



**UNIVERSIDADE CATÓLICA DOM BOSCO**  
**Centro de Ciências Exatas e da Terra**  
**Curso de Bacharelado em Engenharia de Computação**

## **Histograma de Superpixels para Aplicações em Palinologia Forense**

**Alexandre Fernandes Cese**  
**David Augusto Guimarães**

**Orientador: Prof. Dr. Hemerson Pistori**

Projeto de Graduação submetido à  
Coordenação do curso de Bacharelado em  
Engenharia de Computação da Universidade  
Católica Dom Bosco como parte dos  
requisitos para a obtenção do título de  
Bacharel em Engenharia de Computação.

Campo Grande - MS

Junho, 2017

## **Resumo**

*O projeto PALINOVIC busca automatizar o processo de detecção, quantificação e classificação de grãos de pólen. Isto é feito através de técnicas e algoritmos de Visão Computacional e em alguns casos Inteligência Artificial, dentre as quais Superpixels e Aprendizagem Automática foram escolhidas para serem aplicadas neste plano. Como este plano retrata o que já foi produzido anteriormente pelo projeto PALINOVIC, temos como objetivo aplicar novas técnicas para melhorar os resultados do Software já existente. Isto será possível através do aprofundamento e atualização das técnicas de Aprendizagem Automática, K-means e Superpixels, implementação dos algoritmos SLIC e K-means, validação do módulo das técnicas, integração com sistema já existente, e por fim, registro e divulgação dos resultados.*

### **1. Antecedentes e Justificativa**

Gonçalves (2015) descreve que o grão de pólen faz parte do órgão masculino de flores, que é composto por filete, antera e androceu (pólen), bem como carrega o material gênico que é responsável pela fecundação das flores. Os pólenes são compostos de basicamente duas estruturas: as paredes interna e externa, também chamadas de intina e exina, respectivamente. Tais estruturas apresentam certas aberturas ou fendas, que são chamadas de poros e permitem que o material gênico passe para que a fecundação seja feita (GONÇALVES, 2015). Tais aberturas nos pólenes podem ser utilizadas como informações para que os grãos sejam identificados e categorizados. Dentre as duas estruturas polínicas citadas anteriormente, a exina tem um papel crucial no processo de análise e identificação do pólen, porque é nesta estrutura (que também é chamada de parede externa) em que é possível visualizar os poros dentre outras características, que tornam possível a identificação do mesmo (GONÇALVES, 2015).

No entanto, a determinação dos grãos de pólen não se trata de uma tarefa trivial, uma vez que a exina, parede externa do grão, é muito parecida

em determinadas espécies. Em alguns casos, ainda, faz-se necessário classificá-los em tipos polínicos (GONÇALVES, 2015). Sendo assim, tal tarefa é desenvolvida por profissionais da área capacitados a fazer tal identificação a olho, utilizando ferramentas como um microscópio, por exemplo. Esta tarefa, então, apresenta limitações, uma vez que o técnico responsável pode apresentar cansaço ao longo do tempo.

Existem diferentes métodos de detecção, quantificação e classificação de grãos de pólen para diversas aplicações nas áreas da Palinologia (estudo da classificação e estrutura de grãos de pólen) e Palinologia Forense (análise de grãos de pólen em investigações cíveis e criminais), que é o alvo deste trabalho. Dentre estes métodos, podemos destacar a análise microscópica através da visão humana, que também apresenta limitações referentes a fatores biológicos que comprometem o processo de classificação ao longo do tempo. Isto ocorre devido a monotonia e repetitividade desta atividade que, após ser executada por várias horas por uma pessoa, acaba levando a erros. Além disto, esta é uma atividade que demanda um tempo considerável para ser executada (GONÇALVES, 2015). Um outro método alternativo que pode ser citado é o da contagem por varredura eletrônica (COSTA e YANG, 2009), que requer um microscópio de varredura, não presente em todas as instituições (GONÇALVES, 2015). No entanto, ambos os métodos se mostram passíveis de erros humanos (GONÇALVES, 2015).

O Projeto PALINOVIC tem como finalidade automatizar este processo, para a obtenção de resultados mais confiáveis, precisos e rápidos. Tal automação é feita por meio de algoritmos de visão computacional que tratam imagens microscópicas. Dentre as diversas técnicas do campo da Visão Computacional e Inteligência Artificial, foram selecionadas para este trabalho, a técnica de Superpixels, K-means e Aprendizagem Automática, respectivamente. Este trabalho retrata o que já foi produzido pelo projeto PALINOVIC, aplicando novas técnicas para que, assim, seja possível tratar o problema de maneiras diferentes e mais eficazes, tornando assim, os resultados mais precisos e confiáveis.

## **2. Objetivos**

### **2.1. Geral**

Desenvolver um *Software* de Visão Computacional baseado em um novo algoritmo proposto neste plano de trabalho que seja capaz de realizar, de forma rápida e eficiente, contagens de grãos de pólen por meio da análise de imagens microscópicas, tornando seus resultados mais precisos e confiáveis, melhorando, então, os resultados de um *Software* já existente do Projeto PALINOVIC chamado “*pynovisao*”.

### **2.2. Específicos**

Para atingir o objetivo geral definido na seção 2.1, foram estabelecidos os seguintes objetivos específicos:

- ✦ Aprofundamento e atualização da técnica de Segmentação por Superpixels baseada no Algoritmo SLIC
- ✦ Análise e Compreensão do Algoritmo K-means
- ✦ Implementação do novo Extrator de Atributos “Bag of Superpixels”
- ✦ Validação

## **3. Revisão de literatura**

### **3.1. Palinologia Forense**

Palinologia é a ciência que estuda pólen, foi usada tanto para investigações de crimes como para estudos arqueológicos para determinar a idade de fósseis. Tanto para os estudos arqueológicos como para as investigações forenses, a técnica envolve coletar pólen das vítimas ou fósseis, que seriam partículas microscópicas que estão no ar e grudam na roupa ou pele a todo o momento (WRAY, 2016).

A partir disto, há a coleta destes pólen de uma vítima e com a determinação da espécie do pólen, pode-se determinar de que tipo de planta aquele determinado pólen vem. Com o mapa da cidade e sabendo onde cada

árvore está, pode-se determinar aproximadamente em que região daquela cidade a pessoa estava ou até em que região do país o mesmo se encontrava.

Pode-se descobrir que este tipo de investigação ocorre há anos na Europa, Austrália e está começando a ter popularidade nos EUA. O grande problema do processo é a classificação dos pólenes, já que há milhares de espécies de pólenes e muitos são parecidos, além do fato de que, por investigação, há geralmente centenas de pólenes e verificar um a um é um trabalho demorado e árduo (WRAY, 2016). É daí que surge a necessidade de se fazer programas de computador que têm a possibilidade de serem mais consistentes do que humanos e podem ser mais rápidos também.

## 3.2. Visão computacional

### 3.2.1. Superpixel

O método usado para classificar superpixels é chamado SLIC, usando um plano 5-D, com os parâmetros sendo os valores l,a,b do espaço de cores CIELAB, junto com as posições x e y de cada pixel, Para uma imagem de N pixels com K superpixels, o tamanho aproximado de cada superpixel é N/K, onde cada centro de superpixel está em um intervalo de  $S = \sqrt{\frac{N}{K}}$  (SMITH, 2010). A função que determina a distância de cada pixel é dada pelas seguintes expressões:

$$D_{lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2}$$
$$d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2}$$
$$D_s = d_{lab} + \frac{m}{s} d_{xy}$$

As expressões acima constituem-se de funções feitas para a medição de distância entre os superpixels no plano 5-D.  $D_{lab}$  se constitui da distância dos pixels no plano de CIELAB,  $d_{xy}$  se constitui da distância euclidiana entre os pixels pela localização deles na imagem (SMITH, 2010).

Nas mesmas expressões,  $D_s$  se constitui da função final que será usada como critério de distância entre os pixels no plano 5-D. Nesta função, pode-se determinar o quão compacto os superpixels são aumentando o valor de  $m$ , que dá mais ênfase à distância  $d_{xy}$ , normalizada pelo intervalo de grade  $S$ . O valor de  $m$  varia entre 1 e 20 (SMITH, 2010), porque, pondo mais de 20, isso daria muita ênfase à distância euclidiana entre os pixels na imagem, assim aglomerando apenas os pixels mais próximos uns dos outros, sem critério de cor e forma.

### 3.2.2. *Data clustering* com k-means

Em vários campos de pesquisa, como taxonomistas, cientistas sociais, psicólogos, biólogos, estatísticos, matemáticos, engenheiros e pesquisadores médicos, há muito uso de *clustering* (aglomeração, junção) de dados para classificação dos mesmos (JAIN, 2009). Neste trabalho, será usado *clustering* em visão computacional com o k-means.

K-means é o algoritmo tradicional de inteligência artificial onde uma das limitações dele é o fato de termos de escolher o número de *centroids* que temos que usar. Um dos objetivos de qualquer pesquisa em k-means é saber o número correto  $k$  de *centroids* a serem usados para classificar as imagens corretamente.

Os *centroids* seriam apenas pontos em um espaço de  $d$  dimensões onde os dados de nossa escolha residem, outra parte em que iremos estudar várias possibilidades de dados extraídos dos superpixels produzidos de início para serem classificados, e estes dados seriam classificados em  $k$  grupos de dados.

A função abaixo representa uma função local, aplicada a cada um dos  $k$  *centroids* para a classificação de cada elemento baseado no erro quadrático entre cada elemento e um *centroid*. O objetivo é escolher os elementos mais pertos para o  $k$  *centroid* e minimizar o  $J(c_k)$  (JAIN, 2009).

$$J(c_k) = \sum_{x_i \in C_k} (x_i - \mu_k)^2$$

O objetivo do k-means é achar o mínimo global dos erros quadráticos entre os centroids e todos os elementos em cada conjunto, este representado pela equação abaixo (JAIN, 2009).

$$J(c) = \sum_{k=1}^k \sum_{x_i \in C_k} (x_i - \mu_k)^2$$

No entanto, o k-means apenas acha mínimos locais na função  $J(c)$ , por isso precisa-se fazer vários testes com diferentes k para se definir o melhor k para esse tipo de experimento.

K-means será usado apenas para classificar cada superpixel do banco de imagens em k grupos. Com os superpixels categorizados, cada imagem terá um histograma com a quantidade de tipos de superpixels que cada imagem contém.

### 3.2.3. Bag of Superpixels

Esta seção somente irá analisar um trabalho correlato com o que se pretende ser realizado neste trabalho. É um trabalho de localização de objetos com vizinhança de superpixels (FULKERSON, 2009).

É importante notar que este trabalho (FULKERSON, 2009) classifica motos, carros e bicicletas em uma imagem, objetos que usam mais de um superpixel, enquanto que polens podem caber em apenas um superpixel, logo, se feito apropriadamente, o nosso trabalho não necessariamente precisaria usar a vizinhança de superpixels.

Este trabalho usa quick shift para extrair superpixels da imagem. Neste caso, os superpixels produzidos não tem tamanho fixo, algo que seria muito útil em polens. Descritores SIFT são extraídos de cada superpixel, e estes são processados por k-means com o resultado sendo incluído em um histograma (FULKERSON, 2009). E esta é uma estrutura básica para o bag of superpixels que intendemos fazer.

No trabalho de Fulkerson, cada superpixel classificado baseado no label mais frequente que ele contém, e depois é passado por um SVM (Support Vector Machine) para achar que objeto cada superpixel seria. Porém, como o projeto de Fulkerson demanda a classificação de um objeto dentro da imagem

e não de um superpixel, eles usam grafos para classificar uma vizinhança de superpixels e assim, achar e classificar o objeto (FULKERSON, 2009).

### **3.2.4. Histograma de Superpixels**

O objetivo final deste trabalho é montar uma estrutura que usa histograma de superpixels. Este programa vai extrair X características de cada superpixel de todas as imagens com apenas um pólen em um banco de dados e marcá-las com o respectivo tipo de pólen que se encontra na imagem.

Com todas as informações dos superpixels postas em um plano de XD, acha-se K *centroids* com K-means no plano. Define-se qual destes *centroids* são plano de fundo para serem ignorados no processo de fabricação do classificador.

O próximo passo é fazer o histograma de superpixels para cada tipo de pólen, usamos técnicas de machine learning para definir as áreas em que cada classe de pólen se encontra.

Com o classificador pronto, é apenas passar novas imagens de pólen, o classificador deveria ignorar os K superpixels definidos como plano de fundo e classificar o único pólen na imagem pela quantidade de superpixels de cada tipo presente na imagem.

## **4. Metodologia**

Para cada um dos objetivos específicos listados na Seção 3, serão apresentados a seguir os aspectos metodológicos que nortearão a execução desta proposta

### **4.1. Aprofundamento e atualização da técnica de Segmentação por Superpixels baseada no Algoritmo SLIC**

Através de consultas aos principais portais de periódicos mundiais, como IEEE Xplore, ACM DL, Science Direct e Scopus, serão identificados



artigos com trabalhos correlatos nas áreas de Segmentação por Superpixels e Palinologia Forense. Estes artigos serão revisados para complementar o texto apresentado neste plano de trabalho.

#### **4.2. Análise e Compreensão do Algoritmo K-means**

Através de atividades de pesquisa, materiais serão reunidos e estudados, bem como experimentos práticos de implementação serão realizados com o objetivo de melhor tratar o problema previsto neste plano de trabalho.

#### **4.3. Implementação do novo Extrator de Atributos “Bag of Superpixels”**

O módulo será desenvolvido em Linguagem Python, que foi escolhida por apresentar uma sintaxe de fácil aprendizado, bem como considerável desempenho computacional. Como citado anteriormente, um software na mesma linguagem já foi desenvolvido pelo grupo INOVISAO anteriormente: o pynovisao. Dentre as técnicas implementadas previamente no referido software, o segmentador SLIC será reaproveitado no trabalho proposto. Ainda, serão seguidas as regras definidas pelo grupo de pesquisa e desenvolvimento INOVISAO disponíveis no site do grupo<sup>1</sup>. A metodologia de desenvolvimento de software do INOVISAO tem como base o SCRUM (SIMS; JOHNSON, 2011) com todo o material produzido sob controle de versões utilizando a ferramenta GitLab<sup>2</sup>. No entanto, características de outros modelos de processo de software estão sendo estudados e devem ser aplicados no decorrer do projeto, como por exemplo o método ágil XP. O padrão de documentação de código é baseado no JavaDoc.

---

<sup>1</sup>O site do INOVISAO está em [www.gpec.ucdb.br/inovisao](http://www.gpec.ucdb.br/inovisao)

<sup>2</sup>O software de controle de versões GitLab é apresentado em <http://git.inovisao.ucdb.br/>.

#### **4.4. Validação**

Após a implementação do algoritmo “Bag of Superpixels,” proposto neste plano de trabalho, os resultados obtidos serão comparados aos algoritmos já implementados no *Software* anteriormente desenvolvido pelo grupo INOVISAO, tendo como base o banco de imagens de grãos de pólen também remanescente de trabalhos prévios correlatos. Para cada algoritmo testado, serão calculados os desempenhos médios, e então será constatado o quanto os resultados dos algoritmos diferem estatisticamente, comprovando as vantagens de uns em relação aos outros. Para validar o desempenho do *Software* em relação ao desempenho humano, serão convidados Peritos da Secretaria de Segurança Pública do Estado de Mato Grosso do Sul para realizar testes que consistem em mensurar e avaliar o tempo e acertos dos peritos, realizando comparações com os resultados obtidos pelo *Software*. Desta forma, será determinada a Taxa de Classificação Correta (*Correct Classification Rate - CCR*) do *Software*, que será uma das métricas de desempenho aplicadas. Ainda, outras métricas de desempenho serão utilizadas, como Medida-F (*F-Measure*) e Área Sob a Curva ROC (AUC), que são métricas comumente aplicadas em projetos desenvolvidos no grupo INOVISAO, e que inclusive já foram aplicadas em trabalhos correlatos.

#### **4.5. Integração com Sistema já Existente**

A integração será feita por meio da modificação do módulo já implementado anteriormente. Exemplos de modificações a serem citados é a adição de recursos na interface gráfica para que as técnicas implementadas fiquem disponíveis para que o usuário do sistema possa fazer uso das mesmas. Os códigos referentes as implementações das novas técnicas serão enviados ao repositório do grupo INOVISAO no Git, no diretório do módulo anteriormente implementado. Após isto, serão efetuados testes para a verificação de eventuais erros na integração, como por exemplo a utilização do software quanto a todas suas funcionalidades, antigas e novas. Uma vez que constatados comportamentos anômalos quanto a quaisquer das técnicas

disponíveis no sistema, eventuais erros de integração serão verificados diretamente no código da referida técnica. Por fim, após a correção de eventuais erros, a integração ao Sistema estará concluída.

Em resumo, as seguintes atividades serão realizadas:

1. Aprofundamento e atualização da técnica de Segmentação por Superpixels baseada no Algoritmo SLIC
2. Análise e compreensão do Algoritmo K-means
3. Implementação do novo Extrator de Atributos "Bag of Superpixels"
4. Validação
5. Integração com Sistema já Existente
  - a) Modificação do módulo já implementado anteriormente
  - b) Realizar teste para a verificação de erros na integração
  - c) Correção de eventuais erros encontrados na integração.

## 5. Cronograma

O cronograma de execução baseado na metodologia apresentada na seção anterior é apresentado na Tabela 1.

Item metodológico	Meses											
	1	2	3	4	5	6	7	8	9	10	11	12
1 - Aprofundamento e atualização da técnica de Segmentação por Superpixels baseada no Algoritmo SLIC	■	■	■									
2 - Análise e compreensão do Algoritmo K-means				■	■	■						
3 - Implementação do novo Extrator de Atributos "Bag of Superpixels"					■	■	■	■	■	■		
4 - Validação										■	■	■
5a - Modificação do módulo já implementado anteriormente											■	■
5b - Realizar teste para a verificação de erros na integração											■	■
5c - Correção de eventuais erros encontrados na integração											■	■

## 6. Referências Bibliográficas

GONÇALVES, Ariadne Barbosa. **Validação de Métodos Baseados em Visão Computacional para Automação da Identificação de Grãos de Pólen**. 2015. Dissertação (Mestrado) – Centro de Ciências Exatas e da Terra, Universidade Católica Dom Bosco, Campo Grande.

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.

SIMS, C.; JOHNSON, H. L. **The Elements of Scrum**. Dymaxicon, 2011.

WRAY, Diana. **Vaughn Bryant Uses Pollen to Pinpoint Where a Victim has Been and Maybe Solve a Crime**. Houston Press, 8, jun, 2016. Disponível em: <<http://www.houstonpress.com/news/vaughn-bryant-uses-pollen-to-pinpoint-where-a-victim-has-been-and-maybe-solve-a-crime-8519184>> Acesso em 04 abril de 2017.

SZELISKI, R.. **Computer Vision: Algorithms and Applications**. Springer, 2010. Disponível em: <[http://szeliski.org/Book/drafts/SzeliskiBook\\_20100903\\_draft.pdf](http://szeliski.org/Book/drafts/SzeliskiBook_20100903_draft.pdf)> Acesso em 04 abril de 2017.

SMITH, K. **SLIC Superpixels**. EPFL Technical Report 149300, June 2010. Disponível em: <[http://www.kev-smith.com/papers/SLIC\\_Superpixels.pdf](http://www.kev-smith.com/papers/SLIC_Superpixels.pdf)>. Acesso em 04 abril de 2017.

JAIN, A.K. **Data clustering: 50 years beyond K-means**. *Pattern Recognition Letters* 31.8 (2010), Disponível em: <<http://mlsurveys.s3.amazonaws.com/45.pdf>>. Acesso em 04 abril de 2017.

YANG, Jun, et al. **Evaluating bag-of-visual-words representations in scene classification**. *Proceedings of the international workshop on Workshop on multimedia information retrieval*. ACM, 2007. Disponível em: <<http://repository.cmu.edu/cgi/viewcontent.cgi?article=1947&context=compsci>>  
Data de acesso: 04 abril de 2017.

FULKERSON, Brian; ANDREA, Vedaldi; STEFANO, Soatto. **Class segmentation and object localization with superpixel neighborhoods**. *Computer Vision, 2009 IEEE 12th International Conference on IEEE, 2009*. Disponível em <<http://www.vision.cs.ucla.edu/papers/fulkersonVS09.pdf>>. Data de acesso: 04 abril de 2017.