

# Detecção de defeitos visuais em tecidos utilizando *Wavelets* e algoritmos de aprendizado de máquina

Felipe Vieira Roque<sup>1</sup>, Luiz Antonio Macarini<sup>1</sup>, Yuri Crotti<sup>1</sup>,  
Tiago Oliveira Weber<sup>2</sup>, Cristian Cechinel<sup>1</sup>

<sup>1</sup>Coordenadoria Especial Interdisciplinar de Tecnologias  
da Informação e Comunicação  
Universidade Federal de Santa Catarina (UFSC)  
Araranguá – SC – Brasil

<sup>2</sup>Departamento de Computação  
Universidade Federal de Santa Catarina (UFSC)  
Araranguá – SC – Brasil

{felipe.roque, luiz.buschetto, yuri.crotti}@posgrad.ufsc.br

{tiago.weber, cristian.cechinel}@ufsc.br

**Abstract.** *This work proposes the use of Discrete Wavelet Transform (DWT) to extract features from fabric images, aiming to detect visual defects. The images come from a database created by the authors themselves and made available online. In addition, four classification algorithms (Support Vector Machine, k-Nearest Neighbor, Decision Tree, and Naive Bayes) were compared to find the one that would yield the best performance on accuracy and processing time. Results obtained using MATLAB showed that k-Nearest Neighbor brought the best performance when comes to accuracy and the Decision Tree in relation to processing time.*

**Resumo.** *Este trabalho propõe a utilização de Discrete Wavelet Transform (DWT) para a extração de características de imagens de tecidos, tendo como objetivo detectar defeitos visuais. As imagens são provenientes de uma base de dados criada pelos próprios autores, disponibilizada publicamente online. Além disso, quatro algoritmos de classificação (Support Vector Machine, k-Nearest Neighbor, Árvore de Decisão e Naive Bayes) foram comparados visando encontrar aquele que traria o melhor resultado em relação a taxa de acerto e tempo de processamento. Os resultados obtidos utilizando o MATLAB mostraram que o k-Nearest Neighbor trouxe o melhor desempenho em relação a taxa de acerto e a Árvore de Decisão em relação ao tempo de processamento.*

## 1. Introdução

Técnicas de processamento de imagem podem ser uma ferramenta poderosa para detectar defeitos na linha de produção, auxiliando a indústria com informações precisas que lhe ajudam a preservar a qualidade de produção [Watpade et al. 2014]. Mais especificamente, o reconhecimento de padrões vem sendo o responsável por categorizar dados, sejam eles medidos ou observados, como membro de uma entre duas ou mais classes ou categorias. Sua aplicação é muito ampla, podendo ser utilizado em qualquer situação onde necessite-se de informação visual para tomar uma decisão [Bow 2002].

A indústria têxtil nacional é a quinta maior do mundo. É considerada uma das mais poderosas e está entre os três setores mais importantes da economia mundial [Berlin 2014]. O sucesso da tecelagem está significativamente atrelado ao seu sucesso em reduzir defeitos de fabricação. Existem tecidos de primeira e de segunda qualidade, onde os primeiros são livres de defeito, enquanto que os últimos podem conter alguns em sua textura ou na superfície. Por ser um produto que passa por processos delicados, é muito difícil conseguir produtos de primeira qualidade. Assim grande parte da inspeção e verificação de qualidade diz respeito a redução da ocorrência de defeitos nos tecidos durante os estágios iniciais de fabricação [Malek 2012]. O preço de um tecido com defeito reduz em cerca de 45% a 65% o seu valor de venda [Dastoor et al. 1994].

A realização do controle de qualidade (quando feito por uma pessoa) é um processo extremamente cansativo, uma vez que a capacidade de processamento visual humana tem suas limitações e fraquezas. A inspeção realizada por pessoas tem se tornado obsoleta no que diz respeito a detecção de defeitos. Um dos fatores que levam a essa constatação é a produtividade. Uma pessoa consegue inspecionar aproximadamente 20 metros de tecido por minuto. Isso mostra o gargalo que existe no quesito produtividade. Sem contar os outros inúmeros problemas que o sistema visual humano pode sofrer, como por exemplo, o cansaço [Kumar 2008].

Neste contexto, este trabalho apresenta uma solução para detecção de defeitos visuais em produtos têxteis. A base de dados foi criada pelos autores e divide suas amostras em quatro categorias: sem defeitos, amostras com furo, com fio faltante e com manchas. Para a extração de características das amostras será utilizada a Transformada *Wavelet*. Já na etapa de classificação, serão testados quatro algoritmos, sendo eles o *Support Vector Machine* (SVM), o *k-Nearest Neighbor* (k-NN), a *Árvore de Decisão* e o *Naive Bayes*. Além disso, será utilizado o Otimizador Bayesiano para encontrar os parâmetros ótimos para estes classificadores.

O restante do trabalho está organizado da seguinte maneira: na Seção 2, são apresentados os trabalhos relacionados. Na Seção 3, é apresentada uma visão geral do sistema, além da descrição de todas as etapas realizadas para obtenção dos resultados. Estes, são apresentados na Seção 4. E por último, na Seção 5, são mostradas as conclusões obtidas a partir da realização deste experimento, além dos trabalhos futuros pretendidos pelos autores.

## 2. Trabalhos Relacionados

A detecção de defeitos em tecidos é uma área muito ampla, onde vários trabalhos foram realizados com o intuito de aplicar visão computacional neste contexto. Por esta razão, várias abordagens foram utilizadas visando resolver este problema. Na literatura, pode-se encontrar muitos pesquisadores combinando ferramentas e propondo novas soluções, onde algumas delas são apresentadas abaixo.

Em [Abdellah et al. 2014], técnicas de segmentação de imagem foram utilizadas para a extração de características. Para a classificação, foi utilizado um SVM. Um ponto negativo do trabalho é a base de dados, que era relativamente pequena, com apenas 76 exemplos. Já em [Rajpoot and Rajpoot 2004], também foi utilizado um SVM para classificação. Porém, para a extração de características, foram utilizadas *Wavelets*. A utilização de *Wavelets* também é encontrada em [Kim et al. 1999]. Diferente do que é apresentado

nos trabalhos com classificadores, as imagens são testadas com uma *Wavelet* otimizada que ajuda a detectar os defeitos de alta, baixa e média frequência. O autor ainda mostra a diferença significativa entre a relação sinal ruído para as altas e médias frequências.

Combinando duas técnicas visando encontrar o melhor resultado, [Zhang et al. 2015] mostra resultados robustos, sendo este o principal ponto positivo do trabalho. Os resultados foram obtidos combinando a extração de características por *Gray-Level Co-Occurrence Matrix* e *Local Binary Pattern*. Os extratores atuando sozinhos tiveram resultados piores do que atuando juntos. Outra característica deste trabalho é a utilização de uma Rede Neural Artificial como classificador. Ressalta-se que os autores utilizaram a base de dados *TILDA* para realizar o experimento.

Ainda utilizando a base de dados *TILDA*, em [Basu et al. 2012] é utilizado um método de sub-imagem baseado em *Principal Component Analysis* para extrair as características das imagens. Um SVM multi-classe foi utilizado para classificar as amostras. Utilizando uma abordagem de extração conhecida como *Saliency Map*, em [Zhang et al. 2017] obteve-se taxas de acerto bastante expressivas. Foi utilizado um SVM binário, já que existiam apenas duas classes na base de dados.

Em [Habib et al. 2016], são usadas métricas estatísticas tais como média de intensidade de escala de cinza da imagem para a extração de características. O algoritmo de classificação utilizado foi o Bayesiano. A utilização do classificador Bayesiano também pode ser encontrada em [Mottalib et al. 2015]. Este trabalho utiliza uma abordagem estatística, com ênfase em dados geométricos, como o número de regiões com defeitos.

### 3. Metodologia

Um sistema de processamento digital de imagens é constituído por um conjunto de etapas capazes de produzir um resultado a partir do *domínio do problema* [Pedrini and Schwartz 2008]. Sendo assim, escolheu-se por utilizar um sistema com as etapas semelhantes às propostas pelo autor. Esta, pode ser vista na Figura 1.




Figura 1. Etapas da metodologia adotada

#### 3.1. Aquisição e Tratamento das Imagens

A aquisição das imagens é um passo fundamental na execução desta metodologia. Tanto o instrumento de aquisição, o protótipo e a câmera, e até mesmo a posição e iluminação podem interferir nesse aspecto. A câmera utilizada no experimento possui uma resolução máxima de  $3264 \times 2448$  pixels, com uma abertura de sensor de  $F/2$  de 8 megapixels.

Desse modo, para garantir a qualidade das imagens adquiridas decidiu-se realizar a aquisição em um ambiente controlado, com iluminação artificial. Isso significa tentar reduzir ao máximo a atuação de elementos externos sobre as imagens adquiridas. O principal fator de influência externa é a iluminação, que impacta diretamente na qualidade das imagens.

O objetivo de fazer a aquisição em um ambiente controlado é diminuir a interferência da luz externa, evitando ruídos no momento da aquisição das imagens. O ambiente de aquisição utilizado contém iluminação interna, colocada de modo que evite a criação de sombras ou mesmo reflita luz no tecido. Assim, os detalhes podem ser mais facilmente capturados pela câmera. Contudo, mesmo com este sistema que isola uma determinada parte do tecido, foram encontradas dificuldades na análise da imagem. Para reduzir os efeitos de imperfeições, tais como dobras e sujeira no tecido, optou-se por analisar, inicialmente, as partes perfeitas do mesmo.

As imagens capturadas passaram por uma seleção prévia, de modo a retirar aquelas que não representassem as classes em questão. O principal problema encontrado foi a falta de foco na aquisição das imagens. Estas, se utilizadas para treinamento do modelo, gerariam apenas ruído. Isso resulta em diferenças significativas na etapa de processamento com a Transformada *Wavelet*.

Essa classificação prévia das imagens foi feita por uma pessoa capacitada, em parceria com a empresa *Loop Jeans*. Com as imagens selecionadas, o próximo passo foi colocar o rótulo (do inglês, *label*) em cada imagem. Esta etapa é importante para algoritmos de aprendizado supervisionado, já que estes rótulos serão usados pelo classificador para a geração o modelo.

O maior problema nesta abordagem foi a diferença visual entre os exemplos bons (sem defeitos). Na extração de características ficou evidente que mesmo em um ambiente controlado não foi possível evitar totalmente os ruídos, mesmo alterando a posição do sistema de iluminação. Assim, decidiu-se por analisar somente uma porção da imagem, o centro da mesma, onde existia menos ruído. Estas constatações foram feitas através de testes iniciais visando encontrar a configuração ideal. Deste modo, a imagem foi recortada para uma posterior extração de características. A Tabela 1 apresenta a divisão entre os padrões de amostras presentes na base de dados<sup>1</sup> criada. A Figura 2 apresenta exemplos das classes de imagem de tecidos contidas na base de dados criada. Ressalta-se o fato de que o tecido utilizado é do tipo "plano".

Tabela 1. Quantidades de amostras presentes na base de dados

Classe	Tipo de Defeito	Quantidade
C1	Sem Defeitos	197
C2	Furo	122
C3	Fio Faltante	86
C4	Mancha	74
Total		479

### 3.2. Aplicação da Transformada *Wavelet* e Extração das Informações Estatísticas

Tendo-se as imagens pré-processadas, pode-se então aplicar a Transformada *Wavelet* nestas. Este algoritmo retorna como resultado quatro coeficientes. O coeficiente de aproximação *CA* e os coeficientes de detalhes diagonais e verticais. Com estes valores é possível realizar diferentes abordagens para a criação de um vetor de características. Para

<sup>1</sup>A base de dados pode ser encontrada em: <https://bit.ly/2HXZPU3>




Figura 2. Padrões de amostras presentes na base de dados

este trabalho, decidiu-se por utilizar dados estatísticos de Média, Variância, Energia e Entropia.

Estes dados estatísticos foram computados para cada um dos coeficientes. Como se trata de uma imagem, o Coeficiente de Aproximação resultante do filtro passa-baixa nas linhas e colunas é uma das matrizes computadas. Os Coeficientes de Detalhe são resultado do filtro passa-baixa e passa-alta aplicados às linhas e colunas, e resultam em três matrizes. Cada uma destas terá seus próprios dados estatísticos. Ou seja, as quatro variáveis serão calculadas para cada matriz, resultando em um vetor de características com 16 elementos.

Para o presente trabalho foi utilizada uma *Wavelet* de um nível da família de *Daubechies*. A *db1* ou *haar*, resulta em uma matriz com a metade do número de índices nas colunas e nas linhas. Essa matriz é utilizada para montar a base de dados desejada. Foram testadas outras *Wavelets*, também da família de *Daubechies*. Porém, nenhuma apresentou resultado melhor que a *db1*.

Estes vetores de características concatenados formam uma matriz e esta é usada para realizar o treinamento do modelo e a classificação das imagens. As linhas da matriz representam as amostras e as colunas representam as características de cada amostra. Os dados podem ser testados por diferentes classificadores, com diferentes métodos.

### 3.3. Otimização

Praticamente nenhum classificador é livre de parâmetros [Snoek et al. 2012]. Sendo assim, métodos ou algoritmos podem ser utilizados para encontrar os ótimos. No presente trabalho todos os algoritmos de classificação apresentam parâmetros. O fato é que encontrar a melhor combinação destes é difícil, requer conhecimentos específicos e certa experiência com o algoritmo que está sendo utilizado. Outro ponto importante é que os parâmetros também variam de acordo com o problema que está sendo tratado. Portanto, para cada problema, um dado conjunto de parâmetros pode funcionar melhor que outros.

Na etapa de otimização, foram realizadas 1000 iterações para cada classificador, onde esta quantidade foi obtida experimentalmente. Dentre os resultados analisados, optou-se por levar em conta o tempo de otimização, de treinamento, de predição e taxa de acerto. Na etapa de otimização, é realizado o treinamento e teste com validação cruzada.

Optou-se por utilizar *k-Fold Cross Validation*, com valor de  $k = 10$ . A utilização deste método previne que o modelo seja levado a um *overfitting* [Breiman et al. 1984]

### 3.4. Classificação

Na etapa de classificação, foram testados quatro algoritmos. Estes, precisam que seus parâmetros sejam ajustados de acordo com o problema, visando obter o melhor resultado. Para o SVM foi utilizada uma codificação "Um Contra Um", com um *BoxConstraint* de 940,68. O *Kernel* utilizado foi o *Radial Basis Function*, com uma escala de 3,76. Além disso, os dados foram normalizados entre [-1 1].

Já para o k-NN, o otimizador retornou um número  $k$  de vizinhos igual a 2. A função de distância encontrada foi a *Mahalanobis*, onde o peso da distância foi a Raiz Inversa. Não foi utilizado expoente, assim como os dados de entrada não foram padronizados (consequência da utilização desta função de distância).

Em relação a Árvore de Decisão, o otimizador retornou um tamanho de folha mínimo igual a 5. Além disso, o número máximo de divisões foi 190 e o critério de divisão foi o desvio. Por último, para o *Naive Bayes*, utilizou-se uma distribuição *Kernel* e um *kernel* Triangular. A Largura encontrada pelo otimizador foi de  $1,59 \times 10^{14}$ .

## 4. Resultados e Discussões

Os resultados deste trabalho foram obtidos em uma unidade de processamento com Intel(R) Core(TM) i5-4210U CPU @ 1.70GHz, 8GB de memória RAM, HD de 1TB 5400RPM, uma placa de vídeo NVIDIA GeForce 840M com Windows 10 64-bits e MATLAB R2016b. É importante deixar claro que apesar de haver uma GPU dedicada, ela não foi utilizada para realizar nenhum tipo de processamento (paralelo ou não). A Tabela 2 resume os resultados obtidos em relação aos tempos de processamento.

Tabela 2. Resultados obtidos em relação aos tempos necessários para cada etapa

	SVM	k-NN	Árvore de Decisão	Naive Bayes
Tempo de Otimização	4000,8s	618,9s	589,5s	2532,2s
Tempo de Treinamento	3,48s	5,59s	2,18s	7,99s
Tempo de Predição	$4,00 \times 10^{-4}s$	$5,55 \times 10^{-4}s$	$2,27 \times 10^{-4}s$	$1,19 \times 10^{-3}s$
Objetivo Mínimo	0,10	0,09	0,16	0,41
Taxa de Acerto	89,8%	91%	83%	58,70%

Em relação ao tempo de otimização, a árvore de decisão foi o algoritmo que apresentou o melhor resultado, necessitando de 589,5s na etapa de otimização. O destaque negativo em relação a este quesito vai para o SVM. Isto aconteceu porque, dentre os classificadores, este algoritmo é o que possui a maior complexidade.

Já na etapa de treinamento, o algoritmo que apresentou o melhor resultado em relação ao tempo foi novamente a árvore de decisão. Porém, nesta etapa o SVM obteve o segundo melhor tempo. O pior resultado foi obtido pelo *Naive Bayes*. Para a predição, tem-se novamente como melhor resultado a árvore de decisão, mantendo o SVM em segundo lugar e o *Naive Bayes* como pior candidato. Porém, é necessário frisar que para todos os classificadores, o tempo fica abaixo do necessário para ser aplicado em uma linha de produção.

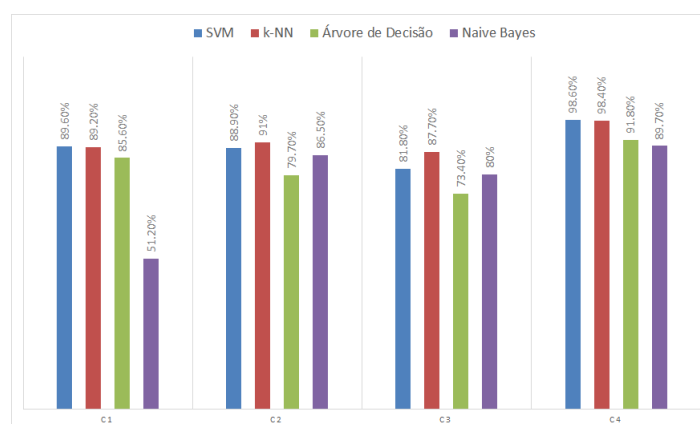


Figura 3. Taxa de acerto (acurácia) para cada classe

Em relação a otimização, o k-NN apresentou o melhor resultado, uma vez que a função objetivo saiu de 0,39 para chegar ao valor de 0,09, obtendo assim, uma melhora significativa. Inicialmente, o SVM possuía um objetivo de 0,59 e, passando pelo processo, atingiu um mínimo de 0,10. Novamente o *Naive Bayes* apresentou o pior resultado. A primeira estimativa do otimizador foi de pouco mais de 0,42, enquanto a melhor foi de cerca de 0,41, ainda sendo o valor mais alto entre os classificadores.

O melhor resultado em relação a taxa de acerto foi obtida utilizando o k-NN, com 91%. Este é um resultado bastante expressivo, principalmente se tratando de uma técnica, em teoria, mais simples que o SVM, por exemplo. Este, por sua vez, vem em segundo lugar com 89,8% de acerto. Já as árvores de decisão apresentaram o melhor desempenho geral em relação ao tempo de processamento necessário para as três etapas deste trabalho. Em relação a taxa de acerto, obteve 83%, mantendo-se em terceiro lugar. O *Naive Bayes*, que obteve os piores resultados em relação ao tempo de processamento, também obteve a menor taxa de acerto, com 58,70%, abaixo dos demais classificadores.

A Figura 3 mostra as taxas de classificação correta (acurácia) de acordo com cada classe da base de dados. Os resultados mostram que, observando as amostras sem defeitos (C1), o *Naive Bayes* apresentou um resultado bem abaixo dos demais classificadores. O restante dos algoritmos apresentou resultados muito parecidos. O k-NN foi o classificador que apresentou as taxas de classificações corretas mais equilibradas dentre todos os tipos de amostras presentes na base de dados. Em C4, o SVM e o k-NN se destacaram, onde ambos atingiram mais de 98% de acerto. O *Naive Bayes* apresentou o seu pior resultado em C1, onde a quantidade de dados é maior.

A Figura 4 mostra as taxas de verdadeiros positivos de acordo com cada classe de amostra presente na base de dados. Em outras palavras, por exemplo, representa os tecidos que são da classe C1 e o algoritmo os classificou corretamente. Pode-se observar que as maiores taxas de verdadeiros positivos são aquelas relacionadas as amostras sem defeitos (C1). Isso se dá pela maior quantidade de amostras presentes na base de dados. O classificador que obteve o melhor resultado foi o *Naive Bayes*. Porém, este apresentou resultados ruins nos outros três tipos de amostras, ficando novamente bem abaixo do restante dos classificadores.

Observando o SVM e o k-NN, pode-se perceber que o segundo apresentou melho-




Figura 4. Taxas de verdadeiros positivos

res resultados nos tipos de amostras C1 e C2. Já em C3 e C4, o SVM apresentou melhores resultados, mostrando que a quantidade de amostras disponíveis pode interferir no desempenho do classificador. Em C4, onde há a menor quantidade de dados disponíveis, o melhor resultado foi obtido pelo SVM, apresentando uma acentuada diferença em relação aos outros algoritmos.

A grande vantagem da Árvore de Decisão em relação à outros algoritmos é sua velocidade, tanto de otimização, quanto de treinamento e predição. Esses valores são os melhores entre todos os classificadores aqui estudados, mostrando que este se encaixa na resolução do problema abordado. Contudo, sua acurácia não foi tão alta, o que pesa contra em relação à sua escolha.

A melhor taxa de acerto obtida neste trabalho foi 91%, atingida com a utilização do k-NN. Já em [Abdellah et al. 2014], foi encontrada uma taxa de acerto maior, 96,15%. Porém, a base de dados deste trabalho é diferente, o que dificulta a comparação de resultados. No entanto, as metodologias utilizadas são semelhantes. Em [Rajpoot and Rajpoot 2004], os resultados são obtidos a partir da medição da taxa de erro nas duas bases de dados. Para uma delas este valor foi de 13,65%. Já para a outra foi de 7,6%. Em [Kim et al. 1999] os resultados são medidos através do *Signal-to-noise Ratio* (SNR). Na detecção de defeitos horizontais, obteve-se um SNR de 16,56. Já em relação aos defeitos verticais, 7,62. O autor considera estes resultados como robustos, apesar de ser difícil compará-los com os obtidos neste.

Em [Zhang et al. 2015] os resultados obtidos foram bons, se comparados à literatura, com acurácia de 97,6% para o melhor resultado. Este foi obtido com a utilização de uma Rede Neural Artificial. Ressalta-se ainda que os autores utilizaram a base de dados *TILDA* para realizar o experimento. Ainda utilizando esta base de dados, em [Basu et al. 2012] foi atingida uma taxa de acerto de 96,36%. Em [Zhang et al. 2017], os autores atingiram 98,60% de acerto. Em [Mottalib et al. 2015], a taxa de acerto foi relativamente alta, se comparada com os outros trabalhos, atingindo 99,19%. De forma geral, os resultados dos trabalhos mostram que os obtidos neste podem ser considerados satisfatórios. Como evidenciado anteriormente, fica difícil a comparação uma vez que as bases de dados são diferentes. Ainda, alguns trabalhos não apresentam resultados em forma de taxa de acerto.



## 5. Conclusão

Este trabalho propôs uma abordagem para verificação de defeitos visuais em tecidos. Esta solução foi fundamentada em processamento de imagens e aprendizado de máquina. Em busca da melhor solução, utilizou-se como algoritmo de extração a Transformada *Wavelet* e quatro classificadores. A solução foi implementada em MATLAB.

Em relação a taxa de acerto, o melhor classificador para este problema foi o k-NN, com uma taxa de acerto de 91%. Outro ponto importante a se destacar é que a Transformada *Wavelet* se mostrou uma técnica poderosa na análise das imagens, uma vez que a mesma possibilitou uma diferenciação entre as classes. O Otimizador de Bayes teve papel fundamental na escolha dos parâmetros dos classificadores. Todos os algoritmos de classificação apresentaram tempo para a predição extremamente baixos, podendo ser aplicados em soluções industriais.

A escolha do classificador depende da aplicação em que este será utilizado. Neste trabalho, o k-NN apresentou a melhor taxa de acerto. Porém, a Árvore de Decisão apresentou os melhores resultados em relação ao tempo de processamento, levando em conta as três etapas presentes no sistema. Ainda assim, o tempo de processamento necessário para o k-NN é suficientemente baixo para ser utilizado nesta aplicação. Logo, este *trade-off* entre taxa de acerto e tempo de processamento deve ser levado em conta no momento da escolha de um algoritmo de classificação.

Outra contribuição deste trabalho foi a criação da base de dados. Apesar de existirem outros trabalhos diretamente relacionados a este tema, nem todas as bases de dados utilizadas são disponibilizadas pelos autores, dificultando a replicação do trabalho. Esta, além de conter amostras sem defeitos, traz amostras com três tipos de avarias bastante comuns na indústria têxtil.

Ressalta-se que existem algumas características que poderiam melhorar o desempenho em termos de acertos gerais. A principal delas é o fazer melhorias no ambiente para a aquisição das imagens, que neste trabalho se limitou a um ambiente com iluminação interna. As variações nas imagens, fato indesejado, foram muito difíceis de evitar. Assim, a melhora no sistema de iluminação e na câmera possivelmente traria melhorias ao desempenho do sistema de classificação.

Como trabalhos futuros, espera-se desenvolver um sistema de aquisição que garanta uma menor variação intraclasses. Além disso, espera-se testar outros algoritmos de otimização. Ainda, fazer a utilização de outras técnicas de extração de características e fazer a combinação entre dois ou mais algoritmos. Também espera-se testar outros classificadores e realizar testes usando métodos de *Deep Learning*, como a *Convolutional Neural Network*.

## Referências

- Abdellah, H., Ahmed, R., and Slimane, O. (2014). Defect detection and identification in textile fabric by SVM method. *IOSR Journal of Engineering (IOSRJEN)*, 4(12):69–77.
- Basu, A., Chandra, J. K., Banerjee, P. K., Bhattacharyya, S., and Datta, A. K. (2012). Sub image based eigen fabrics method using multi-class SVM classifier for the detection and classification of defects in woven fabric. In *Computing Communication &*

- Networking Technologies (ICCCNT), 2012 Third International Conference on*, pages 1–6. IEEE.
- Berlin, L. G. (2014). A indústria têxtil brasileira e suas adequações na implementação do desenvolvimento sustentável. *ModaPalavra e-periódico*, 7(13):15–45.
- Bow, S.-T. (2002). *Pattern recognition and image preprocessing*. Marcel Dekker New York.
- Breiman, L., Friedman, J., Stone, C. J., and Olshen, R. A. (1984). *Classification and regression trees*. CRC press.
- Dastoor, P., Radhakrishnaiah, P., Srinivasan, K., and Jayaraman, S. (1994). SDAS: a knowledge-based framework for analyzing defects in apparel manufacturing. *Journal of the Textile Institute*, 85(4):542–560.
- Habib, M. T., Shuvo, S. B., Uddin, M. S., and Ahmed, F. (2016). Automated textile defect classification by bayesian classifier based on statistical features. In *Computational Intelligence (IWCI), International Workshop on*, pages 101–105. IEEE.
- Kim, S., Lee, M. H., and Woo, K.-B. (1999). Wavelet analysis to fabric defects detection in weaving processes. In *Industrial Electronics, 1999. ISIE'99. Proceedings of the IEEE International Symposium on*, volume 3, pages 1406–1409. IEEE.
- Kumar, A. (2008). Computer-vision-based fabric defect detection: A survey. *IEEE transactions on industrial electronics*, 55(1):348–363.
- Malek, A. S. (2012). *Online fabric inspection by image processing technology*. PhD thesis, Université de Haute Alsace-Mulhouse.
- Mottalib, M. M., Rokonuzzaman, M., Habib, M. T., and Ahmed, F. (2015). Fabric defect classification with geometric features using bayesian classifier. In *Advances in Electrical Engineering (ICAEE), 2015 International Conference on*, pages 137–140. IEEE.
- Pedrini, H. and Schwartz, W. R. (2008). *Análise de imagens digitais: princípios, algoritmos e aplicações*. Thomson Learning.
- Rajpoot, K. M. and Rajpoot, N. M. (2004). Wavelets and support vector machines for texture classification. In *Multitopic Conference, 2004. Proceedings of INMIC 2004. 8th International*, pages 328–333. IEEE.
- Snoek, J., Larochelle, H., and Adams, R. P. (2012). Practical bayesian optimization of machine learning algorithms. In *Advances in neural information processing systems*, pages 2951–2959.
- Watpade, A. B., Amrutkar, M. S., Bagecha, N. Y., and Vaidya, A. (2014). Qcuip: Quality control using image processing. *International Journal of Engineering Research and Applications*, 4:15–18.
- Zhang, H., Hu, J., and He, Z. (2017). Fabric defect detection based on visual saliency map and SVM. In *Computational Intelligence and Applications (ICCIA), 2017 2nd IEEE International Conference on*, pages 322–326. IEEE.
- Zhang, L., Jing, J., and Zhang, H. (2015). Fabric defect classification based on LBP and GLCM. *Journal of Fiber Bioengineering and Informatics*, 8(1):81–89.