
- BENEVENUTI, F. **Calibração de um Conjunto Binocular para Uso em Estereoscopia e Robótica Móvel**. 2001. Dissertação (Mestrado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis.
- CANNY, John. A Computational Approach to Edge Detection. **IEEE Trans. on Pattern Analysis and Machine Intelligence**, v. PAMI-8, n.6, p. 679-698, 1986.
- COSTA, A. C. R.; ROCHA, E. R. P. **Panorama da Cadeia Produtiva Têxtil e de Confecções e a Questão da Inovação**. BNDES, 2009. Disponível em: <http://www.bndes.gov.br/SiteBNDES/export/sites/default/bndes_pt/Galerias/Arquivos/conhecimento/bnset/Set2905.pdf>. Acesso em: 11 dez. 2014.
- DOCKERY, Alfred. Automated fabric inspection: assessing the current state of the art. **TECHEXCHANGE.com**, Jul 2001. Disponível em: http://www.techexchange.com/index_libraryTE_articles_subcategories.php. Acesso em: 10 ago 2015.
- DONGLI, Tao et al. Cloth Defect Classification Method Based on SVM. **International Journal of Digital Content Technology and its Applications**, v. 7, n. 3, p. 614-622, 2013.
- DUDA, R. O.; HART, P. E. Use of the Hough transformation to detect lines and curves in pictures. **Communications of the ACM**, v. 15, n.1, p. 11-1, 1972.
- FIESC. **Santa Catarina em Dados 2014**. v. 24. Florianópolis: FIESC, 2014.
- FRANÇA, J. A.; STEMMER, M. R.; FRANÇA, M. B. M. Calibração Monocular com Gabaritos 1D: Uma Ferramenta Prática com o Matlab. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 8, 2007, Florianópolis. **Anais...** Florianópolis, 2007.
- GOMES, Giancarlos; MACHADO, Denise Del Prá Netto; ALEGRE, Joaquin. Indústria têxtil de Santa Catarina e sua capacidade inovadora: estudo sob a perspectiva da eficiência, eficácia, custos e melhoria de processos. **Revista de administração e inovação**, São Paulo, v. 11, n.2, p. 273-294, abr./ jun. 2014.

GONZALEZ, Rafael C.; WOODS, Richard E. **Processamento Digital de Imagens**. 3 ed. São Paulo: Pearson Prentice Hall, 2010.

GONZALEZ, Rafael C.; WOODS, Richard E. **Processamento Digital de Imagens**. São Paulo: Edgard Blücher, 2000.

GÜVEN ÇELİK MAKINA. **Textile Machinery**. Disponível em: < <http://magazin.gcm.com.tr/Default.html> >. Acesso em: 9 nov. 2015.

HABIB, Tarek, et al. Automated Fabric Defect Inspection: A Survey of Classifiers. **International Journal in Foundations of Computer Science & Technology**, v. 4, n. 1, 2014.

HARALICK, R.M, SHANMUGAN, K.; DINSTEIN, Its'hak. Texture features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**, v. SMC-3, n. 6, p. 610-621, 1973.

HSU, C. W., LIN, C. J. A comparison of methods for multi-class support vector machines. **IEEE Transactions on Neural Networks**, v. 13, n.1, p.415-425, 2002.

HSU, C. W., CHANG, C. C., LIN, C. J. **A Practical Guide to Support Vector Classification**. Department of Computer Science, National Taiwan University, 2010. Disponível em: < <https://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf> >. Acesso em: 10 jan 2016.

ISLAM, Atiqul; AKHTER Shamim; MURSALIN Tumnun E. Automated Textile Defect Recognition System Using Computer Vision and Artificial Neural Networks. **International Journal of Mechanical, Aerospace, Industrial, Mechatronic and Manufacturing Engineering**, v. 2, n.1, p. 110-115, 2008.

KUMAR, Ajay. Computer Vision-based Fabric Defect Detection: A Survey. **IEEE Transactions on Industrial Electronics**, v. 55, p. 348-363, 2008.

KUMAR, K.V.Naveen; RAGUPATHY, U.S. An Intelligent Scheme for Fault Detection in Textile Web Materials. **International Journal of Computer Applications**, v. 46, n. 10, p. 24-29, 2012.

LANDIS, Richard J.; KOCK, Gary G. The Measurement of Observer Agreement for Categorical Data. **Biometrics**, v. 33, n. 1, p.159-174, 1977.

LOESCH, C., SARI, S. T. **Redes neurais artificiais: fundamentos e modelos**. 1 ed. Blumenau: Editora da Furb, 1996.

MAHAJAN P.M.; KOLHE S.R.; PATIL P.M. A review of automatic fabric defect detection techniques. **Advances in Computational Research**, v. 1, n. 2, p. 18-29, 2009.

MARQUES FILHO, Ogê; VIEIRA NETO, Hugo. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999

NEVES, Luis Antônio; VIEIRA NETO, Hugo; GONZAGA, Adilson. **Avanços em Visão Computacional**. Curitiba: Omnipax, 2012.

NGAN, Henry Y. T.; PANG, Grantham K. H; YUNG, Nelson H. C. Automated fabric defect detection - A review. **Image and Vision Computing**, v. 29, n. 7, p. 442-458, 2011.

OTSU, Nobuyuki. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man and Cybernetics**, v. 9, p. 62-66, 1979.

PINHEIRO, Gilson Marques; LIMA, Francisco de Paula A. Variabilidades dos defeitos do produto e desempenho do inspecionista. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 27, 2007, Foz do Iguaçu. **Anais...** Rio de Janeiro: ABEPRO, 2007. p. 1-10.

SILVA, José Felisberto Cardoso da. **Malharia circular**: controle da qualidade no processo de fabricação. Rio de Janeiro: SENAI, 1999.

SISSONS, Juliana. **Malharia**. Porto Alegre: Bookman, 2012.

SMITH, Gary W. **Controle de qualidade na indústria de malhas**. 2 ed. Rio de Janeiro: CETIQT, 1986.

SOUTO, M. C. P. et al. Técnicas de Aprendizado de Máquina para problemas de Biologia Molecular. In: **III Jornada de Mini-Curso de Inteligência Artificial** – Livro Texto, capítulo Técnicas de Aprendizado de Máquina para Problemas de Biologia Molecular, p. 103-152, SBC, 2003.

SRINIVASAN, K., et al. FDAS: A knowledge-based frame detection work for analysis of defects in woven textile structures, **Journal of Textile Institute**, vol. 83, n. 3, p. 431-447, 1992.

STIVANELLO, M. E. **Desenvolvimento de uma Biblioteca para Sistemas de Visão Estereoscópica para Robótica Móvel**. 2008. Dissertação (Mestrado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis.

TRUCCO, E.; VERRI, A. **Introductory Techniques for 3-D Computer Vision**, 1 ed. Prentice Hall, 2003.

VERNON, David. **Machine Vision**: Automated visual inspection and Robot vision. London: Prentice Hall, 1991. Disponível em: <<http://homepages.inf.ed.ac.uk/rbf/BOOKS/VERNON/vernon.htm>>. Acesso em: 5 jul 2015.

ZHANG, Y. H. et al. An intelligent model for detecting and classifying color-textured fabric defects using genetic algorithms and the Elman Neural Network. **Textile Research Journal**, v. 81, n. 17, p. 1772-1787, 2011.

ZHANG, Z. A Flexible New Technique for Camera Calibration. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 11, p. 1330-1334, 2000.