
Metodologia para criação de descritores de *Capsicum ssp* através de imagens

Valdomiro Caetano Martins



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
BACHARELADO EM SISTEMAS DE INFORMAÇÃO

Monte Carmelo - MG
2016

Valdomiro Caetano Martins

Metodologia para criação de descritores de
Capsicum ssp através de imagens

Trabalho de Conclusão de Curso apresentado
à Faculdade de Computação da Universidade
Federal de Uberlândia, Minas Gerais, como
requisito exigido parcial à obtenção do grau de
Bacharel em Sistemas de Informação.

Área de concentração: Ciência da Computação

Orientador: Thiago Pirola Ribeiro

Monte Carmelo - MG


2016

Valdomiro Caetano Martins


Metodologia para criação de descritores de *Capsicum ssp* através de imagens

Trabalho de conclusão de curso apresentado
à Faculdade de Computação da Universidade
Federal de Uberlândia, Minas Gerais, como
requisito exigido parcial à obtenção do grau
de Bacharel em Sistemas de Informação.

Trabalho Aprovado. Monte Carmelo - MG, Brasil, 09 de Dezembro de 2016:



Prof. MSc. Thiago Pirola Ribeiro
Orientador



Prof^ª. Dr^a. Ana Cláudia Martinez



Prof. Dr. Daniel Duarte Abdala

Monte Carmelo - MG, Brasil
2016

Dedico este trabalho primeiramente à Deus por ter me dado todos os recursos necessário para a minha existência, aos meus Professores, Familiares e Amigos que contribuíram para mais esse passo importante em minha vida.

Agradecimentos

Agradeço primeiramente a Deus, fonte da minha existência, por estar presente em cada momento da minha vida.

Agradeço a minha Família em especial a minha Mãe e meu Pai que tanto contribuíram para mais essa conquista em minha vida.

A todos os professores e servidores do Curso de Sistemas de Informação da Universidade Federal de Uberlândia Campus Monte Carmelo, em especial, ao professor Thiago Pirola Ribeiro, meu orientador, pela compreensão e pelo total apoio para que este trabalho fosse realizado. No demais, agradeço a todos aqueles que contribuíram de alguma forma para a realização deste trabalho.

*“O êxito da vida não se mede pelo caminho que você conquistou, mas sim pelas
dificuldades que superou no caminho.”
(Abraham Lincoln)*

Resumo

As texturas em imagens proporcionam diversas informações sobre os objetos em estudo. Diversas técnicas existentes na literatura utilizam essas texturas em imagens para descrevê-las e classificá-las. Neste trabalho foram analisados os descritores HOG, LBP, SIFT, SURF e estatísticas de primeira ordem para imagens de pimentas (*Capsicum ssp*). Foram avaliadas as uniões dos descritores analisados e obteve-se uma acurácia acima de 90% com uma quantidade reduzida de descritores. Para melhor validação do método proposto, utilizou-se as bases de imagens públicas Brodatz, Vistex, Outex e UIUCTex e, o método proposto novamente conseguiu resultados superiores aos da literatura.

Palavras-chave: Processamento de Imagens, Textura, Descritores, Classificação, *Capsicum ssp*.

Lista de ilustrações

Figura 1 –	<i>Telas ilustrando o BG Capsicum.</i>	16
Figura 2 –	<i>Etapas no Processamento Digital de Imagens (GONZALEZ; WOODS, 2010).</i>	22
Figura 3 –	<i>Operação básica do HOG. Adaptado de (INTEL, 2016).</i>	24
Figura 4 –	<i>Operação básica do LBP: (A) Pixels de um imagem, (B) Valor de Intensidade dos Pixels da Imagem, (C) Padrão Binário obtido para o pixel central, (D) Valor final do pixel central convertido do valor binário.</i>	24
Figura 5 –	<i>Gradientes e Descritores SIFT (LOWE, 2004).</i>	26
Figura 6 –	<i>Derivadas parciais de segunda ordem da Gaussiana nas direções y e xy (A e B) e a aproximação das derivadas por filtros do tipo caixa (C e D). Regiões em cinza tem valores iguais a zero (BAY; TUYTELAARS; Van Gool, 2006).</i>	27
Figura 7 –	<i>Exemplo da Classificação utilizando o KNN. Modificado de Sousa (2013).</i>	29
Figura 8 –	<i>Exemplo do LDA (LI; WANG, 2014).</i>	30
Figura 9 –	<i>Exemplo de classificação das duas classes mediante um hiperplano. Modificado de (RAM, 2014).</i>	31
Figura 10 –	<i>Representação do Método proposto.</i>	33
Figura 11 –	<i>Detalhamento do Método Proposto.</i>	34
Figura 12 –	<i>Imagens exemplificando as 3 situações descritas.</i>	35
Figura 13 –	<i>Exemplos das Imagens Fotografadas: (a) Bhut Jolokia, (b) Bode Amarela e (c) Bode Vermelha.</i>	35

Lista de tabelas

Tabela 1	– Tabela de índices dos atributos	38
Tabela 2	– Tabela com os resultados representado as 3 situações.	39
Tabela 3	– Tabela representando a Matriz de Confusão com a taxa de acertos (em %) para cada classe.	40
Tabela 4	– Tabela com a taxa de acertos para a situação 3.	41
Tabela 5	– Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP, SURF e SIFT.	42
Tabela 6	– Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP, SURF, SIFT e HISTOGRAMA.	42
Tabela 7	– Tabela com a taxa de acertos referentes a união entre os descritores HOG e LBP.	43
Tabela 8	– Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP e HISTOGRAMA.	43
Tabela 9	– Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP e SIFT.	43
Tabela 10	– Tabela com a taxa de acertos referentes a união entre os descritores HOG e SIFT.	44
Tabela 11	– Tabela representando a Matriz de Confusão com a taxa de acertos e erros entre a união dos descritores referentes ao HOG.	45
Tabela 12	– Tabela representando a Matriz de Confusão com a taxa de acertos e erros entre a união dos descritores referentes ao SIFT.	46
Tabela 13	– Tabela resumindo a Matriz de Confusão relacionados à união dos des- critores com o HOG e com relação a união dos descritores com o SIFT.	47
Tabela 14	– Resultados da classificação utilizando <i>Fine</i> KNN para a Base Brodatz.	48
Tabela 15	– Resultados da classificação utilizando <i>Fine</i> KNN para a Base Outex.	48
Tabela 16	– Resultados da classificação utilizando <i>Fine</i> KNN para a Base Vistex.	48
Tabela 17	– Resultados da classificação utilizando <i>Fine</i> KNN para a Base UIUCTex.	49

Tabela 18 – Comparação do método proposto com outros métodos usando o classificador SVM.	49
Tabela 19 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP, SIFT e HISTOGRAMA.	56
Tabela 20 – Tabela com a taxa de acertos referentes a união entre os descritores LBP e SIFT.	56
Tabela 21 – Tabela com a taxa de acertos referentes a união entre os descritores LBP, SIFT e HISTOGRAMA.	57
Tabela 22 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP e SURF.	57
Tabela 23 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP, SURF e HISTOGRAMA.	58
Tabela 24 – Tabela com a taxa de acertos referentes a união entre os descritores LBP, SIFT e SURF.	58
Tabela 25 – Tabela com a taxa de acertos referentes a união entre os descritores LBP, SIFT, SURF e HISTOGRAMA.	59
Tabela 26 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, SIFT e HISTOGRAMA.	59
Tabela 27 – Tabela com a taxa de acertos referentes a união entre os descritores HOG e SURF.	59
Tabela 28 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, SURF e HISTOGRAMA.	60
Tabela 29 – Tabela com a taxa de acertos referentes a união entre os descritores LBP e SURF.	60
Tabela 30 – Tabela com a taxa de acertos referentes a união entre os descritores LBP, SURF e HISTOGRAMA.	60
Tabela 31 – Tabela com a taxa de acertos referentes a união entre os descritores SIFT e SURF.	61
Tabela 32 – Tabela com a taxa de acertos referentes a união entre os descritores SIFT, SURF e HISTOGRAMA.	61
Tabela 33 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP, SIFT, SURF e Histograma.	62

Lista de siglas

- BIFs** Características Básicas de Imagem - *Basic Image Features*
- BRISK** Pontos de Interesse Escalonáveis Invariantes Robustos e Binários - *Binary Robust Invariant Scalable Keypoints*
- DoG** Diferença de Gaussianas - *Difference of Gaussians*
- EM** Maximização de Expectativas - *Expectation Maximization*
- FREAK** Ponto de Interesse de Retina Rápido - *Fast Retina Keypoint*
- GNU** Licença Pública Geral - *General Public License*
- HOG** Histograma de Gradiente Orientado - *Histogram of Oriented Gradient*
- HSV** Matiz, Saturação, Valor - *Hue, Saturation, Value*
- KNN** K-Vizinhos Mais Próximos - *k-Nearest Neighbors*
- LBP** Padrão Binário Local - *Local Binary Pattern*
- LDA** Análise de Discriminantes Lineares - *Linear Discriminant Analysis*
- LEP** Local Energético Padrão - *Local Energy Pattern*
- LoG** Laplaciana da Guassiana - *Laplacian of Guassian*
- PCA** Análise de Componente Principal - *Principal Component Analysis*
- PDI** Processamento Digital de Imagens - *Digital Image Processing*
- QDA** Análise Discriminante Quadrática - *Quadratic Discriminant Analysis*
- RGB** Vermelho, Verde e Azul - *Red Green Blue*
- SIFT** Transformada Características Invariante a Escala - *Scale Invariant Feature Transform*

SURF Características Robustas Aceleradas - *Speeded Up Robust Features*

SVM Máquinas de Vetores de Suporte - *Support Vector Machine*

WEKA Ambiente para a Análise do Conhecimento da Waikato - *Waikato Environment
for Knowledge Analysis*

Sumário

1	INTRODUÇÃO	14
1.1	Objetivos: Gerais e Específicos	19
1.2	Organização do Trabalho	20
2	REVISÃO BIBLIOGRÁFICA	21
2.1	Processamento de imagens	21
2.1.1	Reconhecimento de Padrões	22
2.2	Extratores de Características	23
2.2.1	HOG	23
2.2.2	LBP	23
2.2.3	SIFT	24
2.2.4	SURF	26
2.3	Classificadores	28
2.3.1	K-Vizinhos mais Próximos (KNN)	28
2.3.2	Análise Discriminante Linear	29
2.3.3	Análise da Discriminante Quadrática	29
2.3.4	Máquinas de Vetores de Suporte Quadráticas	30
2.4	WEKA	31
2.5	Validação Cruzada	32
3	CONCEITOS E MÉTODO PROPOSTO	33
3.1	Imagem	34
3.2	Criação dos Descritores	36
3.3	Seleção de Atributos	37
3.4	Classificadores	37
4	RESULTADOS	38
4.1	Tabela de Índices dos Atributos	38

4.2	Análise dos Algoritmos	39
4.2.1	Análise dos Algoritmos para a 3ª Situação	41
4.2.2	Tabela de Melhores Algoritmos	41
4.2.3	Tabela de acertos e erros	44
4.3	Bases de Imagens Públicas	46
5	CONCLUSÃO	50
	REFERÊNCIAS	52
	 APÊNDICES	 55
	APÊNDICE A – TABELAS	56

Introdução

O cultivo de pimenta (*Capsicum*, família *Solanaceae*) está entre os de maior importância econômica no mercado hortifrutigranjeiro nacional (ECHER; COSTA, 2002). Algumas espécies são de origem nacional, presentes em várias regiões do território brasileiro. O cultivo de pimenta é realizado, em sua grande parte, por agricultura familiar, gerando emprego e renda para diversas famílias, uma vez que a cultura exige grande quantidade de mão de obra, principalmente, durante a colheita, realizada várias vezes no ano (MOREIRA et al., 2006). De acordo com a Embrapa Hortaliças, desde o preparo do solo até a colheita, a atividade gera de três a quatro empregos diretos, com uma renda bruta que oscila entre R\$4 e 12 mi/ha/ano (RURAL, 2006).

Em Minas Gerais, a mesorregião de Monte Carmelo-MG se destaca no cultivo de pimenta assegurando a renda de dezenas de agricultores familiares nesta região. Esta região é reconhecida nacionalmente pelo cultivo de pimenta, porém praticamente não existem pesquisas que visem dar suporte a esta atividade na região. Segundo o Relatório Sintético para Olericultura, safra agrícola 2016, o município de Monte Carmelo-MG possui mais de 150.000 pés de pimenta. As principais variedades de *Capsicum spp*, cultivadas na mesorregião de Monte Carmelo-MG são: Biquinho, Cumarí-do-pará, Cumarí-goiana, Bode vermelho, Bode amarelo, Malagueta vermelha, Malagueta amarela, Cumari passarinheira, Olho-de-peixe, Habanero, Jamaica e Bhut jalokia (EMATER-MG, 2016).

A expansão das fronteiras agrícolas no Brasil assim como o uso indiscriminado das terras podem levar à extinção de muitas espécies silvestres, incluindo espécies do gênero *Capsicum* (RIBEIRO, 2000). A criação de bancos de germoplasma¹ de diferentes espécies de plantas por instituições de pesquisa nacionais e internacionais, públicas e privadas, tem sido uma estratégia para a conservação de recursos genéticos que se encontram em risco de extinção. O banco de germoplasma de *Capsicum* da Universidade Federal de

¹ "Germoplasma é o tecido vivo a partir do qual novas plantas podem ser cultivadas. Pode ser uma semente ou outra parte da folha de uma planta, um pedaço de caule, pólen ou até mesmo apenas algumas células que podem ser transformadas em uma planta inteira. Germoplasma contém as informações para a composição genética de uma espécie, um recurso natural valioso da diversidade de plantas" (University of California, 2016).

Uberlândia - UFU, campus Monte Carmelo, criado em agosto de 2013 vem sendo utilizado por pesquisadores, extensionistas, estudantes e produtores da região. Até o início do ano de 2015 foi contabilizado uma número superior a 100 resgistro (acessos ou pimentas) cadastrados. A conservação e caracterização de recursos genéticos de *Capsicum spp*, têm sido estratégia ao programa de melhoramento de *Capsicum* da UFU para obtenção de indivíduos superiores que combinem características de interesse de diferentes segmentos da cadeia produtiva especialmente para a importante região produtora de pimenta de Monte Carmelo-MG.

No início do segundo semestre de 2016 estavam cadastrados mais de 110 registros, porém esses cadastros encontrava-se em uma planilha eletrônica, localizada apenas em um computador dentro do Campus. Com a necessidade de informatizar esse processo de cadastro e consulta da informações, foi desenvolvido um sistema responsável pelo armazenamento dessas informações (BG *Capsicum*), que possui 7 tabelas e 203 campos de atributos, possuindo apenas uma forma de consultas de informações que é realizar a consulta por campos específicos (MARTINS et al., 2014). A Figura 1 (superior) ilustra a página inicial do sistema BG *Capsicum* para um usuário com permissão de administrador.




Figura 1 – Telas ilustrando o BG Capsicum.

Na Figura 1 (inferior esquerda) é exemplificada a tela de cadastro. Nessa tela existe a aba de cadastro do local de coleta, em que é referente as informações do produtor onde foram coletadas as pimentas, já a aba de características morfológicas da acesso ao formulário onde é realizado o cadastro das características morfológicas de pimentas. Ao lado, um exemplo de um relatório gerado pelo BG Capsicum, mostrando as informações referentes ao local de coleta das pimentas e as características analisadas de cada pimenta.

No BG Capsicum são realizadas apenas buscas de forma textual para consultar as informações, tendo em vista a necessidade de se realizar consultas de informações de outras formas, é proposto a consulta de informações através de imagens. No contexto de consultas de informações através de imagens foi estudado e analisado as técnicas para extração, descrição e caracterização de imagens.

Diversos trabalhos da literatura utilizam texturas de imagens para descrever e classificar objetos que vão desde uma simples imagem de um campo florido até uma imagem médica de um câncer.

Em 2016, GHANSHYAM RAGHUWANSHI AND VIPIN TYAGI (2016) apresentaram uma pesquisa sobre diversos métodos de recuperação de imagens de textura, abordando uma comparação entre vários métodos de recuperação de imagens com base em precisão e tempo de recuperação com os bancos de dados de referência. Além disso foi realizado uma investigação sobre a extração de características de texturas aplicando-se as variantes de transformada *Wavelet* como *Gabor*, *Haar*, *Standard Wavelet*, *Complex Wavelet*, dentre outros. Após o estudo realizado sobre os diversos métodos foi constatado que os melhores resultados de recuperação de imagens de textura somente são obtidos se a extração é realizada de forma perfeita ou seja a rotação, o dimensionamento e a reflexão das imagens deve ser levadas em consideração.

O trabalho desenvolvido por Bama (2011) teve como objetivo realizar a recuperação de informação de imagens de folhas utilizando-se de forma, cor e textura, em que uma imagem de uma planta é dada como entrada e as imagens mais semelhantes presentes no banco de dados são retornadas. Para isso foi utilizado o espaço de cor HSV para extração de recursos presentes nas folhas e, para a extração das características de textura foi aplicado o *Log-Gabor Wavelet* e o SIFT para a extração de pontos característicos da imagem. Nos resultados apresentados foi obtido uma eficiência alta na recuperação quando aplicado o algoritmo *Log-Gabor* + SIFT. Avaliando-se o desempenho de *Log-Gabor Wavelet* em relação ao *Log-Gabor* obteve-se uma eficiência na recuperação de 93,1% do *Log-Gabor Wavelet* contra 97,9% do *Log-Gabor*.

Araújo, Jr e Falate (2015) tiveram como objetivo o desenvolvimento de uma técnica que dada a imagem da folha de uma planta seja possível identificar a espécie dessa planta. Para a realização desse trabalho foi proposto a avaliação de três descritores para folha e, para o treinamento, foi utilizado a SVM. Os descritores foram: Transformação de Características Invariantes à Escala (SIFT - *Scale - Invariant Feature Transform*), Características Robustas Aceleradas (SURF - *Speeded Up Robust Features*) e Histograma de Gradiente Orientado (HOG - *Histogram of Oriented Gradients*). Os descritores foram combinados utilizando diferentes estratégias: voto majoritário, produto e soma além disso cada classificador foi analisado individualmente.

Nos resultados apresentados pode-se constatar que os descritores SIFT e SURF treinados com SVM obtiveram uma acurácia similar ou superior aos resultados do HOG. Já na combinação de classificadores os resultados são superiores quando se comparados ao obtidos individualmente, de modo que a combinação de classificadores proporcionou um aumento considerável na acurácia. Considerado-se o melhor classificador individual, o SIFT obteve uma taxa de acerto de 90,4%, enquanto o melhor resultado obtido com a combinação de classificadores (Voto Majoritário) obteve uma taxa de acerto de 95,6%, o que proporcionou uma melhora em 5,2%.

No trabalho de Suresha (2012) é proposto uma abordagem para extração de texturas de imagens de legumes para classificação, em que são extraídas as características como,

componentes verde e vermelho, *skewness*, *kurtosis*, variância e energia. A segmentação de *Watershed* foi usado para segmentar imagens de vegetais a partir do fundo, convertendo a imagem RGB em imagens em níveis de cinza. Na região segmentada o componente vermelho, componente verde médio, *skewness*, *kurtosis*, variância e energia dos objetos individuais de vegetais são determinados para a classificação. O método proposto foi utilizado para a normalização das imagens, e em consequência disso os efeitos de orientação são eliminados usando-se da técnica de redimensionamento de imagens com a escala adequada.

Para realizar a classificação foi utilizada árvore de decisão. As imagens foram retiradas da Internet, e algumas retiradas com um câmera digital com luz natural. Para acelerar o processo de classificação, as imagens foram redimensionadas em resolução de 300x300 pixels. Com os resultados obtidos avaliando as amostras de treinamento foi possível conseguir uma precisão na classificação de 95%.

Kwitt et al. (2012) propuseram uma nova abordagem para a idealização de uma codificação semântica de baixa dimensão para imagens endoscópicas, essa codificação fundamenta-se em avanços da visão computacional. Na implementação proposta de codificação semântica necessita-se de misturas gaussianas para realizar as estimativas de densidades de probabilidade condicionais. O algoritmo Maximização de Expectativas (*Expectation Maximization* - EM) realiza a estimativa dos parâmetros de mistura inicializados por meio do *K-Means* e de matrizes de covariância. O descritor SIFT (usando células de grade 4x4 e 8 *bias* de histograma de orientação) é a base representativa de baixo nível. Na implementação os descritores SIFT foram computados em grades de 8x8.

Por meio dessa codificação foi possível demonstrar que a classificação, focada semanticamente, e o cálculo das classes representativas podem ser implementadas em um modelo baseado em princípios de informações geométricas. Os experimentos realizados com uma coleção de imagens de colonoscopia de alta dimensão mostraram que a classificação realizada em espaço semântico atingiram precisões semelhantes e altamente otimizados, além disso a estratégia proposta para busca de imagens por tipo semântico se mostrou capaz de recuperar imagens com mais características e com menor erro.

Em Ribeiro et al. (2015) é apresentado uma abordagem automatizada para caracterizar texturas por meio de redes complexas, com uma seleção de limiar automático na geração de mapas de grau de redes complexas, sendo possível obter uma redução considerável no número de descritores utilizados. O método proposto para classificação de texturas usando-se bases conhecidas na literatura se mostrou eficiente, tanto para reduzir a quantidade de vetores de características, quanto para aumentar consideravelmente a taxa de classificação correta em relação a outros métodos da literatura. Para avaliação de precisão do método proposto foi utilizado a Análise Discriminante Linear (LDA). Os resultados demonstram que o método proposto foi superior a outros métodos, uma vez que com uma quantidade menor de descritores foi possível obter uma taxa de acerto similar

ou superior quando se comparado a outros métodos aplicados para as mesmas bases da literatura como: Brodatz, Vistex e CURET.

Couto et al. (2015) propuseram uma nova abordagem para a descrição de imagens baseadas em textura, para isso uma imagem foi representada como uma rede complexa e um algoritmo de caminhadas determinísticas foi aplicado. Os resultados apresentados pelo método proposto se mostraram superiores aos de outros métodos da literatura, em que o método proposto conseguiu uma taxa de acertos de 98.25% com apenas 78 descritores, enquanto a segunda maior classificação atingiu uma taxa de 95.32% com um descritor de dimensão de 648. Ao passo em que foi combinado a geração e a análise de uma rede complexa de uma imagem, e por meio disso extrair informações significativas e discriminantes sobre os dados de rede, possibilitando superar outros métodos da literatura.

O trabalho de Zhang et al. (2015) propõe uma representação de textura invariante em escala baseada na decomposição de frequências e orientações de gradiente. As intensidades de imagem são decompostas em diferentes orientações utilizando-se filtros no domínio da frequência, e o método de codificação *N-nary* é usado para a quantização do vetor. Em seguida a orientação do gradiente invariante a escala é gerada pela seleção do valor mais estável da orientação do gradiente com diferentes escalas Gaussianas. Por fim, a distribuição conjunta 2D dos dois tipos de descritores locais é utilizada como representação. Para a avaliação de desempenho na classificação de textura foi utilizado um classificador de vizinhos mais próximos. O método proposto atinge uma taxa de classificação muito eficiente na base de dados KTH-TIPS onde obteve uma taxa de acerto de 98,86%, além disso quando comparado com os métodos das características básicas da imagem (BIFs) e do padrão energético local (LEP), o método proposto se mostra superior em desempenho com uma dimensão de representação bem menor.

Através do estudo das técnicas de extração de características, descrição e caracterização de imagens, o presente trabalho propõe estudar e analisar essas técnicas para a criação de vetores de características que serão utilizados no processo de recuperação de consultas através de imagens no sistema BG *Capsicum*.

1.1 Objetivos: Gerais e Específicos

O objetivo geral desse trabalho foi analisar técnicas para a criação de um vetor de características para a recuperação de informações através de imagens. Para isso foram estudadas e analisadas técnicas de processamento digital de imagens.

O objetivo geral está sub-dividido com os seguintes objetivos específicos:

1. Estudou-se sobre as técnicas básicas de aquisição de imagens.
2. Estudou-se sobre as técnicas básicas de extração de características.
3. Estudou-se sobre as técnicas de reconhecimento de padrões.

4. Desenvolvimento de metodologia para construção do vetor de características.
5. Análise dos resultados encontrados, com intuito de avaliar a eficácia de determinados algoritmos para a construção do vetor de características.
6. Realização de experimentos para validar os métodos com base de imagens já classificadas: Brodatz, Vistex, Outex e UIUCTex.

Ao término desse trabalho, espera-se que os resultados encontrados possam auxiliar na escolha da melhor técnica para a criação de vetor de características que possa ajudar no processo de recuperação de informações no sistema BG *Capsicum*.

1.2 Organização do Trabalho

O presente trabalho está dividido da seguinte forma: no capítulo 2 será apresentado o referencial teórico deste trabalho, ou seja a base necessária para o entendimento e para a realização deste projeto.

Já no capítulo 3 será abordada a metodologia para a realização deste trabalho. No capítulo 4 serão demonstrados os resultados obtidos, os testes realizados e problemas enfrentados. E por fim, no último capítulo, serão apresentadas as conclusões obtidas ao fim de todo os estudos realizados, testes e análises realizadas.

Revisão Bibliográfica

Este capítulo abordará os conceitos fundamentais para compreender as etapas necessárias no processo de criação do vetor para caracterizar as imagens de pimentas.

2.1 Processamento de imagens

De acordo com Gonzalez e Woods (2010) Processamento Digital de Imagens (PDI) não se trata de uma tarefa simples, todo o processo inclui um conjunto de tarefas inter-relacionadas, isso pode ser visualizado na Figura 2.

A primeira etapa é a aquisição da imagem ou seja adquirir uma imagem em formato digital. A representação das imagens capturadas podem ser feitas em duas ou mais dimensões. Depois de obtida a imagem digital, a próxima etapa é o pre-processamento da imagem. A etapa de pré-processamento tem como função melhorar a imagem, em que inclui filtragem de ruídos inseridos por meio dos sensores e a correção de distorções geométricas ocasionadas pelo sensor.

Na etapa de segmentação é realizado a extração das características ou atributos das imagens, por exemplo texturas. Em seguida faz-se a separação dos objetos e fundo, de forma que ambos fiquem separados, o que deixa claro que será necessário realizar a identificação por meio de um processo de segmentação de características constantes e descontinuadas. De forma geral a segmentação é uma das etapas mais difíceis de ser realizada no processamento de imagens digitais.

A saída da etapa de segmentação é representada por dados em forma de pixels, neste caso é necessário que os dados sejam convertidos para um formato adequado ao processamento computacional. Já no processo de descrição também conhecido como seleção de características é realizado a extração de características que representem algum tipo de informação relevante para a discriminação entre classes.

A ultima etapa é o reconhecimento e interpretação, é nesta etapa em que é realizado a classificação, e sua função é fazer o reconhecimento, verificação ou realizar a inferência da

identidade dos objetos com base em características e representações adquiridas em etapas anteriores do processamento.




Figura 2 – *Etapas no Processamento Digital de Imagens* (GONZALEZ; WOODS, 2010).

2.1.1 Reconhecimento de Padrões

O reconhecimento de padrões nas imagens engloba uma diversidade de aplicações úteis das quais a visão de máquina geralmente é o principal objetivo. De forma geral o processo de reconhecimento de diversos padrões pelo homem é totalmente eficiente, ao contrário do computador que apresenta problemas.

De acordo com Gonzalez e Woods (2010), a maior dificuldade está em como a máquina realiza a tarefa de reconhecimento de modo eficiente e, possa gerar resultados para sistemas de reconhecimento tão especializados. Segundo os autores, as características como cor, intensidade do pixel e textura concebem um padrão. Algumas das mais importantes abordagens de reconhecimento de padrões podem ser separadas em três segmentos:

- ❑ **Casamento de Modelos (*Template Matching*):** O modelo ou molde é composto de uma determinada característica na qual a imagem e esse molde são comparados com base em uma referência, ou seja com base em alguma métrica de similaridade. Na concepção do molde é fundamental o conhecimento do objeto que está sendo procurado, sendo necessária a tolerância em variações de translação, rotação e escala na imagem que está sendo analisada. Deste modo, as técnicas baseadas nessa abordagem tem um custo computacional muito alto dependendo da forma de como são feitas as comparações.
- ❑ **Classificação Estatística:** Os padrões estão relativamente representados por vetores de propriedades de uma imagem. Por exemplo, em uma imagem de ultrassom, na qual as propriedades como medidas de intensidade do pixel e textura poderiam ser

usadas. A obtenção das fronteiras é feita através das distribuições de probabilidade relacionadas aos padrões que pertencem a cada classe, criando as funções de densidade de probabilidade.

- **Redes Neurais Artificiais:** O reconhecimento de padrões originam-se do fato dessa abordagem ser totalmente adaptável aos problemas complexos. Em virtude das redes neurais artificiais terem sido inspiradas em neurônios biológicos, o processo de aprendizagem e reconhecimento das redes são estritamente aplicados nos problemas de reconhecimento de padrões.

2.2 Extratores de Características

Extratores de características se referem a técnicas capazes de extrair características de imagens das quais conseguem representar uma determinada imagem seja através da cor, textura ou formatos por exemplo. Existe vários extratores de características, por exemplo, HOG, LBP, SIFT, SURF, Wavelet, Gabor, BRISK, FREAK, dentre outros.

2.2.1 HOG

Proposto por Dalal e Triggs (2005) o Histograma de Gradiente Orientado (*Histogram of Oriented Gradient* - HOG) vem sendo utilizado frequentemente em diversas aplicações de reconhecimento de padrões e processamento de imagens. O processo para o cálculo desse descritor pode ser visto na Figura 3. Para a extração do descritor HOG, primeiramente são calculados os gradientes da imagem de entrada utilizando-se o detector de bordas Sobel.

O próximo passo é construir os histogramas das orientações dos gradientes dividindo a imagem em células (pequenas partes). Os histogramas são calculados para cada uma das células sendo que, a quantidade de histogramas dependerá da quantidade de blocos pertencentes a cada célula.

Devido ao fato de existir problemas de iluminação nas imagens do mundo real é apropriado realizar a normalização dos histogramas, para isso utiliza-se a normalização de contraste local. No processo de normalização dos histogramas as células são agrupadas em blocos onde cada um dos blocos é normalizado separadamente.

Por fim todos os elementos normalizados das células de todos os blocos são unidos em um vetor para assim poderem formar o descritor final.

2.2.2 LBP

Conforme Ojala, Pietikainen e Harwood (1996) o descritor de Padrão Binário Local (*Local Binary Pattern* - LBP) é muito utilizado para classificar texturas. A Figura 4




Figura 3 – Operação básica do HOG. Adaptado de (INTEL, 2016).

ilustra as etapas do LBP. O processo consiste em dividir a imagem em pequenas células. Em seguida é realizada uma comparação entre cada pixel da célula e seus 8 vizinhos, caso o valor do pixel vizinho seja maior que o valor do pixel central ele recebe o valor 1, caso seja menor que o valor do pixel central ele recebe o valor 0. Nesse processo de comparação para cada pixel são criados padrões binários com 8 dígitos.

Com base nesses padrões binários são calculados histogramas. Posteriormente é realizado uma normalização dos histogramas e o descritor resultante é composto da junção dos valores normalizados de todos os histogramas referentes as células da imagem.




Figura 4 – Operação básica do LBP: (A) Pixels de um imagem, (B) Valor de Intensidade dos Pixels da Imagem, (C) Padrão Binário obtido para o pixel central, (D) Valor final do pixel central convertido do valor binário.

2.2.3 SIFT

Proposto por Lowe (1999) o Descritor de Transformação de Características Invariantes à Escala (*Scale-Invariant Feature Transform* - SIFT) está relacionado à um algoritmo capaz de realizar a extração de características locais de uma imagem sendo elas invariantes

a alterações na escala, rotação, alterações de iluminação e mudanças de ponto de vista 3D das imagens. Na etapa para detectar pontos de interesse invariantes a escala e rotação são utilizadas funções Gaussianas. Para cada ponto de interesse detectado é gerado um vetor de características capaz de descrever de forma única, para aquela imagem, regiões de interesse referente ao seu local de escala e espaço de coordenadas.

De acordo com Lowe (2004), o SIFT é constituído de quatro etapas:

- ❑ Detecção de extremos no espaço de escalas;
- ❑ Localização do ponto de interesse;
- ❑ Atribuição de orientação;
- ❑ Descritor do ponto de interesse;

A etapa de detecção de extremos no espaço é realizada por meio de uma implementação baseada na técnica de Laplaciano da Guassiana (LoG). Sua realização é dada por meio da substituição do operador Laplaciano pelo operador de Diferença de Gaussianas (DoG), onde a separação entre escalas é definida por k .

Os pontos extremos são identificados com base na $D(x, y, \sigma)$ da mesma maneira que é feita na técnica LoG, isso consiste em comparar cada pixel com os seus vizinhos na vizinha 3D, o que corresponde ao todo a 26 vizinhos.

Os operadores de gradientes locais são usados para atribuir as orientações de modo que possibilite representar o ponto-chave com relação a sua orientação, consequentemente o ponto-chave se torna invariante a rotação. Todos os gradientes são calculados de modo que eles sejam invariantes à escala, o que significa que as operações de gradientes são efetuadas sobre a imagem suavizada $L(x, y, \sigma)$ na escala σ do ponto de interesse identificado. Para isso se faz necessário o uso dos operadores S_x e S_y :

$$S_x = \begin{bmatrix} -1 \\ 0 \\ 1 \end{bmatrix} S_y = \begin{bmatrix} -1 & 0 & 1 \end{bmatrix} \quad (1)$$

Dado que os gradientes já foram calculados, é realizado o cálculo para o valor de magnitude e valor de ângulo para cada um dos vetores. Após isso é criado um histograma referente aos ângulos (orientações) dos gradientes pertencentes à uma região ao redor do ponto de interesse, composto por 36 *bins*, tendo um alcance de 360°.

No histograma de orientações as direções relevantes são observadas como picos, e a orientação principal é retratada pelo maior pico. Para qualquer outro pico que sua contagem ultrapasse 80% em relação ao pico principal, ele deve ser empregado para a criação de um novo ponto de interesse, e tal ponto deve conter orientação diferente da orientação principal. Portanto, para localizações com mais de um pico de contagem no histograma, são formados pontos-chave com orientações diferentes, mas considerando-se a

mesma escala e localização para esses pontos. Por fim, esses pontos de interesse constituem os descritores. A Figura 5 ilustra como isso é realizado.




Figura 5 – *Gradientes e Descritores SIFT* (LOWE, 2004).

Em (A) são demonstrados todos os gradientes ao redor de uma região do ponto-chave. Uma janela Gaussiana representada pelo círculo é responsável por ponderar a magnitude de cada um dos gradientes. A janela possui desvio-padrão σ equivalente a metade da janela, que para esse exemplo, é de 8×8 , seu uso tem como finalidade evitar variações inesperadas no descritor para pequenas variações na localização da janela, como também para atribuir pesos menores aos gradientes distanciados do ponto-chave.

Assim sendo, os gradientes são agrupados em um histograma contendo oito *bins* (que representa todos os sentidos através das direções vertical, horizontal e diagonais) em conformidade com cada uma das sub-região 4×4 do exemplo. (B), soma das magnitudes de cada *bin* representam os descritores referentes a cada sub-região. O tamanho do vetor de características é determinado pelo tamanho da janela e do tamanho de cada sub-região, o que corresponde a $4 \times 4 \times 8 = 128$. Desta forma, cada ponto de interesse é constituído por um vetor com 128 elementos.

2.2.4 SURF

Proposto por Bay, Tuytelaars e Van Gool (2006) o Descritor de Características Robustas Aceleradas (*Speeded Up Robust Features Algorithm* - SURF) é um algoritmo detector de pontos de interesse em imagens, sendo um descritor invariante à escala e a rotação, assim como o SIFT, fundamenta-se em um detector de pontos chaves e de um descritor. Inspirado no SIFT, o SURF tem um custo computacional bem menor em relação ao SIFT. A busca de características através dessa técnica tem como base o detector Hessian-Laplaciano. Em busca de melhora na eficiência é usado a determinante da matriz Hessiana, tanto para detectar a localização espacial quanto para a escala. Isso é realizado aplicando-se um filtro tipo caixa como aproximação para derivada de segunda ordem do

núcleo Gaussiano. Esse processo é ilustrado na Figura 6 em que um filtro 9 x 9 é usado para aproximar uma Gaussiana com $\sigma = 1, 2$. Essas aproximações são denotadas por D_{xx} , D_{yy} , e D_{xy} para L_{xx} , L_{yy} e L_{xy} respectivamente, e para aproximação da matriz Hessiana tem-se o determinante 2:

$$\det(H_{approx}) = D_{xx}D_{yy} - (0,9D_{xy})^2. \quad (2)$$




Figura 6 – Derivadas parciais de segunda ordem da Gaussiana nas direções y e xy (A e B) e a aproximação das derivadas por filtros do tipo caixa (C e D). Regiões em cinza tem valores iguais a zero (BAY; TUYTELAARS; Van Gool, 2006).

A análise do espaço de escala é realizado de maneira mais eficiente devido a essa aproximação. Apenas aumentando-se o tamanho do filtro é possível obter cada escala iterativamente sem que seja necessário reduzir a imagem. O descritor empregado no SURF também utiliza a orientação de características, isto é realizado por meio da resposta da *Wavelet* de Haar nas direções x e y da imagem, acompanhada de uma ponderação realizada por um núcleo Gaussiano centrado no ponto de interesse. Deste modo a maior soma da resposta ponderada e rotacionada é quem determina a orientação, o que corresponde a cobertura de um ângulo de $\frac{\pi}{3}$. A combinação dos vetores é dado por:

$$v = (\sum dx, \sum dy, \sum |dx|, \sum |dy|) \quad (3)$$

A combinação dos vetores em v (Fórmula 3) relacionados as 16 sub-regiões 4 x 4 pertinente a um quadrado centralizado no ponto de interesse e rotacionado em conformidade com a orientação calculada, são os responsáveis por definirem o descritor. Os valores de dx e dy é a resposta da *Wavelet* de Haar que compreende as direções vertical e horizontal em relação à orientação do descritor. O resultado é um descritor composto por 64 elementos (sendo 4 elementos de v para cada uma das 16 sub-regiões) que descreve cada característica detectada.

2.3 Classificadores

Os classificadores são algoritmos responsáveis por classificar imagens como sendo pertencentes a determinada classe, isso é realizado com base nas características extraídas, o que possibilita ao classificador realizar o reconhecimento dessas imagens e posteriormente ser capaz de identificar a qual classe elas pertencem. Dentre a variedade de classificadores existentes pode-se citar alguns: *Simple Tree*, *Complex Tree*, *Bagged Trees*, KNN, *Weighted KNN*, *Quadratic Discriminant*, *SVM Quadratic*, *SVM Cubic* e entre outros.

2.3.1 K-Vizinhos mais Próximos (KNN)

Segundo Sousa (2013), o KNN considera que todas as amostras fazem referência a pontos pertencentes a um espaço n -dimensional, de modo que o n representa a quantidade de descritores usados para retratar as amostras. No processo de classificação ele faz o reconhecimento da chamada "vizinhança" da nova amostra, ou seja, pontos mais próximos que já são conhecidos. Medidas de distância são usadas para calcular a proximidade entre as amostras, a mais simples é a Distância Euclidiana. Analisando-se uma instância x representada por um vetor de características A (Fórmula 4)

$$A = (a_1(x), a_2(x), \dots, a_n(x)) \quad (4)$$

em que $a_r(x)$ determina o valor do r -ésimo atributo da instância x , logo a Distância Euclidiana entre duas distâncias x_i e x_j é determinada por $d(x_i, x_j)$ (Fórmula 5).

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n (a_r(x_i) - a_r(x_j))^2} \quad (5)$$

Depois de calculada a distância entre a nova amostra e as demais já conhecidas, o algoritmo classifica a nova amostra de acordo com a classe em que ela tenha os k vizinhos mais próximos. Por exemplo se for definido ($k=3$) e se, a nova amostra possuir um vizinho próximo da Classe 2, mas dentre os quatro mais próximos os outros três forem da Classe 1, com isso a amostra será classificada como Classe 1.

Figura 7 ilustra um exemplo de classificação considerando-se o $k=3$. Nesse exemplo, são considerados duas classes: a Classe laranja e a Classe verde. Em (A) é apresentada uma nova amostra, neste caso, representado pela bolinha de cor amarela. Em (B) é realizado o cálculo da distância para saber os k vizinhos mais próximos. Em (C) quando a nova amostra (amarela) é submetida ao KNN, ele classifica a amostra amarela como pertencente a Classe laranja, pois são considerados os três vizinhos mais próximos, que são exatamente da Classe laranja, e caso o k fosse 1 a nova amostra seria pertencente a Classe verde.

Sua eficiência computacional é bem notável, mas quando se tratando no número de dimensões utilizadas nos vetores de característica, que podem aumentar consideravelmente,




Figura 7 – Exemplo da Classificação utilizando o KNN. Modificado de Sousa (2013).

o KNN se torna bastante sensível em situações como essa. Outro aspecto que também pode influenciar no resultado é o valor de k .

2.3.2 Análise Discriminante Linear

De acordo com Li e Wang (2014) a Análise Discriminante Linear (*Linear Discriminant Analysis - LDA*) é um método usado em estatísticas, reconhecimentos de padrões e em aprendizagem de máquinas, com a tarefa de encontrar uma combinação linear de recursos de modo que duas ou mais classes de objetos possam ser caracterizadas ou separadas. A combinação resultante pode ser usada como um classificador linear, ou em grande parte da vezes para redução de dimensionalidade antes e depois da classificação.

O LDA está diretamente relacionado a Análise de componente principal (*Principal Component Analysis - PCA*) onde ambos são fundamentados em linearidade o que se traduz em multiplicação de matrizes e transformações. No caso da PCA a transformação consiste em minimizar o erro médio quadrático entre os vetores de dados originais e os vetores de dados estimados através dos vetores de dimensões reduzidas. Este não leva-se em conta qualquer diferença na classe, já para o LDA a transformação consiste em maximizar a relação de "variância entre classe" para "variância dentro da classe" com a finalidade de reduzir a variação de dados em uma mesma classe e por outro lado aumentar a separação entre as classes. Um exemplo da LDA pode ser visto na Figura 8.

Na Figura 8, o gráfico da esquerda ilustra o exemplo de duas classes, a classe vermelha e a azul com seus respectivos histogramas resultante da projeção que une o meio das classes. Pode-se constatar que não existe sobreposição considerável das classes no espaço projetado. No gráfico da direita é ilustrada uma projeção correspondente com base Discriminante Linear, pode-se constatar que a separação das classes melhorou muito.

2.3.3 Análise da Discriminante Quadrática

Conforme Rodrigues et al. (2014), tanto para o LDA quanto para a Análise Discriminante Quadrática (*Quadratic Discriminant Analysis - QDA*), o objetivo é obter funções




Figura 8 – Exemplo do LDA (LI; WANG, 2014).

matemáticas que classificarão determinado objeto em sua determinada classe, de forma que a probabilidade de se classificar determinado objeto errado, seja minimizado. Para a análise de discriminante linear é considerado que a diferença em relação as classes está relacionado apenas com o vetor médio das classes, dado que a matriz de covariância é idêntico em todas as classes.

Similar à LDA, a Análise Discriminante Quadrática estima que cada uma das classes possuam seus próprios vetores média e matriz de covariâncias, o que resulta em funções de decisões quadráticas.

2.3.4 Máquinas de Vetores de Suporte Quadráticas

De acordo com Ram (2014) Máquinas de Vetores de Suporte (*Support Vector Machines - SVM*) são utilizadas na etapa de classificação dos dados de treino. As SVMs mapeiam características do conjunto de dados de entrada em um espaço dimensional no qual é representado como pontos. Desta maneira um hiperplano é tracejado para separar os pontos por meio das margens associadas ou seja das linhas paralelas que são responsáveis por determinar em qual lado ou em que classe cada um dos pontos pertence. Esse procedimento é conhecido como classificação linear ou separação. São denominados vetores de suporte os pontos no limite sobre ou próximos as margens entre as classes, isso pode ser visto na Figura 9.

O propósito é descobrir o hiperplano de separação ótimo em que: o erro de classificação seja minimizado e que o conjunto de testes seja generalizado.

Nas situações em que os dados não são linearmente separáveis, isso impede que o hiperplano com margem máxima seja encontrado. Para resolver isso é usado uma função *kernel* em que são calculados os vetores de suporte de cada um dos pontos e após isso, os projetam em um espaço de dimensões superiores de modo que os dados se sejam linearmente separáveis. Em seguida os pontos do conjunto de teste são mapeados no mesmo espaço utilizando a função de decisão (Fórmula 6), de forma que o hiperplano com




Figura 9 – Exemplo de classificação das duas classes mediante um hiperplano. Modificado de (RAM, 2014).

margem máxima seja detectado e que o novo ponto no espaço equivalente a classe seja mapeado.

$$f(X^T) = \sum_{i=1}^l y_i \alpha_i K(X_i, X_j) + b \quad (6)$$

- X_t representa um dado do conjunto de teste.
- l representa a quantidade de vetores de suporte.
- y_1 representa o rótulo da classe do vetor de suporte.
- α_i, b representa parâmetros achado durante o treinamento.
- $K(X_i, X_j)$ representa a função *kernel* responsável por calcular o produto do dado respectivo ao conjunto de teste para cada um dos vetores de suporte.

O propósito da função *kernel* é retornar o produto interno entre dois pontos em um certo espaço de características, determinando assim uma noção de similaridade com baixo custo computacional até em espaços de dimensões superiores. No entanto existem algumas opções de *kernels* usados em SVMs, no caso desse trabalho está sendo considerado um Kernel Quadrático.

2.4 WEKA

Conforme Alvarenga (2014), WEKA (2016), o Ambiente para Análise de Conhecimento (*Waikato Environment for Knowledge Analysis* - WEKA) trata-se de uma ferramenta para tarefas de mineração de dados, em que compreende uma ampla variedade de

algoritmos para pré-processamento de dados, classificação, regressão, clusterização, regras de associação, e visualização. O WEKA também é adequado para o desenvolvimento de novos sistemas de aprendizagem de máquinas. O objetivo dessa ferramenta é possibilitar que os métodos presentes na ferramenta sejam executados em conjuntos de dados com a maior flexibilidade possível.

O WEKA foi desenvolvido na Nova Zelândia pela Universidade de Waikato. Sua implementação foi feita em Linguagem de programação Java e seu desenvolvimento seguiu os termos da GNU (*General Public License*).

2.5 Validação Cruzada

De acordo com Lara (2013), a Validação Cruzada (*Cross-Validation*) é uma técnica do qual é possível avaliar o quão acurado está o modelo produzido pelo classificador. O conceito empregado nessa técnica é simples no qual o conjunto de dados de treinamento é dividido: parte é usado para criação do modelo, a outra parte tem sua utilidade para validar o modelo.

Para divisão do conjunto de treinamento existe alguns métodos, sendo os principais:

1. *holdout*: nesse método o conjunto de treinamento é dividido em 2: parte para treinamento e parte para validação. Comumente as divisões são de 2/3 para treinamento e 1/3 para validação.
2. *k-fold*: nesse método o conjunto de treinamento é dividido em k conjuntos diferentes onde cada um desses conjuntos possui o mesmo tamanho. Logo o processo para validação terá k etapas, sendo que em cada etapa um dos k subconjuntos serão usados na validação e os outros $k-1$ subconjuntos serão usados para o treinamento.
3. *leave-one-out*: esse é um caso particular do *k-fold* em que o k será idêntico ao respectivo tamanho do conjunto de treinamento.

Conceitos e Método Proposto

Neste trabalho é proposto um método para a criação de vetores de características que irão auxiliar na extração de características de *Capsicum ssp* no BG *Capsicum*.

A Figura 10 ilustra o diagrama de representação do método proposto, especificando os passos realizados para o desenvolvimento desse trabalho. O primeiro passo foi a obtenção das imagens em que foram usadas imagens retiradas da Internet, e imagens fotografadas com alta resolução 14 MegaPixels. Na criação dos descritores é realizado a extração das características de cada imagem o que retorna uma matriz. Da matriz obtida é gerado um histograma e, utilizando-se de estatísticas de 1ª ordem, obtém-se 8 atributos. Após isso, aplica-se o classificador.



Figura 10 – Representação do Método proposto.

A Figura 11 ilustra o detalhamento de cada um dos passos da Figura 10. Pode-se observar o fluxo da realização de cada um dos passos para que seja possível obter os resultados necessários para o trabalho. No item 3.1 são consideradas as situações em que as imagens foram obtidas da Internet com fundo e outros objetos, obtidas da Internet onde foi retirado o fundo e outros objetos, e as imagens fotografadas em alta resolução 14 MegaPixels.

O item 3.2 representa a etapa de criação de descritores para cada uma das imagens. Para cada uma das imagens é criado um descritor referente ao HOG, LBP, SURF, SIFT além de ser calculado o Histograma de cores para cada uma. Portanto cada imagem está relacionada a 5 diferentes descritores, em que cada um desses descritores possui diversos atributos. Dessa forma é realizada a normalização desses descritores por meio das estatísticas de primeira ordem em que, cada descritor passa a ter 8 atributos para cada. Depois de extraídos e normalizados, foi obtido os descritores separados para cada descritor, de modo que seja possível avalia-los separadamente e também unidos em diferentes




Figura 11 – Detalhamento do Método Proposto.

combinações.

No item 3.3 os descritores são usados na ferramenta WEKA para que seja realizado a seleção dos atributos através dos algoritmos de seleção. Depois de selecionados os atributos para cada um dos descritores de forma separa e também em diferentes combinações, o que ocorre no item 3.4 é a classificação dos descritores.

Cada um dos passos ilustrados na Figura 11 estão descritos detalhadamente nos itens 3.1, 3.2, 3.3 e 3.4 desta monografia.

3.1 Imagem

As imagens utilizadas nessa etapa foram obtidas considerando-se três situações: **(a)** Imagens obtidas da Internet com fundo e outros objetos na cena, **(b)** Imagens obtidas da internet sem fundo e sem outros objetos e **(c)** Imagem fotografadas com alta resolução. A Figura 12 ilustra um exemplo das imagens utilizadas no trabalho.

(a) Imagens obtidas da Internet possuindo fundo e outros objetos na cena: Nesta situação foram consideradas imagens obtidas da Internet, em que essas imagens contém diversos objetos (folhas, caule e outros objetos presentes no ambiente em que foram retiradas as imagens). Para esta situação as imagens estão divididas em 6 classes, cada classe contendo em média 7 imagens.

(b) Imagens obtidas da internet sem fundo e objetos removidos: Esta situação é semelhante a anterior, porém o fundo e outros objetos na imagem foram removidos. Unicamente o que restou na imagens foi um objeto que representa pimenta, ou seja são as imagens que estão sendo analisadas no experimento. Foram consideradas nas imagens apenas o fruto que representa uma pimenta sem caule, folhas e entre outros objetos do ambiente em que tais imagens foram retiradas. Nesta situação as imagens estão divididas




Figura 12 – *Imagens exemplificando as 3 situações descritas.*

em 6 classes, cada classe contendo em média 7 imagens.

(c) Imagem fotografadas com alta resolução (14 MegaPixels): Diferente das demais situações, as imagens foram fotografadas com uma câmera profissional Nikon D3100 e as fotos foram tiradas em alta resolução. A obtenção das imagens, por não ser um experimento controlado, restringiu-se as pimentas produzidas naquele momento. A produção de pimentas é sazonal e acontece em determinadas épocas do ano.

Nesta ocasião as pimentas foram coletadas em uma plantação e em seguida fotografadas. Deste modo foi possível registrar as características dos frutos com mais detalhes, além disso foi possível minimizar os efeitos de iluminação e distorção em imagens retiradas em ambientes como muito efeito de luz. Para esta situação foi considerado 3 Classes, de modo que a Classe 1 possui 32 imagens e as Classes 2 e Classe 3 possuem 21 imagens cada.

Na Figura 13 são ilustrados as 3 Classes das imagens fotografadas, sendo (a) Classe 1, (b) a Classe 2 e (c) a Classe 3.




Figura 13 – *Exemplos das Imagens Fotografadas: (a) Bhut Jolokia, (b) Bode Amarela e (c) Bode Vermelha.*

3.2 Criação dos Descritores

Nesta etapa acontece o processo de criação dos descritores referente as imagens. Foram utilizados os descritores HOG, LBP, SURF e SIFT para extrair as características de cada uma das imagens. Além disso, ainda foi gerado o histograma de cor para cada uma das imagens.

Muitos atributos podem ser calculados analisando-se o histogramas. Basicamente são atributos estatísticos de primeira ordem, que são calculados baseados na função de densidade de probabilidade $p(i)$ do histograma $h(i)$:

$$p(i) = \frac{h(i)}{\sum_{i=0}^k h(i)} \quad i = 0, 1, \dots, k. \quad (7)$$

Na fase de estatísticas de histograma foi realizado, uma normalização para cada um dos descritores gerados anteriormente, essa normalização reduziu a quantidade de atributos que foram gerados para cada um dos descritores. Deste modo foi possível obter um histograma com oito atributos para cada uma das imagens, os oito atributos são referentes aos atributos que representam (BACKES; CASANOVA; BRUNO, 2013; FRITZ ALBREGTSEN, 2008):

1. Média

$$\bar{p} = \sum_{i=0}^k p(i)i \quad (8)$$

2. Variância

$$\sigma^2 = \sum_{i=0}^k \frac{p(i)(i - \bar{p})^2}{k} \quad (9)$$

3. Skewness

$$skw = \sqrt{\sigma^2}^{(-3)} \sum_{i=0}^k p(i)(i - \bar{p})^3 \quad (10)$$

4. Kurtosis

$$kurt = \sqrt{\sigma^2}^{(-4)} \sum_{i=0}^k p(i)(i - \bar{p})^4 \quad (11)$$

5. Energia

$$E = \sum_{i=0}^k [p(i)^2] \quad (12)$$

6. Entropia

$$H = - \sum_{i=0}^k p(i) \log_2[p(i)] \quad (13)$$

7. Contraste

$$C = \sum_{i=0}^k p(i)i^2 \quad (14)$$

8. Momento da diferença inversa

$$MDI = \sum_{i=0}^k \frac{1}{1+i^2} p(i) \quad (15)$$

O histograma de cores também foi normalizado usando as estatísticas de histograma onde o mesmo resultou em um histograma referente aos oito atributos anteriormente descritos.

3.3 Seleção de Atributos

Esta é a etapa em que os descritores gerados são convertidos para o formato compatível com a ferramenta WEKA versão 3.6. Para selecionar os atributos foram utilizados os algoritmos de seleção (*Best First*, *Genetic Search*, *Greedy Stepwise*, *Linear Forward Selection*, *Rank Search*, *Scatter SearchV1*, *Subset Size Forward Selection*, *Random Search*), todos eles presentes na ferramenta. Dessa forma foi possível encontrar mais de um algoritmo que selecionou os mesmos atributos. Além disso, também foi possível fazer a interseção entre os atributos selecionados pela ferramenta para que fosse possível encontrar atributos mais apurados.

3.4 Classificadores

Os classificadores usados nos experimentos foram o *Fine KNN*, LDA (*Linear Discriminant Analysis*), *Quadratic Discriminant* e *Quadratic SVM*.

Depois de selecionados os atributos, e com os descritores das imagens já extraídos, foi iniciado o processo de classificação. Para isso utilizou-se a Validação Cruzada com 10 *folds*.

Resultados

Neste capítulo serão apresentados os resultados obtidos através da junção dos descritores, a tabela de índices de atributos, responsável por identificar cada índice ao seu respectivo atributo, além da matriz de confusão com a taxa de acertos para as classes de imagens avaliadas em 3 diferentes situações.

4.1 Tabela de Índices dos Atributos

A Tabela 1 apresenta informações relacionadas aos atributos e seus respectivos índices. Os índices tem por objetivo especificar quais deles estão relacionados a um determinado atributo.

Tabela 1 – Tabela de índices dos atributos

Atributos	Índices de referência					
Média (Fórmula 8)	1	9	17	25	33	
Variância (Fórmula 9)	2	10	18	26	34	
Skewness (Fórmula 10)	3	11	19	27	35	
Kurtosis (Fórmula 11)	4	12	20	28	36	
Energia (Fórmula 12)	5	13	21	29	37	
Entropia (Fórmula 13)	6	14	22	30	38	
Contraste (Fórmula 14)	7	15	23	31	39	
Momento da diferença inversa (Fórmula 15)	8	16	24	32	40	

Para qualquer um dos descritores HOG, LBP, SURF ou SIFT é gerado um vetor com oito atributos (Seção 3.2), na união dos descritores desse exemplo serão obtidos 24 atributos, tais atributos serão inseridos na ferramenta WEKA, posteriormente um dos algoritmos de seleção da ferramenta será escolhido retornando qual ou quais atributos são os melhores ou seja, que são menos interdependentes. Para este exemplo estão sendo considerados: HOG unido com LBP unido com SURF, será usado o *Best First* retornando o conjunto de atributos:

Exemplo:

HOG $\cup$ LBP $\cup$ SURF

3,4,6,10,17,21,24

HOG: 3, 4 e 6 (Skewness, Kurtosis, Entropia)

LBP: 10 (Variância)

SURF: 17, 21 e 24 (Média, Energia, Momento da Diferença Inversa)

Neste exemplo o *Best First* selecionou um conjunto com sete elementos. Os atributos de índice 1 a 8 são referentes ao 1º extrator nesse exemplo, ao descritor HOG, de 9 à 16 ao LBP e os índices de 17 a 24 são referentes ao SURF. Logo pode-se identificar que os atributos 3, 4 e 6 são respectivamente *Skewness*, *Kurtosis*, Entropia que fazem referência ao descritor HOG. Para o descritor LBP, apenas o atributo Variância (índice 10) foi selecionado. Já para o descritor SURF os atributos selecionados foram o 17, 21, 24 respectivamente Média, Energia, Momento da Diferença Inversa.

4.2 Análise dos Algoritmos

A Tabela 2 representa os resultados obtidos para cada uma das 3 situações de obtenção de imagens já descritas anteriormente. Na situação 1 as imagens utilizadas na classificação foram obtidas da Internet e, todas elas contendo fundo, identificadas na Tabela 3 com a letra **C**. A 2ª situação também seguem as mesmas características da anterior a única diferença é que o fundo das imagens foram retirados e sendo identificada com a letra **S**. Já na 3ª situação, todas as imagens foram obtidas dos próprios frutos em condições perfeitas com alta resolução e sem fundo, sendo identificadas pela letra **T**. Pode-se constatar que a 3ª situação (**T**) obteve resultados superiores aos obtidos na 1ª e 2ª situação, isso se deve ao fato de que a resolução das imagens e o fato de não possuírem objetos no fundo da imagem influenciaram em uma melhor acurácia. O melhor resultado considerando esse experimento foi obtido para a 3ª situação (**T**), em que o SURF obteve uma taxa de acerto de 83,8%.

Tabela 2 – Tabela com os resultados representado as 3 situações.

	Acurácia (%)		
	C	S	T
HOG	27,7	48,8	70,3
LBP	27,7	30,2	77,0
SIFT	27,7	20,9	68,9
SURF	23,4	16,3	83,8

As informações presentes na Tabela 3 são referentes a taxa de acertos de cada uma das sete Classes, sendo elas: Biquinho, Cumari, Habanero, Malagueta, Bode Amarela, Bode Vermelha, Bhut Jolokia. Os resultados tiveram como base 3 diferentes situações que já foram descritas anteriormente na Seção 3.1 e ilustradas pela Figura 12.

Tabela 3 – Tabela representando a Matriz de Confusão com a taxa de acertos (em %) para cada classe.

Classes	HOG			LBP			SIFT			SURF		
	C	S	T	C	S	T	C	S	T	C	S	T
Biquinho	44	57	-	38	71	-	44	0	-	44	0	-
Cumari	33	73	-	33	55	-	0	18	-	0	18	-
Habanero	0	14	-	29	0	-	29	43	-	43	29	-
Malagueta	17	20	-	17	20	-	33	20	-	17	0	-
Bode Amarela	43	88	95	29	14	81	14	14	76	0	29	50
Bode Vermelha	0	17	33	0	0	52	20	33	43	0	17	50
Bhut Jolokia	-	-	78	-	-	91	-	-	81	-	-	100

O processo de classificação dessas imagens levou em consideração as 3 situações e, para cada uma das situações foram utilizados os descritores: HOG, LBP, SIFT e SURF. Os resultados apresentados foram obtidos através do classificador *Fine* KNN. Os resultados de cada uma das classes mostram a taxa de acertos que o *Fine* KNN obteve para cada classe. Pode-se constatar que as melhores acurácias obtidas foram das imagens da 3ª situação (**T**), o que leva a afirmar que a resolução das imagens e o fato de não possuírem fundo influenciaram na taxa de acertos das classes. Outro aspecto relevante do qual pode-se identificar é que o descritor SURF aplicado para a 3ª situação (**T**) permite constatar que ele funciona muito bem para diferenciar formatos, isso levando em consideração que a classe das imagens Bhut Jolokia tem seu formato muito diferente da classe Bode Amarela e Bode Vermelha, por sua vez a classe Bode Amarela e Bode Vermelha tem formatos idênticos tendo como principal diferença apenas a cor.

Essa informação pode ser constatada na Tabela 3 em que o SURF aplicado na 3ª situação (**T**) conseguiu 100 % de acerto para a classe Bhut Jolokia, e as classes Bode Amarela e Bode Vermelha, só obtiveram 50 % cada uma. A porcentagem obtida por cada uma das classes é equivalente a quantidade em que cada classe foi classificada corretamente, deste modo todas as imagens da classe Bhut Jolokia foram classificadas corretamente, e para as classes Bode Amarela e Bode Vermelha só metade das imagens foram classificadas corretamente.

A acurácia obtida para o SURF aplicado na 3ª situação (**T**) foi de 83.8%, esse valor é referente a porcentagem de acerto obtido em relação a quantidade de imagens pertencentes a cada uma das classes, e a taxa de acertos obtida para cada uma das classes.

Outro aspecto do qual pode-se constatar é que quando comparado a acurácia entre a 1ª situação (**C**) e 2ª situação (**S**) para os descritores HOG e LBP, pode-se identificar que o simples fato de remover o fundo das imagens ajudou significativamente na classificação das imagens o que resultou em uma maior acurácia em relação as situações observadas aqui.

4.2.1 Análise dos Algoritmos para a 3ª Situação

Na Tabela 4 é ilustrado os resultados obtidos sem a união dos descritores para as 3 Classes: Bhut Joloki, Bode Amarela e Bode Vermelha. Pode-se observar que os resultados obtidos com todos os atributos são menores em relação aos resultados obtidos com a seleção de atributos. Nesta situação foi utilizado o classificador *Fine KNN*. O melhor resultado é obtido com o HISTOGRAMA que obteve uma taxa de acerto de 93,2% com 4 atributos, em que podemos afirmar que é melhor que os 95,9% obtidos com 8 atributos.

Tabela 4 – Tabela com a taxa de acertos para a situação 3.

	Todos (8 Atributos)	Selecionados		
	Acurácia (%)		Qtd	Algoritmos
HOG	77,0	81,1	3	<i>Best First</i>
LBP	82,4	86,5	3	<i>Genetic Search</i>
SURF	85,1	87,8	3	<i>Genetic Search</i>
SIFT	71,6	75,7	3	<i>Best First</i>
HISTOGRAMA	95,9	93,2	4	<i>Best First</i>

4.2.2 Tabela de Melhores Algoritmos

Tendo em vista que os resultados obtidos de forma separada para cada um dos descritores não proporcionaram atingir mais de 90% para a maioria dos descritores, foi realizado as combinações possíveis entre os descritores HOG, LBP, SIFT, SURF e o Histograma para avaliar os resultados entre a união dos descritores.

Os resultados aqui apresentados tem como base os experimentos realizados com a união entre descritores, para cada união de descritores foram realizadas as seleções de atributos com diferentes algoritmos de seleção, de modo que para cada união entre descritores obteve-se mais de uma seleção de atributos. Com os atributos selecionados através dos algoritmos de seleção de atributos da ferramenta WEKA, foram realizado a classificação considerando cada uma das seleções de atributos em diferentes classificadores. Desta forma mais de uma seleção de atributos e mais de um classificador foram usados para avaliar os melhores resultados encontrados.

Itens que apareceram em mais de um algoritmo de seleção de atributos gerando os mesmos atributos e mesmo valor de acurácia estão representados nas Tabelas com o asterisco (*). O item Variação de Atributos significa que houve a realização de uma análise para a escolha dos atributos selecionados.

As Tabelas 5, 6, 7, 8, 9 e 10 apresentam os resultados obtidos para cada um dos experimentos realizados, nas tabelas estão presentes as informações de quais foram os classificadores que apresentaram os melhores resultados, a taxa de acurácia obtida por cada um dos classificadores, os algoritmos usados para seleção de atributos e o conjunto de índices que representa cada um dos atributos selecionados.

A Tabela 5 ilustra os melhores resultados obtidos com a união dos descritores HOG, LBP, SURF e SIFT. Pode-se observar que alguns classificadores obtiveram uma acurácia de 100%, sendo que esses resultados estão considerando as imagens da 3ª situação que foi descrita anteriormente. Quando comparado os resultados da Tabela 3 com a Tabela 5 pode-se constatar que a união entre os descritores possibilita melhores resultados na acurácia, com isso pode-se concluir que a união entre descritores pode proporcionar melhores resultados.

Tabela 5 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP, SURF e SIFT.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Simple Tree, Medium Tree</i>	100	Variação de Atributos	[2,3,4,6,10,25,29,32]
<i>ComplexTree,</i>			
<i>Bagged Trees</i>			
<i>Fine KNN</i>	82,4		
<i>QuadraticDiscriminant</i>	100	<i>Best First*</i>	[2,3,5,9,24,28,31]
<i>Fine KNN</i>	89,2		
<i>Fine KNN</i>	100	<i>Genetic Search</i>	[3,6,10,29,31,32]

Com a união dos quatro descritores explicitados na Tabela 5 observa-se que os atributos selecionados pela ferramenta WEKA são referentes aos quatro descritores, e deve ficar explícito que em certas ocasiões a união dos descritores não irá selecionar atributos referente a todos os descritores presentes na união, mas sim de alguns dos descritores, ou seja aqueles que possuem atributos que são capazes de diferenciar ao máximo uma imagem da outra.

Nos resultados da Tabela 6 observa-se que o algoritmo de seleção que apresentou os melhores atributos a serem usados na classificação foi o *Best First*, tais atributos são referentes aos atributos de (Variância, Energia) para o descritor HOG, (Contraste, Momento da Diferença Inversa) para o SIFT e (Contraste) para o Histograma. Nesse experimento o melhor resultado de acurácia foi obtido pelo classificador *Bagged Trees* com 100%, por outro lado considerando os mesmos atributos para o *Fine KNN* a acurácia foi inferior. Outro aspecto que se identifica nesse experimento é que nenhum atributo referente aos descritores LBP e SURF foram selecionados de modo que, mesmo após a união entre os descritores podem ocorrer situações como esta, não sendo selecionados atributos de certos descritores.

Tabela 6 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP, SURF, SIFT e HISTOGRAMA.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Bagged Trees</i>	100	<i>Best First*</i>	[2,5,31,32,39]
<i>Fine KNN</i>	94,6		

Pode-se observar que na Tabela 7 mesmo com a união dos descritores HOG e LBP, e os atributos selecionados fazerem parte do HOG e do LBP, os melhores resultados obtidos não alcançaram 90%, o que nos permite afirmar que a união de certos descritores não será capaz de proporcionar uma taxa de acurácia tão alta assim. Além dos resultados apresentados nas Tabelas 7, as Tabelas 9, 10, 20, 31 também nos permite identificar casos em que a união entre descritores não proporcionaram uma acurácia igual ou superior a 90%, ou seja não apresentou bons resultados para a união entre os descritores.

Tabela 7 – Tabela com a taxa de acertos referentes a união entre os descritores HOG e LBP.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Weighted</i> KNN	83,8	<i>Best First</i> *	[3,5,10]
<i>Fine</i> KNN	79,7		

A Tabela 8 ilustra que o classificador *Fine* KNN obteve uma acurácia de 100% levando-se em consideração a 3ª situação (**T**). Outro fator que podemos observar é que os atributos selecionados através do *Rank Search* estão totalmente ligados aos três descritores que foram unidos.

Tabela 8 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP e HISTOGRAMA.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Fine</i> KNN	100	<i>Rank Search</i>	[3,6,10,17,18,22,24]

Tabela 9 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP e SIFT.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Fine</i> KNN	83,8	<i>Best First</i> *	[3,5,10]
<i>Subspace Discriminant</i> <i>Fine</i> KNN	83,8	<i>Genetic Search</i>	[2,4,5,7,11,16,22]
<i>Weighted</i> KNN	83,8	<i>Best First</i> $\cap$ <i>Greedy Stepwise</i> $\cap$ <i>Linear Forward Selection</i> $\cap$	[3,10]
		<i>Rank Search</i> $\cap$ <i>Scatter Search V1</i> $\cap$	
		<i>Subset Size Forward Selection</i> $\cap$ <i>Genetic Search</i>	
		<i>Best First</i> $\cap$ <i>Greedy Stepwise</i> $\cap$ <i>Linear Forward Selection</i> $\cap$	
		<i>Rank Search</i> $\cap$ <i>Scatter Search V1</i> $\cap$ <i>Subset Size Forward Selection</i> $\cap$ <i>Genetic Search</i>	
<i>Fine</i> KNN	78,4	<i>Rank Search</i> $\cap$ <i>Scatter Search V1</i> $\cap$ <i>Subset Size Forward Selection</i> $\cap$ <i>Genetic Search</i>	[3,10]

Podemos observar na Tabela 10 que a união dos descritores HOG e SIFT não produziram bons resultados na acurácia de ambos os classificadores, além disso pode-se observar

que os atributos selecionados 2 e 4 fazem referência apenas ao descritor HOG, o que nos indica que a união com o SIFT não surtiu efeito algum. Já quando foi unidos os descritores HOG, SIFT e HISTOGRAMA podemos notar que os resultados apresentados na Tabela 26 aumentou em uma taxa média de 24%, tendo em vista os atributos eles agora estão subdivididos em relação aos três descritores.

Dessa forma pode-se constatar que o fato de associar o HISTOGRAMA com os descritores HOG e SIFT influenciou muito na classificação das imagens, o que leva a dizer que a junção dos descritores HOG e SIFT não conseguem diferenciar muito bem as características de coloração das imagens, logo com a união com o HISTOGRAMA isso se tornou mais visível para os classificadores.

Tabela 10 – Tabela com a taxa de acertos referentes a união entre os descritores HOG e SIFT.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Medium Gaussian SVM</i>	75,7	<i>Best First*</i>	[2,4]
<i>Fine KNN</i>	70,3		

4.2.3 Tabela de acertos e erros

A Tabela 11 e 12 ilustram a matriz de confusão para cada um dos classificadores (*Fine KNN*, *Quadratic Discriminant*, *Quadratic SVM*). Nelas estão identificados na primeira coluna as junções dos descritores, na segunda o classificador, na terceira coluna representa a taxa de acerto para cada uma das três classes avaliadas e na quarta coluna está representado a taxa de erros obtidos por cada uma das três classes em questão. O item **C1** representa a Classe 1 (Bhut Jolokia), o item **C2** a Classe 2 (Bode Amarela) e **C3** a Classe 3 (Bode Vermelha).

Neste experimento foi selecionado o melhor resultado de cada uma das Tabelas de melhores algoritmos, através desses resultados foi possível obter os atributos e selecionar os classificadores que apresentaram melhor performance.

Na primeira linha da Tabela 11 é apresentado os resultados referentes a união dos descritores LBP-HOG, para o classificador *Fine KNN* considerando-se a Classe 1 a taxa de acertos para esta Classe foi de 88% e para as demais Classes 2 e 3 foram respectivamente 95% e 71%. Por outro lado considerando a taxa de erros os resultados são:

- ❑ Classe 1 foi classificada em 5% como sendo da Classe 2 e outros 24% como sendo da classe 3.
- ❑ Classe 2 foi classificada em 5% com sendo da Classe 3.
- ❑ Classe 3 foi classificada em 12% como sendo da Classe 1.

A taxa de erros ilustra o percentual em que cada classe foi classificada incorretamente ou seja, o classificador confundiu uma classe com a outra. Todos os demais resultados da Tabela 11 são interpretados da mesma forma ao descrito anteriormente.

Tabela 11 – Tabela representando a Matriz de Confusão com a taxa de acertos e erros entre a união dos descritores referentes ao HOG.

	Algoritmos	Acerto (%)			Erro (%)		
		C1	C2	C3	C1	C2	C3
LBP-HOG	<i>Fine</i> KNN	88	95	71	C3(24) C2(5)	C3(5)	C1(13)
	<i>Quadratic Discriminant</i>	19	86	90	C2(5) C3(10)		C1(81) C2(10)
SURF-HOG	<i>Fine</i> KNN	97	86	90	C3(5)	C3(5)	C1(3) C2(14)
	<i>Quadratic Discriminant</i>	100	90	95		C3(5)	C2(10)
LBP-SURF-HOG	<i>Fine</i> KNN	100	95	95		C3(5)	C2(5)
	<i>Quadratic Discriminant</i>	100	95	100			C2(5)
HISTOGRAMA-HOG	<i>Fine</i> KNN	100	100	90	C3(10)		
	<i>Quadratic Discriminant</i>	81	100	71	C3(29)		C(19)
HISTOGRAMA-LBP-HOG	<i>Fine</i> KNN	100	100	90	C3(10)		
	<i>Quadratic Discriminant</i>	75	100	86	C3(14)		C1(25)
HISTOGRAMA-SURF-HOG	<i>Fine</i> KNN	100	100	95	C3(5)		
	<i>Quadratic SVM</i>	100	100	95	C3(5)		
HISTOGRAMA-LBP-SURF-HOG	<i>Fine</i> KNN	100	100	95	C3(5)		
	<i>Quadratic SVM</i>	100	100	95	C3(5)		

Por meio dos resultados apresentados na Tabela 11, pode-se constatar que o HOG confundiu na maioria das vezes as cores entre as classes uma vez que as Classe 1 e 3 possuem a mesma cor e ambas foram responsáveis pela maior taxa de erros, mas quando analisando a junção com Histograma pode-se constatar uma melhora na taxa de acertos, deste modo pode-se constatar que o HOG conseguiu diferenciar os formatos entre as classes de forma significativa, o que nos leva a dizer que o HOG é capaz de diferenciar formatos com mais facilidade.

Observando-se os resultados apresentados na Tabela 12, pode-se observar que a Classe 2 e Classe 3 tiveram um índice alto de erros entre essas duas classes, isso permite constatar que o SIFT confundiu muito a cor entre essas duas classes, visto que essas duas classes possuem o mesmo formato, dessa forma pode-se afirmar que o SIFT não consegue diferenciar cores muito bem.

Tabela 12 – Tabela representando a Matriz de Confusão com a taxa de acertos e erros entre a união dos descritores referentes ao SIFT.

	Algoritmos	Acertos (%)			Erros (%)		
		C1	C2	C3	C1	C2	C3
LBP-SIFT	<i>Fine KNN</i>	78	81	38	C3(29)	C3(33)	C1(22) C2(19)
	<i>Quadratic Discriminant</i>	47	62	71	C3(10) C2(14)	C3(19) C1(3)	C1(50) C2(24)
SURF-SIFT	<i>Fine KNN</i>	100	52	52	C3(10)	C3(38)	C2(48)
	<i>Quadratic Discriminant</i>	100	76	62		C3(38)	C2(24)
LBP-SURF-SIFT	<i>Fine KNN</i>	100	76	67	C3(5)	C3(29)	C2(24)
	<i>Quadratic Discriminant</i>	100	81	81		C3(19)	C2(19)
HISTOGRAMA-SIFT	<i>Fine KNN</i>	91	100	90	C3(10)		C1(9)
	<i>Quadratic Discriminant</i>	78	100	81	C3(19)		C1(22)
HISTOGRAMA-LBP-SIFT	<i>Fine KNN</i>	94	100	86	C3(14)		C1(86)
	<i>Quadratic Discriminant</i>	66	100	81	C3(19)		C1(34)
HISTOGRAMA-SURF-SIFT	<i>Fine KNN</i>	100	100	95	C3(5)		
	<i>Quadratic SVM</i>	100	100	95	C3(5)		
HISTOGRAMA-LBP-SURF-SIFT	<i>Fine KNN</i>	100	100	90	C3(5)	C3(5)	
	<i>Quadratic SVM</i>	100	100	95	C3(5)		

Analisando-se a Tabela 13 pode-se constatar que a união entre os descritores com o SIFT obtiveram uma taxa de acurácia inferior a acurácia obtida pelos descritores unidos com o HOG. Observando-se a taxa média por classe é possível concluir que união entre os descritores com o histograma de cores melhorou significativamente os resultados, mas quando comparado os resultados obtidos para Classe 2 e 3 é possível constatar que o SIFT confundiu muito as Classe 2 e 3 em relação a Classe 1, isso se deve ao fato dele não conseguir diferenciar muito bem os formatos entre a imagens da Classe 1 e 3.

Analisando-se a taxa média de acerto em relação ao HOG pode-se constatar que este consegue diferenciar formatos entre imagens.

4.3 Bases de Imagens Públicas

As Bases de Imagens de Textura que foram, inicialmente, utilizadas para os testes e validações dos métodos propostos são:

- **UIUCTex** da Universidade de Illinois em Urbana-Champaign, contendo 25 classes de texturas com 40 imagens por classe, totalizando 1000 imagens (LAZEBNIK;

Tabela 13 – Tabela resumindo a Matriz de Confusão relacionados à união dos descritores com o HOG e com relação a união dos descritores com o SIFT.

	Acertos do <i>Fine</i> KNN (%)					
	HOG			SIFT		
	C1	C2	C3	C1	C2	C3
LBP	88	95	71	78	81	38
SURF	97	86	90	100	52	52
LBP-SURF	100	95	95	100	76	67
HISTOGRAMA	100	100	90	91	100	90
HISTOGRAMA-LBP	100	100	90	94	100	86
HISTOGRAMA-SURF	100	100	95	100	100	95
HISTOGRAMA-LBP-SURF	100	100	95	100	100	90
Média por Classe	97,85	96,57	89,42	94,71	87,00	74,00
Média Geral	94,61			85,23		

SCHMID; PONCE, 2005).

- ❑ **Brodatz** Contém 1776 imagens de texturas agrupadas em 111 classes sendo 16 imagens por classe (BRODATZ, 1966).
- ❑ **VisTex** (*The Vision Texture*) é mantida pelo grupo de Visão e Modelagem do MIT Media LAB. A base de imagens contém 864 imagens representando texturas do mundo real em condições práticas (iluminação, perspectiva, etc.), as imagens estão divididas em 54 classes, cada classe contendo 16 imagens (VISTEX, 2009).
- ❑ **Outex_TC_00013** inclui uma coleção de cenas naturais tendo 1360 imagens, as imagens estão agrupadas em 68 classes, e contendo 16 imagens por classe (OJALA et al., 2002).

O melhor resultado encontrado para a base de pimentas é referente entre a união dos descritores LBP, SIFT, SURF e Histograma. Os resultados são apresentados na Tabela 25 do apêndice, em que pode-se constatar que com diferentes classificadores, e diferentes seleções de atributos foi possível obter uma taxa de acurácia de 100%, além disso, foi possível encontrar uma quantidade mínima de 3 descritores para produzirem o resultado máximo de 100%. Porém, ao analisar essa mesma união de descritores usando-se as bases públicas, o maior resultado entre as Tabelas 14, 15, 16, 17, é de apenas 89,7% (Tabela 16). Deste modo foi analisado outras uniões de descritores e foi possível constatar que a união entre todos os descritores, $HOG \cup LBP \cup SURF \cup SIFT \cup Histograma$, apresentou bons resultados tanto para a base de pimentas quanto para as bases públicas.

Através das análises previamente realizadas e testadas pode-se inferir que a melhor união entre os descritores usados nesse trabalho é a união formada pelos descritores: HOG,

LBP, SIFT, SURF, e Histograma. Deste modo propõe-se esta união como o método proposto desse trabalho.

Para validar o método proposto foram utilizados as bases públicas de imagens Brodatz, Outex, UIUCTex e Vistex. Os resultados apresentados nas Tabelas 14, 15, 16, 17 são referentes a união entre os descritores que apresentaram os melhores resultados para as bases públicas.

Tabela 14 – Resultados da classificação utilizando *Fine* KNN para a Base Brodatz.

Acurácia (%)	Seleção de Atributos	
	Algoritmos	Atributos
HOG $\cup$ LBP $\cup$ SURF $\cup$ SIFT $\cup$ Histograma	Best First $\cap$	
	Genetic Search $\cap$	
	Greedy Stepwise $\cap$	
	Linear Forward Selection $\cap$	3,4,6,7,8,9,10,13,14,15,34,
	Random Search $\cap$	35,36,39,40
	Rank Search $\cap$	
	Scatter Search $\cap$	
LBP $\cup$ SURF $\cup$ SIFT $\cup$ Histograma	Subset Size Forward Selection	
	<i>Rank Search</i>	1,2,3,4,5,6,7,8,16,25,26,27,28,29,30,31,32
SURF $\cup$ SIFT $\cup$ Histograma	<i>Genetic Search</i>	8,18,19,20,21,22,23,24
HOG $\cup$ LBP $\cup$ SURF	<i>Genetic Search</i>	1,3,4,5,6,8,9,10,12,13,14,15,17

Tabela 15 – Resultados da classificação utilizando *Fine* KNN para a Base Outex.

Acurácia (%)	Seleção de Atributos	
	Algoritmos	Atributos
HOG $\cup$ LBP $\cup$ SURF $\cup$ SIFT $\cup$ Histograma	<i>Scatter Search</i>	3,4,5,6,8,10,12,14,15,16,33,34,35,36,38,39,40
LBP $\cup$ SURF $\cup$ SIFT $\cup$ Histograma	<i>Best First</i> $\cap$	
	<i>Genetic Search</i> $\cap$	
	<i>Greedy Stepwise</i> $\cap$	
	<i>Linear Forward Selection</i> $\cap$	
	<i>Random Search</i> $\cap$	2,6,8,25,26,27,28,30,32
	<i>Rank Search</i> $\cap$	
	<i>Scatter Search</i> $\cap$	
	<i>Subset Size Forward Selection</i>	
SURF $\cup$ SIFT $\cup$ Histograma	<i>Best First</i>	17,18,19,20,21,22,23,24
HOG $\cup$ LBP $\cup$ SURF	<i>Scatter Search</i>	3,4,5,6,8,10,12,14,15,16,17

Tabela 16 – Resultados da classificação utilizando *Fine* KNN para a Base Vistex.

Acurácia (%)	Seleção de Atributos	
	Algoritmos	Atributos
HOG $\cup$ LBP $\cup$ SURF $\cup$ SIFT $\cup$ Histograma	<i>Best First</i>	2,4,8,10,12,16,18,33,34,35,36,38,40
LBP $\cup$ SURF $\cup$ SIFT $\cup$ Histograma	<i>Scatter Search</i>	2,6,7,8,10,25,26,27,28,30,32
SURF $\cup$ SIFT $\cup$ Histograma	<i>Best First</i>	2,17,18,19,20,22,24
HOG $\cup$ LBP $\cup$ SURF	<i>Best First</i>	2,3,4,6,8,9,10,14,15,16,18,24

A Tabela 18 ilustra a comparação entre o método proposto e outros métodos da literatura, mostrando também a quantidade de descritores. O método proposto atinge 92,70% com 10 descritores, enquanto que a melhor classificação para a mesma base atinge 98,03% com 108 descritores para a base Vistex. O resultado obtido pelo método proposto se mostra bom, uma vez que para se obter 98,03% foi usado 108 descritores enquanto o método proposto só usou 10 descritores para atingir uma acurácia de 92,70%.

Tabela 17 – Resultados da classificação utilizando *Fine KNN* para a Base UIUCTex.

	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
HOG $\cup$ LBP $\cup$ SURF $\cup$ SIFT $\cup$ Histograma	68,1	<i>Genetic Search</i>	2,3,4,5,10,13,16,22,23,24,30, 33,34,35,36,37,38,39,40
LBP $\cup$ SURF $\cup$ SIFT $\cup$ Histograma	58,6	<i>Best First</i>	5,7,13,22,26,27,28,29,30,31,32
SURF $\cup$ SIFT $\cup$ Histograma	51,8	<i>Genetic Search</i>	8,14,17,18,19,20,21,22,23,24
HOG $\cup$ LBP $\cup$ SURF	42,9	<i>Random Search</i>	3,4,6,10,13,14,22,24

Para os demais métodos da literatura que apresentaram resultados superiores ao do método proposto nesse trabalho, também ocorre a mesma situação descrita anteriormente, em que a diferença de acurácia em relação ao método proposto não é significativa, uma vez que a quantidade de descritores usadas para obtenção da acurácia do método proposto utiliza uma quantidade de descritores bem reduzida.

Tabela 18 – Comparação do método proposto com outros métodos usando o classificador SVM.

Métodos	Nº de Descritores	Acurácia (%)			
		Brodatz	Outex	Vistex	UIUCTex
Gabor	64	82,80	78,90	89,50	65,00
Wavelet	36	68,20	64,50	72,80	50,60
LBP	26	85,40	75,20	86,10	68,80
Estatísticas de 1º Ordem	5	57,70	72,90	68,90	57,20
(BACKES; CASANOVA; BRUNO, 2013)	108	95,27	86,76	98,03	-
(ZHANG et al., 2006)	100	94,90	-	-	-
(RIBEIRO et al., 2015)	[36,48]	93,30	-	96,88	-
Método Proposto	[15,16,10,13]	89,10	90,20	92,70	77,50

Conclusão

O presente trabalho conseguiu demonstrar que para determinadas uniões de descritores de imagens foi possível obter resultados expressivos, porém conclui-se também que nem todos os atributos selecionados são referentes à todos os descritores combinados. Além disso, foi possível demonstrar que a qualidade das imagens influenciam na acurácia, sendo que as imagens fotografadas propiciam uma melhora significativa em relação a imagens obtidas da Internet.

A base de imagens de Pimentas utilizada para os testes, apesar de representar a variação de cor e formato, é reduzida contendo apenas 3 Classes. Isso se deve ao fato do cultivo de pimentas ocorrer em determinadas épocas do ano e, com isso, não foi possível obter outras variedades para a geração de novas Classes. Como um trabalho futuro propõe-se a obtenção novas imagens de pimentas para a melhor validação do método proposto e o desenvolvimento de uma base de imagens de pimentas.

Neste trabalho foram utilizados os algoritmos para extração de características de imagens: HOG, LBP, SIFT, SURF e as estatísticas de primeira ordem, porém existe outros algoritmos para extração de características e que não foram testados. Dessa forma, propõe-se testar outros algoritmos de extração de características para as imagens de pimentas.

Após realizar os testes para a base de imagens de pimentas e para as bases públicas, foi possível constatar que diversas das uniões de descritores que atingiram a taxa máxima de acertos para a base de pimentas não conseguiram a mesma taxa de acertos nas bases da públicas. Exemplo dessa união foi $LBP \cup SURF \cup SIFT \cup \text{Histograma}$. Ao se analisar os resultados obtidos para as diferentes bases públicas e para a base de pimentas, foi possível propor um método que resultou na união de $HOG \cup LBP \cup SURF \cup SIFT \cup \text{Histograma}$, apresentando uma taxa de classificação superior aos 90% e com uma quantidade de atributos bem inferior a outros métodos proposto na literatura.

O método proposto foi comparado a outros métodos da literatura e foi possível demonstrar que com uma quantidade de descritores reduzida obteve-se uma taxa de acerto de 92,70%, enquanto outros métodos da literatura para superar o método proposto tive-

ram que usar uma quantidade superior a 35 descritores.

Como trabalho futuro, propõe-se aplicar o método proposto para a geração do vetor de características para a utilização em métodos de recuperação de imagens em banco de dados de pimentas, no caso as imagens do BG *Capsicum*.

Referências

- ALVARENGA, M. T. Utilização da Ferramenta J48 para Descoberta do Conhecimento em Bases de Dados Fitossanitários, Climáticos e Espectrais. p. 42, 2014. Nenhuma citação no texto.
- ARAÚJO, V. M. D.; JR, A. D. S. B.; FALATE, R. Combinação de classificadores para identificação de plantas a partir da imagem da folha. 2015. Nenhuma citação no texto.
- BACKES, A. R.; CASANOVA, D.; BRUNO, O. M. Texture analysis and classification: A complex network-based approach. **Information Sciences**, v. 219, p. 168–180, 2013. ISSN 00200255. Nenhuma citação no texto.
- BAMA, B. S. Content Based Leaf Image Retrieval (Cblir) Using Shape , Color and Texture Features. **Indian Journal of Computer Science and Engineering**, v. 2, n. 2, p. 202–211, 2011. Nenhuma citação no texto.
- BAY, H.; TUYTELAARS, T.; Van Gool, L. SURF: Speeded up robust features. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, v. 3951 LNCS, p. 404–417, 2006. ISSN 03029743. Nenhuma citação no texto.
- BRODATZ, P. **Textures: a photographic album for artists and designers**. [S.l.]: Dover Publications, 1966. (Dover pictorial archives). Nenhuma citação no texto.
- COUTO, L. N. et al. Texture characterization via improved deterministic walks on image-generated complex network. In: IEEE. **Image Processing (ICIP), 2015 IEEE International Conference on**. [S.l.], 2015. p. 4416–4420. Nenhuma citação no texto.
- DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. **Proceedings - 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2005**, I, p. 886–893, 2005. ISSN 1063-6919. Nenhuma citação no texto.
- ECHER, M. D. M.; COSTA, C. P. D. REACTION OF SWEET PEPPER TO THE POTATO VIRUS Y (PVY m) 1. **Scientia Agricola**, v. 59, n. 2, p. 309–314, 2002. Nenhuma citação no texto.
- EMATER-MG. Relatório sintético para olericultura. **safra agrícola**, 2016. Nenhuma citação no texto.

FRITZ ALBREGTSEN. Statistical Texture Measures Computed from Gray Level Cooccurrence Matrices. 2008. Disponível em: <<http://www.jstor.org/stable/302397?origin=crossref>>. Nenhuma citação no texto.

GHANSHYAM RAGHUWANSHI AND VIPIN TYAGI. A Survey on Texture Image Retrieval. 2016. ISSN 21945357. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-84945947812&partnerID=tZOtx>>. Nenhuma citação no texto.

GONZALEZ, R.; WOODS, R. **Processamento Digital de Imagens**. [S.l.]: Longman do Brasil, 2010. Nenhuma citação no texto.

INTEL, S. **Histogram of Oriented Gradients (HOG)**. 2016. Disponível em: <<https://software.intel.com/en-us/node/529070>>. Nenhuma citação no texto.

KWITT, R. et al. Endoscopic image analysis in semantic space. **Medical Image Analysis**, Elsevier B.V., v. 16, n. 7, p. 1415–1422, 2012. ISSN 13618415. Disponível em: <<http://dx.doi.org/10.1016/j.media.2012.04.010>>. Nenhuma citação no texto.

LARA, A. C. **Descritor de bordas e quantização espacial flexível aplicados a categorização de objetos**. 131 p. Tese (Doutorado) — Universidade de São Paulo, 2013. Nenhuma citação no texto.

LAZEBNIK, S.; SCHMID, C.; PONCE, J. A sparse texture representation using local affine regions. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, v. 27, n. 8, p. 1265–1278, Aug 2005. ISSN 0162-8828. Nenhuma citação no texto.

LI, C.; WANG, B. Fisher Linear Discriminant Analysis. p. 1–6, 2014. Nenhuma citação no texto.

LOWE, D. G. Object recognition from local scale-invariant features. **Proceedings of the Seventh IEEE International Conference on Computer Vision**, v. 2, n. [8, p. 1150–1157, 1999. ISSN 0-7695-0164-8. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=790410>>. Nenhuma citação no texto.

_____. Distinctive image features from scale-invariant keypoints. **International Journal of Computer Vision**, v. 60, n. 2, p. 91–110, 2004. ISSN 09205691. Nenhuma citação no texto.

MARTINS, V. C. et al. IV Encontro de Iniciação Científica e Tecnológica da UFU Recuperação de informações de características morfológicas de acessos de pimenta. p. 2, 2014. Nenhuma citação no texto.

MOREIRA, G. R. et al. Importância econômica, perspectivas e potencialidades do mercado para pimenta. **Informe Agropecuário**, v. 27, n. 235, p. 7–15, 2006. Nenhuma citação no texto.

OJALA, T. et al. Outex-new framework for empirical evaluation of texture analysis algorithms. In: IEEE. **Pattern Recognition, 2002. Proceedings. 16th International Conference on**. 2002. v. 1, p. 701–706. Disponível em: <http://ieeexplore.ieee.org/xpls/abs/_all.jsp?arnumber=1044854>. Nenhuma citação no texto.

OJALA, T.; PIETIKAINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on feature distributions. **Pattern Recognition**, v. 29, n. 1, p. 51–59, 1996. ISSN 00313203. Nenhuma citação no texto.

RAM, L. **Fusão de descritores de histogramas de gradientes para a detecção de faces baseado em uma cascata de classificadores**. Tese (Doutorado) — Universidade Federal de Ouro Preto, 2014. Nenhuma citação no texto.

RIBEIRO, C. S. C. Criando novas variedades. In **Reifschneider FJB (org.) Capsicum: pimentas e pimentões no Brasil**. Embrapa Transferência de Tecnologia/Embrapa Hortaliças, p. 68–80, 2000. Nenhuma citação no texto.

RIBEIRO, T. P. et al. Texture characterization via automatic threshold selection on image-generated complex network. In: SPRINGER. **Iberoamerican Congress on Pattern Recognition**. [S.l.], 2015. p. 468–476. Nenhuma citação no texto.

RODRIGUES, B. U. et al. Cachaça type identification using color information and computer vision. p. 45–49, 2014. Nenhuma citação no texto.

RURAL, P. Pimenta - um mundo de cores e sabores. **Revista Panorama Rural**, p. 7, 30–35,, 2006. Nenhuma citação no texto.

SOUSA, R. T. Avaliação de classificadores na classificação de radiografias de tórax para o diagnóstico de pneumonia infantil. p. 61, 2013. Disponível em: <<http://www.portal.inf.ufg.br/mestrado/sites/www.inf.ufg.br/mestrado/files/uploads/Dissertacoes/Rafael.pdf>>. Nenhuma citação no texto.

SURESHA, M. Texture Features and Decision Trees based Vegetables Classification. n. April, p. 21–26, 2012. Nenhuma citação no texto.

University of California. **Germplasm**. 2016. Disponível em: <<http://sbc.ucdavis.edu/About/US/Seed/Biotechnologies/Germplasm/>>. Nenhuma citação no texto.

VISTEX. **Vision Texture Database**. 2009. Nenhuma citação no texto.

WEKA. **Weka 3: Data Mining Software in Java**. 2016. Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/>>. Nenhuma citação no texto.

ZHANG, J. et al. Scale invariant texture representation based on frequency decomposition and gradient orientation. **Pattern Recognition Letters**, Elsevier Ltd., v. 51, p. 57–62, 2015. ISSN 01678655. Disponível em: <<http://dx.doi.org/10.1016/j.patrec.2014.08.002>>. Nenhuma citação no texto.

_____. Local Features and Kernels for Classification of Texture and Object Categories: A Comprehensive Study. In: **Computer Vision and Pattern Recognition Workshop, 2006. CVPRW '06. Conference on**. [S.l.: s.n.], 2006. p. 13. Nenhuma citação no texto.

Apêndices

APÊNDICE **A**

Tabelas

As Tabelas 19 a 33, representam os resultados das análises realizadas na união entre os descritores para a Base de Pimentas. Em cada uma das Tabelas está presente o classificador usado, a acurácia obtida pelo classificador para a união entre os determinados descritores, o algoritmo de seleção de atributos e o conjunto de índices que representam cada atributo. Pode-se constatar nos resultados que algumas das combinações propiciaram atingir uma taxa de acurácia de 100%, e que em determinadas uniões, os resultados ficaram abaixo de 90%.

Tabela 19 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP, SIFT e HISTOGRAMA.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Fine</i> KNN	100	<i>Rank Search</i>	[3,6,10,25,26,30,32]

Tabela 20 – Tabela com a taxa de acertos referentes a união entre os descritores LBP e SIFT.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Weighted</i> KNN	73,0	<i>Best First*</i>	[2,7,9,13]
<i>Fine</i> KNN	70,3		

Tabela 21 – Tabela com a taxa de acertos referentes a união entre os descritores LBP, SIFT e HISTOGRAMA.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
Quadratic SVM	97,3	<i>Best First</i> $\cap$	[2,18,24]
		<i>Genetic Search</i> $\cap$	
		<i>Greedy Stepwise</i> $\cap$	
		<i>Linear Forward Selection</i> $\cap$	
		<i>Rank Search</i> $\cap$	
		<i>Scatter Search V1</i> $\cap$	
		<i>Subset Size Forward Selection</i>	
Fine KNN	90,5	<i>Best First</i> $\cap$	[2,18,24]
		<i>Genetic Search</i> $\cap$	
		<i>Greedy Stepwise</i> $\cap$	
		<i>Linear Forward Selection</i> $\cap$	
		<i>Rank Search</i> $\cap$	
		<i>Scatter Search V1</i> $\cap$	
		<i>Subset Size Forward Selection</i>	

Tabela 22 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP e SURF.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Simple Tree</i>	100	<i>Best First</i>	[2,3,5,9,16,20,23]
<i>Medium Tree</i>			
<i>Complex Tree</i>			
<i>Quadratic Discriminant</i>	82,4		
<i>Fine KNN</i>			
<i>Simple Tree</i>	100	<i>Genetic Search</i>	[2,3,4,14,16,20,23]
<i>Medium Tree</i>			
<i>Complex Tree</i>			
<i>Fine KNN</i>	83,8		
<i>Quadratic Discriminant</i>	100	<i>Linear Forward Selection</i>	[2,3,5,9,20,21,23]
<i>Fine KNN</i>	94,6		
<i>Bagged Trees</i>	100	<i>Linear Forward Selection</i>	[3,4,6,10,21,22,24]
<i>Fine KNN</i>	97,3		
<i>Bagged Trees</i>	100	<i>Subset Size Forward Selection</i>	[3,5,10,24]
<i>Fine KNN</i>	98,6		

Tabela 23 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP, SURF e HISTOGRAMA.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Quadratic Discriminant</i>			
<i>Weighted KNN</i>	100	<i>Best First*</i>	[3,6,10,21,24,25,32]
<i>Bagged Trees</i>			
<i>Subspace KNN</i>			
<i>Fine KNN</i>	100		
<i>Quadratic Discriminant</i>			
<i>Cubic SVM</i>	100	<i>Genetic Search</i>	[4,6,7,18,21,23,24,25,30,32]
<i>Bagged Trees</i>			
<i>Fine KNN</i>			
<i>Quadratic Discriminant</i>	100	<i>Rank Search</i>	[3,6,17,18,21,22,23,24,25,26,30,32]
<i>Bagged Trees</i>			
<i>Fine KNN</i>			
	98,6		
<i>Quadratic Discriminant</i>	100	<i>Best First</i> $\cap$	[6,21,24,25,32]
<i>Quadratic SVM</i>		<i>Genetic Search</i> $\cap$	
<i>Cubic SVM</i>		<i>Greedy Stepwise</i> $\cap$	
<i>Bagged Trees</i>		<i>Linear Forward Selection</i> $\cap$	
		<i>RankSearch</i> $\cap$	
		<i>Scatter Search VI</i> $\cap$	
		<i>Subset Size Forward Selection</i>	
<i>Fine KNN</i>	98,6	<i>Best First</i> $\cap$	[6,21,24,25,32]
		<i>Genetic Search</i> $\cap$	
		<i>Greedy Stepwise</i> $\cap$	
		<i>Linear Forward Selection</i> $\cap$	
		<i>Rank Search</i> $\cap$	
		<i>Scatter Search VI</i> $\cap$	
		<i>Subset Size Forward Selection</i>	

Tabela 24 – Tabela com a taxa de acertos referentes a união entre os descritores LBP, SIFT e SURF.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Simple Tree</i>	90,5	<i>Genetic Search</i>	[2,9,13,21,23,24]
<i>Linear SVM</i>			
<i>Fine KNN</i>			
<i>Linear SVM</i>	90,5	<i>Greedy Stepwise</i>	[2,9,13,21]
<i>Fine KNN</i>	82,4		
		<i>Subset Size Forward Selection</i>	
<i>Simple Tree</i>	90,5	<i>Rank Search</i>	[2,9,13,24]
<i>Quadratic Discriminat</i>			
<i>Fine KNN</i>			
	81,1		

Tabela 25 – Tabela com a taxa de acertos referentes a união entre os descritores LBP, SIFT, SURF e HISTOGRAMA.

Classificadores	Acurácia (%)	Seleção de Atributos			
		Algoritmos	Atributos		
<i>Quadratic Discriminant</i>	100	<i>Best First*</i>	[2,21,24,25,26,32]		
<i>Quadratic SVM</i>					
<i>Cubic SVM</i>					
<i>Weighted KNN</i>					
<i>Bagged Trees</i>	100				
<i>Fine KNN</i>					
<i>Quadratic Discriminant</i>	100	<i>Genetic Search</i>	[13,21,24,25,30,32]		
<i>Cubic SVM</i>	100				
<i>Fine KNN</i>	98,6				
<i>Complex Tree</i>	100	<i>Rank Search</i>	[21,24,26,27,30,32]		
<i>Medium Tree</i>					
<i>Simple Tree</i>					
<i>Quadratic Discriminant</i>					
<i>Cubic SVM</i>					
<i>Bagged Trees</i>					
<i>Fine KNN</i>	97,3	<i>Best First</i> $\cap$ <i>Genetic Search</i> $\cap$ <i>Greedy Stepwise</i> $\cap$ <i>Linear Forward Selection</i> $\cap$ <i>Rank Search</i> $\cap$ <i>Scatter Search</i> VI $\cap$ <i>Subset Size Forward Selection</i>	[21,24,32]		
<i>Complex Tree</i>	100				
<i>Medium Tree</i>					
<i>Simple Tree</i>					
<i>Quadratic Discriminant</i>					
<i>Linear SVM</i>					
<i>Cubic SVM</i>					
<i>Bagged Trees</i>					
<i>Fine KNN</i>	100	<i>Best First</i> $\cap$ <i>Genetic Search</i> $\cap$ <i>Greedy Stepwise</i> $\cap$ <i>Linear Forward Selection</i> $\cap$ <i>Rank Search</i> $\cap$ <i>Scatter Search</i> VI $\cap$ <i>Subset Size Forward Selection</i>	[21,24,32]		

Tabela 26 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, SIFT e HISTOGRAMA.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Weighted KNN</i>	98,6	<i>Rank Search</i>	[3,6,17,18,22,24]
<i>Fine KNN</i>	97,3		

Tabela 27 – Tabela com a taxa de acertos referentes a união entre os descritores HOG e SURF.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Quadratic Discriminant</i>	100	<i>Best First</i> <i>Random Search</i>	[3,4,6,9,13,16]
<i>Quadratic SVM</i>			
<i>Weighted KNN</i>			
<i>Fine KNN</i>	100	<i>Linear Forward Selection</i>	[3,4,6,10,11,16]
<i>Quadratic Discriminant</i>	100		
<i>Fine KNN</i>	95,9	<i>Best First</i> $\cap$ <i>Genetic Search</i> $\cap$ <i>Linear Forward Selection</i> $\cap$ <i>Random Search</i>	[3,4,16]
<i>Bagged Trees</i>	100		
<i>Fine KNN</i>	94,6	<i>Best First</i> $\cap$ <i>Genetic Search</i> $\cap$ <i>Linear Forward Selection</i> $\cap$ <i>Random Search</i>	[3,4,16]

Tabela 28 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, SURF e HISTOGRAMA.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Quadratic Discriminant</i>	100	<i>Best First*</i>	[3,6,13,16,17,24]
<i>Cubic SVM</i>			
<i>Bagged Trees</i>			
<i>Fine KNN</i>			
<i>Quadratic Discriminant</i>	100	<i>Genetic Search</i>	[3,4,6,13,14,15,16,17,18,19,23,24]
<i>Linear SVM</i>			
<i>Quadratic SVM</i>			
<i>Cubic SVM</i>			
<i>Bagged Trees</i>			
<i>Fine KNN</i>			

Tabela 29 – Tabela com a taxa de acertos referentes a união entre os descritores LBP e SURF.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Cubic SVM</i>	93,2	<i>Scatter Search VI</i> <i>Subset Size Forward Selection</i>	[2,13]
<i>Medium Gaussian SVM</i>			
<i>Fine KNN</i>			
<i>Medium Gaussian SVM</i>	93,2	<i>Rank Search</i>	[2,16]
<i>Fine KNN</i>	90,5		

Tabela 30 – Tabela com a taxa de acertos referentes a união entre os descritores LBP, SURF e HISTOGRAMA.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Quadratic Discriminant</i>	100	<i>Best First*</i>	[2,13,16,17,18,24]
<i>Linear SVM</i>			
<i>Quadratic SVM</i>			
<i>Cubic SVM</i>			
<i>Weighted KNN</i>			
<i>Bagged Trees</i>			
<i>Fine KNN</i>	100	<i>Genetic Search</i>	[2,9,16,17,18,24]
<i>Quadratic Discriminant</i>			
<i>Fine KNN</i>	100	<i>Rank Search</i>	[2,13,18,19,24]
<i>Complex Tree</i>			
<i>Medium Tree</i>			
<i>Simple Tree</i>			
<i>Quadratic Discriminant</i>			
<i>Linear SVM</i>			
<i>Quadratic SVM</i>			
<i>Cubic SVM</i>			
<i>Weighted KNN</i>			
<i>Bagged Trees</i>			
<i>Fine KNN</i>			

Tabela 31 – Tabela com a taxa de acertos referentes a união entre os descritores SIFT e SURF.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Bagged Trees</i>	82,4	<i>Genetic Search</i>	[4,5,13,15,16]
<i>Fine KNN</i>	68,9		
<i>Complex Trees</i>	82,4	<i>Linear Forward Selection</i>	[1,5,16]
<i>Medium Trees</i>			
<i>Fine KNN</i>	71,6	<i>Rank Search</i>	

Tabela 32 – Tabela com a taxa de acertos referentes a união entre os descritores SIFT, SURF e HISTOGRAMA.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Quadratic Discriminant</i>	100	<i>Best First*</i>	[13,16,17,18,24]
<i>Bagged Trees</i>			
<i>Fine KNN</i>	98,6		
<i>Complex Tree</i>	100	<i>Rank Search</i>	[13,16,18,19,22,24]
<i>Medium Tree</i>			
<i>Simple Tree</i>			
<i>Quadratic Discriminant</i>			
<i>Cubic SVM</i>			
<i>Bagged Trees</i>	97,3	<i>Best First</i> $\cap$ <i>Genetic Search</i> $\cap$ <i>Greedy Stepwise</i> $\cap$ <i>Linear Forward Selection</i> $\cap$ <i>Rank Search</i> $\cap$ <i>Scatter Search</i> $\cap$ <i>Subset Size Forward Selection</i>	[13,16,24]
<i>Fine KNN</i>			
<i>Complex Tree</i>	100	<i>Best First</i> $\cap$ <i>Genetic Search</i> $\cap$ <i>Greedy Stepwise</i> $\cap$ <i>Linear Forward Selection</i> $\cap$ <i>Rank Search</i> $\cap$ <i>Scatter Search</i> $\cap$ <i>Subset Size Forward Selection</i>	[13,16,24]
<i>Medium Tree</i>			
<i>Simple Tree</i>			
<i>Quadratic Discriminant</i>			
<i>Cubic SVM</i>			
<i>Bagged Trees</i>	100	<i>Best First</i> $\cap$ <i>Genetic Search</i> $\cap$ <i>Greedy Stepwise</i> $\cap$ <i>Linear Forward Selection</i> $\cap$ <i>Rank Search</i> $\cap$ <i>Scatter Search</i> $\cap$ <i>Subset Size Forward Selection</i>	[13,16,24]
<i>Fine KNN</i>			

Tabela 33 – Tabela com a taxa de acertos referentes a união entre os descritores HOG, LBP, SIFT, SURF e Histograma.

Classificadores	Acurácia (%)	Seleção de Atributos	
		Algoritmos	Atributos
<i>Fine KNN</i>	94,6	<i>Best First</i> $\cap$	[2,5,31,32,39]
		<i>Genetic Search</i> $\cap$	
		<i>Greedy Stepwise</i> $\cap$	
		<i>Linear Forward Selection</i> $\cap$	
		<i>Rank Search</i> $\cap$	
		<i>Scatter Search VI</i> $\cap$	
		<i>Subset Size Forward Selection</i>	
<i>Bagged Trees</i>	100	<i>Best First</i> $\cap$	[2,5,31,32,39]
		<i>Genetic Search</i> $\cap$	
		<i>Greedy Stepwise</i> $\cap$	
		<i>Linear Forward Selection</i> $\cap$	
		<i>Rank Search</i> $\cap$	
		<i>Scatter Search VI</i> $\cap$	
		<i>Subset Size Forward Selection</i>	