

UNIVERSIDADE CATÓLICA DOM BOSCO
PROGRAMA DE PÓS-GRADUAÇÃO EM BIOTECNOLOGIA

Visão Computacional aplicada na classificação de grãos de pólen

Autora: Lia Nara Balta Quinta
Orientador: Prof. Dr. Hemerson Pistori
Coorientadora: Profa. Dra. Marney Pascoli Cereda

Campo Grande
Mato Grosso do Sul
Janeiro - 2013

UNIVERSIDADE CATÓLICA DOM BOSCO
PROGRAMA DE PÓS-GRADUAÇÃO EM BIOTECNOLOGIA

Visão Computacional aplicada na classificação de grãos de pólen

Autora: Lia Nara Balta Quinta
Orientador: Prof. Dr. Hemerson Pistori
Coorientadora: Profa. Dra. Marney Pascoli Cereda

*Dissertação apresentada como parte das exigências para
obtenção do título de MESTRE EM BIOTECNOLO-
GIA, no Programa de Pós-Graduação em Biotecnologia
da Universidade Católica Dom Bosco - Área de concen-
tração: Biotecnologia Aplicada à Agropecuária*

Campo Grande
Mato Grosso do Sul
Janeiro - 2013

Agradecimentos

Agradeço ao apoio, dedicação e compreensão da minha mãe e irmã. Agradeço aos ensinamentos que meu orientador Dr. Hemerson Pistori compartilhou comigo durante todos os anos que passei no grupo INOVISAO. Agradeço pela rigidez que sempre teve, acredito que ela me fez crescer como pessoa e me tornar alguém mais forte e capacitada. Agradeço à equipe do INOVISAO em especial ao Wesley Tessaro, Diogo Soares, Kleber Padovani de Souza e Willian Paraguassu Amorim.

Obrigada à equipe do CeTeAgro que sempre ajudou na coleta de imagens e dados. Em especial à professora Dra. Marney Pascoli Cereda e a Bióloga Ariadne Barbosa Gonçalves.

Agradeço à paciência e dedicação de alguns professores do mestrado. Obrigada especialmente à Ana Paula Ferreira Leal que em muitas aulas me ajudou a "traduzir" o que os termos técnicos que alguns professores falavam. Agradeço as pessoas que ajudaram direta ou indiretamente na realização deste trabalho.

Este trabalho obteve apoio intelectual de Daniel Sage do grupo denominado *Biomedical Image* que nos forneceu o código fonte do plugin método de extração de atributos *wavelets* e do Me. Willian Paraguassu Amorim que nos forneceu a implementação do algoritmo FCO (Floresta de caminhos ótimos).

Este trabalho recebeu apoio financeiro da Universidade Católica Dom Bosco, UCDB, da Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do Estado de Mato Grosso do Sul, FUNDECT e do Conselho Nacional de Desenvolvimento Científico e Tecnológico, CNPq.

Biografia da autora

Lia Nara Balta Quinta, filha de Maria Fátima Balta Quinta e Wolmar Roberto Quinta, nasceu em Cachoeiro de Itapemirim - Espírito Santo no dia 15 de junho de 1987.

Estudou o ensino fundamental e médio na Escola Objetivo Girassol na cidade de Jardim - Mato Grosso do Sul. Formou em Bacharel em Engenharia de Computação no ano de 2009 na Universidade Católica Dom Bosco na cidade de Campo Grande - Mato Grosso do Sul.

Em 2006, integrou-se ao INOVISAO - Grupo de Pesquisa, Desenvolvimento e Inovação em Visão Computacional subgrupo do GPEC - Grupo de Pesquisa em Engenharia e Computação realizando pesquisas na área de Visão Computacional. Durante toda a pesquisa, a autora trabalhou com extração de atributos, seleção de atributos e classificação automática participando do projeto CORIU - que realiza classificação de defeitos em couro bovino -, BioViC - que realiza a contagem de leveduras para auxiliar o controle na produção do etanol - e Pólen - que auxilia a identificação de grãos de pólen em amostras de mel.

Em março de 2010 iniciou o Mestrado em Biotecnologia na Universidade Católica Dom Bosco, dando continuidade às pesquisas na área de Visão Computacional. No dia 11 de setembro de 2012, foi realizada a banca de defesa da dissertação.

Resumo

Devido ao contato das abelhas com as flores durante a extração de néctar para a produção de mel, grãos de pólen dessas flores podem ser transportados por esses insetos para as suas colmeias e, conseqüentemente, caírem no mel ali produzido. Com isso, algumas características do produto, como o sabor, podem ser modificadas, aumentando por vezes seu valor de mercado. Por meio de análise de amostras de mel em microscópio, é possível visualizar os grãos de pólen e, assim, rastrear sua procedência. Atualmente, a rastreabilidade do mel é realizada através da contagem visual, em que um especialista humano registra as quantidades de grãos de pólen de cada espécie. Essa contagem é minuciosa e cansativa. Com o objetivo de auxiliar a rastreabilidade do mel produzido na região Centro-Oeste, este trabalho empregou técnicas de visão computacional e inteligência artificial em imagens microscópicas com o intuito de automatizar essa contagem. Para realizar a classificação dos grãos de pólen, foram aplicadas técnicas denominadas Floresta de Caminhos Ótimos (FCO), C4.5, SVM e KNN. Inicialmente, foi necessário extrair das imagens de grãos de pólen informações relevantes para classificá-los e, para isso, técnicas de extração de atributos foram aplicadas. Atributos de cor (RGB e HSB), forma (fator de forma, circularidade, relação entre eixos e densidade) e textura (matriz de coocorrência, mapas de interação, padrões binários locais, padrões binários locais invariante à rotação e transformada de wavelets) foram utilizados nos experimentos. Com os dados resultantes da extração de atributos, o classificador foi utilizado para distinguir as classes (espécies de grãos de pólen) analisadas. Os resultados obtidos com os algoritmos de classificação foram comparados através do teste *T-Students* e teste de Friedman, utilizando as métricas *recall*, *precision*, *f-score* e taxa de acerto. De acordo com os resultados, em alguns experimentos, o KNN obteve melhor resultado entre os algoritmos testados. O resultado da classificação para experimentos com 9 classes distintas foi superior à 76% de acerto.

Palavras-chave: Visão computacional; Pólen; Classificação automática.

Resumo

Due to the contact between flowers and bees during nectar extraction for honey production, pollen grains of these flowers can be carried by these insects to their hives and hence fall in honey produced there. Thus, some product characteristics, such as flavor, might be modified, increasing or decreasing their market value in some cases. Through analysis of honey samples under a microscope, pollen grains can be seen and thus we can trace honey origin. Currently, the traceability of honey is accomplished by visual count, a rigorous and exhausting task where a human expert registers the number of pollen grains of each species is present. Aiming to help the traceability of honey produced in a specific region of Brazil, this work applied computer vision and artificial intelligence techniques in microscopic images in order to automate this count. For the classification of pollen grains, we applied techniques called Optimal Path Forest (OPF), C4.5, SVM e KNN. Initially, it was necessary to extract relevant information from pollen grains images to classify them. Therefore, feature extraction techniques were applied. Experiments using color features (RGB and HSB), form features (form factor, circularity, aspect ratio and density) and texture features (co-occurrence matrix, interaction maps, local binary patterns, local binary patterns and rotation invariant wavelet transform) were performed. After feature extraction, a classifier was used to distinguish among classes (species of pollen grains). Results from OPF algorithm were compared with traditional classifiers results, namely, C4.5, SVM and KNN. The experimental results were compared using T-Student and Friedman tests, using recall, precision, f-score and hit rate as metrics. According to results, in some experiments, the KNN had the best results among the tested algorithms. The result of the classification for experiments with 9 different classes was higher than 76 % accuracy

Keywords: Computer vision; Pollen; Automatic classification.

Conteúdo

1	Introdução	5
2	Fundamentação Teórica	8
2.1	Palinologia	8
2.2	Classificação visual de grãos de pólen	8
2.3	Mel	9
2.4	Angiospermas	10
2.5	Classificação da frequência polínica	11
2.6	Visão computacional	11
2.6.1	Imagens digitais	12
2.6.2	Extração de atributos	12
2.7	Seleção de atributos	20
2.8	Validação dos resultados	21
2.8.1	Teste de hipótese	22
3	Aprendizagem supervisionada	24
3.1	Floresta de Caminhos Ótimos (FCO)	24
3.2	Treinamento	25
3.3	Classificação	27
4	Materiais e Métodos	29
4.1	Preparo da amostra	31
4.2	Microscópios	33
4.3	Banco de imagens	34
4.3.1	Conjunto de imagens 1	35
4.3.2	Conjunto de imagens 2	36
4.3.3	Conjunto de imagens 3	37
4.3.4	Conjunto de imagens 4	37
4.3.5	Conjunto de imagens 5	37
4.4	Experimentos	38
5	Resultados e Análises	40
5.1	Experimento 1	40
5.2	Experimento 2	41
5.3	Experimento 3	42
5.4	Experimento 4	43
6	Conclusões e Trabalhos Futuros	50

Lista de Figuras

2.1	Amostras de méis com coloração variada capturada na Fazenda Escola da Universidade Católica Dom Bosco	9
2.2	(a) Imagem de grão de pólen de um mamoeiro selvagem com resolução de 672 X 506 <i>pixels</i> e (b) Imagem de grão de pólen de uma roseira com resolução de 187 X 167 <i>pixels</i>	10
2.3	(a) Imagem em tons de cinza, (b) imagem ampliada e (c) matriz de <i>pixels</i> correspondente	12
2.4	(a) <i>pixel</i> na cor preta, (b) <i>pixel</i> na cor cinza e (c) <i>pixel</i> na cor branca	13
2.5	Exemplo de combinações das cores primárias vermelho, verde e azul.	13
2.6	(a) Grão de pólen de eucalipto, (b) grão de pólen de aroeira	14
2.7	Exemplo ilustrando uma imagem de grão de pólen com uma elipse verde, uma linha azul escura indicando o comprimento do objeto e uma linha azul clara indicando a largura do objeto.	15
2.8	(a) Exemplo de textura de uma zebra e (b) exemplo de textura de um dálmata.	16
2.9	Exemplo do método LBP.	17
2.10	(a) representa uma cadeia de binários, (b) representa uma forma de rotação e (c) representa a cadeia de binários após a rotação.	18
2.11	Matriz composta pelos valores de uma imagem (a), matriz de coocorrência com ângulo 0 e distância 1 (b).	19
2.12	Exemplo utilizando mapas de interação.	20
2.13	(a) Imagem original e (b) Imagem das bandas após a aplicação da transformada de <i>Wavelets</i>	20
3.1	(a) Exemplo de imagens da classe A e (b) Exemplo de imagens da classe B.	24
3.2	Grafo completo.	26
3.3	Grafo completo com a relação de adjacência entre as arestas.	26
3.4	Subgrafo gerado a partir da árvore geradora mínima.	26
3.5	Definição dos protótipos de cada classe.	27
3.6	Comparação de uma nova amostra com as amostras existentes no grafo.	27
3.7	Classificação da nova amostra como pertencente à classe azul clara.	28
4.1	(a) Grão de pólen de Assa-peixe, (b)Grão de pólen de Aroeira e (c) Grão de pólen de Cipó-Uva	29
4.2	Imagens de um lápis de escrever capturadas com o objeto em diferentes posições	30
4.3	Diferentes visões do grão de pólen de mamoeiro selvagem.	31
4.4	Imagem com ruídos evidenciados.	31
4.5	(a) Imagem de um microscópio evidenciando a mesa e a objetiva (b) Imagem ilustrativa da placa de vidro (representada pela cor azul clara) e lamela (representada pela cor azul escura).	32
4.6	Imagem obtida de amostras de mel contendo grãos de pólen de diferentes espécies.	33

4.7	(a) Imagem obtida através da primeira técnica, (b) Imagem obtida através da segunda técnica e (c) Imagem obtida através da terceira técnica	34
4.8	(a) microscópio tradicional marca Bel, (b) dispositivo de captura marca Proscope HR e (c) dispositivo de captura acoplado ao microscópio e (d) microscópio Monotela LCD Marca LCD Micro Bresse	34
4.9	(a) Imagem capturada através do microscópio A e (b) Imagem capturada através do microscópio B	35
4.10	(a) Grão de pólen de Mamoeiro Selvagem, (b) Grão de pólen de Assa-peixe, (c) Grão de pólen de Aroeira, (d) Grão de pólen de Cipó-Uva, (e) Grão de pólen de barbatimão, (f) Grão de pólen de eucalipto.	35
4.11	Classes de grãos de pólen presentes no conjunto 1, sendo elas: (a) Grão de pólen de Aroeira, (b) Grão de pólen não identificado, (c) Grão de pólen de Mamoeiro Selvagem, (d) Grão de pólen de Assa-peixe, (e) Grão de pólen não identificado, (f) Grão de pólen não identificado, (g) Grão de pólen não identificado, (h) Grão de pólen não identificado.	36
4.12	Classes de grãos de pólen presentes no conjunto 2, sendo elas: (a) Grão de pólen não identificado, (b) Grão de pólen de assa-peixe, (c) Grão de pólen de mamoeiro selvagem, (d) Grão de pólen não identificado, (e) Grão de pólen de aroeira e (f) Grão de pólen não identificado.	37
4.13	Grãos de pólen das classes presentes no conjunto 4, sendo elas: (a) Grão de pólen de eucalipto, (b) Grão de pólen de assa-peixe, (c) Grão de pólen de cipó-uva, (d) Grão de pólen de aroeira, (e) Grão de pólen não identificado e (f) Grão de pólen não identificado	38
4.14	Grãos de pólen das classes presentes no conjunto 5, sendo elas: (a) Grão de pólen de Arecaceae tipo 1, (b) Grão de pólen de Arecaceae tipo 2, (c) Grão de pólen de Cecropia, (d) Grão de pólen de Fabaceae, (e) Grão de pólen de Schinus, (f) Grão de pólen de Myrtaceae, (g) Grão de pólen de Poaceae, (h) Grão de pólen de Protium e (i) Grão de pólen de Serjania.	39
5.1	Resultado da análise <i>post hoc</i>	44
5.2	Resultado da análise <i>post hoc</i> para o quarto experimento	46
5.3	Matriz com o resultado da classificação realizada pelo algoritmo FCO	47
5.4	Matriz com o resultado da classificação realizada pelo algoritmo KNN	48
5.5	Matriz com o resultado da classificação realizada pelo algoritmo SVM	48
5.6	Matriz com o resultado da classificação realizada pelo algoritmo C4.5	48
5.7	(a) Imagem da espécie cecropia e (b) Imagem da espécie myrtacea	49
5.8	(a) Imagem da espécie protium e (b) Imagem da espécie schinus	49
5.9	(a) Imagem da espécie serjania e (b) Imagem da espécie myrtacea	49

Lista de Tabelas

2.1	Classificação da ocorrência polínica em amostras de mel de acordo com a porcentagem de frequência dos grãos na contagem visual.	11
2.2	Exemplo de matriz de confusão	21
4.1	Número de amostras de cada classe presente no conjunto 1.	36
4.2	Número de amostras de cada classe presente no conjunto 2.	36
4.3	Número de amostras de cada classe presente no conjunto 3.	37
4.4	Número de amostras de cada classe presente no conjunto 4.	38
4.5	Informações sobre o número de amostras presentes em cada classe de cada conjunto do banco de imagens utilizado nesta proposta.	39
5.1	Taxa de acerto para experimento com 3 classes e 5 atributos	40
5.2	Resultado do <i>recall</i> para experimento com 3 classes e 5 atributos	41
5.3	Resultado do <i>precision</i> para experimento com 3 classes e 5 atributos	41
5.4	Resultado do <i>f-score</i> para experimento com 3 classes e 5 atributos	41
5.5	Parâmetros utilizados para a técnica de matriz de coocorrência.	41
5.6	Parâmetros utilizados para a técnica de matriz de interação.	42
5.7	Taxa de acerto para experimentos com 5 classes com atributos de forma, cor e textura	42
5.8	Resultado da métrica <i>precision</i>	42
5.9	Resultado da métrica <i>recall</i>	43
5.10	Resultado da métrica <i>f-score</i>	43
5.11	Porcentagem de acerto de todos os ARFFS e todos os classificadores	43
5.12	Resultado do <i>recall</i> de cada classificador	44
5.13	Resultado do <i>precision</i> de cada classificador	44
5.14	Resultado do <i>f-score</i> de cada classificador	44
5.15	Tempo utilizado para realizar o treinamento dos classificadores	45
5.16	Parâmetros utilizados para a técnica de matriz de coocorrência.	45
5.17	Parâmetros utilizados para a técnica de matriz de interação.	45
5.18	Parâmetros utilizados para o PBL e PBLROT	46
5.19	Síntese das principais informações de cada um dos experimentos realizados neste trabalho	46
5.20	Resultado da taxa de acerto de cada classificador	47
5.21	Porcentagem de amostras classificadas corretamente utilizando os classificadores presentes neste trabalho	47

Capítulo 1

Introdução

O mel é um produto que pode ser comercializado de maneira primária, sendo assim, o produto produzido pelas abelhas não precisa ser industrializado nem tão pouco passar por um processo de transformação para ser consumido pela população. Isso não quer dizer que não existam produtos industrializados derivados do mel. O própolis é um exemplo bastante comum da utilização do mel em produtos industrializados [37]. O valor nutricional e energético que o mel possui traz ao produto uma procura frequente, tanto no mercado interno quanto no externo.

Antigamente, poucos produtores possuíam capacitação adequada para produzir mel. Porém, com a maior procura do produto, normas de padronização foram criadas com o objetivo de estabelecer uma identificação e qualidade do produto produzido [37]. A Instrução Normativa N° 11, de 20 de outubro de 2000 é um exemplo da padronização supracitada [23].

A apicultura traz diversos benefícios, tanto econômicos, com a comercialização do mel e seus derivados, como sociais, através da geração de empregos. Apesar de ser produzido no Brasil há muito tempo, pouco se sabe sobre as características dos méis comercializados.

Para produzir o mel, as abelhas fêmeas responsáveis pela fabricação do produto, capturam néctar das flores e, no momento da captura do néctar, alguns grãos de pólen ficam depositados sobre o inseto. Ao retornar à colmeia, alguns grãos de pólen caem no mel e, por esse motivo, ao analisar microscopicamente uma amostra de mel os grãos das espécies contidas no produto podem ser visualizados. De acordo com o tipo de néctar capturado, as características do produto sofrem alterações, como por exemplo no sabor e coloração.

No momento da captura do néctar, as abelhas realizam um voo próximo à colmeia [16]. Por isso, o pólen das árvores presentes ao redor da colmeia possui grande influência no mel produzido naquela colmeia. Quando o mel é produzido com uma origem controlada, o produtor realiza o plantio de plantas específicas ao redor da colmeia e, por esse motivo, ele pode garantir a presença dos grãos de pólen das espécies que ele plantou no mel produzido. Essa é uma forma de controlar o ambiente para garantir um produto com características específicas.

Há diversos tipos de mel, como os florais e melato, descritos no Capítulo 2. Nesta pesquisa, somente os méis florais foram analisados por apresentarem grãos de pólen. Os méis florais são classificados de acordo com a quantidade de espécies vegetais (grãos de pólen) presentes no produto [19][3]. Uma das características usadas para determinar a origem floral do mel é o grão de pólen.

Este trabalho está contido em um projeto maior e multidisciplinar chamado projeto MEL que tem o objetivo de agregar mais valor ao produto através do incentivo à produção de méis com origem controlada por meio de sua rastreabilidade. Esse trabalho emprega técnicas de visão computacional e inteligência artificial em imagens microscópicas, com o objetivo de auxiliar a rastreabilidade do mel produzido na região centro-oeste. Essa rastreabilidade é realizada através dos grãos de pólen presentes na matéria prima do mel. Como este trabalho visa analisar apenas

os grãos de pólen, ele foi chamado de projeto Pólen. Sendo assim, pode-se dizer que o projeto Pólen visa desenvolver um módulo computacional para compor o projeto MEL.

Atualmente, a contagem das espécies vegetais presentes no mel é realizada visualmente. Essa contagem é uma tarefa minuciosa e muito cansativa, por esse motivo, erros na contagem podem ocorrer devido ao desgaste humano. Nesta proposta, a tarefa de contagem visual é realizada via software acarretando maior agilidade sem perda de eficácia na contagem. Um dos trabalhos desenvolvidos no projeto MEL visa caracterizar os grãos de pólen presentes na região. Este trabalho auxiliou este módulo na etapa de treinamento, descrito no Capítulo 4.

Há alguns trabalhos que realizam a contagem de grãos de pólen, sendo eles: O trabalho [10] analisou imagens com grãos de pólen com o intuito de contar o número de grãos presentes em cada uma das imagens e comparar o resultado da contagem automática com a contagem humana. Imagens das espécies *Carduus acanthoides* e *C. nutans* (Asteraceae) foram obtidas e deixadas em fluorescência sob luz actínica. O IMAGEJ, software que possui implementações do algoritmo de processamento de imagens, foi utilizado para reduzir ruídos e evidenciar os grãos de pólen. As imagens foram processadas utilizando o *watershed*[26] e em seguida foi aplicado o filtro de partículas para realizar a contagem dos grãos das espécies supracitadas. A contagem automática foi comparada com a contagem humana e o resultado obtido foi próximo da contagem realizada pelos humanos. De acordo com este trabalho, foi possível obter uma alternativa rápida e eficaz para a contagem de grãos de pólen.

O trabalho [21] teve o objetivo de realizar a identificação automática de 3 espécies da família *Urticaceae*. As amostras foram obtidas e analisadas microscopicamente com o aumento de 40x. Com as imagens capturadas, foi realizado o pré-processamento dos dados e a obtenção de atributos oriundos da morfologia matemática. Com os dados obtidos, a distância de Mahalanobis foi aplicada e foi obtido 90% de acerto de acordo com a técnica aplicada.

O presente trabalho visa analisar as espécies de grãos de pólen detectadas na região Centro-Oeste, sendo assim, as classes capturadas não passaram por uma seleção antes da classificação. O intuito de capturar as amostras sem limitação de espécie é caracterizar o produto produzido nesta região originalmente. Após a análise, as imagens foram classificadas por 4 algoritmos de aprendizagem de máquina supervisionada.

Para o desenvolvimendo da pesquisa foi necessário extrair informações das imagens de grãos de pólen. Para isso técnicas de extração de atributos foram aplicadas. Com os dados resultantes da extração de atributos, os classificadores foram utilizados para distinguir as classes (espécies de grãos de pólen) analisadas. Os classificadores FCO, C4.5, SVM e KNN foram aplicados. Para avaliar o resultado dos classificadores e analisar se há ou não diferença na aplicação das técnicas supracitadas na classificação de grãos de pólen, foram avaliados o resultado da taxa de acerto, *recall*, *precision* e *f-score* através dos testes de Friedman e T-Students.

Em um dos experimentos realizados, através do teste de Friedman, pode-se afirmar que em relação a estas métricas, não há variação entre os classificadores, ou seja, de acordo com os resultados das métricas pode-se afirmar que eles são iguais. Já em outro experimento, foi possível observar que o KNN obteve melhor desempenho quando comparado aos demais classificadores testados.

Com este trabalho foi possível padronizar o tamanho da imagem capturada, filtro de coloração e o microscópio usado na captura das imagens presentes no projeto Pólen. Foi possível estabelecer, dentre os classificadores analisados, um classificador que apresenta melhor desempenho na classificação dos grãos de pólen, analisar que as imagens com acetólise, processo utilizado para evidenciar características dos grãos de pólen, possuem mais informações para a classificação das classes analisadas neste trabalho e conseguir uma classificação superior a 76% para 9 classes distintas.

O próximo capítulo traz conceitos de visão computacional, mel e técnicas de validação do

sistema. O terceiro e o quarto capítulos descrevem, respectivamente, sobre aprendizagem de máquina e a seção de materiais e métodos que apresenta detalhes do delineamento experimental. O quinto e o sexto capítulos descrevem, respectivamente, os resultados e a discussão dos resultados obtidos com os experimentos, a conclusão e as considerações finais.

Capítulo 2

Fundamentação Teórica

Para melhor compreensão do problema e dos tópicos abordados posteriormente, serão apresentados alguns conceitos sobre mel, visão computacional e técnicas de validação de resultados.

2.1 Palinologia

A palinologia é uma área que realiza estudos sobre alguns temas entre eles os grãos de pólen [28]. Para facilitar a compreensão e atuação da área, alguns trabalhos serão apresentados, sendo eles: O trabalho [2] que teve o objetivo de realizar o estudo palinológico de 12 espécies de Acacia. Para isso, os grãos de pólen passaram pelo processo de acetólise (descrita posteriormente) e foram visualizados através do microscópio de luz e microscópio eletrônico de varredura. Com o estudo, foi possível concluir que, exceto uma espécie, as demais espécies analisadas não podem ser diferenciadas de acordo com sua morfologia.

O trabalho [20] teve o objetivo de analisar e descrever a morfologia polínica de *Euterpe oleracea* Mart. e *Euterpe precatoria* Mart. O material analisado foi submetido à acetólise e posteriormente ocorreu o plaqueamento (descrito posteriormente) e a análise microscópica do produto. As informações analisadas foram o tamanho do eixo polar, diâmetro equatorial, comprimento e largura do colpo (aberturas presentes no grão de pólen) e espessura da exina (estrutura externa do grão de pólen). Foram analisadas 10 imagens de 5 lâminas, totalizando 50 grãos de pólen. Com a pesquisa foi possível verificar que existe diferença entre *Euterpe oleracea* e *Euterpe precatoria*, porém essa diferença não é suficiente para diferenciar as espécies analisadas.

Como observado nos trabalhos acima, a classificação de grãos de pólen não é uma tarefa trivial e, em alguns casos, a obtenção de informações distintas é necessária.

2.2 Classificação visual de grãos de pólen

Atualmente a forma mais tradicional de realizar a classificação de grãos de pólen é através da classificação visual dos grãos. Muitos trabalhos descrevem características e resultados obtidos com essa classificação, sendo eles:

O trabalho [5] teve o objetivo de realizar a análise de amostras de mel encontradas no estado de Roraima com o intuito de realizar a determinação da origem floral através dos grãos de pólen presentes no produto. Neste trabalho, os pesquisadores capturaram amostras de mel na aldeia do Contão situada no nordeste do estado de Roraima. Foram coletados 500ml de mel em cada colheita. A classificação foi realizada através da comparação das imagens microscópicas com as informações presente em diversas literaturas. Os grãos de pólen foram classificados de acordo com sua frequência mensal nas amostras (essa contagem foi possível, pois a coleta teve duração de 5 meses). No total, houve a análise de 9 amostras de mel e a identificação de 20 tipos de

grãos de pólen. Foi observado a dificuldade na identificação visual de grãos de pólen de alguns gêneros devido à semelhança entre os grãos analisados. Foi possível analisar que nessa região os pólen de *Mimosa polydactyla* H.B.K. e *Curatella americana* L. ocorreram com maior frequência.

Há algumas espécies de grãos de pólen que causam alergias em algumas pessoas. Essas espécies são chamadas de alergóginas. O trabalho [8] realizou uma pesquisa durante 12 meses na cidade de São Paulo com o objetivo de identificar as espécies encontradas com mais frequência naquela região. As amostras capturadas foram comparadas com lâminas de referência. As lâminas foram produzidas por grãos de pólen presentes em um herbário, por isso, as espécies eram conhecidas. Com o desenvolvimento do trabalho foi possível perceber a necessidade de um catálogo contendo as características das plantas que possuem efeitos alergógenos para tornar mais fácil a identificação dessas espécies principalmente pelos médicos alergistas. O estudo encontrou algumas espécies com características alergóginas e iniciou o desenvolvimento do catálogo mencionado anteriormente.

2.3 Mel

O mel é um produto comestível produzido por abelhas melíferas. Esse produto possui características próprias, como cheiro, sabor e cor, que varia de amarelada a castanho-escuro [7]. A Figura 2.1 ilustra a variação de coloração entre méis. Existem diferentes tipos de mel, como os méis florais e o melato. A diferença entre esses produtos diz respeito a forma com que estes são produzidos, sendo que o primeiro é originado do néctar das flores e o segundo da secreção das plantas ou excreções de insetos sugadores [23].



Figura 2.1: Amostras de méis com coloração variada capturada na Fazenda Escola da Universidade Católica Dom Bosco

O mel floral apresenta subclasses, sendo elas o mel unifloral, também chamado de monofloral, que ocorre quando o produto é obtido através de flores originadas de uma mesma espécie, família ou gênero. Desse modo o mel monofloral apresenta características microscópicas semelhantes. Outra subclasse do mel floral é o mel multifloral, que apresenta néctar de diferentes origens vegetais [23]. As características microscópicas das subclasses foram evidenciadas devido ao fato deste trabalho utilizar imagens microscópicas para obter informações sobre os grãos de pólen.

2.4 Angiospermas

Nas plantas que produzem flores, denominadas Angiospermas, o órgão reprodutor feminino é chamado de gineceu. Esse órgão é formado pelo estigma e ovário. O órgão reprodutor masculino, chamado de androceu, é composto pela antera, conectivo e filete.

O grão de pólen, que é produzido nas anteras, é um grão microscópico formado pela exina e intina. A exina é uma parede externa e resistente que envolve o grão de pólen, ela possui a função de proteger o material reprodutor masculino durante o processo de transferência do grão da antera até o estigma. Ela é bastante resistente e apresenta uma forma de diferenciar grãos de pólen de uma mesma espécie [29]. Já a intina é a parede interna do grão. A diferenciação do grão de pólen de uma espécie para outra se dá pela estrutura externa do grão. A Figura 2.2 (a) ilustra um grão de pólen de um mamoeiro selvagem e a Figura 2.2 (b) ilustra uma imagem de grão de pólen de roseira.

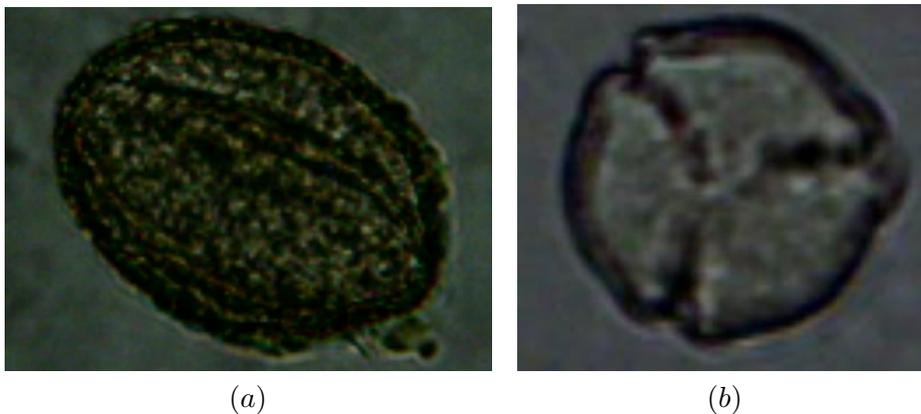


Figura 2.2: (a) Imagem de grão de pólen de um mamoeiro selvagem com resolução de 672 X 506 *pixels* e (b) Imagem de grão de pólen de uma roseira com resolução de 187 X 167 *pixels*.

Quando há o encontro de um óvulo, células existentes dentro do ovário, com um grão de pólen, ocorre a fecundação. O transporte necessário para levar os grãos de pólen até o estigma de uma flor é chamado de polinização que é realizada através de agentes polinizadores. Esses agentes são representados pelo vento, insetos, água e morcegos, por exemplo [29].

Para ocorrer a fecundação, primeiro o grão de pólen precisa chegar até o estigma de uma flor, germinar e formar um tubo polínico. É através do tubo polínico que as células reprodutivas masculinas chegarão até o ovário. No interior do ovário existem vários óvulos que são fecundados por essas células masculinas. Quando uma fecundação é bem sucedida, o óvulo gera uma semente e o ovário gera um fruto [29].

O néctar é um líquido açucarado presente nas plantas. Esse líquido é um atrativo para alguns agentes polinizadores devido ao seu valor nutritivo [29]. Esses agentes utilizam o néctar como alimento. No momento que os agentes vão até uma planta para capturar o néctar, eles acabam esbarrando nos grãos de pólen e ao capturar o néctar de outra planta ou no momento que voltam para a colmeia levam consigo todos os grãos das plantas que visitaram. Nas plantas esses pólenes são utilizados para realizar a fecundação, já na colmeia, esses grãos funcionam como uma espécie de identificadores contidos no mel. É através desse identificador que o mel será classificado.

2.5 Classificação da frequência polínica

A contagem e classificação visual do mel é realizada através da análise microscópicas de amostras do produto. Quando o especialista encontra grãos de pólen no mel, ele realiza a classificação visual e contagem dos grãos observados. Após a contagem visual realizada pelo especialista, a porcentagem de cada espécie é calculada para verificar a frequência dos grãos de pólen presentes na amostra. A classificação das frequências segue o padrão presente na Tabela 2.1. Nessa tabela a primeira coluna representa a porcentagem da frequência de grãos de pólen de cada uma das espécies presentes na amostra e a segunda a classificação atribuída às espécies de acordo com a frequência dos grãos. [15].

Ocorrência na amostras	Classificação
$> 45\%$	pólen dominante
$\geq 15\%$ a $< 45\%$	pólen acessório
$\geq 3\%$ e $< 15\%$	pólen isolado importante
$\geq 1\%$ a $< 3\%$	pólen isolado ocasional
$< 1\%$	pólen traço

Tabela 2.1: Classificação da ocorrência polínica em amostras de mel de acordo com a porcentagem de frequência dos grãos na contagem visual.

2.6 Visão computacional

Na área da visão computacional, são desenvolvidos algoritmos para obtenção de informações a partir de imagens, algumas vezes, buscando a automatização de tarefas geralmente associadas à visão humana. Na visão humana, os olhos capturam as imagens e posteriormente o cérebro realiza a análise e identificação de seu conteúdo. A visão computacional possui uma série de etapas para reproduzir essa tarefa realizada pelos seres humanos.

Para determinados problemas, todas as etapas da visão computacional são aplicadas em sequência, porém essa não é uma regra para aplicações nessa área. Embora os conceitos mencionados em seguida estejam apresentados em sequência e relacionados, eles são independentes, sendo assim, pode haver situações em que apenas uma ou algumas etapas conseguem resolver o problema em questão com metodologias diferentes dessa apresentada.

Na etapa de pré-processamento, ocorrem processos como a redução de ruídos e o realce das imagens, geralmente, com o intuito de aumentar a qualidade da imagem para que as etapas posteriores não sofram as interferências dessas imperfeições. Com a imagem pré-processada, ocorre a segmentação, que tem como objetivo dividir a imagem de acordo com os objetos de interesse. Com os grupos de objetos segmentados (por exemplo, as espécies de grãos de pólen), é necessário realizar a extração de informações que permitam a caracterização dos tipos de objetos de interesse para cada problema. Um grupo de objetos do mesmo tipo também é denominado classe. Definidas as classes de um determinado problema, quando apenas a informação do objeto específico é analisada, consegue-se identificar a qual classe essa informação pertence. Esse processo é realizado por algoritmos de reconhecimento de padrões. Uma das principais abordagens para reconhecimento de padrões é a aprendizagem supervisionada, que, a partir de exemplos previamente classificados de objetos das diferentes classes, busca inferir modelos capazes de representar e reconhecer novos objetos [24][13].

2.6.1 Imagens digitais

Na área de visão computacional, a principal informação obtida refere-se à imagem a ser analisada. Uma imagem é composta por um conjunto de *pixels*. Cada um desses *pixels* pode fornecer uma série de informações. Dependendo do espaço de cor que esse *pixel* apresenta, um conjunto diferente de dados pode ser observado.

Por exemplo, a Figura 2.3 (a) ilustra uma imagem em tons de cinza com 21X19 *pixels*. A Figura 2.3 (b) ilustra a imagem (a) que foi ampliada para facilitar sua visualização e a Figura 2.3 (c) representa uma matriz com o valor de cada *pixel* presente na Figura 2.3 (a). Se a imagem estivesse no modelo de cor RGB (detalhado na seção 2.6.2), o valor presente na matriz seria decomposto em três valores, um para cada componente (R, G e B).

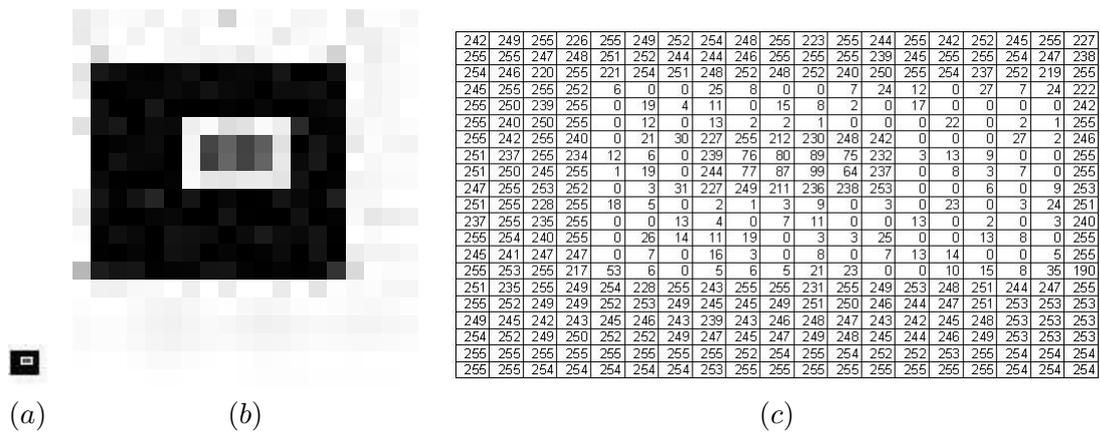


Figura 2.3: (a) Imagem em tons de cinza, (b) imagem ampliada e (c) matriz de *pixels* correspondente

2.6.2 Extração de atributos

A extração de atributos visa extrair um conjunto de informações relevantes para cada classe. Essas informações são utilizadas para caracterizar objetos de uma mesma classe. A etapa de segmentação irá evidenciar apenas as regiões de interesse, nesse caso, os grãos de pólen. Para caracterizar cada grão de pólen, a extração de atributos poderá ser aplicada, pois necessita-se discriminar os objetos e, posteriormente, caracterizá-los de acordo com as classes que eles constituem. Por exemplo, os valores obtidos pela extração de atributos para caracterizar uma determinada espécie de grão de pólen deverá ser diferente dos obtidos para caracterizar o fundo da imagem. Desse modo, será possível discriminar todas as classes que o projeto englobar. O tipo de característica a ser extraída está relacionado ao problema em questão, a extração pode utilizar diversos atributos [13][31][34]. Segue abaixo uma descrição dos extratores de atributos baseados em forma, cor e textura que foram utilizados nesse projeto.

Atributos de cores

De acordo com o modelo de cor que uma imagem é processada, cada *pixel* pode obter um conjunto de informações diferentes. Essas informações podem ser utilizadas de acordo com o problema a ser analisado. Por exemplo, um determinado trabalho pode utilizar a média dos valores presentes nos *pixels*, outro pode analisar os *pixels* individualmente ou um histograma com as variações de cores pode ser utilizado. Esta proposta utiliza a média dos valores de cada componente presente em um modelo de cor.

- Modelo baseado em tons de cinza

O modelo de cores baseado em tons de cinza mais comum possui uma variação de 256 tonalidades, pois possuem 8 bits para representarem essas tonalidades. O número de bits usado para representar esse espaço de cor pode ser variado. Nesse módulo o modelo usado foi de 256 tonalidades. Essas tonalidades vão da cor preta, representada pelo número 0, variedades de cinza até chegar na cor branca, representada pelo número 255. A Figura 2.4 ilustra 3 *pixels*, o primeiro com valor 0, o segundo com o valor 180 e o terceiro com valor 255 [24]. Para analisar uma imagem colorida com esse modelo, é necessário realizar a conversão de cada *pixel* da imagem para tons de cinza.

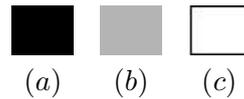


Figura 2.4: (a) *pixel* na cor preta, (b) *pixel* na cor cinza e (c) *pixel* na cor branca

- Modelo RGB de cores

O modelo RGB é baseado nas cores primárias vermelho, verde e azul. Cada uma dessas cores possui uma variação de 256 valores. Como são três componentes, esses podem ser combinados e gerar novas cores. Caso ocorram todas as combinações, poderá haver mais de 16,7 milhões de cores distintas. A Figura 2.5 ilustra um exemplo de combinação das RGB. O nome desse modelo são as iniciais dessas cores primárias (*Red*, *Green* e *Blue*) [13][24].

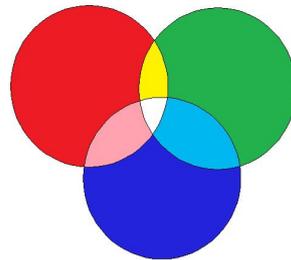


Figura 2.5: Exemplo de combinações das cores primárias vermelho, verde e azul.

- Modelo HSB de cores

O modelo de cor HSB (*Hue*/matiz, *Saturation*/saturação e *Brightness*/brilho) baseia-se na visão humana. Descrevendo cada um desses componentes, pode-se entender melhor como o modelo trata as informações de cor. Matiz refere-se à cor propriamente dita - como vermelho, verde e azul -, já a saturação diz respeito à vivacidade da cor e o brilho corresponde à intensidade de luz em uma cor - separando as cores em claras e escuras, por exemplo.

Atributos de Forma

Dependendo do objeto a ser analisado, seu formato pode trazer informações bastante importantes com relação à classe que ele representa. Por exemplo, supondo que em uma determinada situação haja a necessidade de identificar a diferença entre um grão de pólen de eucalipto e aroeira, ilustrados nas imagens (a) e (b), respectivamente, da Figura 2.6. Ao analisar o formato desses dois objetos a caracterização deles torna-se trivial. Para este trabalho, os atributos de forma utilizados foram os seguintes:

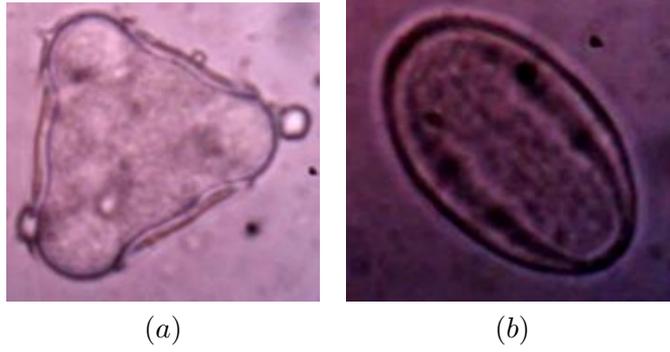


Figura 2.6: (a) Grão de pólen de eucalipto, (b) grão de pólen de aroeira

- Fator de forma (*form factor*)

O fator de forma é um atributo obtido através da divisão da área do objeto pela área de uma circunferência. Supondo que em cima do seu objeto de interesse haja o desenho de uma circunferência. No momento que o perímetro do objeto for calculado, pode-se obter, por aproximação, o perímetro da circunferência. Com o valor do perímetro, o raio da circunferência pode ser calculado e por consequência a área da circunferência pode ser obtida. Como o perímetro da circunferência é obtido através da equação $2 \times \pi \times R$, em que R representa o raio da circunferência, é possível afirmar que o raio da circunferência pode ser representado pela equação $\frac{P}{2 \times \pi}$, em que P representa o perímetro do objeto. Com essas informações é possível obter a área da circunferência e o fator de forma do objeto em questão poderá ser calculado. As Equações 2.1 e 2.2 são utilizadas para calcular a área da circunferência e o fator de forma, respectivamente [35]. Para as equações, as siglas FF representam o fator de forma, A_{obj} representa a área do objeto e A_{circ} representa a área da circunferência.

$$A_{circ} = \pi \times R^2 = \pi \times \left(\frac{P}{2 \times \pi} \right)^2 = \frac{\pi \times P^2}{4 \times \pi^2} = \frac{P^2}{4 \times \pi} \quad (2.1)$$

$$FF = \frac{A_{obj}}{A_{circ}} = \frac{A_{obj}}{\frac{P^2}{4 \times \pi}} = \frac{A_{obj} \times 4 \times \pi}{P^2} \quad (2.2)$$

- Circularidade (*roundness*)

A circularidade tem o objetivo de medir o quão alongado é um objeto e seu cálculo é obtido de forma similar ao do fator de forma. Suponha que uma circunferência é desenhada em torno do objeto de interesse. Como a circunferência foi desenhada em torno do objeto, o diâmetro da circunferência será proporcional ao comprimento do objeto, sendo assim, a metade do comprimento do objeto corresponde ao raio da circunferência. Com o valor do raio a circularidade do objeto poderá ser medida. A Equação 2.3 é utilizada para calcular a circularidade de um objeto [35]. Para a equação as siglas A_{obj} representa a área do objeto, A_{circ} representa a área da circunferência e comprimento representa o comprimento do objeto.

$$C = \frac{A_{obj}}{A_{circ}} = \frac{A_{obj}}{\pi \times R^2} = \frac{A_{obj}}{\pi \times \left(\frac{\text{comprimento}}{2} \right)^2} = \frac{A_{obj}}{\frac{\pi \times \text{comprimento}^2}{4}} = \frac{4 \times A_{obj}}{\pi \times \text{comprimento}^2} \quad (2.3)$$

- Relação entre eixos (*aspect ratio*)

Um outro atributo capaz de medir a circularidade de um objeto é a relação entre os eixos. Para obter essa informação é necessário saber qual é a largura e o comprimento do objeto. Essa informação é obtida quando uma elipse é desenhada sobre o objeto. O maior eixo da elipse criada representa o comprimento e o menor eixo representa a largura do objeto. Assim que esses valores são divididos, a relação entre eixos é obtida. A Equação 2.4 é utilizada pra calcular a relação entre eixos [35]. Para auxiliar a compreensão da relação entre os eixos, na Imagem 2.7 foi criada a elipse, com o maior e o menor eixo descritos nesta seção. Essa imagem ilustra um grão de pólen de aroeira com uma elipse, representada pela cor verde, uma reta azul escura indicando o maior eixo e uma reta azul clara que representa o menor eixo.

$$AR = \frac{\text{comprimento}}{\text{largura}} \quad (2.4)$$

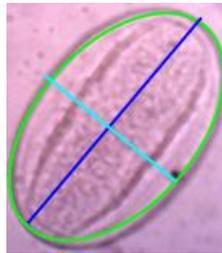


Figura 2.7: Exemplo ilustrando uma imagem de grão de pólen com uma elipse verde, uma linha azul escura indicando o comprimento do objeto e uma linha azul clara indicando a largura do objeto.

- Densidade

Para obter a densidade de um objeto, é necessário extrair a raiz quadrada da circularidade, como ilustra a Equação 2.5. Nessa equação, C representa a circularidade. [35].

$$D = \sqrt{C} \quad (2.5)$$

Atributos de textura

Um atributo de textura visa caracterizar um objeto de acordo com a distribuição de cor existente nele. Conforme a organização das cores presentes na imagem o objeto pode ser totalmente modificado. Por exemplo, a textura de uma zebra, ilustrada na Figura 2.8 (a), e a de um dalmata, ilustrada na Figura 2.8 (b), possuem as mesmas cores, mas a forma como elas estão presentes na imagem torna possível a distinção entre essas imagens. Em seguida serão apresentadas algumas técnicas para extrair informações relacionadas à textura de uma imagem.

PBL - Padrões Binários Locais

O PBL é um método de extração de atributos que consiste em atribuir um valor a cada *pixel* da imagem de acordo com a variação da intensidade do *pixel* em relação aos seus vizinhos. Várias aplicações utilizam o método PBL, dentre elas destacam-se o reconhecimento de faces, texturas e movimentos [22] [32].



Figura 2.8: (a) Exemplo de textura de uma zebra e (b) exemplo de textura de um dálmata.

A Figura 2.9(a) representa uma imagem na forma de matriz, os índices dessa matriz estão evidenciados pela cor cinza. Cada posição dessa matriz representa um *pixel* da imagem. O método realiza uma varredura na imagem e para cada *pixel* calcula sua vizinhança através de um número de vizinhos v e um raio r . Por exemplo, o *pixel* na posição (2,3) da matriz da Figura 2.9(a), com $r=1$ e $v=8$, terá a vizinhança conforme ilustrado na Figura 2.9(b). Posteriormente ocorre uma comparação do valor da intensidade do *pixel* central, no caso (2,3), com cada *pixel* vizinho. Os vizinhos que possuem valor maior ou igual ao *pixel* central recebem 1 e os menores 0, conforme a Figura 2.9(c). Com essa nova matriz binária, cada posição é multiplicada pelo valor do peso de cada *pixel*, como ilustra a Figura 2.9(d) e finalmente a soma dos valores da matriz é o resultado do LBP para o *pixel* central. O valor do peso do *pixel* é calculado assim como a conversão do valor binário para decimal. A Figura 2.9(e) resulta no valor do PBL para o *pixel* (2,3), $16 + 32 + 64 + 128 = 240$. O Algoritmo 1, pode ser usado para calcular o PBL.

Com o intuito de encontrar um valor invariante à rotação para representar o PBL, surgiu o PBLROT - Padrão Binário Local - Rotação Invariante. A rotação invariante tem como objetivo realizar a variação em uma imagem com o intuito de encontrar um menor valor para representá-la, sem que haja uma alteração na sua forma original. Para a rotação invariante a variação angular de uma imagem não altera sua representação, porém para o método LBP uma variação desse tipo representa uma alteração no seu resultado final devido ao peso atribuído a cada *pixel*. Esse peso é calculado através da expressão 2^p , sendo que o valor de p representa a posição do *pixel* da imagem. Esse valor inicia em 0 e possui acréscimo unitário a cada novo *pixel* presente na imagem analisada.

PBLROT - Padrões Binários Locais Invariante à Rotação

O PBLROT realiza rotações com a cadeia de binários, ilustrada anteriormente através da Figura 2.9(c). O número de rotações é igual ao tamanho da cadeia de binários, pois o algoritmo realiza rotações até que a cadeia volte ao estado original. Desse modo, todas as combinações são analisadas. A cada rotação uma nova cadeia é obtida e multiplicada pelo valor do peso de cada *pixel*. O valor do peso do *pixel* não sofre alteração, com isso, apenas a cadeia de binários é modificada. Por exemplo, a Figura 2.10 (a) ilustra uma cadeia de binários, a Figura 2.10 (b) ilustra uma forma de rotação dessa cadeia de binários e a Figura 2.10 (c) ilustra a cadeia de binários após a rotação. Sendo assim, a cada rotação uma nova cadeia é multiplicada pelos pesos fixos e, desse modo, um novo valor de LBP é obtido. No decorrer do algoritmo, várias rotações são realizadas e o menor valor obtido é escolhido [32]. O Algoritmo 2 pode ser utilizado para calcular o PBLROT.

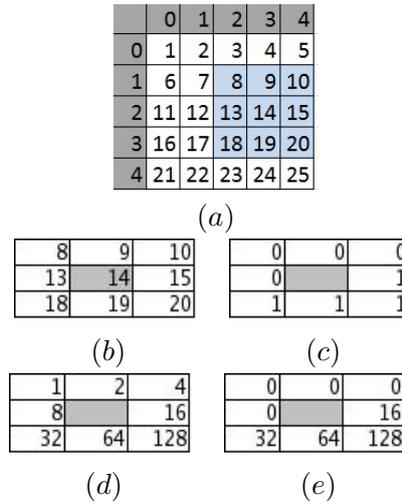


Figura 2.9: Exemplo do método LBP.

Algoritmo 1 PBL - Realiza a extração de atributos usando o método Padrões Binários Locais

Entrada: Matriz I, mXn. Cada posição dessa matriz representa um *pixel* da imagem.

Raio R, distância para calcular os vizinhos do pixel central.

P, representa o número de vizinhos.

i e j posição do *pixel* em questão.

Saída: Matriz L, mXn, com o resultado do Padrão Binário Local de pixel.

Matriz N, mXn, contendo o resultado da Rotação Invariante de cada pixel.

Vetor V[], com a cadeia de binários gerada para o pixel em questão.

Vetor Z[], contendo a representação decimal de cada *pixel*.

Q=0;

para (p=0) to (p<(P-1)) **faça**

X = i + R*cos((2*π*p)/P);

Y = j - R*sen((2*π*p)/P);

W = Interpolação(X, Y);

se ((I[i][j] - W)<=0) **então**

V[p]=0;

Q = 0;

senão

V[p]=1;

Q += 2^p;

fim se

Z[p] = 2^p; L[i][j] = Q + L[i][j];

fim para

N[i][j]=LBPROT(V[], Z[]);



Figura 2.10: (a) representa uma cadeia de binários, (b) representa uma forma de rotação e (c) representa a cadeia de binários após a rotação.

Algoritmo 2 PBLROT - Obtém um código PBL invariante à rotação.

Entrada: Cadeia de binários representada pelo vetor V .

Cadeia contendo a representação decimal de cada *pixel*.

Saída: S , menor valor resultante da rotação da cadeia em questão.

$A = 0, S = 0, T = -1;$

para ($x=0$) to ($x<8$) **faça**

$y = 0; S = 0;$

enquanto ($y<8$) **faça**

$A = \text{resto}(x+y)/8;$

$S += (V[A]*Z[y]);$

$y++;$

fim enquanto

se ($S < T \parallel T == -1$) **então**

$T = S;$

fim se

fim para

Matriz de Coocorrência

O método matriz de coocorrência baseia-se na análise de pares de tons de cinza em uma imagem. O objetivo desse método é representar uma imagem de acordo com a quantidade de ocorrências dos pares de tons de cinza. A partir do algoritmo de matriz de coocorrência atributos como rugosidade, granulosidade, aspereza, regularidade, direcionalidade de um objeto podem ser obtidos.

O método percorre a imagem verificando a coocorrência de *pixels* separados por um ângulo a e uma distância d . Para cada valor de distância e ângulo, uma matriz chamada de matriz de coocorrência é criada. Essa matriz possui dimensão igual à variação de tons de cinza analisados. Por exemplo, se 255 variações de tons de cinza fossem analisadas, a matriz de coocorrência teria dimensão de 255x255 *pixels*. A cada iteração a matriz de coocorrência recebe o acréscimo do valor 1 referente ao par de *pixel* analisado [1].

A Figura 2.11 (a) representa uma imagem na forma de matriz. Cada posição da matriz representa um *pixel* da imagem original. Para esse exemplo, uma variação de 3 tons de cinza será utilizada, por isso a matriz de coocorrência terá dimensão de 3X3. Também serão utilizados o ângulo 0 e a distância 1. O número de variações de ângulo e/ou distância é correspondente ao número de matrizes de coocorrência criadas, ou seja, se 3 variações de ângulo fossem analisadas, 3 matrizes de coocorrência seriam criadas e cada uma delas corresponderia à ocorrência de pares de tons de cinza para uma distância d e um ângulo a . Cada linha da matriz de coocorrência representa um valor de tom de cinza que para esse exemplo será 0, 1 e 2. O mesmo acontece com as colunas presentes nesta matriz. Desse modo, é possível representar todas as combinações possíveis de pares de tons de cinza presentes na imagem. Para preencher a matriz de coocorrência todos os pares de tons de cinza são obtidos. Por exemplo, ao analisar o par de tons de cinza 0 e 0, percebe-se que eles aparecem quatro vezes na imagem, a primeira ocorrência desse par está presente na posição (0,0)(0,1), a segunda na posição (0,1)(0,2), a terceira na posição (2,3)(2,4) e a quarta na posição (4,0)(4,1) da matriz com as informações da imagem, por isso a posição (0,0) da matriz de coocorrência possui valor quatro.

	0	1	2	3	4
0	0	0	0	1	2
1	1	1	0	1	1
2	2	2	1	0	0
3	1	1	0	2	0
4	0	0	1	0	1

(a)

	0	1	2
0	4	4	1
1	4	3	1
2	1	1	1

(b)

Figura 2.11: Matriz composta pelos valores de uma imagem (a), matriz de coocorrência com ângulo 0 e distância 1 (b).

Mapas de Interação

O método baseado em mapas de interação analisa os pares de *pixel* de uma imagem, em tons de cinza. O mapa de interação permite a obtenção de atributos como entropia, dissimilaridade, contraste, momento da diferença inversa, segundo momento angular e diferença inversa de uma imagem.

O método consiste em, dado um valor do ângulo a e uma distância d , calcular a soma do módulo da diferença entre os *pixels* e armazenar este valor em uma matriz. Esta matriz, chamada de mapa polar de interação, terá dimensão igual às variações de distâncias e ângulos escolhidos. O valor da diferença entre os *pixels* é armazenado na posição referente à posição do ângulo e

da direção, os valores seguintes são somados às suas respectivas posições até que a varredura da imagem seja concluída [1].

Nesse exemplo os ângulos 0° , 45° e 90° e distância 1 e 2 serão usados. A Figura 2.12(a) ilustra uma matriz na forma de imagem. Cada posição dessa matriz representa um *pixel* da imagem. O método percorre a matriz e para cada *pixel* calcula a diferença entre o *pixel* em questão com o *pixel* calculado, de acordo com os valores do ângulo e da distância. O resultado da diferença é adicionado à posição da distância e do ângulo utilizados. Os *pixels* que, dadas a distância e o ângulo se encontrarem fora da matriz, são desconsiderados 2.12(b).

	0	1	2	
0	10	15	20	25
1	3	6	9	12
2	2	4	6	8
3	30	15	10	19

	0°	45°	90°
1	69	94	104
2	64	63	94

(a)
(b)

Figura 2.12: Exemplo utilizando mapas de interação.

Transformada de Wavelets

A transformada de *Wavelets* é uma técnica capaz de analisar simultaneamente informações de frequência e espaço em uma mesma imagem. Ela analisa a imagem através de múltiplas visões, criando assim sub-imagens da imagem original também chamadas de sub-bandas. A Figura 2.13 (a) ilustra uma imagem de grão de pólen e a Figura 2.13 (b) ilustra as sub-bandas, da imagem original. As diferentes texturas encontradas na imagem original podem ser representadas a partir das informações existentes em cada uma das sub-bandas criadas pelo algoritmo [30].

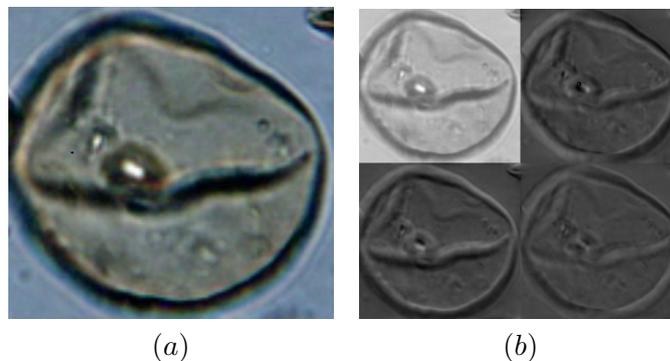


Figura 2.13: (a) Imagem original e (b) Imagem das bandas após a aplicação da transformada de *Wavelets*

2.7 Seleção de atributos

Dependendo do problema analisado, vários atributos são extraídos, porém determinada informação pode não auxiliar na classificação do objeto ou ser um dado que representa, em uma porcentagem pequena, a classe a ser analisada. Quando um atributo representa pouco uma classe, sua presença no conjunto de atributos torna-se pouco importante, pois o sistema deverá processar um dado com pouca ou nenhuma relevância no resultado final. Nesses casos, uma área

chamada seleção de atributos consegue eliminar esses atributos pouco importantes que podem trazer custo computacional e até atrapalhar o resultado final [17].

A seleção de atributos verifica quais atributos são relevantes na caracterização de uma classe. Desse modo, ela apresenta uma lista de atributos relevantes e, com base nesses valores, um novo conjunto de atributos pode ser gerado. Esse novo conjunto irá conter o grupo de atributos selecionados pelos algoritmos. Em muitos casos, após a seleção de atributos, o resultado da classificação dos dados não sofre uma interferência negativa. Sendo assim, a classificação das informações permanece a mesma ou sofre uma alteração positiva (melhor classificação). A melhoria da classificação se deve a remoção de atributos que em vez de auxiliar a distinção da classe acabavam confundindo o classificador no momento da classificação [17].

2.8 Validação dos resultados

A utilização de métricas para avaliar o desempenho de algoritmos é uma forma de realizar comparações entre as técnicas utilizadas. Existem várias métricas que avaliam diferentes informações. A escolha das métricas depende do problema e dos algoritmos aplicados. Tentando analisar melhor o resultado da classificação dos algoritmos testados nesta proposta, algumas métricas serão utilizadas para avaliar tanto o erro quanto o acerto apresentado pelo classificador. Para avaliar os classificadores, testes de hipótese serão aplicados a fim de verificar se os resultados obtidos com as métricas são estatisticamente diferentes ou não.

O exemplo descrito em seguida será utilizado para explicar as métricas utilizadas neste trabalho. Por exemplo, supondo que em uma determinada aplicação o experimento realizado apresente 9 imagens da classe 1 e 1 da classe 2. Supondo que o classificador enquadre todas as imagens como pertencentes à classe 1. Esse problema resultaria uma matriz, chamada de matriz de confusão, que apresenta o número de imagens classificadas corretamente na diagonal principal e os demais fora dela. A Tabela 2.2 ilustra a matriz de confusão do exemplo supracitado. Em seguida, as métricas serão descritas.

9	0	Classe1
1	0	Classe2

Tabela 2.2: Exemplo de matriz de confusão

Taxa de acerto

Quando a classificação de objetos de interesse é realizada, obtém-se um valor denominado de taxa de acerto. Essa taxa apresenta a porcentagem de acerto obtida no experimento que, em alguns casos, pode não representar de forma clara a classificação obtida. O que a taxa de acerto não leva em consideração é a quantidade de informações do classe 2 que não foram classificadas, pois no exemplo 100% da classe 2 foi classificada incorretamente. A equação 2.6 ilustra como a taxa de acerto é calculada. Para realizarmos esse cálculo é necessário calcular o total de acerto obtido pelo classificador dividido pelo total de classificações realizadas. As variáveis NTA e NTC representam o número total de acerto e número total de classificações, respectivamente. Para o exemplo, o resultado da taxa de acerto seria 90%, pois 9 das 10 imagens foram classificadas corretamente.

$$taxaDeAcerto = \frac{NTA}{NTC} \quad (2.6)$$

Recall

O *recall* é capaz de avaliar o número de objetos que o classificador conseguiu classificar. Seu resultado varia de 0 a 1, sendo que 0 é obtido quando o classificador não consegue acertar nenhum objeto da classe de interesse e 1 quando o classificador acerta todos os objetos analisados. A equação 2.7 exibe como o *recall* deve ser calculado. As variáveis TA e TC representam o total de acerto e o total de objetos classificados como pertencentes à uma determinada classe, respectivamente [6]. Para o exemplo o *recall* da classe1 seria 0.9 e o da classe2 seria 0.

$$recall = \frac{TA}{TC} \quad (2.7)$$

Precision

O *precision* visa avaliar quão preciso foi a classificação dos dados. Assim como o *recall*, o *precision* também varia de 0 a 1, porém o valor 1 representa que o classificador não errou nenhum dado e 0 significa que ele errou todos os dados. Ao contrário do *recall*, o *precision* leva em consideração a quantidade de erros cometidos durante a classificação dos dados. A equação 2.8 é utilizada para calcular esta métrica. As variáveis TA e TE representam o número de objetos que o classificador acertou e o número de objetos de determinada classe que o classificador errou, respectivamente [6]. Com base no exemplo, o resultado do *precision* da classe1 seria $9 / (9 + 0) = 1$ e da classe2 seria 0.

$$precision = \frac{TA}{TA + TE} \quad (2.8)$$

f-score

O *f-score* é uma união do resultado do *recall* com o resultado do *precision*. Esse resultado é calculado através da equação 2.9 e também varia de 0 a 1.

$$F = 2 * \frac{precision * recall}{precision + recall} \quad (2.9)$$

2.8.1 Teste de hipótese

Teste de Friedman

O teste de Friedman é um teste não - paramétrico. Isso significa que a distribuição das informações são apresentadas de forma livre e não seguem um padrão de distribuição modelado através de uma distribuição gaussiana, por exemplo.

Para esta proposta, o teste de Friedman visa analisar o resultado obtido pelos classificadores e verificar se a hipótese previamente descrita por ele é verdadeira ou não. Uma das situações que o teste de Friedman foi aplicado neste trabalho é no resultado dos algoritmos de classificação. Para facilitar a compreensão deste teste, o exemplo dos classificadores serão utilizados.

Este teste assume a hipótese que os classificadores são iguais. Essa hipótese que o teste assume, também é chamada de hipótese nula. Um valor, chamado de valor p é calculado e, com base no resultado que ele apresenta, a hipótese nula pode ser rejeitada ou não. Através do valor de p é possível rejeitar ou não a hipótese nula de acordo com o grau de significância que seu teste irá adotar. Se o valor de p for menor que o valor de significância a hipótese nula será rejeitada, logo pode-se afirmar que os classificadores são diferentes. Caso contrário, pode-se afirmar que a hipótese nula é aceita e que os classificadores são iguais. Por exemplo, se um experimento possuir 5% de significância e o resultado do p for de 1% quer dizer que o valor de p é menor que

o valor de significância e a hipótese nula pode ser rejeitada. Ao rejeitar a hipótese nula, pode-se dizer que os classificadores são diferentes, porém não se sabe qual é o melhor deles. Por isso, a análise de *post hoc* é aplicada. Esse teste consegue mostrar qual classificador apresenta melhor resultado [12].

Teste T-Student

O teste T-Student é um teste paramétrico. Isso significa que a distribuição das informações pode ser modelado através de uma distribuição gaussiana. Uma forma de utilizar esse teste é através da comparação dois a dois. Por exemplo, supondo que existam 3 classes (A, B e C) que precisam ser comparados, aplicando a comparação em par, o grupo A deveria ser comparado com o grupo B, o grupo A com o grupo C e o grupo B com o grupo C. Esse teste considera como hipótese nula que os dados comparados são iguais e dependendo do valor de significância obtido a hipótese nula pode ser rejeitada ou não. O teste T-Students é um teste muito usado e presente no WEKA. Para esta proposta cada grupo representa um classificador. O teste T-Students também pode ser aplicado para realizar a comparação simultânea entre 3 ou mais grupos como mencionado no trabalho de [14].

Capítulo 3

Aprendizagem supervisionada

Há três tipos de algoritmos de aprendizagem automática, sendo eles: supervisionado, quando as informações das classes são previamente conhecidas, não supervisionado, quando as informações das classes não são conhecidas e semi-supervisionado, quando algumas das informações referentes às classes são obtidas [25][36]. Este trabalho utilizará a aprendizagem supervisionada.

O principal objetivo da aprendizagem supervisionada é generalizar as informações recebidas no treinamento para que as classes analisadas possam ser classificadas com eficácia. Ela é utilizada para a classificação dos objetos desconhecidos de acordo com informações já conhecidas de classes pertencentes ao problema em questão, ou seja, os algoritmos serão treinados com as informações de cada classe presente no problema que serão previamente fornecidas aos classificadores. Quando um objeto desconhecido for analisado, ele será comparado com as informações dos objetos já conhecidas e de acordo com as métricas utilizadas pelos algoritmos de classificação a amostra será classificada.

Por exemplo, supondo que uma determinada aplicação necessite realizar o reconhecimento de letras a e b, ilustradas na Figura 3.1 (a) e (b). Usando a aprendizagem supervisionada, o classificador precisará ser treinado com atributos extraídos das classes supracitadas. O treinamento é a fase em que o classificador “aprende” com base nos dados extraídos das amostras das classes. Para avaliar a aprendizagem do algoritmo, após ele aprender com os valores dos atributos, de cada classe, fornecidos na fase de treinamento, um novo conjunto de informações pode ser testado. O objetivo desse teste geralmente é validar se o treinamento foi bom o suficiente para que o classificador consiga reconhecer um conjunto de informações até então desconhecido.

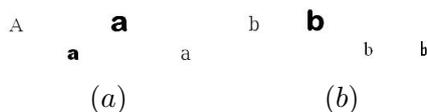


Figura 3.1: (a) Exemplo de imagens da classe A e (b) Exemplo de imagens da classe B.

Esse trabalho irá utilizar 4 algoritmos de aprendizagem supervisionada, sendo eles o KNN[9], C4.5[9], SVM[9] e FCO (Floresta de Caminhos Ótimos). A FCO será explicada com mais detalhes por ser o algoritmo menos conhecido.

3.1 Floresta de Caminhos Ótimos (FCO)

Para cada imagem analisada, um conjunto de características (atributos) é extraído. Esse conjunto é chamado de vetor de atributos. Para que os atributos sejam utilizados para generalizar

as características de uma classe, algoritmos de aprendizagem de máquina supervisionada são utilizados para criar classificadores a partir de exemplos.

Existem vários algoritmos que desempenham a classificação dos atributos extraídos. A técnica estudada neste trabalho é denominada Floresta de Caminhos Ótimos (FCO). O FCO é baseado no algoritmo da Transformada de Imagem Floresta (IFT) [25][11].

Nessa técnica, os dados obtidos da extração de atributos são modelados como grafos. Nesses grafos, cada vetor de atributos compõe um nó e as arestas são obtidas através da relação de adjacência entre os nós do grafo. Cada nó possui um rótulo que representa a classe do nó. No problema abordado neste trabalho, o rótulo é o nome da espécie de grão de pólen, por exemplo. A relação de adjacência pode ser definida e ponderada por alguma técnica que calcula a distância entre os valores obtidos nos vetores de atributos. Na abordagem utilizada neste trabalho, a relação de adjacência entre todos os nós será realizada, sendo assim um grafo completo será formado.

Na etapa do treinamento, é aplicado um algoritmo que gera uma árvore geradora mínima ou MST (*Minimum Spanning Tree*) no grafo completo. Esse algoritmo resulta um subgrafo gerado a partir do grafo completo. Com o subgrafo, nós de fronteira (nós de classes diferentes que estão fortemente conexos) são detectados e definidos como os protótipos. Nesse momento, a relação de adjacência entre os rótulos é quebrada e árvores com caminhos ótimos são criadas (uma árvore é criada para cada classe). Várias árvores de caminhos ótimos induzem uma floresta de caminhos ótimos que dá nome ao algoritmo.

Na classificação, uma nova amostra é comparada com os nós das árvores de caminhos mínimos gerados no treinamento e a relação de adjacência entre o novo nó com todos os nós do grafo é realizada. A relação de adjacência que possuir menor custo é mantida e as demais são desfeitas. Desse modo, o novo nó fica conectado a um nó de uma das árvores e nesse momento o rótulo presente no nó que foi conectado é copiado para o novo nó e ele passa a pertencer àquela árvore. A seguir os passos para o aplicação da técnica serão descritos e exemplificados.

3.2 Treinamento

Neste trabalho cada grão de pólen gera um vetor de atributos que gera um nó do grafo. Nos exemplos usados neste capítulo, as informações presente nos nós representam os atributos dos grãos de pólen e os valores entre eles ilustra a relação de adjacência entre os nós obtida através da distância Euclidiana.

Na etapa de treinamento, após a criação de todos os nós ocorre, a relação de adjacência entre todos os nós que gera um grafo completo. A Figura 3.2 ilustra um exemplo de grafo completo que apresenta dois rótulos ilustrados pelas cores azul escuro e claro. Após a realização do grafo completo, a relação de adjacência entre os nós é calculada. A Figura 3.3 ilustra a relação de adjacência entre todos os nós do grafo completo. Outras medidas podem ser utilizadas para calcular a distância entre os nós, porém este trabalho seguiu a mesma distância proposta por [25]. O subgrafo do grafo da Figura 3.3 pode ser visualizado na Figura 3.4. Como mencionado anteriormente, o subgrafo é obtido após a aplicação do algoritmo que gera a árvore geradora mínima.

Com o subgrafo definido é necessário encontrar os protótipos de cada classe. Os nós presentes nas regiões de fronteira entre classes distintas serão definidos como protótipos. Em alguns casos, mais de um nó pode ser considerado protótipo de uma mesma classe, porém é necessário garantir que uma classe possui no mínimo 1 protótipo. Fazendo uma analogia com o problema proposto, cada classe é uma espécie de grão de pólen como o assa-peixe e aroeira, por exemplo. O número de classe não é fixo, porém foram usadas apenas duas classes para facilitar a compreensão do algoritmo. A Figura 3.5 ilustra a escolha dos protótipos pertencente à classe azul escura e

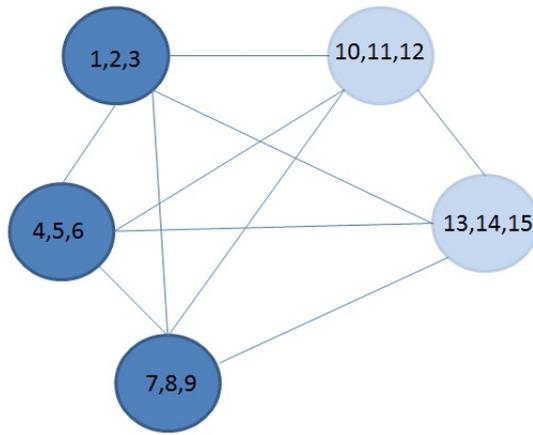


Figura 3.2: Grafo completo.

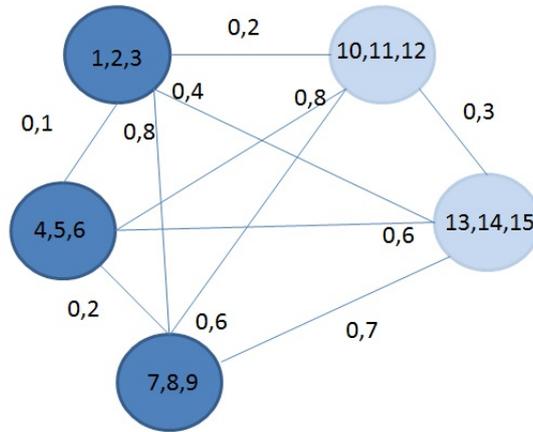


Figura 3.3: Grafo completo com a relação de adjacência entre as arestas.

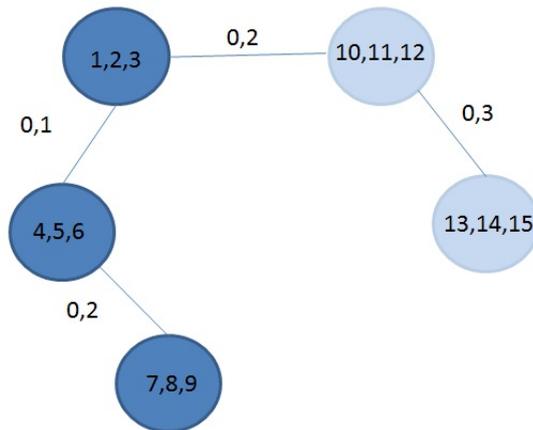


Figura 3.4: Subgrafo gerado a partir da árvore geradora mínima.

o protótipo pertencente à classe azul clara. Os protótipos estão evidenciados por um círculo vermelho presente ao redor do nó. Assim que os protótipos são escolhidos, a ligação entre eles é desfeita. Por esse, motivo na Figura 3.5 a relação entre esses dois nós deixou de existir.

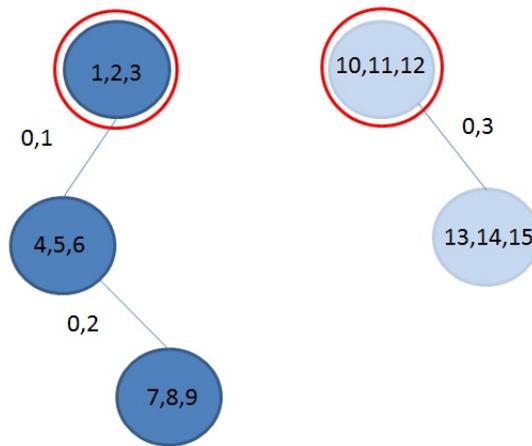


Figura 3.5: Definição dos protótipos de cada classe.

3.3 Classificação

Com o grafo treinado, é possível iniciar a etapa de classificação de uma nova amostra. Nessa etapa, um novo nó é comparado com todos os nós. Após a relação do novo nó com os demais, o custo entre eles é calculado. A Figura 3.6, ilustra um novo nó representado pela cor branca e a comparação deste com os nós presentes no grafo.

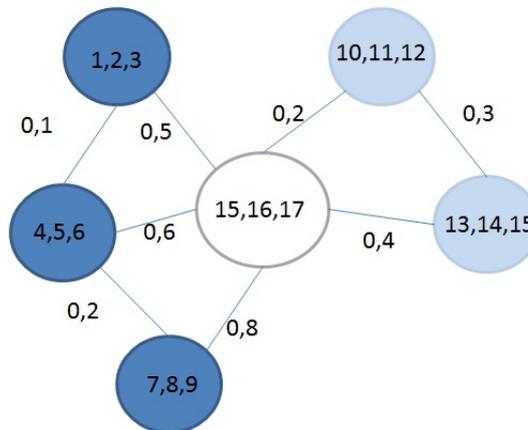


Figura 3.6: Comparação de uma nova amostra com as amostras existentes no grafo.

Após realizar todas as comparações, a relação com o menor custo é escolhida e o novo nó é definido como pertencente à classe do nó que ele foi conectado. A Figura 3.7 ilustra um exemplo de classificação em que o último nó inserido foi classificado como pertencente à classe azul clara.



Figura 3.7: Classificação da nova amostra como pertencente à classe azul clara.

Capítulo 4

Materiais e Métodos

Em um dos trabalhos englobados no projeto MEL, foi realizada uma pesquisa na região centro-oeste a fim de obter informações dos apicultores com relação à forma como o produto é produzido e às características mais comuns dos produtos comercializados por eles. Dentre essas características, pode-se citar o nome das espécies florais mais predominantes na região. Essas espécies funcionam como um marco para uma região. Neste trabalho, essas plantas que funcionam como marco serão chamadas de plantas regionais.

No trabalho [4], a autora percorreu algumas cidades da região centro-oeste, realizou um questionário com os apicultores, coletou 0.5kg de mel de cada apiário visitado e através das informações obtidas, foi possível encontrar as plantas regionais, sendo elas: Cipó-uva, Assa-peixe, Aroeira, Peito de Pombo e Capitão. As espécies foram catalogadas de acordo com seu nome vulgar e com a percepção dos apicultores. Atualmente, dentre as plantas regionais, o projeto Pólen possui amostras de imagens das seguintes classes: Assa-peixe, ilustrado na Figura 4.1 (a), Aroeira, ilustrado na Figura 4.1 (b) e Cipó-Uva, ilustrado na Figura 4.1 (c). Foi através do trabalho de [4], que as espécies regionais puderam ser conhecidas. É importante lembrar que as plantas regionais foram obtidas através da percepção dos apicultores, ou seja, não houve um estudo dos grãos de pólen mais frequentes para que as plantas regionais fossem identificadas.

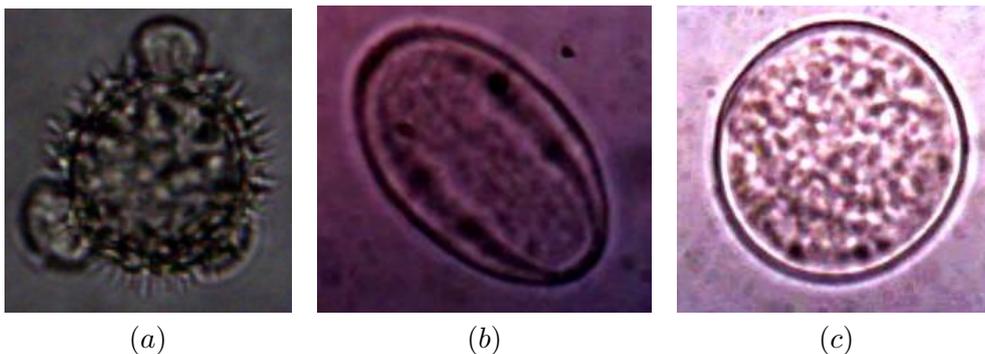


Figura 4.1: (a) Grão de pólen de Assa-peixe, (b)Grão de pólen de Aroeira e (c) Grão de pólen de Cipó-Uva

Outra pesquisa realizada no projeto MEL visou analisar os méis capturados na região centro-oeste e verificar se as espécies apontadas pelos apicultores como espécies regionais seriam encontradas nos méis observados. Esses méis foram capturados na cidade de Bonito - Mato Grosso do Sul.

Com as plantas regionais já conhecidas, outro trabalho também pertencente ao projeto MEL,

capturou grãos de pólen diretamente da planta. Desse modo, os membros do projeto puderam caracterizar de forma mais precisa cada grão de pólen e obter imagens dos grãos em diferentes visões. Uma visão representa a observação de um objeto, nesse caso, o grão de pólen, em diferentes ângulos. Todos os trabalhos supracitados serviram como base de informações, obtenção das imagens e identificação de espécies utilizadas nos experimentos realizados nesta proposta.

Para facilitar a compreensão da diferença que uma visão traz no reconhecimento de um objeto, a Figura 4.2 ilustra um lápis de escrever fotografado em diferentes posições. A distância entre a câmera e o objeto assim como o dispositivo de captura foram mantidos em todas as imagens. Ao verificar as imagens é possível perceber que a posição do objeto traz diferenças na análise do mesmo.

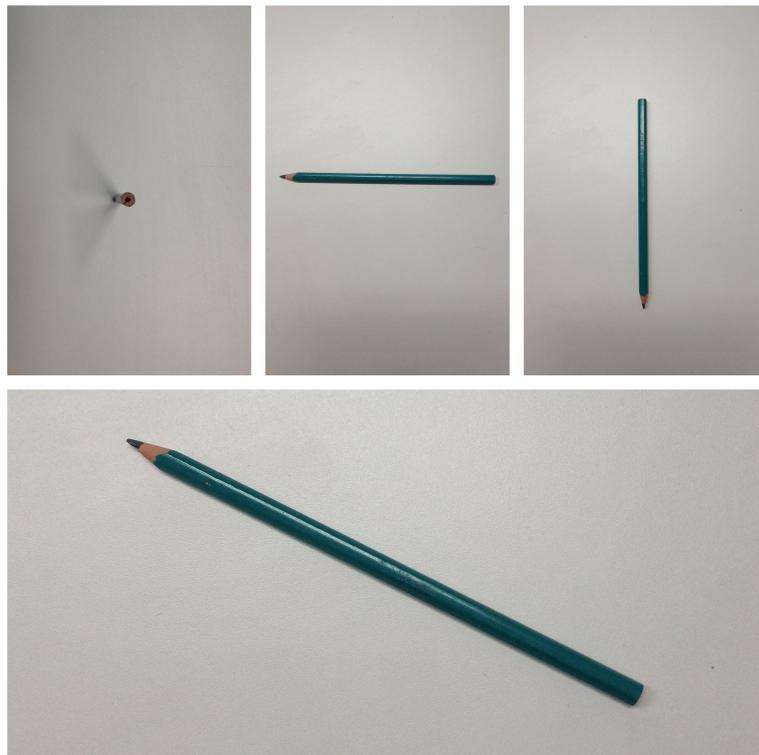


Figura 4.2: Imagens de um lápis de escrever capturadas com o objeto em diferentes posições

Em uma imagem capturada de um grão de pólen, ele pode se apresentar de diferentes formas. As imagens da Figura 4.3 ilustram visões diferentes de um grão de pólen de mamoeiro selvagem. As visões de um grão de pólen recebem nomes específicos. Os nomes utilizados com maior frequência são: visão polar e visão equatorial. Quando a região polar (similar aos polos do globo terrestre) do grão de pólen está virada para a pessoa que visualiza a imagem, essa visão é chamada de polar e quando a região equatorial (análoga a linha do equador do globo terrestre) do grão de pólen está virada para a pessoa que visualiza a imagem, ela é chamada de visão equatorial. A Figura 4.3 (d) ilustra uma visualização polar e a Figura 4.3 (c) ilustra um exemplo de visualização equatorial [28].

Na amostra do mel há presença de resíduos e/ou subprodutos das plantas, comumente denominados de “material vegetal”. A Figura 4.4 ilustra uma imagem contendo material vegetal, evidenciado com a marcação vermelha, bolhas de ar, evidenciadas pela marcação azul, sujeira evidenciada pela marcação verde e o grão de pólen evidenciado pela cor marrom presente no

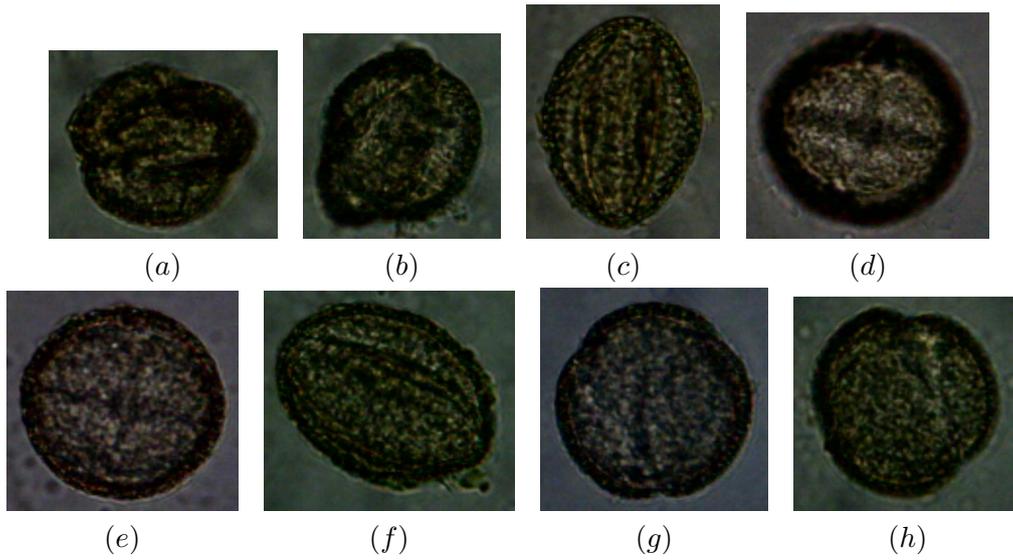


Figura 4.3: Diferentes visões do grão de pólen de mamoeiro selvagem.

centro da imagem.

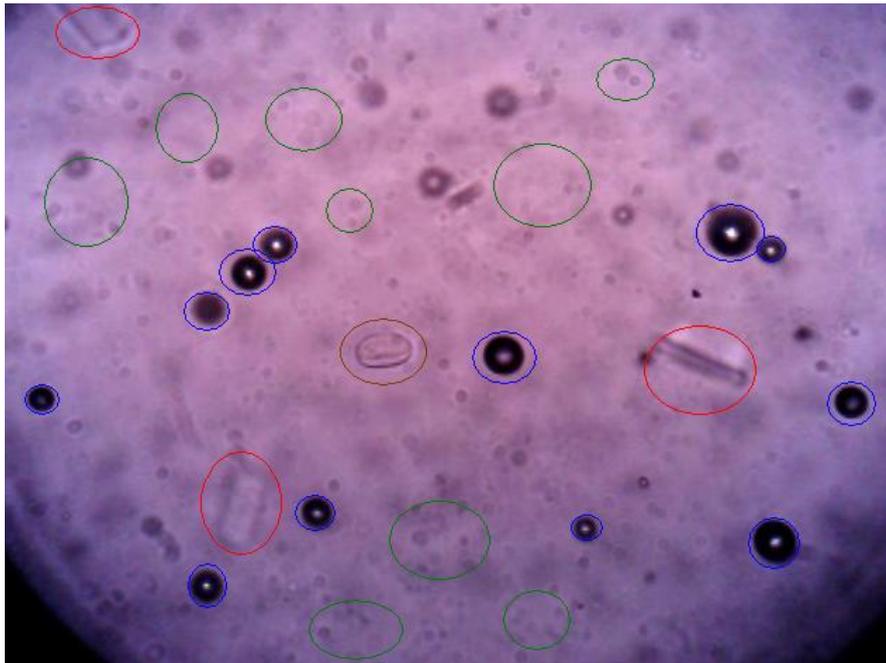


Figura 4.4: Imagem com ruídos evidenciados.

4.1 Preparo da amostra

Após capturar as amostras de méis e/ou grãos de pólen é necessário preparar essas amostras para que elas possam ser visualizadas através de um microscópio. Foi preciso utilizar o microscópio, pois não é possível observar com detalhes um grão de pólen a olho nu.

Para que a imagem seja obtida, é necessário transferir a amostra para uma placa, material de vidro em formato retangular. A placa é colocada na mesa — componente do microscópio que suporta e “trava” a placa para que ela não se movimente durante a observação da amostra — e através da objetiva — que é responsável pela ampliação ocular —, a amostra pode ser visualizada. A Figura 4.5 (a) ilustra um microscópio e evidencia a objetiva e a mesa. Para proteger a amostra e para que ela não encoste na objetiva, uma lamela (material similar a placa, mas com tamanho inferior) é inserido em cima da amostra. Sendo assim, a amostra fica entre a placa e a lamela, a Figura 4.5 (b) ilustra a representação de uma placa e uma lamela. O ato de transferir a amostra para a placa é chamado de plaqueamento.



Figura 4.5: (a) Imagem de um microscópio evidenciando a mesa e a objetiva (b) Imagem ilustrativa da placa de vidro (representada pela cor azul clara) e lamela (representada pela cor azul escura).

Com a amostra inserida no microscópio, o especialista realizou capturas de imagens de diferentes locais da placa, ou seja, após cada captura o especialista realizava uma movimentação da mesa presente no microscópio para garantir que as imagens visualizadas não tinham sido visualizadas anteriormente. O número de imagens capturadas corresponde ao número de grãos de pólen que o especialista deseja contar. Esse número é definido previamente pelo especialista. Desse modo, assim que ele consegue capturar imagens da quantidade de grãos que ele necessita, a obtenção de imagens é interrompida. A Figura 4.6 ilustra um exemplo de imagem de mel visualizada por ele. É através de imagens deste tipo que a contagem de grãos de pólen foi realizada.

Nesse trabalho, 3 maneiras foram usadas para preparar a amostra do mel antes do plaqueamento ter início. O primeiro processo capturava a amostra do mel e realizava a transferência dessa amostra para a placa, sendo assim, nenhum processamento prévio era realizado.

Com o intuito de evidenciar os grãos de pólen, o segundo processo utilizou o método proposto pela Terra Scenica[33]. Essa metodologia sofreu uma alteração e foi desenvolvida como descrita a seguir. Para a aplicação da modificação da metodologia, as amostras foram centrifugadas em centrífuga marca BEL a 2500g por 5 minutos com o intuito de concentrar o grão de pólen em parte do recipiente. Em seguida ocorreu o plaqueamento dessas amostras. Posteriormente, elas foram analisadas microscopicamente e imagens dos grãos de pólen foram capturadas. No experimento com essa metodologia, foram contados 200 grãos de pólen e as imagens foram obtidas com aumento de 40x.

O terceiro processo utilizou uma técnica chamada acetólise. Essa técnica tem o intuito de evidenciar a estrutura externa dos grãos de pólen. Para realizar essa técnica, foi necessário pesar as amostras usando uma balança analítica. Para cada experimento 10g de mel foram obtidas. Após pesar a amostra, ela foi diluída em 10ml de água destilada morna e foi adicionado 50ml de álcool etílico 95%. Em seguida, a mistura foi centrifugada a 2500 rpm. Após essa tarefa o material com grão de pólen ficou no fundo do recipiente e acima dele o material líquido (sobrenadante) ficou posicionado. Após a centrifugação, o material líquido foi descartado e o sedimento polínico



Figura 4.6: Imagem obtida de amostras de mel contendo grãos de pólen de diferentes espécies.

(material contendo intensa concentração de grãos de pólen que ficou no fundo do recipiente) recebeu 2ml de ácido acético para retirar a água presente no interior do grão de pólen. Após esse momento, a acetólise proposta por [15] e adaptada por [18] foi iniciada através da inserção de 2ml de solução acetolítica nas amostras que foram colocadas em banho-maria por 2 minutos. Após concluir o processo, o sobrenadante foi descartado e 2ml de glicerina foi adicionado na amostra que ficou em repouso por uma hora para que os grãos de pólen pudessem se reidratar (já que a água do interior deles foi “sugada” nos processos anteriores). Para preparar as lâminas, um cubo de gelatina glicerinada com dimensão 3mm X 3mm foi cortado e posicionado no fundo do recipiente para que os grãos de pólen pudessem se aderir ao cubo. Após esse processo, os grãos de pólen foram transferidos para a placa e observados no microscópio. Para os experimentos com acetólise, 500 grãos de pólen foram contados. As imagens capturadas utilizando essa metodologia foram obtidas com aumento de 40x. A Figura 4.7 ilustra uma imagem obtida através de cada uma das técnicas aplicadas.

4.2 Microscópios

Para a captura de imagens, dois microscópios foram usados, um deles obtinha a iluminação sob a imagem e outro apresentava a iluminação sobre a imagem. Para facilitar a compreensão, o primeiro microscópio será chamado de microscópio A e o segundo de microscópio B. O microscópio A possui a seguinte configuração: microscópio tradicional Marca Bel Equipamentos analíticos Ltda, ilustrado na Figura 4.8 (a), acoplado com o dispositivo de captura Marca Proscope HR com lente de 400X, ilustrado na Figura 4.8 (b). O microscópio com o dispositivo de captura pode ser visualizado na Figura 4.8 (c). Enquanto o microscópio B é um Monotela LCD marca LCD Micro Bresse com aumento de 40 a 1600 X, ilustrado na Figura 4.8 (d).

Como os dois microscópios presentes no projeto possuem configurações distintas, as imagens resultantes de cada microscópio possuem características específicas. Por exemplo, as imagens

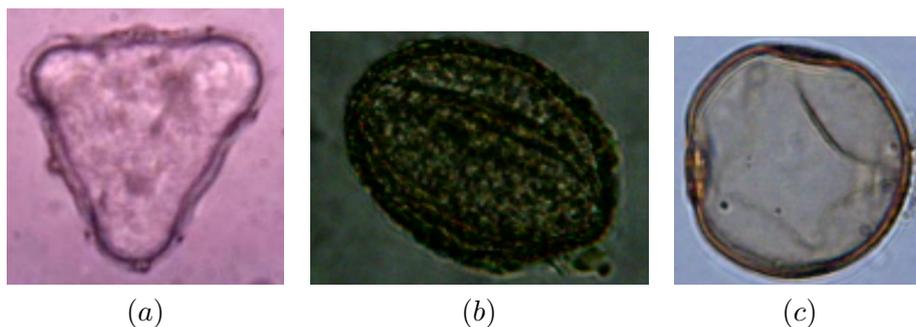


Figura 4.7: (a) Imagem obtida através da primeira técnica, (b) Imagem obtida através da segunda técnica e (c) Imagem obtida através da terceira técnica

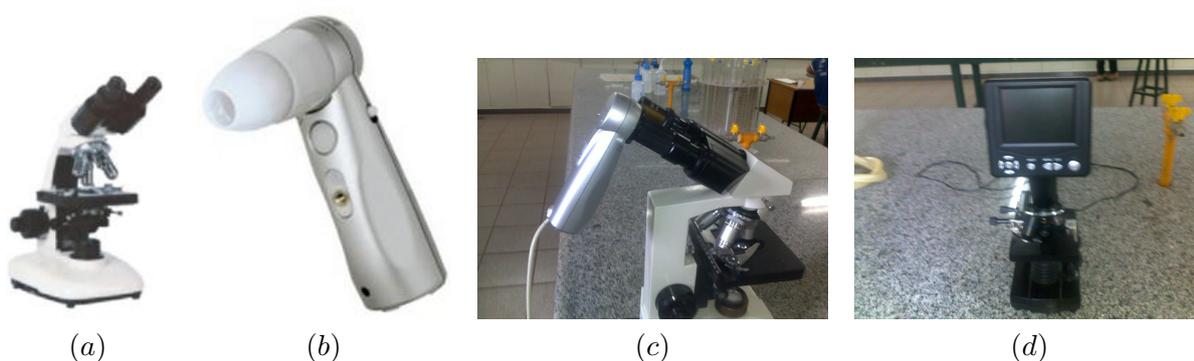


Figura 4.8: (a) microscópio tradicional marca Bel, (b) dispositivo de captura marca Proscope HR e (c) dispositivo de captura acoplado ao microscópio e (d) microscópio Monotela LCD Marca LCD Micro Bresse

capturadas pelo microscópio A possuem resolução de 640×480 *pixels* enquanto as imagens capturadas pelo microscópio B possui vários tipos de resolução sendo que o tamanho máximo é de 1520×1120 *pixels* cada. As Figuras 4.9 (a) e (b) ilustram imagens de grãos de pólen de uma mesma espécie capturadas através dos microscópios A e B, respectivamente.

4.3 Banco de imagens

O conjunto de imagens obtido pelo especialista foi aglomerado e denominado banco de imagens. Foi através das imagens presentes no banco de imagens do projeto que todos os experimentos foram desenvolvidos e que a classificação das diferentes espécies de grãos de pólen foi realizada. A Figura 4.10 ilustra alguns exemplos de imagens presentes no banco de imagens do projeto e de suas respectivas espécies florais. As imagens obtidas foram divididas em 5 conjuntos de treinamento e teste (*datasets*) com o intuito de verificar se o microscópio, a coloração e/ou a técnica utilizada para o tratamento da amostra iria influenciar a classificação.

Como algumas classes presente no banco de imagens não foram identificadas, elas foram denominadas através de um código constituído pela palavra “indefinido” seguido de um número, por exemplo: indefinido7. Para as classes já classificadas, o nome vulgar ou científico do grão de pólen informado pelo especialista foi mantido. Se uma mesma classe que não possui identificação estiver presente em mais de um conjunto de imagens, o nome destinado a ela foi mantido em



Figura 4.9: (a) Imagem capturada através do microscópio A e (b) Imagem capturada através do microscópio B

todos os conjuntos que ela está presente. Por exemplo, a mesma classe denominada indefinido1 está presente no conjunto 1, 2 e 3. As imagens de grãos de pólen foram recortadas manualmente e cada uma das imagens possui apenas o grão de pólen, como ilustram as figuras de cada conjunto descritos posteriormente.

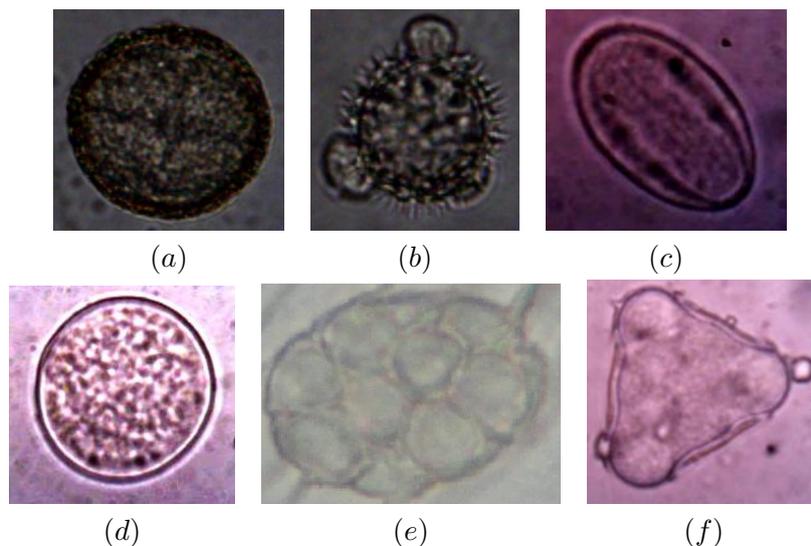


Figura 4.10: (a) Grão de pólen de Mamoeiro Selvagem, (b) Grão de pólen de Assa-peixe, (c) Grão de pólen de Aroeira, (d) Grão de pólen de Cipó-Uva, (e) Grão de pólen de barbatimão, (f) Grão de pólen de eucalipto.

4.3.1 Conjunto de imagens 1

O conjunto 1 apresenta imagens capturadas com o microscópio B que possuía um filtro de visualização na cor azul. Esse filtro é similar a uma lente que não apresenta nenhum aumento, porém apresenta uma coloração. Essa coloração influencia na imagem a ser capturada e, por esse motivo, a imagem obtém a cor do filtro usado. Esse filtro é posicionado em cima da luz do microscópio. Por esse motivo, ele consegue refletir uniformemente a coloração em toda a

amostra. As Figuras 4.11 (a), (b), (c), (d), (e), (f), (g) e (h) e a Tabela 4.1 ilustram exemplos de cada uma das classes e quantidade de amostras presentes no conjunto 1, respectivamente. Esse conjunto foi desenvolvido utilizando a segunda técnica de preparo de amostra.

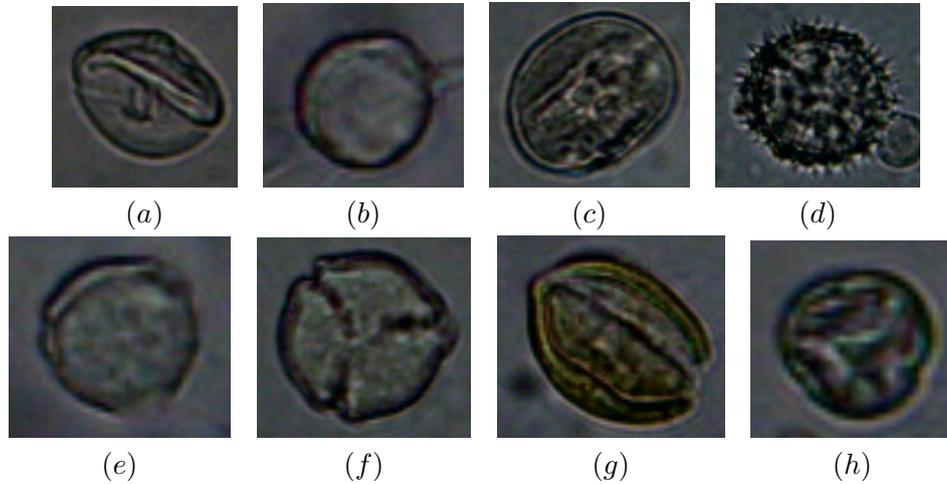


Figura 4.11: Classes de grãos de pólen presentes no conjunto 1, sendo elas: (a) Grão de pólen de Aroeira, (b) Grão de pólen não identificado, (c) Grão de pólen de Mamoeiro Selvagem, (d) Grão de pólen de Assa-peixe, (e) Grão de pólen não identificado, (f) Grão de pólen não identificado, (g) Grão de pólen não identificado, (h) Grão de pólen não identificado.

Nº do conjunto	Código da classe	Nº de amostras
1	aroeira	19
1	indefinido1	7
1	mamoeiro selvagem	17
1	assa-peixe	10

Tabela 4.1: Número de amostras de cada classe presente no conjunto 1.

4.3.2 Conjunto de imagens 2

O conjunto 2 foi obtido utilizando um filtro roxo, microscópio B e o segundo método de preparo de amostra. Essas imagens podem ser visualizadas nas Figuras 4.12 (a), (b), (c), (d), (e) e (f). A Tabela 4.2 apresenta a quantidade de amostras presentes no conjunto 2.

Nº do conjunto	Código da classe	Nº de amostras
2	indefinido1	14
2	aroeira	9
2	indefinido2	8
2	mamoeiro selvagem	12
2	assa-peixe	14
2	indefinido3	8

Tabela 4.2: Número de amostras de cada classe presente no conjunto 2.

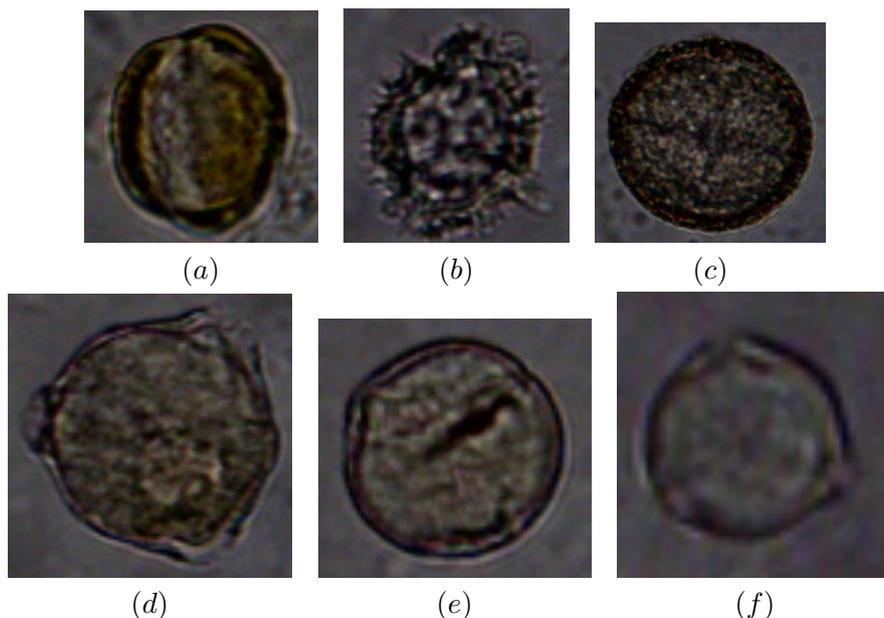


Figura 4.12: Classes de grãos de pólen presentes no conjunto 2, sendo elas: (a) Grão de pólen não identificado, (b) Grão de pólen de assa-peixe, (c) Grão de pólen de mamoeiro selvagem, (d) Grão de pólen não identificado, (e) Grão de pólen de aroeira e (f) Grão de pólen não identificado.

4.3.3 Conjunto de imagens 3

O terceiro conjunto é formado por imagens capturadas através do microscópio B, com os filtros roxo e azul, essas imagens foram capturadas diretamente do grão de pólen e podem ser visualizadas através das Figuras 4.12 e 4.11. A Tabela 4.3 apresenta a quantidade de amostras presentes no conjunto 3.

Nº do conjunto	Código da classe	Nº de amostras
3	indefinido1	26
3	indefinido2	26
3	mamoeiro selvagem	28
3	assa-peixe	32
3	indefinido3	11

Tabela 4.3: Número de amostras de cada classe presente no conjunto 3.

4.3.4 Conjunto de imagens 4

O quarto conjunto é representado por imagens obtidas através do microscópio A, essas imagens foram capturadas diretamente do mel, ou seja, usaram o primeiro método de preparo de amostra. As Figuras 4.13 (a), (b), (c), (d), (e) e (f) e a Tabela 4.4 ilustram exemplos de cada uma das classes e quantidade de amostras presentes no conjunto 4, respectivamente.

4.3.5 Conjunto de imagens 5

Com base nas imagens obtidas com as técnicas anteriores notou-se que a quantidade de imagens por classe não seguia um padrão e, em alguns casos, algumas classes obtinham poucas imagens

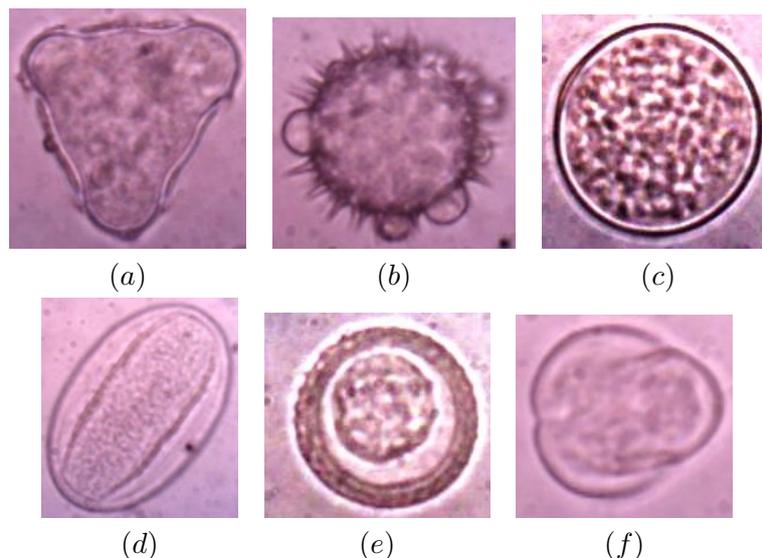


Figura 4.13: Grãos de pólen das classes presentes no conjunto 4, sendo elas: (a) Grão de pólen de eucalipto, (b) Grão de pólen de assa-peixe, (c) Grão de pólen de cipó-uva, (d) Grão de pólen de aroeira, (e) Grão de pólen não identificado e (f) Grão de pólen não identificado

Nº do conjunto	Código da classe	Nº de amostras
4	eucalipto	14
4	assa-peixe	8
4	cipó-uva	8
4	aroeira	9
4	indefinido4	4
4	indefinido5	4

Tabela 4.4: Número de amostras de cada classe presente no conjunto 4.

para sua caracterização. Para o quinto conjunto de imagens, o filtro de coloração foi padronizado na cor branca, todas as imagens foram obtidas na resolução de 1280 x 960 *pixels* e foi estabelecido que a quantidade de amostras por classe deveria ser próxima ou superior a 30 grãos. O intuito de estabelecer uma quantidade para as amostras era eliminar a possível discrepância na quantidade de imagens de classes diferentes. A quantidade de imagens foi definida subjetivamente e foi utilizada para que o especialista obtivesse uma referência para a obtenção de imagens de grãos de pólen que foram utilizadas para os experimentos computacionais. O microscópio B foi padronizado para a realização deste experimento e as imagens obtidas podem ser visualizada na Figura 4.14 (a), (b), (c), (d), (e), (f), (g), (h) e (i) . A Tabela 4.5 apresenta os 5 conjuntos com a quantidade de amostras e classes que cada um deles contém.

4.4 Experimentos

Para realizar os experimentos, algoritmos de extração de atributos foram aplicados e informações das amostras de cada classe foram obtidas. Com essas informações, os algoritmos de classificação foram treinados e testados. Os experimentos realizados utilizaram a validação cruzada presente no WEKA. Para realizar essa validação, um dos parâmetros solicitou o número de dobras que o classificador realizou. Através desse número, o classificador realizou uma alteração nos conjuntos

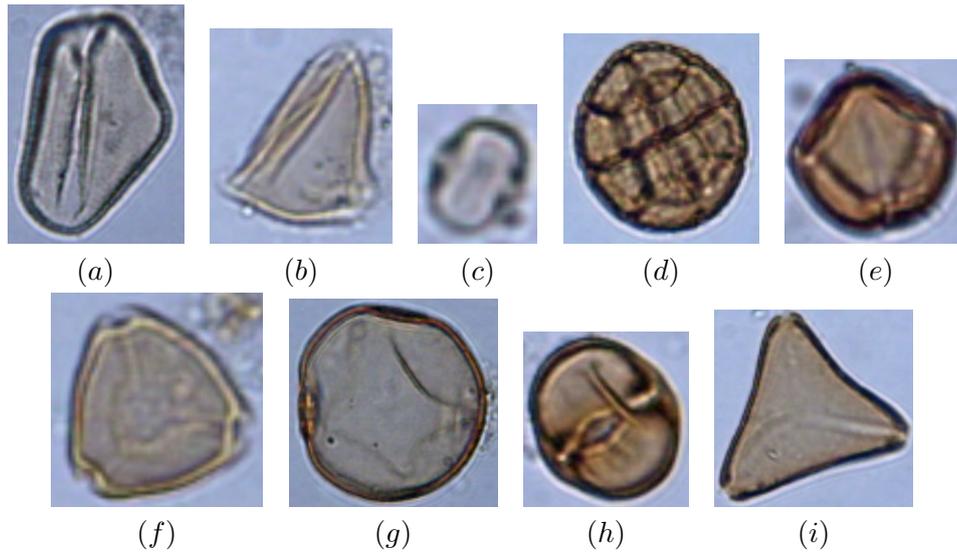


Figura 4.14: Grãos de pólen das classes presentes no conjunto 5, sendo elas: (a) Grão de pólen de Arecaceae tipo 1, (b) Grão de pólen de Arecaceae tipo 2, (c) Grão de pólen de Cecropia, (d) Grão de pólen de Fabaceae, (e) Grão de pólen de Schinus, (f) Grão de pólen de Myrtaceae, (g) Grão de pólen de Poaceae, (h) Grão de pólen de Protium e (i) Grão de pólen de Serjania.

Nº do conjunto	Código da classe	Nº de amostras
5	arecaceae tipo 1	21
5	arecaceae tipo 2	34
5	cecropia	36
5	fabaceae	30
5	myrtaceae	32
5	poaceae	26
5	protium	30
5	schinus	30
5	serjania	30

Tabela 4.5: Informações sobre o número de amostras presentes em cada classe de cada conjunto do banco de imagens utilizado nesta proposta.

de teste e de treinamento. Por exemplo, se para um experimento foram escolhidas 10 dobras, o classificador irá capturar os dados de uma amostra para teste e 9 para treinamento do classificador. Em seguida, um novo conjunto é selecionado para teste e os outros 9 realizam o treinamento do classificador. Essa repetição acontece até que todas as variações tenham sido feitas.

Para a classificação, os classificadores foram comparados e com o resultado da classificação, o teste de Friedman foi aplicado para verificar se há diferença entre os classificadores. Para a utilização do teste de Friedman, um programa chamado R foi utilizado [27]. Para esse teste foi considerado 5% de significância, sendo assim, se o valor de p (resultante do teste de Friedman) for menor que 5% a hipótese nula é rejeitada, ou seja, pode-se afirmar que os classificadores são diferentes, caso contrário a hipótese nula é aceita e pode-se dizer que os classificadores são iguais. Se a hipótese nula não for aceita, a análise post hoc é realizada para verificar qual classificador apresenta melhor resultado.

Capítulo 5

Resultados e Análises

Neste capítulo, serão descritos os resultados dos experimentos realizados neste trabalho. Para cada experimento, as métricas *recall*, *precision*, *f-score* e taxa de acerto foram analisadas e os algoritmos de teste de hipótese foram aplicados. As análises dos resultados também estarão contidas neste capítulo.

O WEKA calcula o teste T-Students, por isso, quando o resultado de um experimento é obtido, um círculo pode estar presente ao lado do resultado de algum classificador. Esse círculo revela que o classificador ganhou ou perdeu do classificador posicionado na primeira coluna das Tabelas de resultado. Quando o círculo estiver vazio, quer dizer que o classificador ganhou do primeiro algoritmo. A ausência de círculos significa que houve um empate entre os classificadores analisados.

5.1 Experimento 1

Apenas algumas classes foram selecionadas para o este experimento, sendo elas: indefinido1, indefinido2 e indefinido3 do conjunto 3. Os atributos extraídos foram média dos canais H, S e B e atributos de forma (todos os atributos de forma foram utilizados). No total foram extraídos 7 atributos sendo 3 de cor e 4 de forma. O algoritmo de seleção de atributos chamado *Best-First*¹ foi aplicado e 5 atributos foram selecionados, sendo eles: média dos canais H, S e B e fator de forma e circularidade.

Os resultados das métricas taxa de acerto, *recall*, *precision* e *f-score* podem ser visualizados nas Tabelas 5.1, 5.2, 5.3 e 5.4². De acordo com os resultados, pode-se perceber que o algoritmo SVM e C4.5 obtiveram melhor desempenho do FCO em relação ao resultado do *recall* e *precision*. Analisando somente a taxa de acerto, pode-se perceber que o FCO possui resultado inferior, em torno de 11%, em relação ao C4.5 que apresentou melhor resultado dentre os classificadores. Porém quando o *recall*, *precision* e *f-score* são analisados essa diferença torna-se maior. Neste experimento, pode-se perceber que o resultado do FCO usando o *recall* e *precision* é inferior a todos os classificadores testados.

Tabela 5.1: Taxa de acerto para experimento com 3 classes e 5 atributos

Dataset	(FCO)	(KNN)	(SVM)	(C4.5)
Conjunto1	71.85±14.63	78.31±14.20	74.67±14.07	80.79±13.04

o, • degradação ou melhoria estatisticamente significante

¹Testes exploratórios foram utilizados para a escolha deste algoritmo de seleção de atributos.

²O sinal '+' foi utilizado ao lado do nome do conjunto para ilustrar que ele não possui todas as classes daquele conjunto

Tabela 5.2: Resultado do *recall* para experimento com 3 classes e 5 atributos

Dataset	(FCO)	(SVM)	(KNN)	(C4.5)
Conjunto1-	0.485000	0.793333 ◦	0.715000	0.816667 ◦

◦, • degradação ou melhoria estatisticamente significativa

Tabela 5.3: Resultado do *precision* para experimento com 3 classes e 5 atributos

Dataset	(FCO)	(SVM)	(KNN)	(C4.5)
Conjunto1-	0.593500	0.882667 ◦	0.834333	0.869833

◦, • degradação ou melhoria estatisticamente significativa

Tabela 5.4: Resultado do *f-score* para experimento com 3 classes e 5 atributos

Dataset	(FCO)	(SVM)	(KNN)	(C4.5)
Conjunto1-	0.508262	0.806762 ◦	0.743881	0.813286 ◦

◦, • degradação ou melhoria estatisticamente significativa

5.2 Experimento 2

Neste experimento, as imagens do conjunto 3 foram utilizadas. Neste experimento, foram inseridos atributos de textura com o intuito de conseguir caracterizar melhor as amostras das classes. Por isso, os algoritmos de matriz de coocorrência e mapas de interação foram adicionados ao conjunto de atributos utilizado neste experimento. Os métodos de extração de atributos utilizados foram escolhidos de forma empírica. O conjunto de atributos extraídos foram a média dos canais H, S, B, R, G e B e atributos de forma (todos os atributos de forma foram utilizados), matriz de coocorrência (entropia, diferença inversa, correlação, dissimilaridade, momento da diferença inverso, contraste e uniformidade) e mapas de interação (entropia, diferença inversa, correlação, dissimilaridade, momento da diferença inverso, contraste e uniformidade). Os valores dos parâmetros utilizados nos experimentos para os algoritmos matriz de coocorrência e mapas de interação estão presentes nas Tabelas 5.5 e 5.6, respectivamente. Os valores dos parâmetros foram definidos experimentalmente e o algoritmo *Best-First* foi aplicado. Após a aplicação do algoritmo, 9 atributos foram selecionados, sendo eles: média dos canais H, S, B, G e B, fator de forma, dissimilaridade180, entropia135 e dissimilaridade135 (os três últimos atributos foram extraídos através do algoritmo de matriz de coocorrência). Os valores presentes após os atributos de textura referem-se ao ângulo de cada atributo.

Ângulo	Distância
180	1
135	1
90	1
45	1

Tabela 5.5: Parâmetros utilizados para a técnica de matriz de coocorrência.

No segundo experimento houve uma melhora significativa no resultado do *recall*, *precision* e *f-score* quando comparado aos outros classificadores. Essa melhora pode ser decorrente do aumento de atributos. Por exemplo, o *recall* obtido no experimento 1 foi 0.485000 quando o maior foi 0.816667. Já o obtido neste experimento foi de 0.84 quando o maior foi 0.89.

Ângulo	Distância
180	2
135	2
90	2
45	2
180	1
135	1
90	1
45	1
180	0
135	0
90	0
45	0

Tabela 5.6: Parâmetros utilizados para a técnica de matriz de interação.

Tabela 5.7: Taxa de acerto para experimentos com 5 classes com atributos de forma, cor e textura

Dataset	(FCO)	(SVM)	(KNN)	(C4.5)
Conjunto2	74.85±11.20	80.68±10.43	87.03±10.17 ◦	81.95±10.73

◦, • degradação ou melhoria estatisticamente significante

5.3 Experimento 3

Já no terceiro experimento, todas as classes dos conjuntos 1, 2, 3, e 4 foram utilizados. Todos os grupos de imagens obtiveram a extração e classificação das classes com o conjunto de atributos mais representativo presente nos experimentos desenvolvidos até a realização do terceiro experimento, sendo eles: a média dos canais H, S, B, R, G e B e atributos de forma (todos os atributos de forma foram utilizados), matriz de coocorrência (entropia, diferença inversa, correlação, dissimilaridade, momento da diferença inverso, contraste e uniformidade) e mapas de iteração (entropia, diferença inversa, correlação, dissimilaridade, momento da diferença inverso, contraste e uniformidade). Para esse experimento, o algoritmo de seleção de atributos *Best-First* foi aplicado para cada um dos conjuntos de imagem e posteriormente, a classificação e comparação entre eles foi realizada.

Os experimentos visam verificar quais conjuntos de atributos são mais relevantes para a classificação de grãos de pólen e qual é o resultado do FCO em relação à classificação e tempo de treinamento quando comparado aos demais classificadores selecionados.

Os resultados apresentados na Tabela 5.11, são referentes ao experimento 3. Esses resultados foram analisados através do teste de Friedman para verificar se há ou não distinção entre os classificadores. Ao submeter o resultado do experimento presente na Tabela 5.11 ao teste de Friedman o resultado de p obtido foi igual a 5.7%. De acordo com o resultado a hipótese nula pode ser aceita. Porém quando o resultado do tempo de treinamento dos classificadores foi analisado, obteve-se um valor de p igual a 0.7%. A Tabela 5.15 apresenta o tempo utilizado no

Tabela 5.8: Resultado da métrica *precision*

Dataset	(FCO)	(SVM)	(KNN)	(C4.5)
Conjunto2	0.93	0.87	0.90	0.86

◦, • degradação ou melhoria estatisticamente significante

Tabela 5.9: Resultado da métrica *recall*

Dataset	(FCO)(SVM)	(KNN)(C4.5)
Conjunto2	0.84 0.85	0.87 0.89

o, • degradação ou melhoria estatisticamente significante

Tabela 5.10: Resultado da métrica *f-score*

Dataset	(FCO)(SVM)	(KNN)(C4.5)
Conjunto2	0.86 0.84	0.87 0.86

o, • degradação ou melhoria estatisticamente significante

treinamento de cada classificador. De acordo com o resultado a hipótese nula pode ser rejeitada, porém precisa saber qual é o classificador que apresenta maior tempo de treinamento. Para isso, a análise de *post hoc* foi aplicada e o resultado está presente na imagem 5.1. De acordo com o gráfico pode-se analisar que o SVM apresenta maior tempo de treinamento quando comparado aos outros classificadores.

Ao analisar, através do teste de Friedman o *recall*, *precision* e o *f-score* das Tabelas 5.14, 5.12 e 5.13 pode-se confirmar o resultado obtido através da taxa de acerto dos classificadores. De acordo com o experimentos analisando o *recall*, o valor de p foi igual a 20.54%. Para o *precision*, o valor de p foi igual a 55.20% e para o *f-score* o valor obtido foi de 99.42%. Analisando os dados supracitado, os 3 valores obtiveram resultado superior à 5%, por isso também pode-se rejeitar a hipótese nula para os 3 itens supracitados. Analisando apenas o resultado do teste T-Students para a métrica da taxa de acerto, pode-se perceber que o KNN apresentou melhores resultados quando comparado ao FCO em 3 conjuntos.

5.4 Experimento 4

Neste experimento, foram utilizadas todas as classes presentes no conjunto 5. Os parâmetros utilizados nos experimentos anteriores foram variados para caracterizar melhor cada uma das classes. A variação dos parâmetros ocorreu de forma experimental e estão presentes nas Tabelas 5.16 e 5.17. Os algoritmos PBL, PBLROT e *wavelets* foram inseridos. Para a aplicação do algoritmos PBL, os valores da extração de atributos foram calculados com base no *pixel* central de cada imagem devido à variação de tamanho dos grãos de pólen de acordo com as diferentes posições que eles foram obtidas. Para esses algoritmos foi obtida a média dos valores calculados. Os parâmetros utilizados foram definidos experimentalmente e estão descritos na Tabela 5.18. Para a transformada de *wavelets* o valor grau utilizado foi -0.49 e a variação foi de -0.5 (esses atributos são parâmetros utilizados para a configuração do algoritmo) e os valores extraídos foram: contraste, correlação, entropia, uniformidade, momento da diferença inverso. O algoritmo de seleção de atributos *Best-First* foi aplicado e os atributos selecionados foram: a média dos canais H, S, B, R, fator de forma, circularidade, dissimilaridade360, entropia135, dissimilaridade270, dissimilaridade225, momento da diferença inverso180, inversa180, dissimilaridade45 (os sete atri-

Tabela 5.11: Porcentagem de acerto de todos os ARFFS e todos os classificadores

Dataset	(FCO)	(SVM)	(KNN)	(C4.5)
Conjunto1	74.43±16.28	67.69±12.91	87.00±12.14 o	71.45±15.91
Conjunto2	45.83±22.35	67.37±15.77 o	73.13±18.83 o	75.27±18.11 o
Conjunto3	74.85±11.20	80.68±10.43	87.03±10.17 o	81.95±10.73
Conjunto4	43.35±23.73	47.35±12.68	52.00±19.58	59.15±19.77

o, • degradação ou melhoria estatisticamente significante

Tabela 5.12: Resultado do *recall* de cada classificador

Dataset	(FCO)	(SVM)	(KNN)	(C4.5)
Conjunto1	0.78	0.78	0.70	0.70
Conjunto2	0.54	0.90 ◦	0.64	0.68
Conjunto3	0.84	0.85	0.87	0.89
Conjunto4	0.59	1.00 ◦	0.63	0.66

◦, • degradação ou melhoria estatisticamente significativa

Tabela 5.13: Resultado do *precision* de cada classificador

Dataset	(FCO)	(SVM)	(KNN)	(C4.5)
Conjunto1	0.74	0.55	0.64	0.57
Conjunto2	0.52	0.57	0.68	0.75
Conjunto3	0.93	0.87	0.90	0.86
Conjunto4	0.50	0.45	0.44	0.57

◦, • degradação ou melhoria estatisticamente significativa

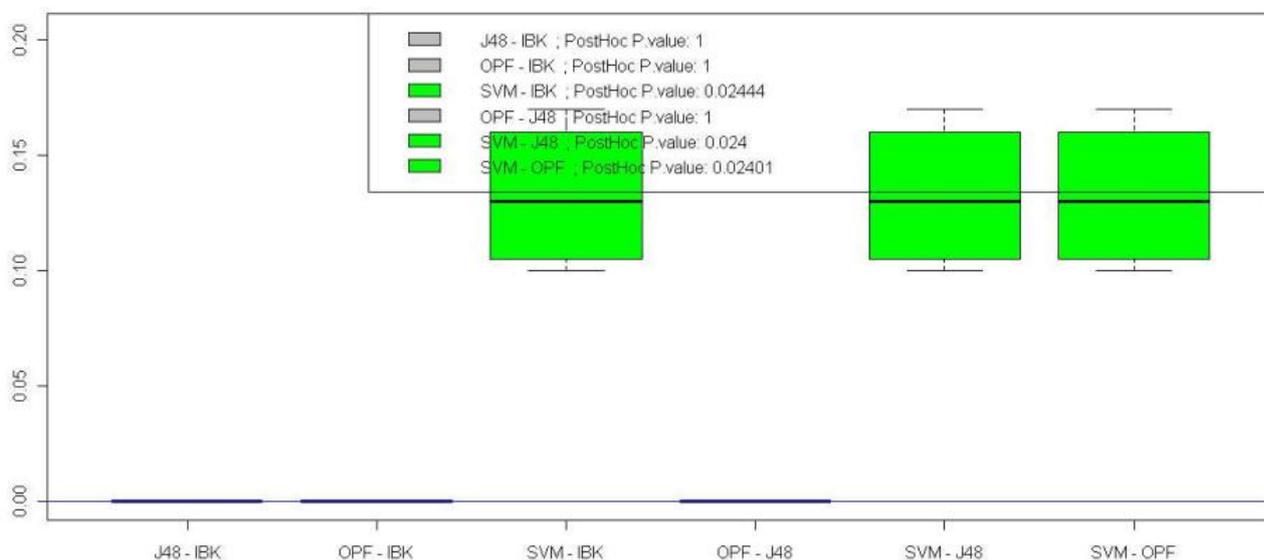


Figura 5.1: Resultado da análise *post hoc*

butos anteriores foram obtidos pelo algoritmo de matriz de coocorrência), inversa (obtido através do algoritmo de mapas de iteração), contraste1 e contraste3 (obtidos através do algoritmo de *wavelets*), PBL (obtido através do algoritmo de padrões binários locais).

Tabela 5.14: Resultado do *f-score* de cada classificador

Dataset	(FCO)	(SVM)	(KNN)	(C4.5)
Conjunto1	0.73	0.62	0.64	0.60
Conjunto2	0.50	0.67	0.63	0.67
Conjunto3	0.86	0.84	0.87	0.86
Conjunto4	0.51	0.60	0.48	0.58

◦, • degradação ou melhoria estatisticamente significativa

Tabela 5.15: Tempo utilizado para realizar o treinamento dos classificadores

Dataset	(FCO)	(SVM)	(KNN)	(C4.5)
Conjunto1	0.002980	0.172150	0.000000	0.001090
Conjunto2	0.002030	0.109370	0.000000	0.002030
Conjunto3	0.013280	0.104380	0.000000	0.003600
Conjunto4	0.000460	0.146240	0.000000	0.001080

o, • degradação ou melhoria estatisticamente significante

Ângulo	Distância
360	1
315	1
270	1
225	1
180	1
135	1
90	1
45	1

Tabela 5.16: Parâmetros utilizados para a técnica de matriz de coocorrência.

Ângulo	Distância
180	4
135	4
90	4
45	4
180	3
135	3
90	3
45	3
180	2
135	2
90	2
45	2
180	1
135	1
90	1
45	1
180	0
135	0
90	0
45	0

Tabela 5.17: Parâmetros utilizados para a técnica de matriz de interação.

Para auxiliar a compreensão dos experimentos realizados neste trabalho, a Tabela 5.19 apresenta uma síntese das principais informações contidas em cada um deles. O símbolo * foi usado para representar que o valor presente na tabela foi obtido através da soma de todos os *datasets* e o símbolo ** representa que o valor contido na tabela está presente em cada um dos *datasets*.

As Figuras 5.3, 5.4, 5.5 e 5.6 ilustram o resultado da classificação de cada uma das classes

Parâmetros	Valores
Número mínimo de vizinhos	6
Incremento do número de vizinhos	2
Número máximo de vizinhos	10
Número mínimo do raio	1
Incremento do número do raio	2
Número máximo do raio	13

Tabela 5.18: Parâmetros utilizados para o PBL e PBLROT

Experimento	Nº de classes	Nº de amostras	Nº atributos extraídos	Nº de atributos selecionados
Experimento 1	3	84	7	5
Experimento 2	5	123	45	9
Experimento 3	21*	289*	45 **	30
Experimento 4	9	267	95	18

Tabela 5.19: Síntese das principais informações de cada um dos experimentos realizados neste trabalho

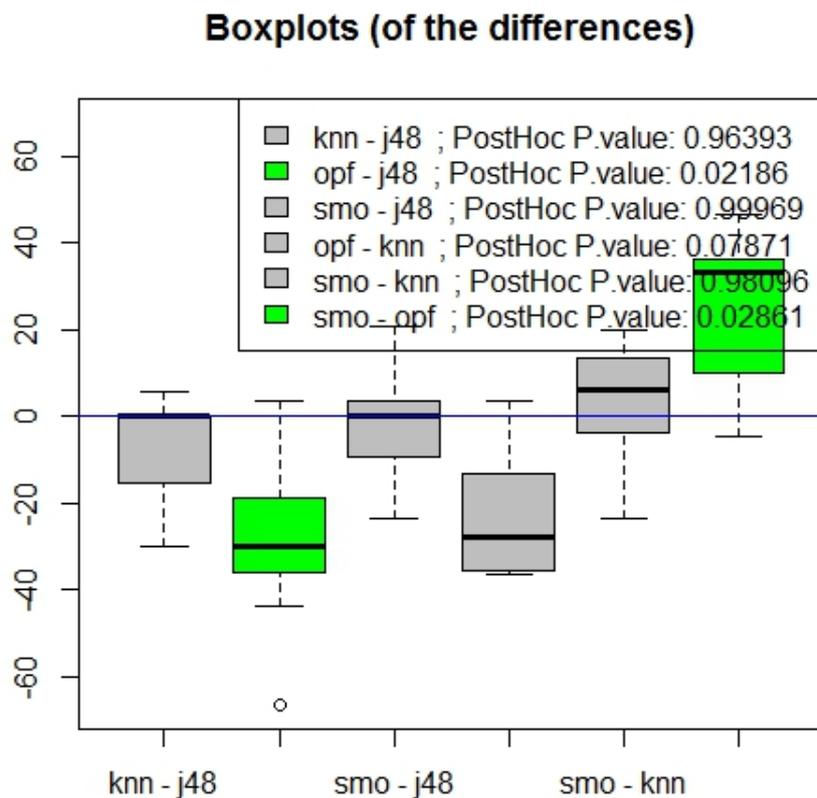


Figura 5.2: Resultado da análise *post hoc* para o quarto experimento

Tabela 5.20: Resultado da taxa de acerto de cada classificador

Dat aset	(C4.5)	(SVM)	(KNN)	(FCO)
Conjunto5	76.30±7.39	77.28±7.43	71.25±6.62	51.45±9.29 •

o, • degradação ou melhoria estatisticamente significante

obtida após a aplicação dos 4 classificadores. A diagonal principal de cada uma das tabelas presente nas figuras apresenta o número de amostras classificadas corretamente e as informações presentes fora da diagonal principal representam as amostras classificadas incorretamente. De acordo com os resultados, é possível observar que o FCO obteve desempenho similar aos demais algoritmos na classificação das espécies fabaceae, poaceae, protium e arecaceae tipo 1. A Tabela 5.21 apresenta a porcentagem de amostras classificadas corretamente por cada um dos classificadores utilizados para a realização do teste de Friedman.

Espécie	FCO	SVM	C4.5	KNN
Serjania	50.0	78.57	85.71	85.71
Fabaceae	76.67	86.67	73.33	73.33
Schinus	33.33	80.00	100.0	70.00
Protium	36.67	70.00	66.67	50.00
Acecaceae Tipo 2	55.58	100.00	79.47	85.29
Arecaceae Tipo 1	38.10	33.33	57.14	57.14
Myrtaceae	31.25	65.63	75.00	59.38
Poaceae	50.00	53.85	53.85	57.69
Cecropia	61.11	97.22	97.22	97.22

Tabela 5.21: Porcentagem de amostras classificadas corretamente utilizando os classificadores presentes neste trabalho

```

a b c d e f g h i <-- classified as
14 0 0 0 2 2 7 3 0 | a = serjania
0 23 6 1 0 0 0 0 0 | b = fabaceae
0 8 10 7 0 1 3 0 1 | c = schinus
1 1 11 11 0 3 3 0 0 | d = protium
3 0 0 0 19 2 7 1 2 | e = arecaceatipo2
2 0 2 3 2 8 2 2 0 | f = arecaceatipo1
4 0 4 1 6 1 10 4 2 | g = myrtaceae
3 1 0 1 2 3 3 13 0 | h = poaceae
1 0 2 0 3 0 8 0 22 | i = cecropia

```

Figura 5.3: Matriz com o resultado da classificação realizada pelo algoritmo FCO

Após a seleção de atributos, os métodos foram comparados e de acordo com o resultado, pode-se afirmar que há diferença entre os algoritmos de classificação, pois o resultado de p foi 0.01166. Sendo assim, é possível afirmar que há diferença entre os classificadores. Por esse motivo a análise *post hoc*, ilustrada na Figura 5.2 foi aplicada e de acordo com o resultado, foi possível observar que o FCO apresentou diferença estatística em relação ao SVM e ao J48, porém em relação ao KNN é possível afirmar que os classificadores não apresentaram diferença estatística. A Tabela 5.20 ilustra o resultado da taxa de acerto de cada um dos classificadores.

Observando o resultado do FCO, é possível constatar que algumas amostras da classe cecropia foram classificadas como sendo da classe myrtaceae, amostras da classe serjania foram classificadas como myrtaceae e amostras da classe protium foram classificadas com pertencentes

```

a b c d e f g h i <-- classified as
24 0 0 1 1 0 1 1 0 | a = serjania
0 22 2 5 0 0 1 0 0 | b = fabaceae
0 2 21 3 0 0 4 0 0 | c = schinus
1 8 4 15 0 0 1 1 0 | d = protium
0 0 0 0 29 2 0 3 0 | e = arecaceae tipo2
0 0 0 0 3 12 0 6 0 | f = arecaceae tipo1
1 0 1 3 6 0 19 1 1 | g = myrtaceae
1 0 0 1 4 4 1 15 0 | h = poaceae
0 0 0 0 0 0 1 0 35 | i = cecropia

```

Figura 5.4: Matriz com o resultado da classificação realizada pelo algoritmo KNN

```

a b c d e f g h i <-- classified as
25 0 0 1 0 0 0 2 0 | a = serjania
0 20 3 7 0 0 0 0 0 | b = fabaceae
0 0 28 0 0 0 1 0 1 | c = schinus
1 6 7 16 0 0 0 0 0 | d = protium
0 0 0 0 34 0 0 0 0 | e = arecaceae tipo2
0 0 0 0 8 10 0 3 0 | f = arecaceae tipo1
0 0 1 3 3 0 25 0 0 | g = myrtaceae
2 0 0 0 7 4 1 12 0 | h = poaceae
0 0 0 0 0 0 0 0 36 | i = cecropia

```

Figura 5.5: Matriz com o resultado da classificação realizada pelo algoritmo SVM

```

a b c d e f g h i <-- classified as
24 1 0 1 0 0 0 2 0 | a = serjania
3 22 0 4 0 0 0 1 0 | b = fabaceae
0 0 30 0 0 0 0 0 0 | c = schinus
4 3 0 20 0 0 3 0 0 | d = protium
0 0 0 0 26 1 3 4 0 | e = arecaceae tipo2
0 0 0 0 4 12 0 5 0 | f = arecaceae tipo1
1 0 0 3 1 0 24 3 0 | g = myrtaceae
1 3 0 0 2 3 2 14 1 | h = poaceae
0 0 0 0 0 0 1 0 35 | i = cecropia

```

Figura 5.6: Matriz com o resultado da classificação realizada pelo algoritmo C4.5

à classe schinus. A Figura 5.7 (a) e (b) ilustra um exemplo da classe cecropia e myrtaceae, respectivamente. Uma hipótese para o erro na classificação está relacionada à semelhança existente entre as amostras. No momento da classificação, a nova amostra é classificada de acordo com a menor relação de adjacência com um determinado nó presente nas árvores de caminhos ótimos. É provável que pela semelhança, a nova amostra obteve relação de adjacência muito pequena o que possivelmente gerou a classificação incorreta.

A mesma situação pode ter ocorrido na classificação das classes protium e schinus. As classes apresentam uma semelhança que pode ser visualizada através das imagens 5.8 (a) e (b). Essas imagens ilustram exemplos de algumas visões das classes supracitadas que são bastante similares. É provável que, por esse motivo, as classes tenham sido classificadas incorretamente pelo FCO por apresentarem nós fortemente conexos. Amostras das classes serjania e myrtaceae também apresentem semelhanças quando visualizadas em determinadas visões. As Figuras 5.9 (a) e (b)

ilustram os exemplos de imagens das classes serjania e myrtaceae, respectivamente.

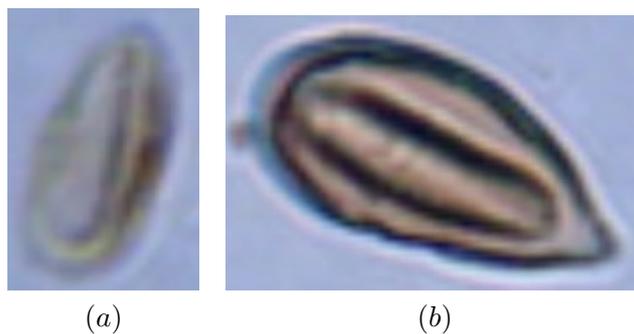


Figura 5.7: (a) Imagem da espécie cecropia e (b) Imagem da espécie myrtacea

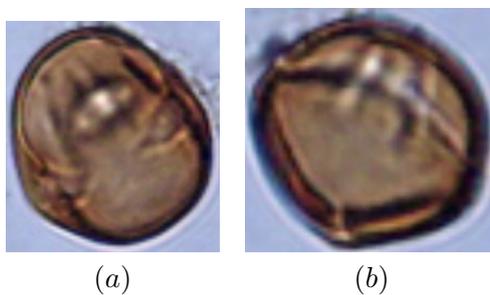


Figura 5.8: (a) Imagem da espécie protium e (b) Imagem da espécie schinus

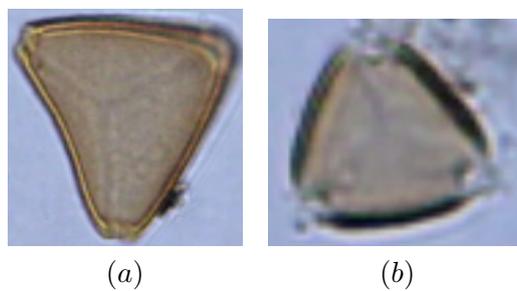


Figura 5.9: (a) Imagem da espécie serjania e (b) Imagem da espécie myrtacea

Capítulo 6

Conclusões e Trabalhos Futuros

A classificação de grãos de pólen é uma tarefa minuciosa e cansativa. Essa contagem é feita de forma visual e este trabalho além de ser exaustivo está muito sujeito à subjetividade humana. Diante desse problema, surgiu o projeto Pólen, que tem como intuito desenvolver um sistema baseado em visão computacional que realize a contagem microscópica automaticamente. Com o desenvolvimento desse projeto, estima-se que a classificação de grãos de pólen aconteça de forma mais rápida, considerando que o especialista possui um cansaço natural.

Quatro experimentos foram realizados e quando eles foram comparados, percebeu-se que houve uma melhora nos resultados das métricas (taxa de acerto, *recall*, *precision* e *f-score*) com a inserção de atributos de textura. Para classificar os grãos de pólen, técnicas de extração de atributos foram aplicadas e o resultado foi classificado utilizando os classificadores FCO, SVM, KNN e C4.5. O resultado foi analisado através do teste de Friedman. Todos os experimentos deste trabalho utilizaram 5% de significância. No terceiro experimento, o resultado obtido foi de 5.7%, por isso a hipótese nula pode ser aceita. Desse modo, pode-se afirmar que, de acordo com o teste de Friedman, os classificadores não apresentam diferença estatística na classificação dos grãos.

No experimento 4, o resultado de p para a taxa de acerto foi de 0.01166. De acordo com o resultado a hipótese nula é aceita e o teste pos-hoc foi aplicado para verificar qual classificador apresentou melhor resultado. Com o resultado do teste é possível analisar que o algoritmo KNN obteve desempenho estatisticamente igual ao FCO e que o FCO obteve resultado estatisticamente diferente que o SVM e J48.

Como trabalhos futuros estima-se realizar a captura de imagens de novas classes e desenvolver testes com diferentes métodos de seleção e extração de atributos.

Este projeto contribuiu para a padronização do microscópio utilizado para a captura de imagens, filtro utilizados nos microscópios e técnica de preparo de amostra. Foi possível classificar 9 classes distintas com taxa de acerto superior à 76% e obter os atributos mais relevantes para o problema em questão. Durante o projeto um sistema para o cadastro de grãos de pólen iniciado e está em desenvolvimento. Foi realizada filmagens em um apiário do CeTeAgro para observar a preferência alimentar das abelhas.

Após as referências bibliográficas contidas neste trabalho foi anexado um artigo produzido sobre alguns experimentos presentes neste projeto.

Referências Bibliográficas

- [1] W. P. Amorim. Redução de atributos utilizando análise discriminante com aplicações na detecção de defeitos em couro bovino. Master's thesis, Universidade Federal de Mato Grosso do Sul, 2009.
- [2] S. T. S. M. e. V. G.-E. Ana Luiza Du Bocage, Mariana Albuquerque de Souza. Palinotaxonomia de espécies de acácia (leguminosae-mimosoideae) no semi-Árido brasileiro. In *Revista do Jardim Botânico do Rio de Janeiro*, 2009.
- [3] O. M. Barth. *O Pólen no mel Brasileiro*. 1989.
- [4] D. G. S. Coiado. Caracterização do setor apícola do mato grosso do sul como atividade sustentável e fator de desenvolvimento local. Master's thesis, Universidade Católica Dom Bosco, 2010.
- [5] S. J. R. da Silva e Ana Lúcia Absy. Análise do pólen encontrado em amostras de mel de *Apis mellifera* L. (hymenoptera, apidae) em uma área de savana de roraima, brasil. In *Acta Amazonica*, volume 30, 2000.
- [6] J. Davis and M. Goadrich. The relationship between precision-recall and roc curves. In *Proceedings of the 23rd international conference on Machine learning*, ICML '06, pages 233–240, New York, NY, USA, 2006. ACM.
- [7] A. N. de Vigilância Sanitária. Gerência-geral alimentos resolução - cnpa nº 12, de 1978. d.o. de 24/07/1978. Acessado no dia: 22/02/2010.
- [8] T. S. M. e Hiroko Makino. Grãos de pólen de plantas alergógenas. In *Portal de Periódicos Eletrônicos em Geociências*, 2011.
- [9] R. C. B. R. e Roberto Henrique da Rocha Viana. Máquinas de vetores de suporte aplicadas à classificação de defeitos em couro bovino. Qualificação de Bacharel em Engenharia de Computação na Universidade Católica Dom Bosco Campo Grande - MS Brasil, novembro 2007.
- [10] C. M. C. e Suann Yang. Counting pollen grains using readily available, free image processing and analysis software. Technical report, Department of Biology, 208 Mueller Laboratory, The Pennsylvania State University, University Park, PA 16802, USA, 2009.
- [11] P. A. e Vechiatto de Miranda. Segmentação de imagens pela transformada imagem-floresta. Master's thesis, Universidade Estadual de Campinas, 2006.
- [12] S. García and F. Herrera. An extension on statistical comparisons of classifiers over multiple data sets for all pairwise comparisons. In *Journal of Machine Learning Research*, pages 2677 – 2694, 2008.

- [13] R. C. Gonzalez and R. E. Woods. *Processamento de Imagens Digitais*. Primeira edition, 2000.
- [14] G. Huang and Ângela Tavares Paes. Posso usar o teste t de student quando preciso comparar três ou mais grupos? In *einstein - Educação Continuada em Saúde*, volume 7, abril/junho 2009. <http://apps.einstein.br/revista/arquivos/PDF/1390-EC%20v7n2p63-4.pdf>.
- [15] A. M. e. G. V. J. Louveaux. Methods of melissopalynology. In *Bee World*, volume 51, pages 125–131, 1970.
- [16] J. S. e. M. C. Jerri Teixeira Zanusso, Daniel Rutz. Utilização de imagens de satélite para localização de um apiário fixo. *Mensagem Doce*, (98), Setembro 2008.
- [17] L. V. D. Joelma Carla Santos, João Ricardo de F. Oliveira. Uso de algoritmos genéticos na seleção de atributos para classificação de regiões. *Joelma Carla Santos, João Ricardo de F. Oliveira, Luciano V. Dutra*, pages 253–261, novembro 2005.
- [18] V. M. J. JONES, G. D. BRYANT. The use of etoh for the dilution of honey. Technical report, Grana, 2004.
- [19] L. C. S. K. S. VENTURINI, M. F. SARCINELLI. Características do mel. Pró-Reitoria de Extensão - Programa Institucional de Extensão. Boletim Técnico - PIE-UFES: 01107 - Editado: 18.08.2007.
- [20] J. D. C. G. K. F. M. D. R. LUDMILA C. OLIVEIRA, THAÍS F. NANI and G. A. TORRES. Caracterização palinológica de euterpe oleracea mart. e euterpe precatória mart. In *XIX CONGRESSO DE PÓS-GRADUAÇÃO DA UFLA*, 2010.
- [21] A. F. e. M. P. D. S.-O. M. Damiàn, E. Cernadas. Pollen classification on the three types of plants of the family *Urticaceae*. In *12th Portuguese Conference on Pattern Recognition*.
- [22] T. Maenpaa. The local binary pattern approach to texture analysis. Master's thesis, University Oulu, 2003.
- [23] P. e. A. Ministério da Agricultura. Instrução normativa núm. 11, de 20 de outubro de 2000 e regulamento técnico de identidade e qualidade do mel. Diário Oficial da União de 23/10/2000, Seção 1, Página 23, Fevereiro 2010.
- [24] M. S. Nixon and A. S. Aguado. *Feature Extraction & Image Processing*. Primeira edition, 2002.
- [25] J. P. Papa. *Classificação Supervisionada de Padrões Utilizando Florestas de Caminhos Ótimos*. PhD thesis, UNICAMP, novembro 2008.
- [26] G. Peccini and M. C. Ornellas. Segmentação de imagens por watersheds: Uma implementação utilizando a linguagem java. [*REIC*] - *Revista Eletrônica de Iniciação Científica ANO V*, (IV), 2005.
- [27] L. A. Peternelli and M. P. Mello. *Conhecendo o R: uma visão estatística*. Série Didática. Editora UFV, 1 edition, March 2011.
- [28] P. F. Quieroz. Glossário de termos usados em morfologia polínica. Terra Scenica - Centro para a criatividade partilhada das ciências, artes e tecnologia, 2012.
- [29] P. H. Raven. *Biologia Vegetal*. 6ª edition, 2001.

- [30] W. R. S. e. H. P. Ricardo Dutra da Silva. Avaliação da invariância à rotação de descritores texturais extraídos por transformadas wavelets. In *XIV Simpósio Brasileiro de Sensoriamento Remoto*, pages 7159 – 7166, 04 2009.
- [31] R. C. B. Rodrigues and R. H. R. Viana. Máquinas de vetores de suporte aplicadas à classificação de defeitos em couro bovino. Qualificação de Bacharel em Engenharia de Computação na Universidade Católica Dom Bosco Campo Grande - MS - Brasil, 2007.
- [32] C. L. Sanches. Novel image processing of 3d textures. Master's thesis, Heriot Watt University, september 2003.
- [33] T. Scenica. Pólen, mel e território. Consultado em 21 de fevereiro de 2010, 2010.
- [34] J. A. Silva and W. N. Gonçalves. Modelos ocultos de markov aplicados na identificação de comportamento de animais. Qualificação de Bacharel em Engenharia de Computação na Universidade Católica Dom Bosco Campo Grande - MS - Brasil, 2007.
- [35] K. P. Souza and H. Pistori. Aplicação de modelos de markov ocultos na obtenção de taxas de mortalidade das larvas do mosquito da dengue. Dissertação de Mestrado apresentada na Faculdade de Computação do Centro de Ciências Exatas e Tecnologia da Universidade Federal de Mato Grosso do Sul, 2010.
- [36] P. N. Stuart Russell. *Inteligência Artificial*. Elsevier, ii edition, 2004.
- [37] T. Vargas. Avaliação da qualidade do mel produzido na região dos campos gerais do paraná. Master's thesis, Universidade Estadual de Ponta Grossa, 2006. Mestrado em ciência e tecnologia de alimentos.