

UNIVERSIDADE CATÓLICA DOM BOSCO
PROGRAMA DE PÓS-GRADUAÇÃO EM BIOTECNOLOGIA

Validação de Métodos Baseados em Visão Computacional para Automação da
Identificação de Grãos de Pólen

Autora: Ariadne Barbosa Gonçalves – Bolsista CAPES
Orientador: Prof^o. Dr^o. Hemerson Pistori
Coorientadora: Prof^a. Dr^a. Marney Pascoli Cereda

Campo Grande
Mato Grosso do Sul
Fevereiro – 2015

UNIVERSIDADE CATÓLICA DOM BOSCO
PROGRAMA DE PÓS-GRADUAÇÃO EM BIOTECNOLOGIA

Validação de Métodos Baseados em Visão Computacional para Automação da
Identificação de Grãos de Pólen

Autora: Ariadne Barbosa Gonçalves – Bolsista CAPES
Orientador: Prof^o. Dr^o. Hemerson Pistori
Coorientadora: Prof^a. Dr^a. Marney Pascoli Cereda

Dissertação apresentada para fins de
obtenção do título de MESTRE EM
BIOTECNOLOGIA, no Programa de Pós-
Graduação em Biotecnologia da
Universidade Católica Dom Bosco - Área
de Concentração: Biotecnologia Aplicada
à Agropecuária.

Campo Grande
Mato Grosso do Sul
Fevereiro – 2015

Ficha Catalográfica

Gonçalves, Ariadne Barbosa

G635v Validação de métodos baseados em visão computacional para automação da identificação de grãos de pólen / Ariadne Barbosa Gonçalves; orientação Hemerson Pistori. 2015
75 f.

Dissertação (mestrado em biotecnologia) – Universidade Católica Dom Bosco, Campo Grande, 2015.

1. Biotecnologia 2. Melissopalínologia 3. Palinologia 4. Mel
5. Programa de computador I. Pistori, Hemerson II. Título

CDD – 641.38

**Validação de Técnicas Baseadas em Visão Computacional para
Automação da Identificação de Grãos de Pólen**

Autora: Ariadne Barbosa Gonçalves
Orientador: Prof. Dr. Hemerson Pistori
Coorientadora: Profa. Dra. Marney Pascoli Cereda

TITULAÇÃO: Mestre em Biotecnologia
Área de concentração: Biotecnologia Aplicada à Agropecuária.

APROVADA em 13 de fevereiro de 2015.



Prof. Dr. Hemerson Pistori - UCDB
(orientador)



Prof. Dr. Arnildo Pott - UFMS



Prof. Dr. Marco Hiroshi Naka - UCDB

EPÍGRAFE

Na vida nada é certo, amigos, amores, vínculos, profissões, bens, dinheiro, a única certeza é a de que um dia não faremos mais parte desse mundo. Sendo assim, não podemos perder tempo com pequenos tropeços e algumas decepções, devemos levar a certeza de que o dia seguinte será melhor e que coisas boas vão acontecer. Por isso, devemos conhecer lugares, pessoas, fazer novas amizades, dançar e cantar a música preferida como se ninguém estivesse olhando. Não se apegar a bens materiais e valorizar cada momento como se fosse único, e ele é, pois no final das contas o que se leva da vida é a vida que se leva. Mas podemos deixar muitas coisas as pessoas que cruzam nosso caminho, um abraço, beijo, carinho, sorrisos, paz, felicidade e tantas outras recordações que nos tornam imortais, assim, deixo nesta obra um pouco de mim, não para ser lembrada, mas para não ser esquecida.

(Ariadne Barbosa Gonçalves)

AGRADECIMENTOS

Primeiramente agradeço a Deus, pela saúde, capacidade de aprender, coragem, sabedoria, paciência e por ter me ajudado a transpor todos obstáculos, me proporcionando a graça de mais uma conquista.

À minha família, meus pais Antonio e Elzan e à minha irmã Angela, por serem meus alicerces, torcer e acompanhar todas as etapas de minha formação.

Ao meu orientador, Professor Doutor Hemerson Pistori, sou imensamente grata pela oportunidade de sua orientação, confiança e ideias discutidas todas as vezes que precisei.

À minha coorientadora, Professora Doutora Marney Pascoli Cereda, o meu reconhecimento pelo apoio, palavras trocadas e amizade.

Ao casal Arnildo e Vali Pott, pela identificação das plantas além de toda disponibilidade, paciência e aprendizagem proporcionada, sem dúvida, são pessoas excepcionais.

Aos meus colegas Junior Silva de Souza, Pedro Lucas França de Albuquerque, Carolini Nascimento Martins Rodrigues, Diogo Soares da Silva, Bruno Aristimunha Pinto, Hugo Jeller Ferreira, Jéssica Beatriz Pereira, Karen Cristine Bezerra da Silva Santos e Moysés Simão Kaveski pela dedicação, auxílio e presteza sempre que precisei, pois sem eles não estaria neste momento.

Aos amigos, companheiros de mestrado e todos aqueles que, direta ou indiretamente, contribuíram para a conclusão deste trabalho deixo meus sinceros agradecimentos.

BIOGRAFIA DO AUTOR

ARIADNE BARBOSA GONÇALVES, nasceu e reside na cidade de Campo Grande, Mato Grosso do Sul, Brasil.

Em 2009, iniciou o curso de Ciências Biológicas (Bacharelado) na Universidade Católica Dom Bosco. Desde o início do curso foi aluna de iniciação científica, bolsista CNPq e recebeu prêmio de destaque de iniciação científica. Formou-se no ano de 2012. Possui registro de Bióloga conferido pelo Conselho Regional de Biologia.

No mês de fevereiro de 2013 ingressou no Programa de Pós-Graduação em Biotecnologia à nível de Mestrado, Biotecnologia aplicada à Agropecuária, na Universidade Católica Dom Bosco, realizando estudo na área de Visão Computacional aplicada à Palinologia, sob orientação do Profº Drº Hemerson Pistori.

No dia 13 de fevereiro de 2015, submeteu-se à banca para defesa da Dissertação.

SUMÁRIO

	Página
LISTA DE FIGURAS	vii
LISTA DE TABELAS	ix
RESUMO	x
ABSTRACT	xii
1- INTRODUÇÃO	1
2- REVISÃO DE LITERATURA	4
2.1 Apicultura	4
2.2 Pólen	5
2.3 Técnicas de Extração de Atributo	8
2.3.1 Cor, Forma e Textura (CFT)	8
2.3.2 Histograma de Palavras Visuais	12
2.4 Classificadores	14
2.4.1 KNN	14
2.4.2 J. 48	14
2.4.3 Máquina de Vetor de Suporte	15
2.5 Métricas de Classificação	16
2.5.1 Porcentagem de Classificação Correta – PCC	16
2.5.2 Medida-F	16
2.5.2 Curva Área sob a curva ROC	17
2.6 Técnica de Amostragem	17
2.6.1 Validação Cruzada	17
2.6.2 Matriz de Confusão	18
2.7 Testes de Hipótese	18
2.7.1 Friedman	18
2.7.2 ANOVA	19
2.7.3 T-Student	19
3. REFERÊNCIAS	20
4. OBJETIVOS	27
4.1 Objetivo Geral	27
4.2 Objetivos Específicos	27

5. ARTIGO: Comparação de Técnicas de Extração de Atributos e Aprendizagem Automática para Classificação de Tipos Polínicos	28
Resumo	29
1. Introdução	30
2. Trabalhos Correlatos	31
3. Materiais e Métodos	33
3.1 Técnicas de Extração de Atributos	36
3.2 Classificação por Visão Humana	39
4. Resultados	41
5. Discussão	48
6. Conclusão	51
7. Referências	52
CONSIDERAÇÕES FINAIS	55
NORMAS DA REVISTA	57

LISTA DE FIGURAS

	Página
Figura 1: Grãos de pólen em uma lâmina melissopalínológica	1
Figura 2: Estrutura floral de flor bixessuada	6
Figura 3: Detalhes das estruturas do grão de pólen. a) Ilustração; b) Imagem microscópica	6
Figura 4: Variação da matiz na imagem do tipo <i>Hyptis</i>	9
Figura 5: Variação de saturação na imagem do tipo <i>Croton</i>	9
Figura 6: Variação da intensidade luminosa na imagem do tipo <i>Faramea</i>	9
Figura 7: Diferença do formato entre grãos de pólen	10
Figura 8: Diferença de textura entre polens pertencentes à família Anacardiaceae.	11
Figura 9: Detecção de pontos de interesse em uma imagem de pólen do tipo <i>Faramea</i>	13
Figura 10: Atributos extraídos pelo BOW	13
Figura 11: Histograma de palavras visuais	14
Figura 12: Imagem dos 23 tipos polínicos utilizados no experimento, representando a flora do Cerrado	33
Figura 13: Lâmina polínológica dividida em setores para captura das imagens	34
Figura 14. Microscópio digital onde as imagens de pólen foram capturadas e armazenadas	35
Figura 15. Processo de segmentação das imagens de pólen	35
Figura 16. Teste com diferentes valores de k para o classificador KNN	37
Figura 17. Representação da grandeza da porcentagem de classificação correta por cores	38
Figura 18. Disposição das questões no questionários	39
Figura 19: Exemplo de imagens do polen da espécie <i>Senegalia plumosa</i> , nome comum arranha-gato, e da maneira que estava no material de apoio ...	40
Figura 20: Apicultores voluntários sendo instruídos sobre como fazer a classificação dos tipos polínicos	41
Figura 21. Diagrama de caixas com o desempenho estatístico das técnicas ($p= 0.576$)	42
Figura 22: Diagrama de caixas do desempenho de classificação dos tipos polínicos ($p= 0.000000125$)	42

Figura 23: Matriz de confusão de PCC dos tipos polínicos classificados por visão humana	45
Figura 24. Matriz de confusão com a técnica CFT	46
Figura 25: Matriz de confusão do desempenho da técnica BOW	47
Figura 26: Matriz de confusão para o conjunto de dados CFT+BOW	47
Figura 27: Polens que tiveram maior e menor PCC pelos humanos	49
Figura 28: Imagem de <i>Mimosa somnians</i>	50
Figura 29: Agrupamento de imagens do tipo <i>Dipteryx alata</i>	56

LISTA DE TABELAS

	Páginas
Tabela 1: Desempenho das técnicas sob análise da métrica PCC	43
Tabela 2: Desempenho das técnicas sob análise da métrica Medida-F	44
Tabela 3: Desempenho das técnicas sob análise da métrica área sob a curva...	44

RESUMO

As análises quantitativas e qualitativas dos polens presentes nos produtos apícolas são realizadas por especialistas da área, através das técnicas de palinologia e melissopalinologia. No entanto, a identificação realizada pelo ser humano é passível de erros devido ao desgaste na tentativa de classificar os polens, além de ser uma atividade morosa que requer muita experiência. Assim, dispor de um programa de computador capaz de realizar a automação da identificação de grãos de pólen torna o processo de identificação polínica mais rápido e preciso. Para comparar o índice de acerto da classificação pela visão humana com a que utiliza técnicas computacionais, 34 apiculcutores voluntários classificaram 46 imagens de pólen com tempo cronometrado. Os tipos polínicos utilizados foram previamente identificados por especialista. As técnicas computacionais testadas utilizaram os atributos de gradiente (histograma de palavras visuais), cor (RGB e HSV), forma (fator de forma) e textura (Matriz de coocorrência) visando automatizar o reconhecimento de imagens microscópicas de 23 tipos polínicos. Os resultados da extração de atributos foram analisados pelos classificadores KNN, J.48 SMO e C-SVC. Os desempenhos obtidos pelos classificadores foram medidos pelas métricas de porcentagem de classificação correta, medida-F e área sob a curva ROC (*Receiver Operating Characteristic*). O teste com visão humana classificou corretamente 63.7% das imagens, das quais o pólen de *Chromolaena odorata* foi o melhor reconhecido. Não foi detectada diferença significativa entre os índices de acerto das técnicas de identificação automática $p= 0.1902$. Foi possível realizar o reconhecimento automático das imagens dos 23 tipos polínicos analisados com índice de acerto de 64%, desempenho muito próximo ao obtido pelos humanos (63.7%). O pólen com maior índice de acerto com o que utilizou o emprego de todas as técnicas computacionais foi *Mimosa somnians*. Em relação ao tempo, a identificação das 46 imagens por visão humana levou quase duas horas para ser concluída,

enquanto que as técnicas automáticas testadas levaram menos de 10 minutos para classificação de todo o banco com 805 imagens. Assim, comprova-se a eficiência do tempo e da porcentagem correta de classificação realizada de maneira automática em relação à humana.

Palavras-chave: Melissopalinologia, Palinologia, Programa de computador.

ABSTRACT

Quantitative and qualitative analyses of pollen present in bee products is made by experts through the techniques of palynology and melissopalynology. However, the identification performed by humans may have errors due to tiredness attempting to classify certain pollen grains. Besides it is a consuming task that takes time and requires a lot of experience. Thus, a computer program that is able to perform the automation of the identification of pollen grains is very important, because it would make the process of pollen identifying faster and more accurate. We made a test with 34 volunteers beekeepers who rated 46 pollen images with recorded time, to have a classification rate parameter done by the human vision. Previously an expert did the pollen identification through plant morphology. Therefore, this research used extraction algorithms of gradient attributes (bag of word), color (RGB and HSV), shape (form factor) and texture (local binary patterns and binary patterns invariant to rotation) to automate the recognition of microscopic images of 23 pollen types. The results of the feature extraction were analyzed by classifiers such as KNN, J. 48, SMO and C-SVC. The performance obtained by classifiers was measured by the metrics percentage of correct classification, F-measure and area under the ROC (*Receiver Operating Characteristic*) curve. The human vision test had an accuracy of 63.7% at image classification. *Chromolaena odorata* pollen was the best classified by humans. The *p* value obtained by the automatic identification techniques was 0.1902, proving that the tested techniques are similar. We achieved the automatic classification of the 23 pollens types analysed with accuracy rate of 64%, close to the rate achieved with human vision (63.7%). The best pollen classified with automatic techniques was *Mimosa somnians*. The identification of 46 images by human vision took almost two hours, while the tested automatic techniques took less than 10 minutes to classify all pollen database with 805 images. This research proved the efficiencies of time and

performance of automatic techniques in pollen identification, these techniques achieved at least the efficiency in human identification.

Keywords: Melissopalynology, Palynology, Computer Program.

1 – INTRODUÇÃO

O estudo dos polens (Figura 1) é denominado de Palinologia e tem sido utilizado na identificação de grãos de pólen em restos orgânicos, fósseis, coprólitos, dentre outros. A Paleobotânica ajuda na reconstrução de ambientes passados, como forma de estabelecer a história das evoluções ocorridas no planeta. Através da palinologia, também é possível saber os tipos polínicos responsáveis por ocasionar reação alérgica ocasionada pela febre de feno.

A Palinologia Forense se utiliza de grãos de pólen presentes em cenas de crime, cadáveres, vítimas, suspeitos, dentre outros. Através do pólen presente no objeto analisado é possível saber se este pertence ou não ao caso estudado, e se foi deixado no local. Assim, o pólen contribui para a investigação criminal. Já a Melissopalynologia trata do estudo dos grãos de pólen presentes em produtos apícolas. O pólen tem grande importância na determinação da origem botânica de produtos apícolas pois, para a fabricação, as abelhas precisam visitar várias flores em busca recursos florais.

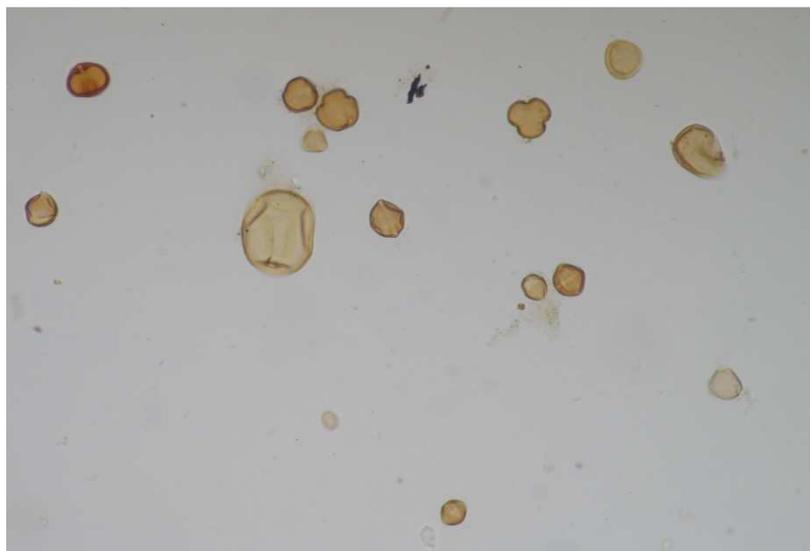


Figura 1: Grãos de pólen em uma lâmina melissopalínológica.

A identificação microscópica de pólen com visão humana apresenta limitações devido às aberturas, formas e características ornamentais da exina dos grãos de pólen serem muito parecidas, dificultando a identificação. A classificação é realizada por especialistas, mas é uma tarefa morosa, cansativa e de treinamento contínuo. Em alguns gêneros, a identificação até espécie é dificultada, devido à grande semelhança entre os polens, que por esta razão, são agrupados em tipos polínicos (SILVA e ABSY, 2000). A questão da determinação da espécie pela análise do pólen torna-se ainda mais complexa em algumas espécies por ocorrer variabilidade polínica intraespecífica, com a exina apresentando variações entre os tipos polínicos de um mesmo gênero (SANTOS e PIN-FERREIRA, 2001).

Por esta razão, o desenvolvimento de um programa de computador para automação da identificação de grãos de pólen pode reduzir o tempo, além de garantir maior precisão da classificação. A automação no processo de identificação de grãos de pólen torna a análise mais rápida e menos trabalhosa, pois permite identificar com exatidão uma maior quantidade de pólen (LANGFORD et al., 1990). Um sistema computacional que otimize e solucione o problema da identificação de pólen pode ser utilizado em diversas áreas de conhecimento da Palinologia que demandam esta técnica.

A automatização pode ser realizada por visão computacional, que busca automatizar a tomada de decisões úteis sobre objetos físicos e cenas reais com base em imagens detectadas (SHAPIRO e STOCKAN, 2001). O campo da visão computacional é dedicado à extração de atributo de uma imagem, que significa a retirada de informações importantes e diferenciais em uma imagem, suficientes para o seu reconhecimento. A extração de atributos é realizada por algoritmos, que também podem melhorar a imagem captada. Um exemplo de seu uso é a eliminação do chamado ruído, constituído de sombras, pontos, manchas, dentre outros elementos e informações desnecessárias na imagem. Entre outros métodos de reconhecimento de padrões para automatizar o processo do reconhecimento de imagens, pode-se utilizar algoritmos de extração de atributos como o Histograma de Palavras Visuais (*Bag of Word* - BOW) (CSURKA et al., 2004), composto de um histograma com os números dos descritores de padrões e técnicas que extraem informações de cor, forma e textura das imagens (CHICA, 2012).

As técnicas aplicadas em uma imagem precisam ter o desempenho mensurado para estabelecer a eficiência da técnica. Para tanto, existem vários tipos de classificadores que fazem a classificação das informações fornecidas, dentre os quais, KNN, J.48 e SMO. Existem, também, medidas de análise das variáveis obtidas em um experimento, dentre as quais, a porcentagem de classificação correta, que apresenta os dados que foram classificados como certos, e a macro-média da medida-F, uma média harmônica que é calculada com base nos resultados de verdadeiro positivos, verdadeiro negativos, falso positivos e falso negativos encontrados para cada classe de um conjunto de dados. A macro-média da medida-F é utilizada para estabelecer o desempenho geral do conjunto de dados (RIJSBERGEN, 1979). Por fim, a medida de curva ROC (*Receiver Operating Characteristic*) viabiliza a visualização, organização e seleção de técnica, com base nos valores de verdadeiros positivos e falso negativos encontrados no conjunto de dados.

Conhecer apenas quais foram os resultados das métricas aplicadas nos dados não é suficiente para saber o desempenho das técnicas. Para tanto, é necessária a aplicação de testes estatísticos, que permitem a interpretação dos resultados obtidos em um conjunto de dados, que podem ou não seguir uma distribuição gaussiana. Em modelos paramétricos, nos quais a distribuição das informações dos dados segue uma distribuição gaussiana, é possível a aplicação dos teste de ANOVA e T-Student, enquanto que em modelos não paramétricos a distribuição dos dados não segue necessariamente uma curva gaussiana, e neste caso, o teste de Friedman pode ser adequado.

Desta maneira, o objetivo desta pesquisa é construir um programa de computador para automatizar a identificação de imagens microscópicas de grãos de pólen. Os atributos de cor, forma, textura e gradiente são padrões de reconhecimentos que, em conjunto com aprendizagem de máquina, possibilitam a identificação automática de polens mais eficiente e rápida do que a visão humana.

2- REVISÃO DE LITERATURA

2.1. Apicultura

Apicultura é atividade de criação de abelhas do gênero *Apis* e se diferencia da meliponicultura, que é a criação de abelhas sem ferrão, geralmente nativas. Ambas as atividades criam as abelhas em colmeias artificiais visando à produção de mel. Além de boa opção para o agronegócio por meio de seu produto principal, o mel, a criação de abelhas é uma atividade ambientalmente sustentável, que contribui para a manutenção das espécies nativas e aumento da produção agrícola (LOPES et al., 2001). Apesar dos ecossistemas Cerrado e Pantanal ainda contarem com vegetação nativa abundante, a ação da meliponicultura e apicultura ligada à flora apícola ainda é pouco explorada.

Muitas das plantas do Cerrado possuem princípios ativos de alto valor econômico e estratégico. Dentre os vários elementos a serem levados em conta quando se pretende instalar um apiário, os recursos florais são considerados os mais importantes para o sucesso do negócio (CABRERA et al., 2013), levando-se em conta não só as espécies apícolas, como também a densidade populacional e os períodos de floração que influenciam na produtividade.

O mel é o principal produto produzido pelas abelhas *Apis mellifera*, sendo o pólen apícola o segundo, considerados ambos benéficos para saúde. Para a produção do mel e de outros produtos como a própolis e geleia real, as abelhas precisam visitar várias flores em busca de néctar, óleos e polens (ABNT, 2012), estes últimos presentes nas flores masculinas e bissexuadas. Desta forma, em todos os produtos produzidos pelas abelhas haverá grãos de pólen que aderem a seu corpo ou que colheram para formação dos poços de pólen dentro da colmeia (PICOLLI, 2011). Por meio desses, é possível rastrear a origem botânica dos produtos apícolas através da identificação dos tipos polínicos encontrados nos produtos ou dentro da colmeia.

A produção brasileira de mel é cerca de 30 a 35 Kg por colmeia/ano, no entanto, em algumas regiões esta produção pode chegar entre 60 a 70 Kg por colmeia/ano, produtividade próxima a grandes produtores como China, Turquia e Argentina, que alcançam mais de 100 Kg por colmeia/ano (SILVA, 2010). O Mato Grosso do Sul é um pequeno produtor de mel, com apenas 1,3% da produção nacional. No entanto, o estado é o maior produtor do Centro-Oeste, com 41% da produção regional (BUAINAIN; BATALHA, 2007) e conta com grande potencial de produção, com áreas de Cerrado, Mata Atlântica e Pantanal ainda com floresta nativa, além das culturas comerciais que também complementam o pasto apícola.

Pela presença polínica nas amostras de méis, caracterização e mapeamento das áreas de exploração apícola é possível abordar e modelar a paisagem e territórios apícolas regionais utilizando as técnicas dos Sistemas de Informação Geográfica (VASCONCELOS et al., 2011), da Computação Gráfica e rastrear o mel através de grãos de pólen. A análise das amostras de pólen nos méis e nos demais produtos apícolas é uma ferramenta preciosa para avaliar as plantas apícolas nativas e permitir o acompanhamento de sua existência ao longo do tempo, valorizando os produtos apícolas que possuem um certificado de rastreabilidade botânica.

2.2 Pólen

As flores estão presentes em angiospermas. Uma flor bissexuada possui os órgãos femininos e masculinos na mesma flor, e é composta de sépala, pétala e os conjuntos de órgãos sexuais. O órgão feminino é composto de estigma, estilo, ovário e óvulo (gineceu), enquanto o masculino é composto de filete, antera e o grão de pólen (androceu) (Figura 2). As flores unissexuadas apresentam o órgão feminino ou o masculino (GONÇALVES e LORENZI, 2007).

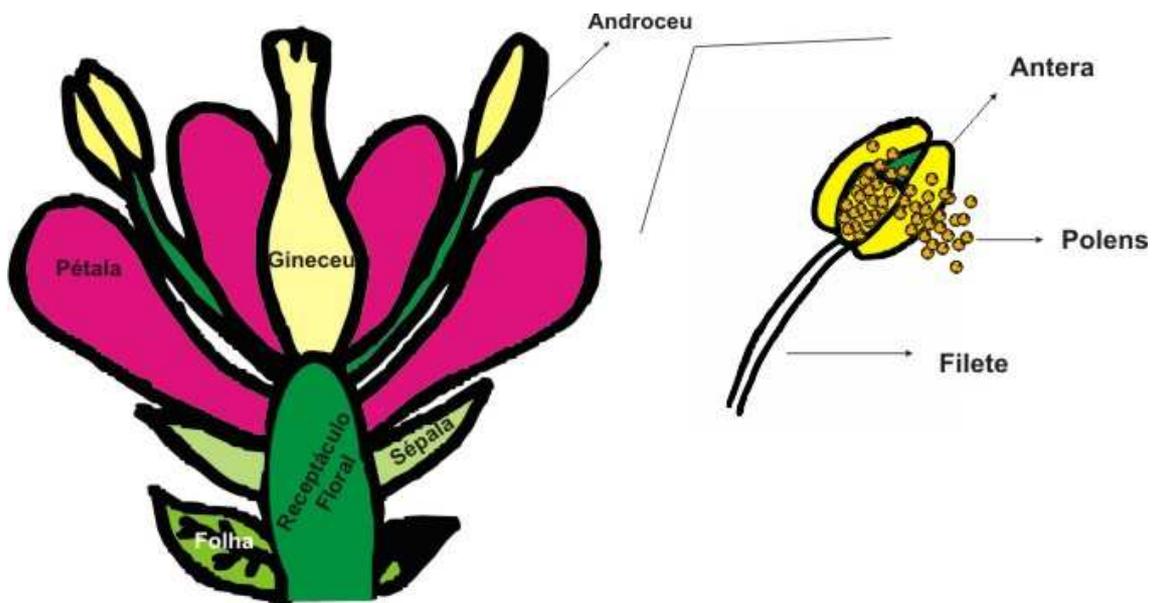


Figura 2: Estrutura floral de flor bixessuada.

O grão de pólen carrega o material gênico, responsável pela fecundação das flores e propicia a variabilidade genética entre as espécies. O pólen apresenta duas estruturas: intina (parede interna) e a exina (parede externa). As aberturas ou poros, que é por onde o material gênico sai da célula, é outra característica que permite a identificação polínica (GONÇALVES e LORENZI, 2007). A exina é importante para classificação de tipos polínicos, pois é onde estão os elementos de análise para classificação, como os detalhes, aberturas como poros, fissuras, dentre outras características do grão de pólen (Figura 3).

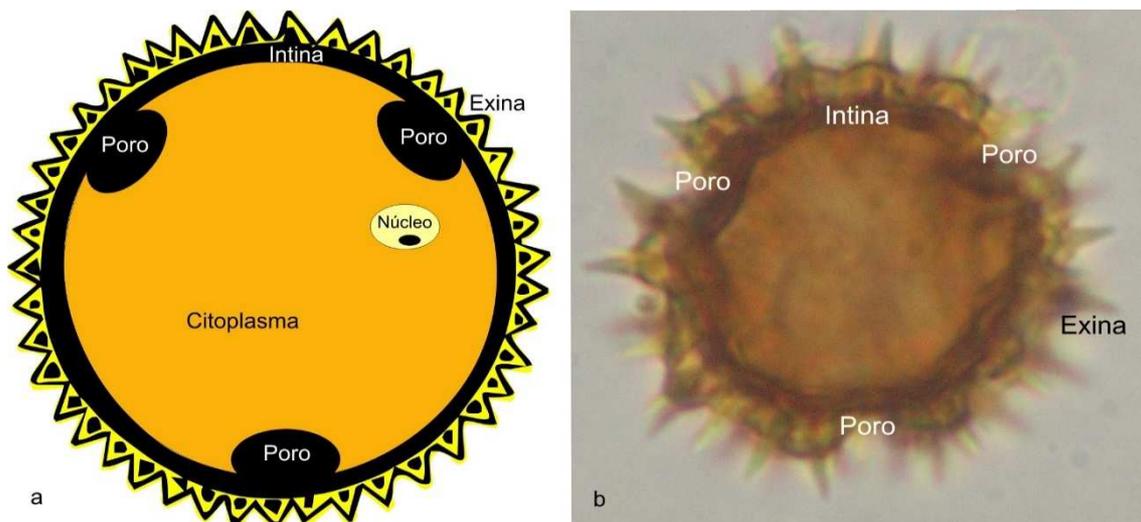


Figura 3: Detalhes das estruturas do grão de pólen. a) Ilustração; b) Imagem microscópica.

Os grãos de pólen podem aderir-se ao corpo das abelhas quando elas visitam as flores para coleta dos recursos florais. As abelhas também colhem os

grãos de pólen presentes nas anteras das flores, para a formação do pão-de-abelha, que é o armazenamento de pólen dentro dos favos. Assim, em todos os produtos elaborados pelas abelhas, existirão grãos de pólen, transferidos para os produtos apícolas: geléia real, mel, propólis e pólen de abelha (MORGADO et al., 2008; GONÇALVES et al., 2013a; SILVA et al., 2013; SANTOS et al., 2014)

A identificação de tipos polínicos é feita por um especialista que coleta os grãos de pólen de interesse, processa a amostra e visualiza sob o microscópio a lâmina palinológica. No entanto, a identificação de pólen tem interferência de fatores humanos como o cansaço, fadiga e capacidade limitada da memória (MANDER et al., 2014), que influenciam no reconhecimento das características dos polens, levando a classificações errôneas.

A determinação da espécie pela análise do pólen torna-se ainda mais complexa em algumas espécies por ocorrer variabilidade polínica intraespecífica, na qual a exina apresenta variações entre indivíduos da mesma espécie (SANTOS e PIN-FERREIRA, 2001). Ainda assim, em algumas situações é possível determinar a origem do grão de pólen até o nível de espécie, quando se dispõe de uma palinoteca da flora local, que possibilita a comparação entre o pólen presente no mel com o de uma eventual espécie presente no local. Essa análise leva em conta a vegetação local e os caracteres morfológicos de cada pólen para classificação dos grãos de pólen (MAIA et al., 2005).

Existem diferentes métodos na identificação e contagem de grão de pólen, entre os quais destaca-se a contagem com olho humano, feita no microscópio. No entanto, consome-se muito tempo do pesquisador (GONÇALVES et al., 2013b), além de ser uma atividade monótona e exaustiva que leva a erros de classificação dos polens com o passar do tempo (CULVERHOUSE et al., 2013)

Outro método é a contagem por varredura eletrônica (COSTA e YANG, 2009). Este método requer um microscópio de varredura e não são todas as instituições que o possuem. O método é mais preciso na identificação do grão de pólen por mostrar com nitidez, os detalhes microscópicos do pólen.

Outra possibilidade é usar um equipamento de partículas a laser (DELL'ANA et al., 2010), mas não é uma técnica muito apropriada, pois tem maior precisão em grãos esféricos, ocorrendo perda de informações nos formatos que fogem deste padrão (COSTA e YANG, 2009). No entanto, estes métodos são muito cansativos de realizar e são passíveis de erro humano.

A automatização no processo de identificação e contagem de grãos de pólen torna a análise mais rápida e menos trabalhosa, pois permite contar com praticidade um número maior de grãos e é mais precisa na identificação polínica (LANGFORD et al., 1990). Ocorreram várias tentativas para automatizar a identificação de grãos de pólen em imagens microscópicas por algoritmos de computador mas, ainda assim, não é um processo acessível economicamente e totalmente automatizado (CHICA e CAMPOY, 2012).

QUINTA (2009) relata que na área da visão computacional são desenvolvidos algoritmos para obtenção de informações a partir de imagens, 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 apresenta uma série de etapas para reproduzir essa tarefa realizada pelos seres humanos.

2.3. Técnicas de Extração de Atributos

2.3.1. Cor, Forma e Textura (CFT)

A extração de informações de cor, forma e textura das imagens podem utilizar as seguintes técnicas:

- Cor

A cor é a capacidade dos corpos de absorver ou refletir a luz em maior ou menor grau (HOUAISS et al., 2009). A intensidade luminosa é regulada pelas pupilas até chegar à retina que possui os pigmentos fotorreceptores, onde a luz irá interagir. A informação percebida por eles é transmitida por terminações nervosas até o nervo ótico e o estímulo segue para o cérebro, onde a cor é interpretada (LEE, 2005).

Na área computacional as cores primárias, vermelho (*Red*), verde (*Green*) e azul (*Blue*), que originam as demais cores do espectro luminoso, são definidas como cores RGB. Dentro deste sistema, as cores são obtidas através da mistura das três cores RGB, em que cada cor varia numa escala de 0 a 255. O primeiro número corresponde ao vermelho, o segundo ao verde e o terceiro ao azul, e o conjunto destes valores forma as cores com o valor mínimo representado pelo branco (0,0,0) e o valor máximo com a cor preta (255,255,255). Os valores das

cores primárias são representadas pelo vermelho (255,0,0), verde (0,255,0) e o azul (0,0,255) (PASCALE, 2003).

O modelo a que se refere a matiz (*Hue*), saturação (*Saturation*) e brilho (*Brightness*) da imagem, denomina-se HSB. Nesse modelo, a matiz é um atributo que descreve uma tonalidade ou cor pura, que é medido de -180° a 180° , totalizando 360° (Figura 4). A saturação determina a profundidade da cor, ou seja, de esmaecida a intensa (Figura 4) (PASCALE, 2003).

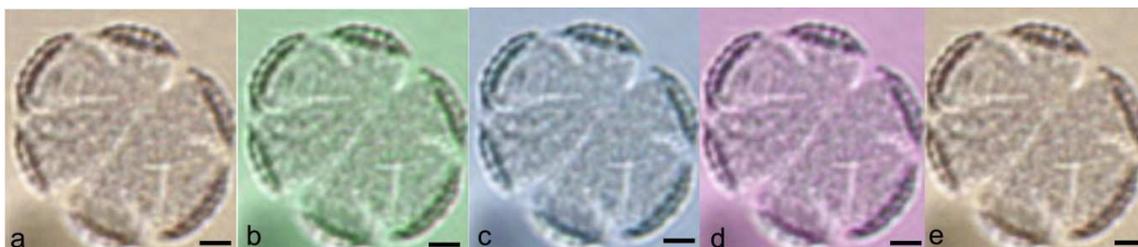


Figura 4: Variação da matiz na imagem do tipo *Hyptis*. a) Matiz -180° ; b) Matiz -90° ; c) Imagem original; d) Matiz 90° ; e) Valor máximo da matiz em 180° (Escala = $10\ \mu\text{m}$).

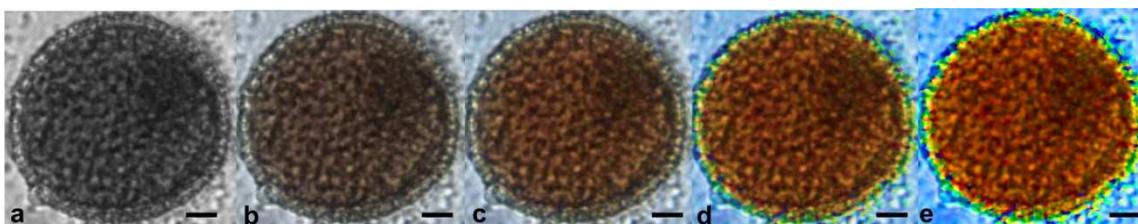


Figura 5: Variação de saturação na imagem do tipo *Croton*. a) -100% de saturação. b) -50% de saturação; c) Imagem original; d) 50% de saturação; e) Saturação máxima igual a 100% (Escala = $10\ \mu\text{m}$).

O brilho indica o nível de iluminação, ou seja, é a intensidade de luz em uma cor que define claro e escuro, em uma escala 0% sem luz (preto) e 100% iluminação completa (branco), logo as cores com percentual abaixo de 50% serão mais escuras e as acima de 50% serão mais claras (Figura 6) (PASCALE, 2003).

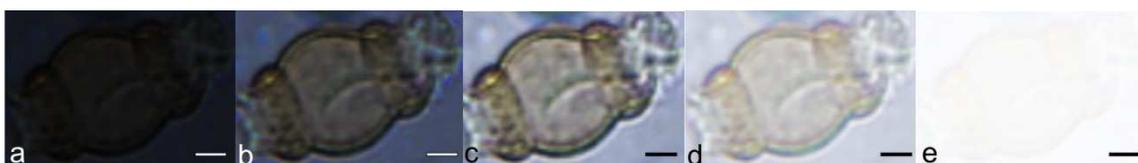


Figura 6: Variação da intensidade luminosa na imagem do tipo *Faramea*. a) -85% de iluminação. b) -50% de iluminação; c) Imagem original; d) 50% de iluminação; e) 95% de iluminação (Escala = $10\ \mu\text{m}$).

- Forma

A forma é um dos elementos levados em consideração para a classificação de imagens, onde a linha que limita exteriormente o objeto é o contorno ou borda (VERNON, 1991). A delimitação da fronteira é importante para determinar sua forma e assim o distinguir entre outros objetos. Por exemplo, a partir da forma dos tipos *Anadenanthera colubrina* e *Serjania* é possível fazer a distinção entre eles (Figura 7).

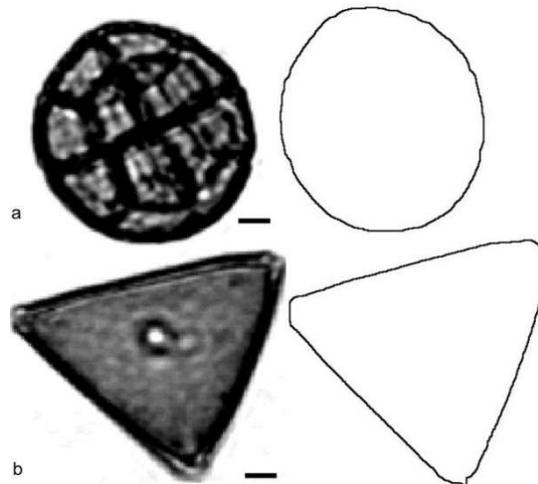


Figura 7: Diferença do formato entre grãos de pólen. a) Pólen circular de *Anadenanthera colubrina* e seu respectivo contorno. b) Pólen triangular do tipo *Serjania* e seu contorno (Escala = 10 μ m).

O tamanho da borda de um objeto (t) é obtido pelo fator de forma, que é uma equação obtida através da divisão da área que compõe o número total de pixels que um objeto ocupa na imagem (a) sobre o perímetro aproximado, que é a distância da borda externa do objeto (p). Geralmente o fator de forma varia entre 0 e 1, sendo que quanto mais próximo do valor 1, mais perfeita é a forma geométrica, enquanto que valores mínimos correspondem a formas irregulares (GOMES e PACIORNIK, 2005). A área do objeto é encontrada computacionalmente na imagem através da utilização de programas como o ImageJ.

$$t = \frac{A}{P}$$

O valor do perímetro do objeto, conforme a seguinte equação, permite encontrar o valor aproximado do raio com o perímetro, pois nem todos os objetos são circulares, então calcula-se a área do objeto de interesse. Com a obtenção do raio da circunferência encontra-se o valor do perímetro do objeto, então é possível estabelecer a área da circunferência e o fator de forma (VERNON, 1991).

$$P = 2\pi r$$

A circularidade mensura o contorno do objeto, dando um valor recíproco do fator de forma. Objetos em forma de círculo tem valor igual a 1 ou um pouco maior. Os demais, com diferentes formas, por exemplo, triângulo ou quadrado, terão um valor maior de contorno, que é calculado e aproximado da forma circular para se obter o raio do objeto.

- Textura

Não existe um conceito formado e nem uma fórmula matemática para definição da textura, a qual é atribuída à percepção humana e apresenta uma repetição de padrões como brilho, tonalidade, tamanho, inclinação, dentre outros (NIXON e AGUADO, 2002; SÁ-JUNIOR et al., 2013). Entre os grãos de pólen, é possível visualizar a textura através da parede da exina que apresenta superfícies distintas entre os tipos polínicos (Figura 8).

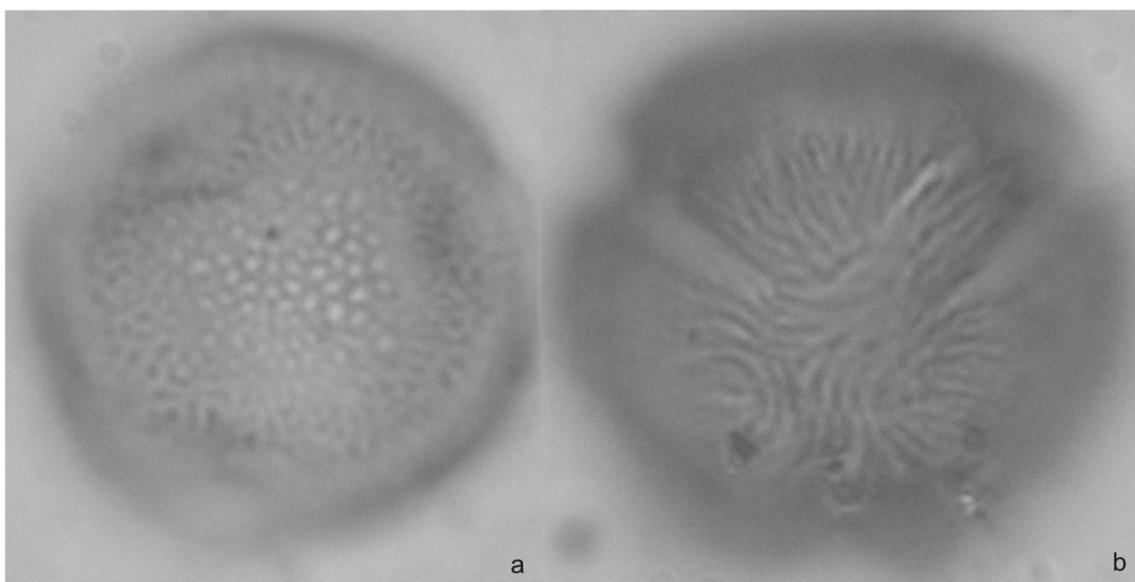


Figura 8: Diferença de textura entre polens pertencentes à família Anacardiaceae. a) Superfície com pontos. b) Superfície ondulada.

Dentre os algoritmos para extração de textura, existem os Padrões Binários Locais (PBL) e os Padrões Binários Locais Invariantes à Rotação (PBLROT). O PBL analisa a textura local, e é definido como uma medida da textura invariante à escala de cinza. É um código binário que descreve o padrão de textura local sendo construído por pixels vizinhos que são somados para obtenção do PBL (MÄENPÄÄ et al., 2000). O PBLROT consiste na utilização dos valores obtidos pelo operador PBL de textura, mas que se diferencia deste por ser invariante à rotação (ZHAO e PIETIKÄINEN, 2007).

A Matriz de Co-ocorrência é um método proposto por Haralick et al. (1973), que determina quantas vezes um determinado tom de cinza aparecerá em par com outro tom de cinza na imagem. Neste método, a imagem é representada em valores de tons de cinza, baseado na distância e ângulo com que cada valor de cinza ocorre na imagem, é construída a matriz. Uma imagem terá várias matrizes de co-ocorrência, de acordo com os pares de tons de cinza analisados. Através dos valores gerados por cada matriz de co-ocorrência é possível extrair atributos de textura como, por exemplo, a entropia que fornece o grau de dispersão de tons de cinza em uma imagem, dentre outros atributos. Assim, uma imagem apresenta um determinado vetor para a entropia encontrada, além dos demais vetores dos atributos escolhidos.

2.3.2 Histogramas de Palavras Visuais

A técnica de Histograma de Palavras Visuais (*Bag of Visual Words – BOW*) é composta de um histograma com números dos descritores de padrões encontrados em uma imagem (CSURKA et al., 2004). Os pontos de interesse na imagem são encontrados e extraídos pelo algoritmo *Speeded Up Robust Features* (SURF), que é rápido em detectar os pontos de interesse (Figura 9). De cada ponto de interesse, que está representado em vermelho e azul na Figura 9.b, são gerados os vetores de atributos, que é a direção de variação que está ocorrendo em torno do ponto de interesse e está representado em amarelo na Figura 9.c. Os processos de extração dos atributos são feitos em pontos diferenciais da imagem e não na imagem inteira.

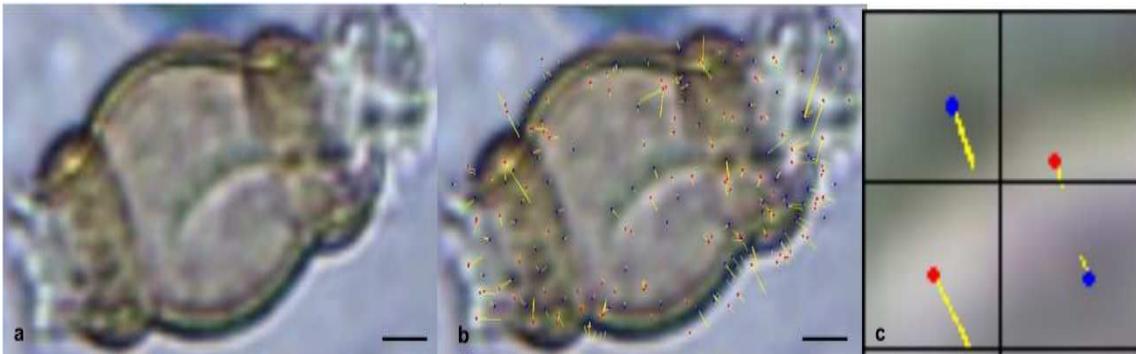


Figura 9: Detecção de pontos de interesse em uma imagem de pólen do tipo *Faramea*. a) Imagem original. b) Imagem com os pontos de interesse. c) Zoom dos pontos de interesse na imagem (Escala = 1 µm).

Após a detecção dos pontos de interesse na imagem (Fig. 10a) é realizado o agrupamento dos conjuntos de vetores (Fig. 10b) com o algoritmo *K-means* baseado na distância Euclidiana que, de acordo com o valor atribuído a *k*, agrupa os vetores mais próximos e cria um descritor central (Fig. 10c) correspondente a cada agrupamento (BAHRI e ZOUAKI, 2013). Por exemplo, em um dicionário de tamanho quatro, serão realizados quatro agrupamentos de descritores a, b, c e d, que são quatro centroides utilizados para compor o vocabulário de cada conjunto de vetores.

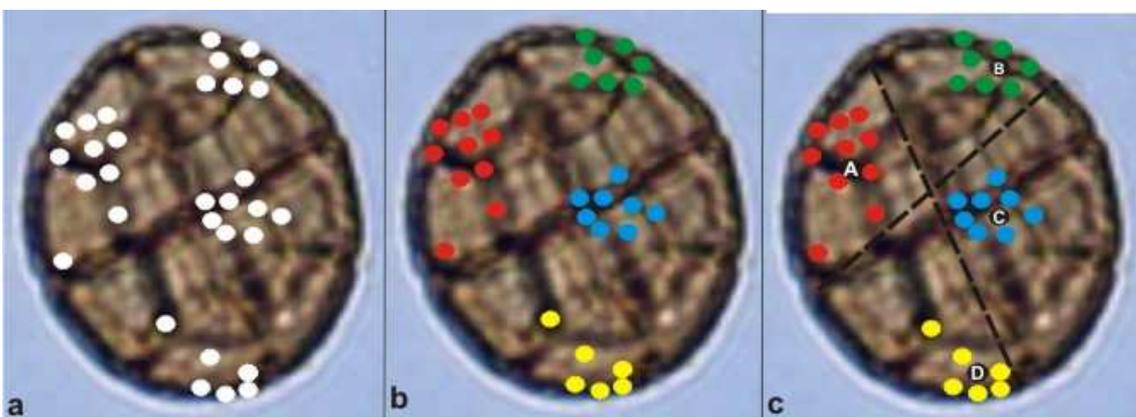


Figura 10: Atributos extraídos pelo BOW. a) Detecção dos pontos de interesse pelo algoritmo Surf; b) Agrupamento dos vetores pelo *K-means*. c) Cada agrupamento é transformado em uma palavra pelo BOW.

Cada agrupamento forma uma palavra e o conjunto destas palavras forma um vocabulário (Figura 10. d). O tamanho do vocabulário é representado por um histograma, onde todas as palavras visuais do vocabulário terão uma frequência (BAY et al., 2006; YANG et al., 2007). O histograma de uma imagem

é o conjunto de números indicando o percentual de palavras visuais de uma imagem, que é representado em um gráfico de barras como demonstrado na Figura 11, um vetor de A 10, B 7, C 8 e D 6.



Figura 11: Histograma de palavras visuais.

2.4. Classificadores

2.4.1. KNN

O K-Nearest Neighbor (KNN) é um algoritmo baseado em instâncias, ou seja, agrupamento dos dados que faz a classificação entre os k -vizinhos mais próximos. Cada instância é um dado d -dimensional em que d representa o número de atributos de cada imagem. As instâncias de treinamento são armazenadas e quando aparece uma nova imagem é feita uma busca nas instâncias registradas para classificação da imagem (BATISTA, 2003). A seguinte equação apresenta a distância Euclidiana, onde $p(i)$ e $q(i)$ são dois pontos correspondentes.

$$\sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} = \sqrt{\sum (p_i - q_i)^2}$$

2.4.2 J.48

Este algoritmo é baseado em árvore de decisão, que é formada a partir de nós de decisão que tomam uma escolha no valor de um atributo. A partir de um conjunto de dados, o J.48 constrói árvores de decisão, compostas das folhas

que contém as classes que devem ser classificadas e os nós são atributos da imagem que apresenta melhor eficiência (BHARGAVA et al., 2013).

2.4.3. Máquina de Vetor de Suporte

O algoritmo de Máquina de Vetor de Suporte do inglês *Support Vector Machines* (SVM) foi desenvolvido por Vladimir Vapnik e pertence a uma categoria de classificadores lineares. A classificação é feita de acordo com um hiperplano entre as bordas mais próximas de dois vetores (CORTEZ e VAPNIK, 1995). A biblioteca LIBSVM presente no *software* Weka utiliza este algoritmo, que é utilizado primeiramente treinando os conjuntos de dados para achar um modelo, e posteriormente, utilizar o modelo encontrado para dar a informação sobre os conjuntos de dados (CHANG e LIN, 2013).

O SVM implementa o modelo de aproximação um-contra-um para a classificação de múltiplas classes, em que k significa o número de classes. Então, através da equação $k(k-1)/2$, os classificadores são construídos e cada um treina dados de duas classes (CHANG e LIN, 2013).

Como os problemas de duas classes são muito mais fáceis de resolver, é proposta a utilização de classificadores com duas classes para a classificação multi-classe, que utiliza o processo de votação de classes. O SVM constrói uma regra para discriminar entre cada par de classes e, em seguida, seleciona a classe com as decisões de duas classes vencedoras. Embora o processo de votação requeira apenas as decisões de pares, só se prevê um rótulo de classe (WU e LIN, 2004).

O SVM é uma técnica de aprendizagem de máquina para classificação de vetores, regressão e estimativa de distribuição em que os dados são divididos em um conjunto de treinamento e outro para o conjunto de teste, em que o SVM de treinamento resolve um problema de otimização para produzir um modelo. Em seguida, o SVM gerado usa o modelo obtido para classificar o conjunto de teste, para que o resultado final apresente as classes geradas (CHANG e LIN, 2013).

No entanto, o SVM apresenta problemas com o armazenamento de dados devido ao tamanho necessário para armazenamento de dados de Programação Quadrática (PQ), que não são facilmente resolvidos através das técnicas padrões de PQ. A forma quadrática é uma matriz que tem um número de

elementos igual ao quadrado do número de exemplos de treinamento. Desta maneira, não cabem em uma matriz com 128 megabytes mais do que 4000 exemplos de treinamento, levando em consideração que cada elemento armazenado é de oito bytes (PLATT, 2000).

Para resolver o problema de armazenamento, o algoritmo de Otimização Mínima Sequencial (*Sequential Minimal Optimization* - SMO) resolve rapidamente a programação quadrática do SVM, sem que necessite de qualquer matriz de armazenamento adicional, pois o SMO se decompõe por PQ em subproblemas. O SMO torna a implementação de *softwares* mais fácil e eficiente, fazendo com que seja utilizada uma memória linear para o treinamento de dados. Desta maneira, o SMO permite o trabalho com um maior número de arquivos para treinamento (PLATT, 2000).

O algoritmo C-SVC (*Support Vector Classification*), busca encontrar e otimizar um hiperplano em que seja possível a decisão entre as escolhas de objetos alvos. Além do mais, este algoritmo é especializado em resolver problemas multiclases, onde os vetores de suporte estão próximos dos limites entre as classes. O valor de C é que controla a relevância dos critérios para classificação (MATEOS et al., 2008).

2.5. Métricas de Classificação

2.5.1. Porcentagem de Classificação Correta (PCC)

O PCC (BOUCKAERT et al., 2010) é o índice de acerto de classificação correta obtida em um conjunto de imagens, ou seja, de um grupo contendo 100 imagens, se 60 são classificadas corretamente, então dividindo o valor de acerto pelo total de imagens, tem-se uma índice de 60% de acerto, que pode ser calculado pela seguinte equação:

$$PCC = \frac{\text{Total classificado corretamente}}{\text{Total de imagens}}$$

2.5.2. Medida-F

Uma imagem classificada como verdadeiro positivo (VP) é uma imagem que foi classificada corretamente. Uma imagem classificada como falso negativo (FN) é uma imagem que foi classificada erroneamente. Já o verdadeiro negativo

(VN) ocorre quando uma imagem que não pertence a um determinado grupo é classificada como pertencente a este. Um falso positivo (FP) ocorre quando uma imagem é classificada como não pertencente ao grupo, mas na verdade é pertencente a ele (BOUCKAERT et al., 2010).

A medida-F é utilizada para comparação de classificadores, além de ser uma média entre precisão e revocação que mede a capacidade do sistema na recuperação da classificação do conjunto de imagens (BOUCKAERT et al., 2010; RIJSBERGEN, 1979), e é expressa pela equação:

$$F = 2 * \frac{\text{Precisão} * \text{Revocação}}{\text{Precisão} + \text{Revocação}}$$

2.5.3. Área sob a Curva ROC

A métrica área sob a curva ROC (*Receiver Operating Characteristic*) (BOUCKAERT et al., 2010), viabiliza a visualização, organização e seleção da técnica com base no seu desempenho. A curva ROC é construída em um plano cartesiano em que os dados falsos-positivos (eixo X) e verdadeiros-positivos (eixo Y) são distribuídos em um gráfico, formando uma curva ascendente.

É possível encontrar um único valor da curva ROC, através do cálculo da área abaixo da curva, que é chamada de área sob a curva. Quanto maior a área sob a curva, melhor é o desempenho. Dada a curva ROC de técnicas para um mesmo conjunto de dados, torna-se interessante compará-las, a fim de identificar qual apresentou melhor desempenho (WITTEN e FRANK, 2005; FAWCETT, 2005).

2.6 Técnica de Amostragem

2.6.1 Validação Cruzada

Na classificação de um conjunto de dados é necessário medir o desempenho das técnicas utilizadas, para saber se a classificação do conjunto de dados foi satisfatória ou não. Para chegar ao verdadeiro índice de erro obtida pela técnica utilizada, é necessário que o conjunto de treinamento e teste sejam diferentes. Desta maneira, deve-se dividir o conjunto de dados em conjunto para treinamento, que é utilizado com uma ou mais técnicas de aprendizagem, e um conjunto de teste, que é empregado para estabelecer o índice de erro obtida pela técnica (WITTEN e FRANK, 2005).

Uma das maneiras de avaliar um conjunto de dados é através da validação cruzada, que consiste em separar parte dos dados para treinamento e outra parte para teste. Na validação cruzada, é necessário decidir previamente um número de dobras a que os dados serão divididos. Por exemplo, supondo que se usem três dobras em um determinado conjunto de dados, estes serão divididos aleatoriamente em dois terços que serão utilizados para treinamento e um terço dos dados será utilizado para teste. Este processo é repetido três vezes e no final é apresentada a média do desempenho do conjunto de dados (WITTEN e FRANK, 2005).

2.6.2 Matriz de Confusão

Uma matriz de confusão ou tabela de contingência é uma apresentação gráfica da relação de pelo menos dois atributos em relação à sua frequência (LAURITZEN, 2002; TSUMOTO e HIRANO, 2008). A coloração da matriz de confusão é baseada no método termal Lee (2005), que utiliza as cores eletromagnéticas do infravermelho para representar a emissão de calor dos objetos. Assim, através do comprimento de onda é possível representar os valores que estão na matriz em cores, ou seja, os valores maiores são coloridos em tons vermelhos, valores médios por tons laranja e os valores baixos por amarelo.

2.7. Testes de Hipótese

2.7.1 Friedman

O teste de Friedman que é um teste não paramétrico, é conhecido como teste de distribuição livre, porque faz poucas ou nenhuma suposições sobre o tipo de dados que pode ser utilizado (FIELD, 2009). Para esta proposta, o teste de Friedman visa analisar o resultado obtido por cada grupo. O teste assume a hipótese de que os conjunto de dados uns contra os outros são iguais, ou seja, é o que se chama de hipótese nula. Um valor chamado de p é calculado e, com base no resultado que ele apresenta, a hipótese nula pode ser rejeitada ou não, de acordo com o grau de significância que o teste irá adotar.

Para o teste de Friedman, os dados se dispõem em uma tabela de dupla entrada com n linhas e k colunas. As linhas apresentam os vários indivíduos ou

conjunto correspondentes de indivíduos, e as colunas representam as diversas condições. Assim, os dados dos indivíduos são observados sob todas as k condições.

2.7.2 ANOVA

A Análise de Variância, ou ANOVA, pode ser utilizada para duas ou mais variáveis independentes, informando de que modo essas variáveis interagem umas com as outras e quais as interações apresentam sobre a variável dependente. ANOVA é um teste que abrange os dados de uma maneira geral, informando se o experimento teve sucesso ou não através do valor p encontrado. Para tanto, ela se utiliza da razão F que compara a variância dos dados e informa se o experimento teve efeito ou não (FIELD, 2009).

2.7.3 T-Student

O teste T-Student (FIELD, 2009) é um teste paramétrico, ou seja, os dados são normalmente distribuídos e medidos pelo intervalo de confiança adotado previamente. É utilizado quando existem duas condições experimentais e ambos os conjuntos de dados foram utilizados nas mesmas condições, então a média das amostras é calculada.

Se o resultado das médias entre os participantes forem estatisticamente similares, pode-se considerar hipótese nula, ou seja, as variáveis sob os conjuntos de dados não tiveram efeito. No entanto, quanto maiores as médias observadas entre as amostras, maior será o índice de confiança de uma hipótese experimental, isto é, as médias encontradas são diferentes devido às manipulações do experimento exercidas sobre cada amostra (FIELD, 2009).

3. REFERÊNCIAS

1. ABNT. Associação Brasileira de Normas Técnicas. **Normalização: Guia de uso e aplicação de normas da cadeia apícola**. Rio de Janeiro: ABNT e SEBRAE, 2012. 63 p.
2. BAHRI, A.; ZOUAKI, H. A Surf-Color Moments For Images Retrieval Based On Bag-Of-features. **European Journal of Computer Science and Information Technology**. v. 1, p.11-22, 2013.
3. BATISTA, G.E.A.P.A. Pré-processamento de dados em aprendizado de máquina supervisionado. 2003. 232 f. Tese (Doutorado em Ciências da Computação e Matemática Computacional) – Instituto de Ciências de Matemática e de Computação, Universidade de São Paulo, São Carlos, 2003.
4. BAY, H.; TUYTELAARS, T.; GOOL, L.V. SURF: Speeded Up Robust Features. **European Conference on Computer Vision**, v. 1, p. 404–417, 2006.
5. BHARGAVA, N.; SHARMA, G.; BHARGAVA, R.; MATHURIA, M. Decision Tree Analysis on J48 Algorithm for Data Mining. **Journal of Advanced Research in Computer Science and Software Engineering**. v. 3, 2013.
6. BOUCKAERT, R.R.; FRANK, E.; HALL, M.; KIRKBY, R.; REUTEMANN, P.; SEEWALD, A.; SCUSE, D. **WEKA Manual for Version 3-6-2**. New Zealand: University of Waikato. 2010. 303p.

7. BUAINAIN, A.M; BATALHA, M.O. **Cadeia produtiva de flores e mel**. Brasília: Ministério da Agricultura, Pecuária e Abastecimento / Secretaria de Política Agrícola; Instituto Interamericano de Cooperação para a Agricultura, 2007. 140 p.
8. CABRERA, M.; ANDRADA, A.; GALLEZ, L. Floración de especies con potencial apícola en el Bosque Nativo Formoseño, Distrito Chaqueño Oriental (Argentina). **Boletín de la Sociedad Argentina de Botánica**, v. 48, p. 477-491, 2013.
9. CHANG, C.C.; LIN, C.J. **LIBSVM: A Library for Support Vector Machines**. Transactions on Intelligent Systems and Technology, 2013.
10. CHICA, M. Authentication of Bee Pollen Grains in Bright-Field Microscopy by Combining One-Class Classification Techniques and Image Processing. **Microscopy Research And Technique**, v. 75, p.1475–1485, 2012.
11. CHICA, M.; CAMPOY, P. Discernment of bee pollen loads using computer vision and one-class classification techniques. **Journal of food Engineering**, v. 112, p. 50–59, 2012.
12. CORTEZ, C.; VAPNIK, V. Support-Vector Networks. **Machine Learning**, v. 20, p. 273-297, 1995.
13. COSTA, C.M.; YANG, S. Counting pollen grains using readily available, free image processing and analysis software. **Annals of Botany**, v. 104, p. 1005–1010, 2009.
14. CSURKA, G.; DANCE, C.; FAN, L.; WILLAMOWSKI, J.; BRAY, C. Visual categorization with bags of keypoints. **In: Workshop on Statistical Learning for Computer Vision**, p. 59–74, 2004.

15. CULVERHOUSE, P.F.; MACLEOD, N.; WILLIAMS, R.; BENFIELD, M.C.; LOPES, R.M.; PICHERAL, M. An empirical assessment of the consistency of taxonomic identifications. **Mar Freshwater Res**, v. 10, p. 73-84, 2014.
16. DELL'ANNA, R.; CRISTOFORI, A.; GOTTARDINI, E.; MONTI, F. A critical presentation of innovative techniques for automated pollen identification in aerobiological monitoring networks. **Pollen: Structure, types and effects**. Ed: KAISER, B.J. New York, Nova science, p. 273-288, 2010.
17. FAWCETT, T. An introduction to ROC analysis. **Pattern Recognition Letters**, v. 27, p. 861-874, 2006.
18. FIELD, A.P. **Descobrimo a estatística usando o SPSS**. 2. ed. Porto Alegre: Artmed, 2009.
19. GOMES, O.F.M.; PACIORNIK, S. Automatic Classification of Graphite in Cast Iron. **Microscopy and Microanalysis**, v. 11, p. 363–371, 2005.
20. GONÇALVES, A.B.; SILVA, A.P.C.; CEREDA, M.P.; SANTOS, F.A.R. Identificação botânica do pólen encontrado em amostras de mel de *Apis mellifera* L. produzido no município de Bonito-MS. **Cadernos de Agroecologia**, v. 8, p. 14658, 2013a.
21. GONÇALVES, A.B; RODRIGUES, C.N.M.; CEREDA, M.P.; PISTORI, H. Identificação computadorizada de tipos polínicos através de Bag of Words. **Cadernos de Agroecologia**, v. 8: p.14634, 2013b.
22. GONÇALVES, E.G.; LORENZI, H. **Morfologia vegetal: Organografia e dicionário ilustrado de Morfologia das Plantas Vasculares**. São Paulo: Instituto Plantarum, 2007. 415p.
23. HARALICK, R.M., SHANMUGAM, K., DINSTEN, H. Textural features for image classification. **IEEE Trans. Syst. Man Cybern.**, v. 3, p. 610–621, 1973.

24. HOUAISS, A., VILLAR, M.S., FRANCO, F.M.M. **Minidicionário Houaiss da língua portuguesa**. 3. ed. Rio de Janeiro: Objetiva, 2009. 992p.
25. LANGFORD, M.; TAYLOR, G.E.; FLENLEY, J.R. Computerized identification of pollen grains by texture analysis. **Review of Palaeobotany and Palynology**, v. 64, p. 197-203, 1990.
26. LAURITZEN, S.L. Lectures on Contingency Tables. 2002. 53p. Disponível online em: < <http://www.stats.ox.ac.uk/~steffen/papers/cont.pdf>>. Acesso em: 26 jan. 2015.
27. LEE, H.C. **Introduction to Color Imaging Science**. Cambridge: New York, 2005, 717p.
28. LOPES, M.T.R.; CAMARGO, R.C.R.; VILELA, S.L.O. **Apicultura**. Empresa Brasileira de Pesquisa Agropecuária Meio-Norte. Teresina, 2001, 2 p.
29. MÄENPÄÄ, T.; OJALA, T.; PIETIKÄINEN, M. SORIANO, M. Robust texture classification by subsets of local binary patterns. **In: Proc. 15 International Conference on Pattern Recognition, Barcelona (Spain)**, v. 3, p. 947–950, 2000.
30. MAIA, M., RUSSO-ALMEIDA, P.A., PEREIRA, J.O. Caracterização do espectro polínico dos méis do Alentejo (Portugal). **Silva Lusitana**, v. 13, p. 95 – 103, 2005.
31. MANDER, L.; BAKER, S.J.; BELCHER, C.M.; HASELHORST, D.S.; RODRIGUEZ, J.; THORN, J.L.; TIWARI, S.; URREGO, D.H.; WESSELN, C.J.; PUNYASENA, S.W. Accuracy and consistency of grass pollen identification by human analysts using electron micrographs of surface ornamentation, **Applications in plant sciences**. v., 8, p. 1-11, 2014.
32. MATEOS, I.; RAMOS, D.; LOPEZ-MORENO, I.; GONZALES-RODRIGUEZ, J. Support vector regression in nist sre 2008 multichannel

- core task. **In:** Jornadas en Tecnología del Habla, V, 2008, Bilbao. Anais... Bilbao, 2008.
33. MORGADO, L. N., BARRETO, C. F., FREITAS, A. S., BARTH, O. M. Espectro polínico de geleia real de *Apis mellifera* (Apidae: Apini) em Pindamonhangaba, São Paulo, Brasil. **In:** SIMPÓSIO DE PALEOBOTÂNICOS E PALINÓLOGOS, XII, 2008, Florianópolis. Anais... Porto Alegre: ALPP, 2008. Versão eletrônica. Disponível em <http://www6.ufrgs.br/alpp/XII_SBPP_Boletim_%20de_Resumos.pdf>.
34. NIXON, M.S.; AGUADO, A.S. **Feature Extraction and Image Processing**. Oxford: Newnes, 2002. 330 p.
35. PASCALE, D. **A Review of RGB Color Spaces**. Babel Color: Canada, 2003.
36. PLATT, J.C. Fast Training of Support Vector Machines using Sequential Minimal Optimization. In: Schölkopf, B.; Burges, C.J.; Smola, A.J. (Eds) **Advances in Kernel Methods: Support Vector Learning**. MIT Press, Cambridge, MA, cap. 12, p. 41-65, 2000.
37. PICOLLI, P.O. Polinização de grão em grão contribuindo para o aumento da produção. **Mensagem Doce**, v. 112, p. 1, 2011.
38. QUINTA, B.N.L. C. **Desenvolvimento de um Sistema de Visão Computacional para o Controle Microbiano em Processos de Produção de Etanol**. 2009. 50p. Monografia (Final de Curso de Engenharia de Computação, Universidade Católica Dom Bosco, Campo Grande, 2009.
39. RIJSBERGEN, C. A. **Information retrieval**. London: Butterworths, 1979.
40. SÁ-JUNIOR, J.J.M.; BACKES, A.R.; CORTEZ, P.C. Color texture classification based on gravitational collapse. **Pattern Recognition**, v. 46, p. 1628–1637, 2013.

41. SANTOS, F.A.R.; PIN-FERREIRA, A.B. Variabilidade polínica de *Opuntia brasiliensis* (Willd.) Haw. (Cactaceae), **Sitientibus**, v. 1, p. 95-98, 2001.
42. SANTOS, K.C.B.S; PEREIRA, J.B.; GONÇALVES, A.B.; CEREDA, M.P. Identificação de grãos de pólen e plantas nativas de importância apícola em uma área de Cerrado em Campo Grande-MS. In: CONGRESSO LATINOAMERICANO DE APICULTURA, XI, 2014. Anais...Puerto Iguazú, FILAPI, 2014.
43. SHAPIRO, L.; STOCKMAN, G. **Computer vision**. New Jersey: Prentice Hall, 2001.
44. SILVA, C.R.B.; PUTAROV, T.; ORSI, R.O. Pollen spectrum of propolis samples from São Paulo State, Brazil. **Acta Scientiarum. Animal Sciences**. v. 35, p. 297-300, 2013.
45. SILVA, R.A. **ANÁLISE DA CONJUNTURA AGROPECUÁRIA SAFRA 2008/09**: Apicultura. 2010. 25p. Disponível online em: <http://www.agricultura.pr.gov.br/arquivos/File/deral/Prognosticos/apicultura_0809.pdf>. Acesso em: 23 jan. 2015.
46. SILVA, S.J.R., ABSY, M.L. Análise do pólen encontrado em amostras de mel de *Apis mellifera* L. (Hymenoptera, Apidae) em uma área de savana de Roraima, Brasil. **Acta Amazonica**, v. 30, 579-588, 2000.
47. TSUMOTO, S.; HIRANO, S. L. Contingency Matrix Theory: Investigation of Information Granules in Statistics. In: MAGDALENA, M. OJEDA-ACIEGO, J.L. VERDEGAY (eds): **Proceedings of IPMU'08**. p. 1765–1772, 2008.
48. VASCONCELOS, B.R.; GONÇALVES, A.B.; VILPOUX, O.F.; CEREDA, M.P. Georeferencing Methodology For Honey Tracking. In: INTERNATIONAL APICULTURAL CONGRESS, XLII, 2011, Buenos Aires. Anais...Buenos Aires, APIMONDIA, 2011.

49. VERNON, D. **Machine Vision: Automated Visual Inspection and Robot Vision**. Cap 7. An overview of techniques for shape description. Cambridge: Prentice Hall. p. 140-155, 1991.
50. WITTEN, I.; FRANK, E. **Data Mining: Practical Machine Learning Tools and Techniques**. 2. ed. United States of America: Elsevier. 2005. 558 p.
51. WU, T.F.; LIN, C.J. Probability Estimates for Multi-class Classification by Pairwise Coupling. **Journal of Machine Learning Research**, v. 5, p. 975-1005, 2004.
52. YANG, J.; JIANG, Y.G.; HAUPTMANN, A.G.; NGO, C.W. Evaluating Bag-of-Visual-Words Representations in Scene Classification. **In: ACM Multimedia Information Retrieval (MMSP)**, New York, USA, p. 197-206, 2007.
53. ZHAO, G.; PIETIKÄINEN, M. Dynamic Texture Recognition Using Local Binary Patterns with an Application to Facial Expressions. **IEEE Transactions On Pattern Analysis And Machine Intelligence**, v. 29, p.915 -928, 2007.

4. OBJETIVOS

4.1 Objetivo geral

Desenvolver e validar um programa de computador com base em extração de atributos de cor, forma, textura e gradiente, que seja capaz de realizar a identificação de imagens microscópicas de grãos de pólen com índice de acerto igual ou melhor do que o obtido na identificação polínica realizada por visão humana com pessoas sem contato anterior com a palinologia.

4.2 Objetivos Específicos

1. Capturar e tratar as imagens de polens para serem utilizadas no software;
2. Criação de um banco de imagens dos tipos polínicos;
3. Aplicação de técnicas de visão computacional e áreas afins para realização de reconhecimento de grãos de pólen;
4. Correlação dos resultados obtidos com o conhecimento de pessoas inexperientes nesta área e validar com os resultados obtidos com o programa de computador.

O artigo a seguir foi elaborado seguindo as normas da revista **Plos One**.

1 **Comparação de Técnicas de Extração de Atributos e** 2 **Aprendizagem Automática para Classificação de** 3 **Tipos Polínicos**

4 **Ariadne Barbosa Gonçalves^{1*}, Junior Silva Souza^{2&}, Gercina Gonçalves da Silva^{3&},**
5 **Marney Pascoli Cereda^{1,3¶}, Arnildo Pott^{4¶}; Marco Hiroshi Naka^{1¶}; Hemerson Pistori^{1,2b¶}**

6
7 ¹Programa de Biotecnologia, Universidade Católica Dom Bosco, Campo Grande, Mato
8 Grosso do Sul, Brasil.

9 ²Departamento de Ciência da Computação, Universidade Federal de Mato Grosso do
10 Sul, Campo Grande, Mato Grosso do Sul, Brasil.

11 ³Centro de Tecnologia e Análise do Agronegócio, Universidade Católica Dom Bosco,
12 Campo Grande, Mato Grosso do Sul, Brasil.

13 ⁴Departamento de Biologia Vegetal, Universidade Federal de Mato Grosso do Sul,
14 Campo Grande, Mato Grosso do Sul, Brasil.

15
16
17 * Autor Correspondente

18 E-mail: ariadne.gon@gmail.com

19
20 ¶ Estes autores contribuíram igualmente para este trabalho

21 & Estes autores contribuíram igualmente para este trabalho

1 **Resumo**

2 O reconhecimento de grãos de pólen em méis faz parte do processo de certificação de origem
3 das plantas visitadas pelas abelhas. Com uso da visão computacional foram implementadas três
4 técnicas de extração de atributos em imagens microscópicas de 23 tipos polínicos selecionados
5 da flora local, o que se constituiu em uma inovação por utilizar vários tipos polínicos. As
6 técnicas avaliadas foram Histograma de Palavras Visuais (*Bag of Word* – BOW), Cor Forma e
7 Textura (CFT) e a união das duas primeiras técnicas (CFT+BOW). Os resultados da
8 classificação dos polens foram comparados com aqueles obtidos pela visão humana. O
9 percentual de acerto foi menor quando os atributos foram avaliados por uma só técnica (CFT
10 63%; BOW 61%), mas melhorou com a união delas. Com CFT + BOW obteve-se 64% de
11 acerto. O valor de p encontrado na análise das técnicas com o teste de ANOVA foi de 0.576.
12 Com esse desempenho, foi possível automatizar a classificação das imagens dos tipos polínicos
13 com percentual muito próximo ao obtido pela visão humana.

14 Palavras-chave: Classificação automática, Visão computacional, Palinologia.

15

1 **Introdução**

2 A identificação microscópica de pólen com visão humana apresenta limitações porque
3 é dificultada pela semelhança nas aberturas, formas e textura da exina dos grãos de pólen. Além
4 disso, trata-se de tarefa morosa e cansativa, que exige um especialista. A reunião de grãos de
5 pólen em tipos polínicos, facilita a identificação até espécie, dificultada em alguns gêneros,
6 devido à grande semelhança entre os polens [1].

7 Um sistema computacional que otimize e solucione o problema da identificação de
8 pólen pode ser utilizado em diversas áreas de conhecimento, que demandam esta técnica, como
9 a paleopalinologia, melissopalinologia, palinologia, palinologia forense, dentre outras. Essa
10 solução poderá reduzir o tempo de identificação, além de garantir maior precisão de sua
11 classificação, pois permite identificar com exatidão, uma maior quantidade de pólen em menos
12 tempo [2].

13 O trabalho apresenta sua contribuição na análise de técnicas de extração de atributos
14 com as técnicas Histograma de Palavras Visuais (Bag of Word - BOW), Cor Forma e Textura
15 (CFT), e uma terceira técnica que une as duas primeiras, ou seja, Bag of Word mais Cor Forma
16 e Textura (CFT+BOW), com aplicação em imagens microscópicas de diferentes tipos polínicos.
17 A principal contribuição desta pesquisa é o desenvolvimento de um programa de computador
18 que seja capaz de automatizar a identificação de pólen de maneira eficiente e rápida.

19 Na seção seguinte, são apresentados os trabalhos correlatos, seguido da seção de
20 materiais e métodos. Posteriormente, são apresentados os resultados, discussão e a conclusão.
21 Por fim, são sugeridos trabalhos futuros.

1 **Trabalhos Correlatos**

2 A importância da identificação de polens de outras eras para a reconstrução
3 paleoambiental do ecossistema remoto é descrito por France, Duller, Duller e Lamb [3]. Esses
4 autores também buscam automatizar o processo de determinação de pólen e relatam o uso de
5 redes neurais em teste na classificação de três tipos polínicos. Apesar da dificuldade na
6 classificação devido a deformidades na estrutura do pólen e agrupamentos dos grãos, os autores
7 conseguiram eficiência de até 97% na classificação de um tipo polínico.

8 A técnica para identificação de pólen com atributos de forma e textura, foi utilizada por
9 Rodriguez-Damian, Cernadas, Formella, Fernandez-Delgado e De Sa-Otero [4], para
10 classificação de polens da família Urticaceae, na qual alguns tipos polínicos são responsáveis
11 por provocar alergias respiratórias. Ressalta-se assim, a importância de se estabelecer um
12 sistema capaz de distinguir os polens desta família, que são frequentes durante todo o ano na
13 Espanha. O sistema desenvolvido conseguiu 89% de acerto na classificação dos polens
14 analisados, percentual esse que é maior do que um palinólogo pode acertar em sua rotina, ou
15 seja, 87.5% [5].

16 No trabalho de Chica e Campoy [6], com o objetivo de autenticar polens da flora local
17 como *Rubus*, *Echium*, *Cistus ladanifer*, *Quercus ilex* contra pólen exótico não identificado, eles
18 desenvolveram um sistema para reconhecimento destes quatro tipos polínicos mais frequentes
19 em plantas espanholas, baseando-se no atributo de cor dos polens. O sistema desenvolvido
20 conseguiu precisão de 94% na classificação dos tipos polínicos.

21 O desenvolvimento de um método baseado em segmentação *watershed* para automatizar
22 o processo de identificação de polens presentes no mel brasileiro, foi desenvolvido por
23 Andrade, Quinta, Gonçalves, Cereda e Pistori [7]. Para isso, os autores utilizaram um banco

1 com 333 imagens dos polens da família Fabaceae (60 imagens) e dos gêneros *Schinus* (136
2 imagens), *Protium* (64 imagens) e *Serjania* (73). A segmentação *watershed* consiste em reduzir
3 as informações desnecessárias na imagem através do desfocamento e suavização da imagem. O
4 melhor desempenho da técnica atingiu 98,93% de acerto.

5 O trabalho de Silva, Quinta, Gonçalves, Pistori e Borth [8] teve o objetivo de
6 automatizar a identificação de tipos polínicos, com as técnicas de cor, forma e textura em
7 imagens microscópicas de sete tipos polínicos encontrados na região Centro-Oeste do Brasil:
8 *A. colubrina*, *C. pachystachya*, *Myrcia*, *Protium*, *Schinus*, *Serjania* e *S. oleracea*. Os autores
9 utilizaram 30 imagens de cada tipo polínico, que primeiramente passaram por um processo de
10 segmentação por *watershed*. Então os atributos de cor, forma e textura foram extraídos das
11 imagens. Em especial, foi utilizada a técnica de transformada *wavelet* para extração da textura,
12 que através da matriz de co-ocorrência, extraiu atributos de contraste, correlação e entropia nas
13 imagens. Para análise do desempenho da técnica, utilizaram a métrica medida-F, que obteve
14 um valor de 79% de desempenho.

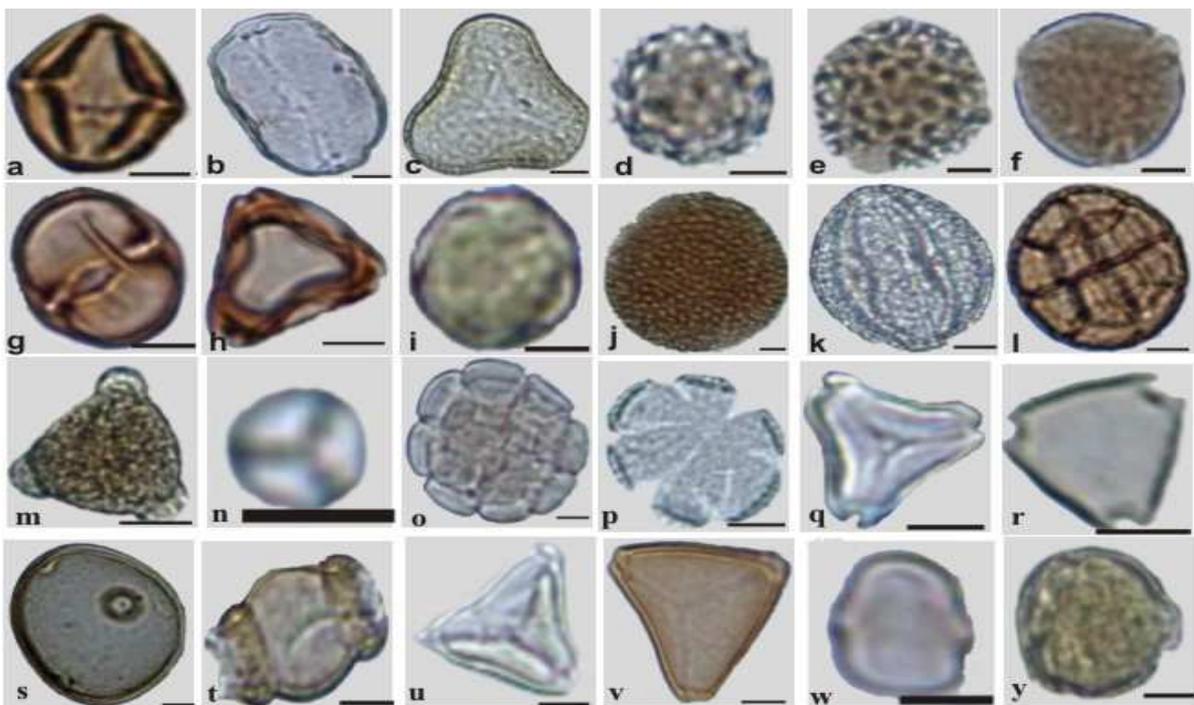
15 A técnica de histograma de palavras visuais foi utilizada para reconhecimento de nove
16 tipos polínicos encontrados no mel brasileiro, incluindo a *Anadenanthera colubrina*,
17 *Arecaceae*, *Cecropia pachystachya*, *Myrcia*, *Protium*, *Poaceae*, *Serjania*, *Schinus* e *Syagrus*
18 *oleracea*. O desempenho da técnica foi analisada por 5 classificadores. O melhor desempenho
19 para todos os tipos polínicos foi obtido com o classificador SMO que chegou a apresentar 100%
20 de acerto para o pólen de *Cecropia pachystachya* [9].

21

22

1 Material e Métodos

2 Foram selecionados 23 tipos polínicos (Fig. 12) comprovados como de importância
 3 apícola por ocorrerem com mais frequência em 68 amostras de méis do estado. Alguns dos
 4 grãos de pólen utilizados nesta pesquisa já foram relatados como de importância para apicultura
 5 do estado [7-10]. O curador do herbário da Universidade Federal de Mato Grosso do Sul,
 6 Arnildo Pott, identificou a origem dos pólenes, através das plantas coletadas. Para fabricação das
 7 lâminas microscópicas dos grãos de pólen, as anteras dos tipos polínicos utilizados foram
 8 retiradas das próprias flores e tratadas pelo método de acetólise proposto por [11].

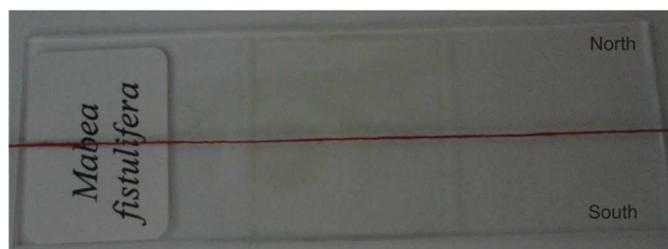


9 **a) Anacardiaceae:** *Schinus*; **b-c) Arecaceae:** b- *Arecaceae*; c- *Syagrus oleracea*.
d-e) Asteraceae: d) *Chromolaena odorata*; e) *Tridax procumbens*. **f) Bignoniaceae:**
Arrabidaea florida. **g-h) Burseraceae:** *Protium heptaphyllum* duas visões.
i) Combretaceae: *Combretum discolor*. **j-k) Euphorbiaceae:** j) *Croton urucurana*;
 k) *Mabea fistulifera*. **l-o) Fabaceae:** l) *Anadenanthera colubrina*; m) *Dipteryx alata*;
 n) *Mimosa somnians*; o) *Senegalia plumosa*; **p) Lamiaceae:** *Hyptis*. **q-r) Myrtaceae:**
 q) *Eucalyptus*; r) *Myrcia*. **s) Poaceae:** *Urochloa decumbens*. **t) Rubiaceae:** *Faramea*.
u-v) Sapindaceae: u) *Matayba guianensis*; v) *Serjania larrotteana*. **w) Urticaceae:**
 10 *Cecropia pachystachya*. **y) Vochysiaceae:** *Qualea multiflora*.

10 Figura 12: Imagem dos 23 tipos polínicos utilizados no experimento, representando a flora do
 11 Cerrado. (Escala = 10 µm).

1 A captura de imagens dos grãos de pólen foi realizada após o preparo das lâminas
2 palinológicas, que permite melhor visualização dos detalhes. Para contornar a representação
3 plana do grão de pólen, cada imagem de tipo polínico foi capturada várias vezes em diferentes
4 posições, para compor um banco de imagens.

5 Na lâmina palinológica foi estabelecida uma linha imaginária dividindo a lâmina em
6 dois setores, Norte e Sul (Fig. 13). No setor Norte, foram capturadas 30 imagens de cada tipo
7 polínico, que foram utilizadas para compor as imagens de treinamento, totalizando 690
8 imagens. No setor Sul da lâmina, foram capturadas 5 imagens de cada tipo polínico para compor
9 as imagens de teste, ao todo com 115 imagens.



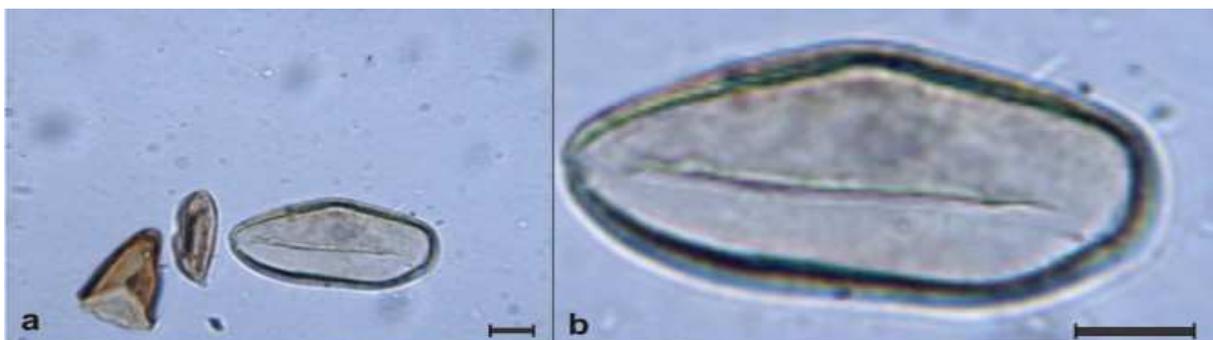
10
11 Figura 13: Lâmina palinológica dividida em setores para captura das imagens.

12 As imagens dos tipos polínicos compuseram o banco de imagem POLEN23E,
13 constituído de um total de 35 imagens de cada tipo polínico em diferentes ângulos de visões
14 dos grãos de pólen, que no seu conjunto disponibilizaram 805 imagens, que foram as utilizadas
15 nos experimentos. A captura das imagens foi realizada em microscópio digital LCD micro
16 Bresser com lentes de aumento de 40x (Fig. 14) em lâmina microscópica. As imagens foram
17 transferidas para um *laptop*, onde foi feita a segmentação (Fig. 15), usando o programa
18 Photoshop®, de maneira que em cada imagem, permanecesse somente o grão de pólen de
19 interesse.



1

2 Figura 14. Microscópio digital onde as imagens de pólen foram capturadas e armazenadas.



3

4 Figura 15. Processo de segmentação das imagens de pólen. a) Imagem capturada do
5 microscópio. b) Segmentação de um tipo polínico (Escala = 5 μ m).

6 Nos seguintes subtópicos serão apresentadas as técnicas utilizadas para extração de
7 atributos nas imagens de pólen pelo programa de computador. É apresentado como foi
8 mensurado o desempenho das técnicas manual e automática utilizando as métricas de percentual
9 de acerto, medida-F, área sob a curva ROC, que estão disponíveis no software Weka. Por fim,
10 são relatados os métodos estatísticos utilizados para comparar os resultados obtidos pelas
11 técnicas. Os resultados foram também comparados com a classificação polínica feita por leigos,
12 sem prévio treinamento em observação de morfologia de grãos de pólen. Por seu interesse
13 profissional nos resultados, esse confronto foi realizado com apicultores voluntários.

1 **Técnicas de Extração de atributos**

2 Extrair atributos de uma imagem consiste em retirar da mesma informações relevantes
3 e únicas que serão responsáveis por sua caracterização [12]. Foram utilizados os atributos cor,
4 forma, textura e gradiente para extração das informações das imagens de pólen. Os atributos de
5 cor, forma e textura foram agrupados em um único programa denominado técnica CFT [13]. A
6 técnica de cor utilizada foi obtida através da média dos canais H (matiz), S (saturação) B (brilho)
7 e R (vermelho). Para extração da forma, foram utilizados os métodos de fator de forma e
8 circularidade, com algoritmos de k-curvaturas e descritores de forma. Para a textura foi
9 utilizado o método de Matriz de Co-ocorrência, para a extração dos atributos de entropia e
10 contraste,

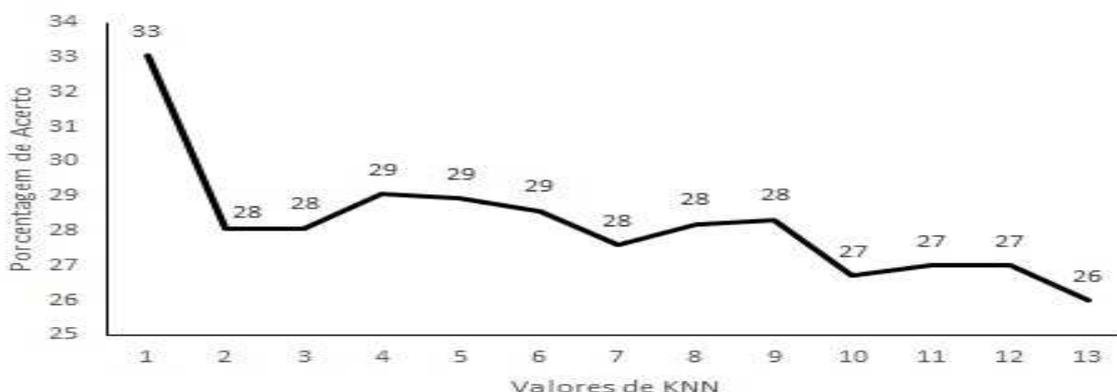
11 Para extração de informações de gradiente foi usado um algoritmo baseado em
12 histograma de palavras visuais (Bag of Visual Word, análogo ao Bag of Word - BOW) [14] e
13 [15]. Para estabelecer o melhor desempenho de classificação pela técnica de histograma de
14 palavras visuais, foram feitos testes com o tamanho do vocabulário variando exponencialmente
15 entre 02 à 8192. Para mensurar o desempenho dos vocabulários foram utilizados classificadores
16 KNN, J.48, assim como máquinas de vetores de suporte SMO. Os melhores desempenhos foram
17 encontrados para vocabulários de 512 e 1024 com o classificador SMO. Ambos atingiram 57%
18 com a métrica percentual correto de acerto.

19 Considerando que o melhor desempenho poderia estar entre esses intervalos, foram
20 realizados novos testes entre os valores de 514 a 768. Nestes testes, o vocabulário de tamanho
21 768 alcançou o melhor desempenho na classificação dos tipos polínicos analisados, com 60%
22 de classificação correta. Esse dicionário de tamanho 768 em conjunto com o algoritmo SURF
23 que realiza a extração de atributos na imagem, foram empregados para gerar os vetores. Por

1 fim, as técnicas descritas anteriormente foram agrupadas em um único programa que deu
2 origem à técnica CFT+BOW.

3 Para avaliar o desempenho das técnicas na identificação dos tipos polínicos, as imagens
4 de treinamento e de teste do banco POLEN23E foram agrupadas e submetidas à validação
5 cruzada com três dobras. Optou-se pela escolha de três dobras, por ser este valor o mais próximo
6 do que foi utilizado pelos apicultores, ou seja, 66% de imagens são utilizadas para treinamento
7 e 33% das imagens para teste.

8 O software Weka 3.7.9 Experimenter foi utilizado com os classificadores SMO e o J.48
9 todos com configuração padrão. Foram realizados testes nos valores de k do classificador KNN,
10 com variação entre os valores de 1 a 13. O melhor desempenho foi obtido com a configuração
11 do valor de k igual a 1, superior ao desempenho nos valores de k de 2 e 3. O desempenho obtido
12 com os valores de k 4 à 6 foram maiores que o anterior, mas inferior ao desempenho de k igual
13 a 1. Por fim, o desempenho do KNN com os valores de k entre 7 e 13 foram inferiores ao
14 desempenho obtido com os valores de k igual a 6. Como o desempenho começou a decrescer
15 substancialmente, o teste com os valores de k foram interrompidos (Fig. 16). Portanto, para o
16 classificador KNN a configuração adotada para análise das técnicas foi com de k igual a 1, por
17 seu melhor desempenho.

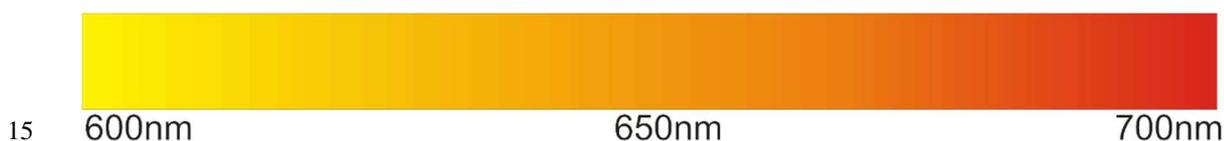


18

19 Figura 16. Teste com diferentes valores de k para o classificador KNN.

1 Para mensurar o desempenho de cada técnica na identificação dos polens, foram
2 utilizadas as métricas de Porcentagem de Classificação Correta (PCC), Medida-F e curva ROC.
3 A PCC apresenta o percentual de imagens identificadas corretamente em cada técnica. A
4 medida-F é uma média harmônica entre as identificações positivas verdadeiras, falsos positivos
5 e falsos negativos, que mede a capacidade do sistema na classificação de dados [16]. Quando a
6 métrica área sob a curva é avaliada, quanto maior for a área embaixo da curva, melhor é o
7 desempenho da técnica [12] and [17].

8 Para melhor representar os dados obtidos com a métrica PCC, os dados são apresentados
9 em uma matriz de confusão, que demonstra com qual tipo polínico cada imagem foi
10 classificada. Na matriz, as linhas representam os tipos polínicos que estão sendo analisados e
11 as colunas indicam como as imagens foram classificadas. A coloração da matriz de confusão
12 foi baseada no método termal [18], onde o número de classificação das imagens de cada classe
13 foi representado com cores em gradiente que variam do amarelo (mais baixo) ao vermelho (mais
14 alto), sendo intermediários os tons laranjas (Fig. 17).



16 Figura 17. Representação da grandeza da porcentagem de classificação correta por cores.

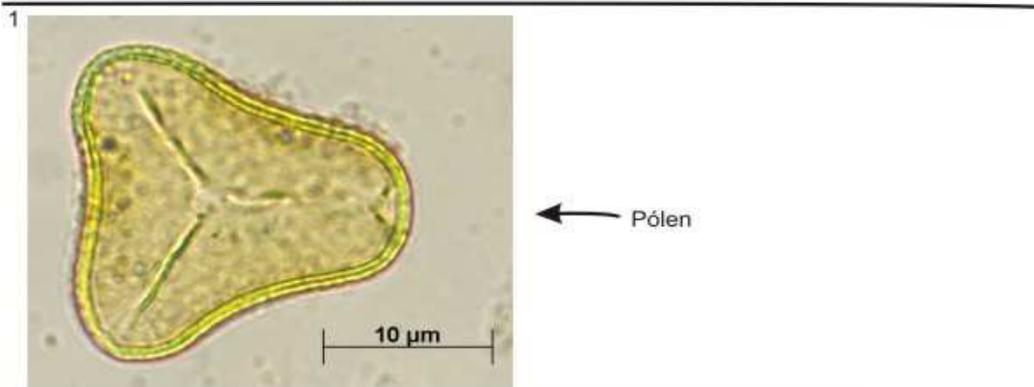
17 O teste estatístico T-Student com intervalo de confiança de 95% foi empregado para
18 avaliação do desempenho das técnicas em relação às métricas. A análise estatística das técnicas
19 utilizadas foi feita no programa estatístico R. Foi empregado o teste ANOVA com intervalo de
20 confiança de 95% ($p < 0,05$), para gerar os gráficos de caixas. O pós-teste de Turkey foi
21 utilizado para análise duas a duas das técnicas que apresentaram diferenças. Também foi
22 aplicado o teste de Friedman adotando o intervalo de confiança a 95%.

1 Classificação por Visão Humana

2 Foi elaborado um questionário ([https://docs.google.com/forms/d/1m5Sa-](https://docs.google.com/forms/d/1m5Sa-XVxmojXsvS6yyqHtUBPB3DeJ8aXpuCY32TIC0/viewform)
3 [XVxmojXsvS6yyqHtUBPB3DeJ8aXpuCY32TIC0/viewform](https://docs.google.com/forms/d/1m5Sa-XVxmojXsvS6yyqHtUBPB3DeJ8aXpuCY32TIC0/viewform)) contendo as imagens dos grãos
4 de pólen e as opções nominais dos 23 tipos polínicos, de forma a permitir ser assinalada apenas
5 uma alternativa correspondente à imagem apresentada. O questionário foi aplicado para avaliar
6 o desempenho de leigos voluntários humano na classificação de pólen.

7 Para formulação do questionário, foram selecionadas aleatoriamente, do banco de
8 imagem POLEN23E Teste, duas imagens distintas de cada tipo polínico, totalizando 46
9 imagens que deveriam ser identificadas (Figura 18). Nas opções a serem marcadas, foram
10 colocados os nomes vernáculos de cada tipo polínico, para facilitar a assimilação das imagens.

Temos a seguir 46 imagens de grãos de pólen. Para cada imagem, escolha (clique) a opção que melhor representa a espécie do grão de pólen. Ao final da página, clique no botão enviar para fechar o formulário e enviar as suas respostas.



1 Marque uma opção para o tipo polínico que este pólen pertence.

- Alfazema-brava (*Hyptis* sp.)
- Almecega (*Protium heptaphyllum*)
- Angico (*Anadenanthera colubrina*)
- Aroeira (*Schinus* sp.)
- Arranha-gato (*Senegalia plumosa*)
- Brachiaria (*Urochloa decumbens*)
- Café-do-mato (*Faramea* sp.)
- Camboatá (*Matayba guianensis*)
- Canela-de-ema (*Combretum discolor*)
- Cumbaru (*Dipteryx alata*)
- Cipó-neve (*Arrabidaea florida*)
- Cipó-uva (*Serjania larrotteana*)
- Dorme-dorme (*Mimosa somnians*)
- Eucalipto (*Eucalypto* sp.)
- Guariroba (*Syagrus oleracea*)
- Imbaúba (*Cecropia pachystachya*)
- Mamoeiro-selvagem (*Mabea fistulifera*)
- Margarida-do-campo (*Tridax procumbens*)
- Mata-pasto (*Chromolaena odorata*)
- Myrcia (*Myrcia* sp.)
- Palmeira (*Arecaceae*)
- Pau-terra (*Qualea multiflora*)
- Sangra-d'água (*Croton urucurana*)

12 Figura 18. Disposição das questões no questionários.

1 Do banco POLEN23E foram utilizadas 5 imagens de cada tipo polínico, totalizando 115
2 imagens de grãos de pólen, para compor o material de apoio
3 (<https://docs.google.com/file/d/0B5giTXRwIBEPQ2JJeVp3YWd0MUU/edit>) (Fig. 19). Os
4 leigos voluntários tiveram acesso ao material didático para fazer a classificação das imagens
5 que apareciam no questionário, exemplificadas na Fig. 18, pelo pólen de arranha-gato. Neste
6 material, também optou-se por utilizar o nome comum das plantas de origem dos tipos
7 polínicos, pela facilidade de memorização.



9 Figura 19. Exemplo de imagens do polen da espécie *Senegalia plumosa*, nome comum arranha-
10 gato, e da maneira que estava no material de apoio.

11 Para este experimento, foi utilizado um grupo voluntário de 34 apicultores sem
12 conhecimento de identificação polínica. Eles foram instruídos (Fig. 20) sobre como fazer a
13 classificação dos 46 tipos polínicos presentes no questionário-virtual, com a possibilidade de
14 assinalar apenas uma alternativa que fosse referente à imagem apresentada.

15 O tempo de início da resolução do questionário foi marcado e durante a classificação, o
16 grupo teve acesso ao material auxiliar, contendo as 5 imagens de cada tipo polínico que foram
17 utilizadas como treinamento para os apicultores. Ao final do teste, o participante clicou no botão
18 'submeter' do questionário e este foi salvo e enviado para o e-mail do pesquisador, com as
19 respostas e o horário de término de resolução do questionário.



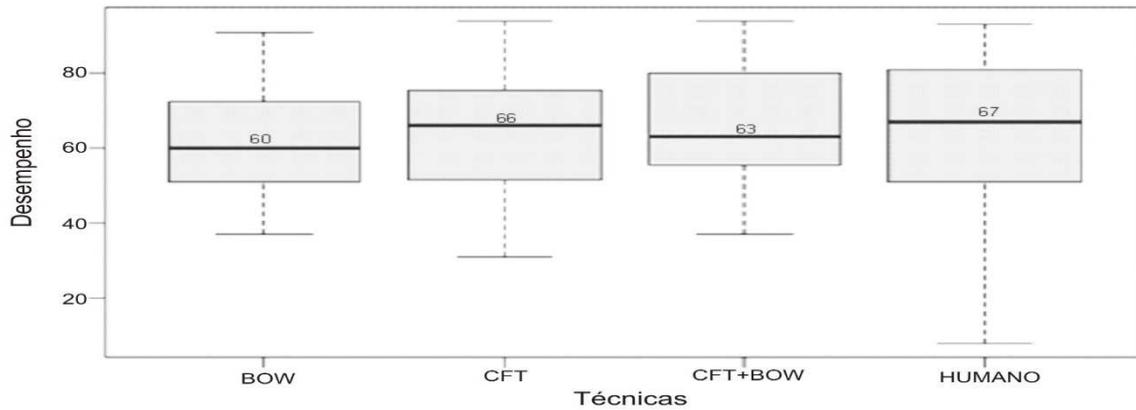
1

2 Figura 20. Apicultores voluntários sendo instruídos sobre como fazer a classificação dos tipos
3 polínicos.

4 O desempenho humano na classificação dos tipos polínicos e o tempo foram parâmetros
5 utilizados para comparação do desempenho entre diferentes técnicas de extratores de atributos
6 de imagens através da aprendizagem de máquina, que torna possível estabelecer o desempenho
7 da classificação das técnicas computacionais em relação ao humano.

8 **Resultados**

9 A comparação do PCC de cada técnica confirmou a hipótese de que não houve diferença
10 significativa entre as técnicas ($p= 0.1902$), dispensando o pós teste de Wilcoxon. A Fig. 21
11 representa o resultado estatístico do desempenho das técnicas utilizadas na pesquisa pelo teste
12 ANOVA, mostrando que não houve diferença entre as técnicas ($p= 0.576$), ou seja, não pode-
13 se descartar a hipótese nula.



1

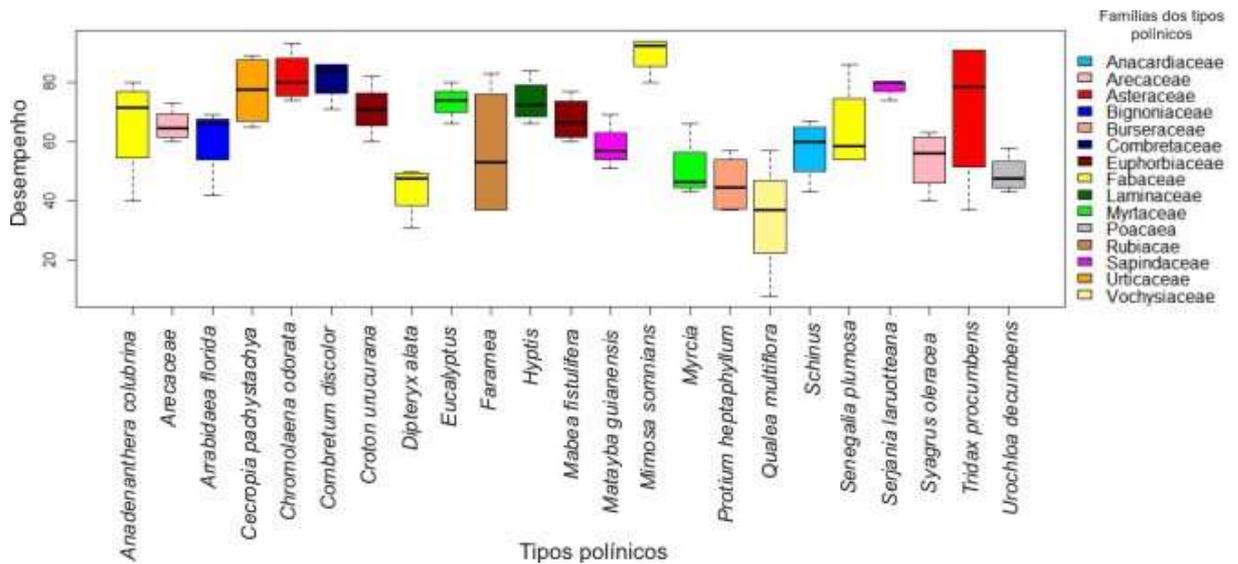
2 Figura 21. Diagrama de caixas com o desempenho estatístico das técnicas ($p= 0.576$).

3

4

5

A Fig. 22 apresenta o desempenho da classificação correta obtida por cada tipo polínico com todas as técnicas analisadas. O teste ANOVA comprovou que houve diferença significativa, para os tipos analisados, confirmando as diferenças dos tipos polínicos entre si.



6

7 Figura 22. Diagrama de caixas com o desempenho de classificação dos tipos polínicos ($p=$

8

0.000000125).

9

10

11

Os resultados destacam que não foi possível distinguir dentre as 15 famílias analisadas, uma família específica que tenha levado à um melhor desempenho de classificação que outra, fato possível de ser observado entre os gêneros [1] e [19]. Pólen da espécie *Tridax procumbens*

1 apresentaram grande variação de porcentagem de acerto na classificação, com variação entre
 2 37% à 91%. O pólen que proporcionou o maior índice de acerto com as técnicas testadas foi
 3 *Mimosa somnians*, com variação na porcentagem de acerto entre 80% à 94%, enquanto o que
 4 apresentou menor índice de acerto foi o pólen de *Serjania laruotteana*, 74% a 80%.

5 As Tabelas 1, 2 e 3 apresentam os resultados do desempenho das técnicas
 6 computacionais em relação a cada classificador testado, onde o primeiro classificador SMO é
 7 comparado com os demais classificadores. Os melhores resultados são destacados em negrito.
 8 A Porcentagem de Classificação Correta (Tabela 1) representa o índice de acerto na
 9 classificação dos polens por cada técnica. O melhor desempenho foi de 64% com a técnica
 10 CFT+BOW e o classificador C-SVC. A técnica CFT apresentou desempenho de 63% e o BOW
 11 61%. Em ambos os testes o melhor classificador foi o C-SVC.

12 Tabela 1: Desempenho das técnicas sob análise da métrica PCC.

CLASSIFICADORES	TÉCNICAS		
	CFT	BOW	CFT+BOW
SMO	48 ± 2.21 ^{Bc}	60 ± 2.58 ^{Aa}	63 ± 2.26 ^{Aa}
C-SVC	63 ± 3.89^{Aa}	61 ± 2.59^{Aa}	64 ± 2.13^{Aa}
J.48	54 ± 3.27 ^{Ab}	28 ± 3.27 ^{Cb}	47 ± 1.92 ^{Bb}
KNN	60 ± 2.15 ^{Aa}	30 ± 2.02 ^{Bb}	31 ± 2.42 ^{Bc}

13 Letras maiúsculas nas linhas representam as comparações entre os desempenhos das técnicas e letras
 14 minúsculas nas colunas representam as comparações entre o desempenho dos classificadores.

15 Com a métrica F-Measure (Tabela 2) obteve-se o melhor desempenho com o
 16 classificador C-SVC, para todas as técnicas. O desempenho do CFT foi de 63%, BOW (61%)
 17 e CFT+BOW foi de 64%, onde este último teve o mesmo desempenho com SMO. O
 18 desempenho com a métrica Area Sob a Curva ROC (Tabela 3) foi melhor com SMO, o
 19 desempenho do CFT foi de 95%, BOW (96%) e o melhor desempenho de técnica foi com CFT
 20 + BOW (97%).

21

22

1 Tabela 2: Desempenho das técnicas sob análise da métrica Medida-F.

CLASSIFICADORES	TÉCNICAS		
	CFT	BOW	CFT+BOW
SMO	46 ± 0.03 ^{Cd}	60 ± 0.03 ^{Bb}	64 ± 0.02^{Aa}
C-SVC	63 ± 0.04^{Ba}	61 ± 0.03^{Ca}	64 ± 0.02^{Aa}
J.48	54 ± 0.03 ^{Ac}	28 ± 0.03 ^{Cd}	47 ± 0.02 ^{Bb}
KNN	60 ± 0.02 ^{Ab}	29 ± 0.02 ^{Cc}	30 ± 0.02 ^{Bc}

2 Letras maiúsculas nas linhas representam as comparações entre os desempenhos das técnicas e letras
 3 minúsculas nas colunas representam as comparações entre o desempenho dos classificadores.

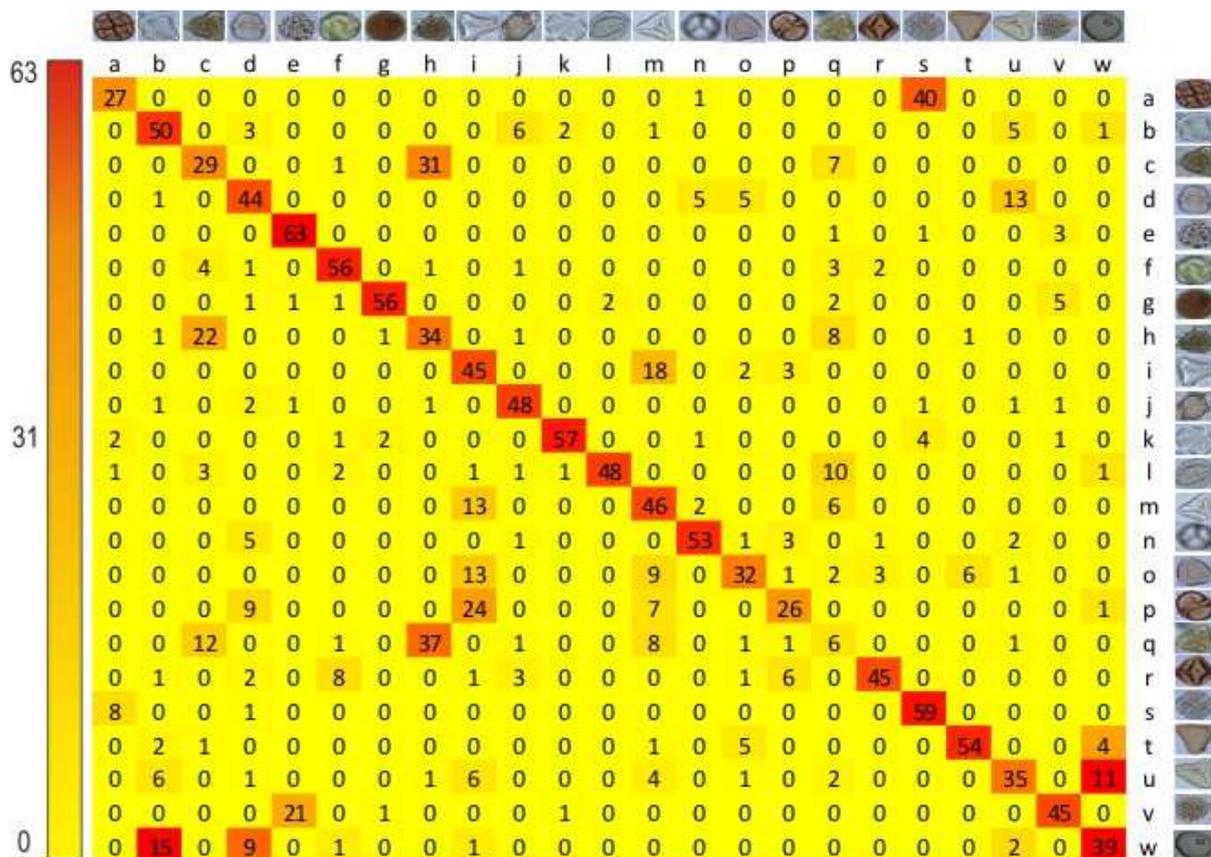
5 Tabela 3: Desempenho das técnicas sob análise da métrica área sob a curva.

CLASSIFICADORES	TÉCNICAS		
	CFT	BOW	CFT+BOW
SMO	95 ± 0.02^{Ca}	96 ± 0.04^{Ba}	97 ± 0.04^{Aa}
C-SVC	83 ± 0.08 ^{Bb}	86 ± 0.09 ^{Ab}	87 ± 0.08 ^{Ab}
J.48	76 ± 0.09 ^{Ad}	63 ± 0.09 ^{Cc}	73 ± 0.05 ^{Bc}
KNN	79 ± 0.09 ^{Ac}	56 ± 0.02 ^{Cd}	57 ± 0.03 ^{Bd}

6 Letras maiúsculas nas linhas representam as comparações entre os desempenhos das técnicas e letras
 7 minúsculas nas colunas representam as comparações entre o desempenho dos classificadores.

8 As técnicas que apresentaram melhores desempenhos com os classificadores testados
 9 foram selecionadas para gerar a matriz de confusão, que permite uma melhor visualização das
 10 classificações realizadas por cada técnica. A diagonal principal da matriz representa a
 11 quantidade de imagens classificadas corretamente. Os valores que não fazem parte da diagonal
 12 representam erros da classificação. A matriz de confusão para todas as técnicas foi construída
 13 com o desempenho obtido com a métrica PCC com o classificador C-SVC.

14 Na Fig. 23 é demonstrada a quantidade de acertos e erros dos tipos polínicos
 15 classificados pelo ser humano, onde 64% das imagens foram classificadas corretamente. O tipo
 16 polínico *C. odorata* foi o melhor classificado com 92% de acerto, em contrapartida, o tipo
 17 polínico *Q. multiflora* teve apenas 9% de classificações corretas.

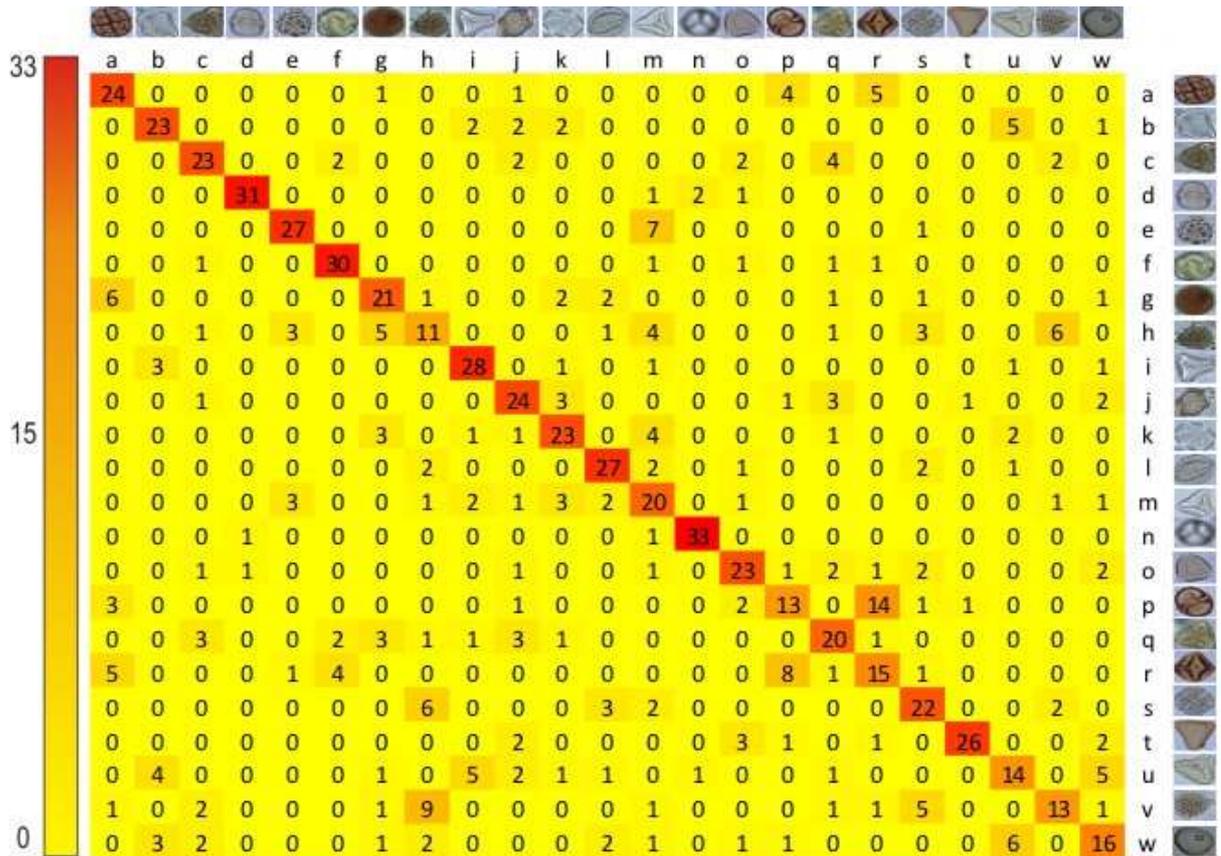


a) *Anadenanthera colubrina*; b) *Arecaceae*; c) *Arrabidaea florida*; d) *Cecropia pachystachya*; e) *Chromolaena odorata*; f) *Combretum discolor*; g) *Croton urucurana*; h) *Dipteryx alata*; i) *Eucalyptus* sp.; j) *Faramaea* sp.; k) *Hyptis* sp.; l) *Mabea fistulifera*; m) *Matayba guianensis*; n) *Mimosa somnians*; o) *Myrcia* sp.; p) *Protium heptaphyllum*; q) *Qualea multiflora*; r) *Schinus*; s) *Senegalia plumosa*; t) *Serjania laruotteana*; u) *Syagrus oleracea*; v) *Tridax procumbens*; w) *Urochloa decumbens*.

1

2 Figura 23. Matriz de confusão de PCC dos tipos polínicos classificados por visão humana de
3 voluntários leigos.

4 Na Fig 24, é apresentado o PCC com a técnica CFT. O pólen de *M. somnians* apresentou
5 o maior PCC das imagens (94%), além de ter sido o pólen com menor erro de classificação. Por
6 outro lado, o pólen de *D. alata* apresentou o menor desempenho, pois apenas 26% das imagens
7 foram classificadas corretamente.



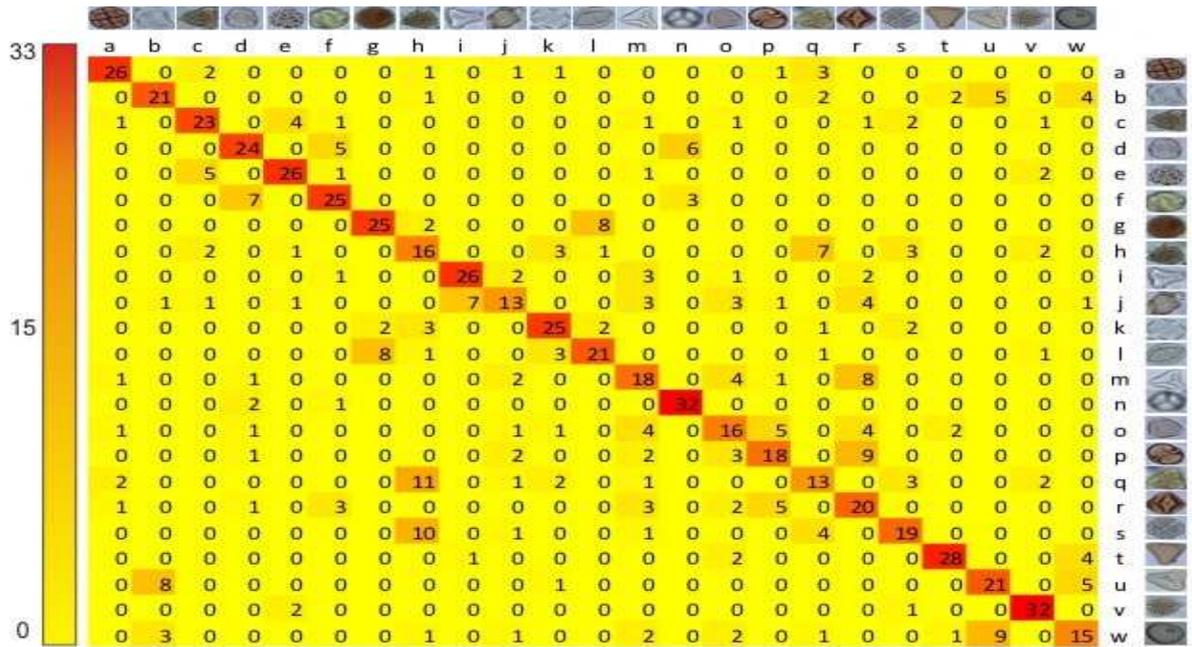
a) *Anadenanthera colubrina*; b) *Arecaceae*; c) *Arrabidaea florida*; d) *Cecropia pachystachya*; e) *Chromolaena odorata*; f) *Combretum discolor*; g) *Croton urucurana*; h) *Dipteryx alata*; i) *Eucalyptus*; j) *Faramea*; k) *Hyptis*; l) *Mabea fistulifera*; m) *Matayba guianensis*; n) *Mimosa somnians*; o) *Myrcia*; p) *Protium heptaphyllum*; q) *Qualea multiflora*; r) *Schinus*; s) *Senegalia plumosa*; t) *Serjania laruotteana*; u) *Syagrus oleracea*; v) *Tridax procumbens*; w) *Urochloa decumbens*.

1

2 Figura 24. Matriz de confusão com a técnica CFT.

3 Na técnica BOW, os tipos polínicos *M. somnians* e *T. procumbens* foram os que tiveram
 4 maior PCC, ambos com 91% de suas imagens classificadas corretamente, enquanto que o tipo
 5 *Q. multiflora* e *Faramea* foram os que tiveram o menor índice de acerto com 37% (Fig. 25).
 6 Na técnica CFT+BOW (Fig. 26), *M. somnians* obteve-se o maior percentual de acerto, com
 7 94%, enquanto que mais uma vez os tipos *Q. multiflora* e *Faramea* foram os que tiveram menor
 8 percentual de acerto com esta técnica, com apenas 37% de PCC.

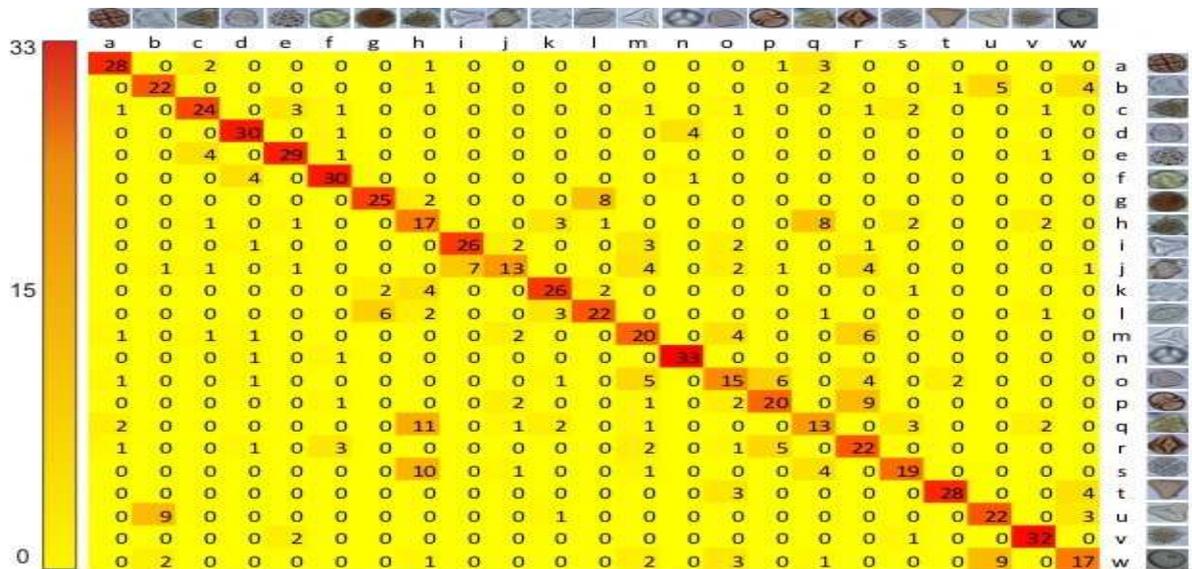
9



a) *Anadenanthera colubrina*; b) *Arecaceae*; c) *Arrabidaea florida*; d) *Cecropia pachystachya*; e) *Chromolaena odorata*; f) *Combretum discolor*; g) *Croton urucurana*; h) *Dipteryx alata*; i) *Eucalyptus*; j) *Faramaea*; k) *Hyptis*; l) *Mabea fistulifera*; m) *Matayba guianensis*; n) *Mimosa somnians*; o) *Myrcia*; p) *Protium heptaphyllum*; q) *Qualea multiflora*; r) *Schinus*; s) *Senegalia plumosa*; t) *Serjania laruotteana*; u) *Syagrus oleracea*; v) *Tridax procumbens*; w) *Urochloa decumbens*.

1

2 Figura 25: Matriz de confusão do desempenho da técnica BOW.



a) *Anadenanthera colubrina*; b) *Arecaceae*; c) *Arrabidaea florida*; d) *Cecropia pachystachya*; e) *Chromolaena odorata*; f) *Combretum discolor*; g) *Croton urucurana*; h) *Dipteryx alata*; i) *Eucalyptus*; j) *Faramaea*; k) *Hyptis*; l) *Mabea fistulifera*; m) *Matayba guianensis*; n) *Mimosa somnians*; o) *Myrcia*; p) *Protium heptaphyllum*; q) *Qualea multiflora*; r) *Schinus*; s) *Senegalia plumosa*; t) *Serjania laruotteana*; u) *Syagrus oleracea*; v) *Tridax procumbens*; w) *Urochloa decumbens*.

3

4 Figura 26: Matriz de confusão para o conjunto de dados CFT+BOW.

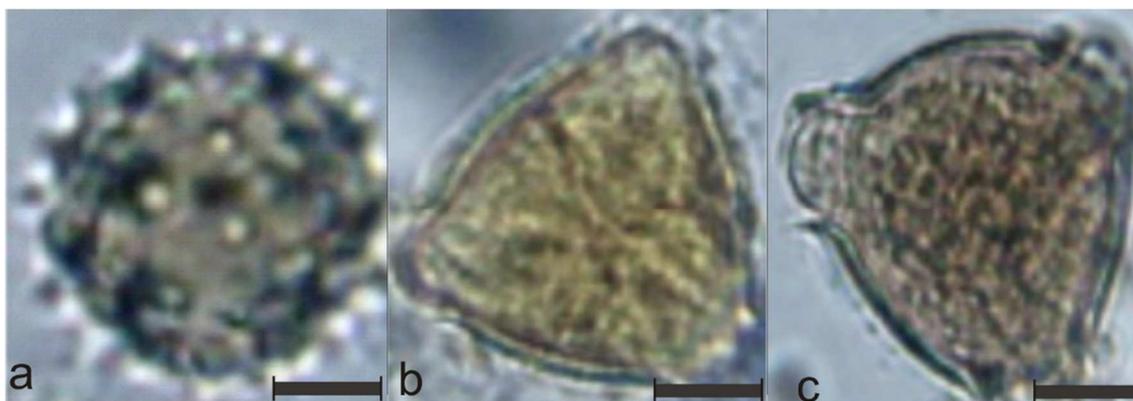
1 **Discussão**

2 Através do questionário, os apicultores informaram que o formato do grão de pólen,
3 além da coloração, tamanho e textura foram os critérios mais utilizados para a classificação dos
4 tipos polínicos. Eles relataram que analisaram principalmente o formato do grão de pólen, além
5 da coloração, tamanho e textura. Destaca-se que estas características foram também
6 selecionadas nas técnicas computacionais para obter as maiores orcentagens de acerto.

7 Embora o desempenho de classificação pela visão humana tenha sido muito próximo do
8 obtido pelas técnicas automáticas de classificação, os apicultores gastaram quase duas horas
9 para completar a classificação, enquanto que com as técnicas computacionais, o tempo foi de
10 menos de 10 minutos para classificação de todo banco de imagem. Assim, comprova-se a
11 eficiência do tempo de classificação realizada de maneira automática em relação à humana.

12 Nas avaliações realizadas pelos apicultores (Fig. 23), o tipo que obteve o maior índice
13 de acerto foi o tipo *C. odorata* (Fig. 27 A). O pólen dessa espécie possui um formato
14 arredondado e a presença de espinhos espaçados em sua superfície, que possivelmente
15 auxiliaram os apicultores no reconhecimento.

16 A maior dificuldade relatada pelos apicultores na classificação dos polens foi em relação
17 às formas similares dos grãos, falta de percepção do tamanho, imagens pouco nítidas e as
18 diferentes visões dos pólenes. Como apresentado na Fig. 23, *Q. multiflora* teve o pior PCC (9%),
19 explicado pela similaridade deste pólen com o pólen de *D. alata* em todas as visões planas dos
20 polens, como é possível observar na Fig. 27 B e C. Ademais, 54% das imagens de *Q. multiflora*
21 foram classificadas erroneamente como pertencentes à *D. alata*.



1

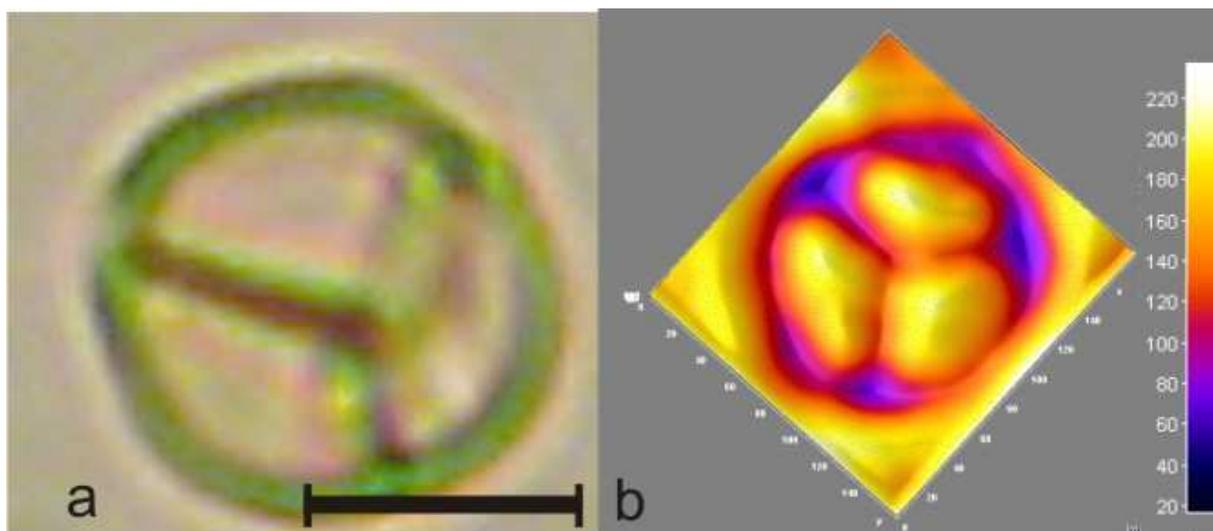
2 Figura 27: Polens que tiveram maior e menor PCC pelos humanos. a) *Chromolaena odorata*,
 3 melhor classificado; b) *Qualea multiflora*, pior classificação c) *Dipteryx alata*, similaridade
 4 com *Q. multiflora*. (Escala= 5 μ m)

5

Entre as técnicas CFT (Fig. 24), BOW (Fig. 25), CFT + BOW (Fig. 26) e também com
 6 visão humana (Fig. 23), os polens mais confundidos e com piores PCC foi *Q. multiflora* e *D.*
 7 *alata* (Fig. 27 B e C). Para corrigir este erro e permitir a distinção entre esses polens, mais
 8 imagens de diferentes ângulos e com mais detalhes externos da superfície dos grãos devem ser
 9 capturadas. Através da análise dos tipos polínicos classificados pelas técnicas computacionais,
 10 foi possível verificar que todos os atributos foram eficientes na extração de informações das
 11 imagens do tipo *M. somnians*, o que obteve melhor PCC com todas as técnicas utilizadas.

12

A análise do gradiente obtido das imagens de *M. somnians* (Fig. 28 A), permite explicar
 13 o resultado pelas características de sua superfície com pontos de mudanças de gradiente interno
 14 sem grandes variações na Fig. 28 B, com as cores frias, variando do amarelo ao laranja,
 15 destacando a superfície elevada do pólen. A mudança brusca de pixels próximos ao limite da
 16 borda do grão é representada por pixels com cores quentes, variando do vermelho ao roxo que
 17 destacam o decrescimento da superfície da borda do pólen. Por fim, os tons amarelos além do
 18 limite da borda do pólen representam o fundo de imagem (Fig. 28 B).



1

2 Figura 28: Imagem de *Mimosa somnians*. a) Imagem original. b) Variações de gradiente.
 3 (Escala= 2 μ m)

4 Este tipo de grão de pólen (Fig. 28 A) caracteriza-se por apresentar cor clara, distinta
 5 dos demais grãos de pólen que apresentam cores mais uniformes. Quanto a textura, é nítida a
 6 percepção de que as fissuras do pólen, auxiliaram na extração deste atributo. Quanto a forma,
 7 é possível visualizar a perfeita circularidade do grão, facilitando seu reconhecimento.

8 Como demonstrado anteriormente na Tabela 3, a técnica BOW obteve um desempenho
 9 de 96% na curva ROC, na classificação das imagens de pólen. Este valor foi bem próximo do
 10 desempenho obtido no trabalho de Lozano-Vega, Benezeth, Marzani e Boochs [20]. Esses
 11 autores buscaram automatizar a classificação do tipos polínicos pertencentes ao gênero *Betula*,
 12 pela forma das aberturas dos polens. No mesmo trabalho [20], os autores utilizaram a técnica
 13 BOW com um dicionário de 184 descritores, com 92 imagens apresentando as aberturas do
 14 pólen e 92 imagens sem as aberturas. A análise do desempenho da técnica foi analisada com
 15 SVM e o resultado avaliado com a métrica área sob a curva ROC com desempenho de 95.8%.

16 Não foram encontradas pesquisas que tenham utilizado igual ou mais tipo polínicos
 17 como o utilizado neste trabalho. O desempenho obtido com a técnica CFT+BOW (64%) com

1 23 tipos polínicos é menor do que o obtidos por Langford [2] (94,3%), Rodriguez-Damian [4]
2 (89%) e Chica e Campoy [6] (94%), no entanto, estes autores utilizaram de três a seis tipos
3 polínicos em suas pesquisas para alcançar os respectivos desempenhos.

4 Quanto mais tipos polínicos se utiliza para testes automáticos de identificação, maior é
5 o grau de complexidade para encontrar técnicas computacionais para distinção entre os grãos
6 de pólen com um desempenho aceitável. Assim, o resultado obtido pela presente pesquisa é
7 promissor, além de ser pioneira no Brasil na construção de um programa de computador para
8 identificação polínica, além do mais, o banco com 805 imagens de polens pode ser utilizado em
9 outros testes computacionais para identificação de polens.

10 **Conclusão**

11 As técnicas selecionadas foram eficientes em classificar os tipos polínicos em suas
12 respectivas espécies, gêneros e família, utilizados na pesquisa de maneira eficiente e rápida.
13 Assim, comprova-se a viabilidade de automatizar a identificação e grãos de pólen com as
14 técnicas apresentadas nesta pesquisa, que conseguiu identificar as imagens de 23 polens
15 distintos. Para aprimoramento da classificação é necessário melhorar a nitidez na captura das
16 imagens para que as estruturas polínicas sejam melhor reconhecidas pelo programa.

17 A melhor técnica para ser usada para automatização da classificação de tipo polínicos
18 foi CFT+BOW com o classificador C-SVC. Com o programa de reconhecimento de tipos
19 polínicos ele contribuirá com as pesquisas da flora local e de outras localidades, na
20 denominação de origem botânica de produtos apícolas, e demais áreas de interesse como
21 ciências forenses e alergologia, dentre outras.

1 Referências

- 2 1. Silva SJR, Absy ML (2000) Análise do pólen encontrado em amostras de mel de *Apis*
3 *mellifera* L. (Hymenoptera, Apidae) em uma área de savana de Roraima, Brasil. *Acta*
4 *Amazonica* 30: 579-588.
- 5 2. Langford M, Taylor GE, Flenley JR (1990) Computerized identification of pollen grains by
6 texture analysis. *Review of Palaeobotany and Palynology* 64: 197-203.
- 7 3. France I, Duller AWG, Duller GAT, Lamb HF (2000) A new approach to automated pollen
8 analysis. *Quaternary Science Reviews* 19: 537-546.
- 9 4. Rodriguez-Damian M, Cernadas E, Formella A, Fernandez-Delgado M, De Sa-Otero P,
10 (2006) Automatic detection and classification of grains of pollen based on shape and texture.
11 *IEEE Transactions on Systems Man and Cybernetics* 36: 531–542.
- 12 5. Mander L, Baker SJ, Belcher CM, Haselhorst DS, Rodrigues J, Thorn JL, Tiwari S, Urrego
13 DH, Wesseln CJ, Punyasena SW (2014) Accuracy and consistency of grass pollen identification
14 by human analysts using electron micrographs of surface ornamentation. *Applications in Plant*
15 *Sciences* 8: 1-11.
- 16 6. Chica M, Campoy P (2012) Discernment of bee pollen loads using computer vision and one-
17 class classification techniques. *Journal of food Engineering* 112: 50–59.
- 18 7. Andrade WT, Quinta LNB, Gonçalves AB, Cereda MP, Pistori H (2012) Segmentação
19 baseada em Textura e Watershed aplicada a imagens de Pólen. In: 25 Conference on Graphics,
20 *Patterns and Images* 108-113.

- 1 8. Silva DS, Quinta LNB, Gonçalves AB, Pistori H, Borth MR (2014) Application of wavelet
2 transform in the classification of pollen grains. African Journal of Agricultural Research 9: 908-
3 913.
- 4 9. Gonçalves AB, Rodrigues CNM, Cereda MP, Pistori H (2013) Identificação
5 computadorizada de tipos polínicos através de Bag of Words. Cadernos de Agroecologia 8:
6 14634.
- 7 10. Gonçalves AB, Vasconcelos BR, Thomaselli-Junior I, Silva-Coiado DG, Cereda MP (2011)
8 Identification of native bee trees pollen from honey samples of Mato Grosso do Sul, Brazil. In:
9 XLII International Apicultural Congress, Buenos Aires.
- 10 11. Louveaux J, Maurizio A, Vorrwohl, G (1970) Methods of melissopalynology. Bee World
11 51: 125-131.
- 12 12. Witten I, Frank E (2005) Data Mining: Practical Machine Learning Tools and Techniques
13 2 ed. United States of America: Elsevier 558.
- 14 13. Quinta LNB, Pistori H (2012) Visão Computacional aplicada na classificação de grãos de
15 pólen. Campo Grande: Universidade Católica Dom Bosco 50p.
- 16 14. Yang J, Jiang YG, Hauptmann AG, Ngo CW (2007) Evaluating bag-of-visual-words
17 representations in scene classification. Proceedings of the international Workshop on
18 Workshop on Multimedia information Retrieval , 197- 206.
- 19 15. Hotho A, Staab S, Stumme G (2003) Explaining text clustering results using semantic
20 structures. Principles of Data Mining and Knowledge Discovery, 22-26p.
- 21 16. Rijsbergen CA (1979) Information retrieval. London: Butterworths 288p.
- 22 17. Fawcett T (2006) An introduction to ROC analysis. Pattern Recognition Letters, 27: 861-
23 874.

- 1 18. Lee HC (2005) Introduction to Color Imaging Science. Cambridge: New York, 717p.
- 2 19. Santos, FAR, Pin-Ferreira, AB (2001) Variabilidade polínica de *Opuntia brasiliensis*
- 3 (Willd.) Haw. (Cactaceae). Sitientibus 1: 95-98.
- 4 20. Lozano-Vega G, Benezeth Y, Marzani F, Boochs F (2013) Classification of Pollen
- 5 Apertures Using Bag of Words. Lecture Notes in Computer Science 8156: 712-721.

CONSIDERAÇÕES FINAIS

Como relatado pelos humanos em conjunto, com a deficiência das técnicas utilizadas para classificar algumas imagens devido à falta de nitidez, sugere-se que para futuros trabalhos sejam utilizadas imagens nítidas, para correção deste problema e otimização da classificação correta das imagens. Uma maneira de tornar as imagens nítidas é através do empilhamento de imagens. É possível a captura de várias imagens de um mesmo pólen, mudando apenas o foco do que é observado. Assim, através do programa ImageJ é possível empilhar todas as imagens capturadas do grão, e formar apenas uma imagem com os detalhes adquiridos das imagens agrupadas.

O método de empilhamento deve ser utilizado na captura das imagens, pois não há perda dos detalhes dos grãos de polens e mesmo imagens desfocadas ficam nítidas com o agrupamento das imagens. Na Fig. 29, é possível visualizar o processo de empilhamento das imagens do tipo *D. alata*. Foram capturadas quatro imagens deste tipo, mudando apenas o foco no grão. Após o agrupamento das imagens é possível ver o resultado final na Fig. 29 E, que apresenta todos os detalhes adquiridos das imagens capturadas.

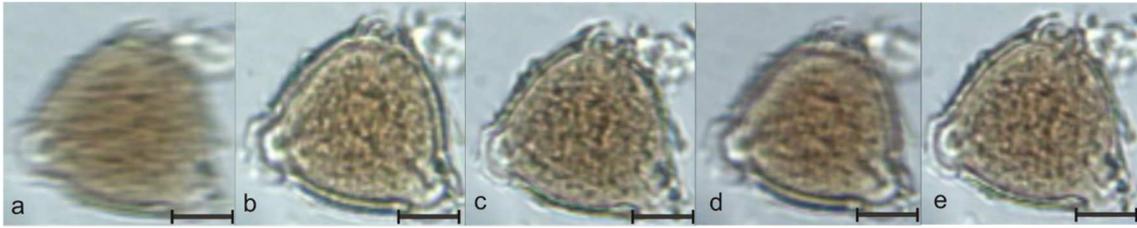


Figura 29: Agrupamento de imagens do tipo *Dipteryx alata*. a-d) Vários focos de um mesmo grão. e) Imagem nítida obtida através do agrupamento das imagens a-d.

NORMAS DA REVISTA



MANUSCRIPT BODY FORMATTING GUIDELINES

Modified December 2014

Abstract

Level 1 Heading

- Use Level 1 heading for all major sections (Abstract, Introduction, Materials and Methods, Results, Discussion, etc.).
- Bold type, 20pt font.
- Only use italics and text formatting where needed (e.g. genus and species names, genes, etc.).
- Do not use ALL CAPS.

NOTE: Do not cite figures, tables, supporting information, or references in the Abstract.

Lorem ipsum dolor sit amet, consectetur adipiscing elit. Vestibulum adipiscing urna ut lectus gravida, vitae blandit tortor interdum. Donec tincidunt porta sem nec hendrerit. Vestibulum nec pharetra quam, vitae convallis nunc. Mauris in mattis sapien. Fusce sodales vulputate auctor. Nam lacus felis, fermentum sit amet nulla ac, tristique ultrices tellus. Integer rutrum aliquet sapien, eu fermentum magna pellentesque vitae. Integer semper viverra mauris vel pulvinar. Suspendisse sagittis malesuada urna. Praesent mauris diam, fringilla id fringilla ac, posuere non lorem. Vestibulum mauris ante, fringilla quis tortor sit amet, accumsan fermentum quam. Nulla dictum consectetur leo. Ut vulputate ipsum purus, a interdum nibh viverra et. Praesent aliquam sapien vel massa sodales bibendum. Nulla interdum accumsan lectus, sed auctor elit accumsan a. Suspendisse quis rhoncus nibh. The verum est de illic.

Introduction

Lorem ipsum dolor sit amet, consectetur adipiscing elit. Vestibulum adipiscing urna ut lectus gravida, vitae blandit tortor interdum. Donec tincidunt porta sem nec hendrerit. Vestibulum nec pharetra quam, vitae convallis nunc.

Figure Citations

- Cite figures as “Fig. 1”, “Fig. 2”, etc.
- Cite figures and tables in order.
 - Do not cite “Fig. 2” before “Fig. 1”.
- Cite multiple figures as “Figs. 1 and 2”, “Figs. 1-3”, etc.

Materials and Methods

Lorem ipsum dolor sit amet, consectetur adipiscing elit. Vestibulum adipiscing urna ut lectus gravida, vitae (Fig. 1) interdum. Donec tincidunt porta sem nec hendrerit. Vestibulum nec pharetra quam, vitae convallis nunc. Mauris in mattis sapien. Fusce sodales vulputate auctor. Nam

sit amet nulla lacus a, Figs. 1 and 2 ultrices tellus. Integer rutrum aliquet sapien, eu fermentum magna pellentesque vitae.

Figure Legends

- Each figure legend should appear directly after the paragraph in which they are first cited.
- Do not include tables within legends.
- Use bold type for the figure titles.

Fig. 1. This is the Fig. 1 Title. This is the Fig. 1 legend.

Fig. 2. This is the Fig. 2 Title. This is the Fig. 2 legend.

File Naming for Figures

- Figure files should be saved as “Fig1.tif”, “Fig2.eps”, etc.
- Acceptable file formats for figures are “.tif”, “.tiff”, and “.eps”

Lorem ipsum dolor sit amet, consectetur adipiscing elit. Vestibulum adipiscing urna ut lectus gravida, vitae blandit tortor interdum. Donec et tincidunt porta sem nec hendrerit. *2p 2q*

Display/Numbered Equation

- Format display equations in Mathtype or Equation Tools.
- Do not use Graphic Objects.

$$(1) 2221ppqq++=$$

Inline Equation

- Format in regular text or as an inline equation in Mathtype or Equation Tools
- Do not use Symbol Font.
- Do not use Graphic Objects.

Vestibulum nec pharetra quam, vitae convallis nunc. Mauris in mattis sapien. Fusce sodales vulputate auctor. Nam lacus felis, fermentum sit amet nulla ac, tristique ultrices tellus. Integer rutrum aliquet sapien, eu fermentum magna pellentesque vitae. Integer semper viverra mauris vel pulvinar dolor sit amet en. *2()1pq+=*

Level 2 Heading

- Use Level 2 headings for sub-sections of major sections.
- Bold type, 16pt font.
- Only use italics and text formatting where needed.
- Do not use ALL CAPS.

Genotyping

Lorem ipsum dolor sit amet, consectetur adipiscing elit. Vestibulum adipiscing urna ut lectus gravida, vitae blandit tortor interdum. Donec tincidunt porta sem nec hendrerit. Omnes tuum basi sunt pertinent ad nos. Mauris in mattis sapien. Fusce sodales vulputate auctor. Nam lacus felis, fermentum sit amet nulla ac, tristique ultrices tellus. Integer rutrum aliquet sapien, eu fermentum magna pellentesque vitae. Integer semper viverra mauris vel pulvinar et alst.

Level 3 heading

- Use Level 3 headings for sub-sections within Level 2 headings.
- Bold type, 12pt font.
- Only use italics and text formatting where needed.
- Do not use ALL CAPS.

Whole genome RFLP analysis

Lorem ipsum dolor sit amet, consectetur adipiscing elit. Vestibulum adipiscing urna ut lectus gravida, vitae blandit tortor interdum. Donec tincidunt porta sem nec hendrerit. Vestibulum nec pharetra quam, vitae convallis nunc. Mauris in mattis sapien. Fusce sodales vulputate auctor. Numquam iens dare tibi up.

Modified December 2014

Results and Discussion

Tables and Table Citations

- Tables should be cited as “Table 1”, “Table 2”, etc.
- Cite multiple tables as “Tables 1 and 2”, “Tables 1-3”, etc.
- Tables should be included directly after the paragraph in which they are first cited.
- Tables must be cell-based in Microsoft Word or embedded with Microsoft Excel
- No hard returns.
- Do not use empty rows to create spacing.
- Do not include graphic objects, images, colored text, or shading patterns.
- Typeset tables will be formatted to match PLOS ONE style.
- See PLOS ONE Table Guidelines for more complete instructions

Lorem ipsum dolor sit amet, consectetur adipiscing elit. Vestibulum adipiscing urna ut lectus gravida, et bland Table 1 Donec tincidunt porta sem nec hendrerit. Vestibulum nec pharetra quam, vitae convalli. Fido nemo.

References

1. Doe J, Data A, van Stats J, Testperson M, Ribosome D Jr, McBio GHT, et al. (2014) This is the article title. PLOS ONE 0(0): e0.
2. Doe J, Data A, van Stats J, Testperson M, Ribosome D Jr, McBio, GHT et al. (In Press) Bunny dynamics in cartoon landscapes. PLOS ONE