# PLANO DE TRABALHO

**Título do Projeto:** Visão Computacional e Aprendizagem Automática para Aplicações em Agropecuária e Ciências Forenses.

**Título do Plano de trabalho:** Cálculo de Distribuição Polínica utilizando Redes Neurais Convolucionais.

**Orientador:** Hemerson Pistori (pistori@ucdb.br)

Orientando: Felipe Silveira (felipe silveira@live.com) RA: 161231

Curso: Engenharia de Computação Semestre: 5°

#### Resumo

A Palinologia é importante em diversas áreas da sociedade, incluindo a área Forense, para resolução de crimes. A partir da análise de grãos de pólen provenientes de amostras forenses, as imagens obtidas serão analisadas por um software que classificará os grãos de pólen e exibirá ao usuário a quantidade destes grãos de acordo com sua espécie. Tal software será desenvolvido a partir de técnicas de visão computacional e de aprendizagem de máquina, a partir de algoritmos segmentadores, extratores de atributos, classificadores, de aprendizagem automática e de redes neurais, que resultem em um software final, que execute sua tarefa de modo simples, rápido e eficaz.

#### 1. Antecedentes e Justificativa

Os grãos de pólen, mesmo que não vistos a olho nu, possuem uma relevante importância de nível mundial, já que estão presentes em todos os ecossistemas. Foi a partir dessa micropartícula proveniente das flores que a área da Palinologia nasceu, e dela outras diversas áreas do conhecimento se ramificaram, como por exemplo a Palinologia Forense, foco deste trabalho.

Sua contribuição é significativa pois torna-se o elemento primordial na Melissopalinologia, para a caracterização da origem botânica e geográfica de produtos apícolas, como por exemplo o mel, pólen e própolis. Atualmente, a partir da compra de um frasco de mel não é possível determinar a origem dos grãos ali presentes, sendo assim tornam-se limitadas a precisão e regularidade para a qualidade do mesmo. Segundo Gonçalves et al. (2014), quando se analisa amostras de produtos apícolas é possível identificar os grãos de pólen

presentes neles, pois o pólen é uma marca indelével da procedência botânica do produto, o que influência diretamente na sua denominação de origem.

Também na Imunologia, para a detecção dos pólens causadores de alergias. De acordo com Vieira et al. (2006), a importância da polinose no Brasil é uma questão que tem sido vista como de menor importância. Entretanto, o desenvolvimento de extratos brutos dos principais alérgenos de pólen de gramíneas relacionados à polinose no Brasil deve ser considerado para melhor compreensão da doença polínica em nosso meio.

Do mesmo modo, na Paleoecologia, na reconstrução de ecossistemas do passado a partir da reconstituição de floras pretéritas. Registros fósseis que preservam grãos de pólen, esporos e demais palinomorfos são abundantes, já que os mesmos se petrificam de forma fácil. A partir de uma mesma área é possível a obtenção de dados sobre a vegetação atual e também da que existiu milhões de anos atrás. Tais estudos permitem descrever as alterações do clima em diversas escalas de tempo e a resolução de mistérios que até hoje não foram desvendados pela sociedade.

Na Palinologia Forense, para a resolução de crimes. A partir da análise dos grãos provenientes de amostras de objetos pertencentes a cenas de crime, como por exemplo a roupa de determinada pessoa ou até mesmo o objeto utilizado para o crime, é feita a análise e classificação dos grãos presentes nesses objetos, assim guiando os forenses a pistas de suma importância. Dinis (2015) define que, efetuando uma análise polínica, e identificando o tipo de pólen existente no material em análise, é possível obter informações sobre o tipo de vegetação com que esse material contactou, direta ou indiretamente, sendo essa vegetação muitas das vezes específica. Desta forma, a comparação de amostras de pólen pode ser efetuada com o intuito de provar a existência ou inexistência de relação entre vítimas, suspeitos, testemunhas, objetos e/ ou locais.

Todas as áreas do ramo da palinologia possuem como elemento comum e principal o grão de pólen, e para que as mesmas possam realizar seus objetivos, há a necessidade da classificação desse grão. Resumindo, todas as áreas necessitam da identificação e contagem dos grãos de pólen e para tal feito o atual procedimento mais utilizado segue por:

 Obtenção de amostras para as lâminas palinológicas a partir das anteras ou esporângios, geralmente pelo método da acetólise. Nesse método, gera-se uma mistura dos esporos com anidrido acético e ácido sulfúrico,

- destruindo o conteúdo desnecessário e preservando as estruturas da parede do grão.
- Análise a partir de especialistas da área, para a sua classificação. Um microscópio comum possuindo a escala de 10x gera 100 diferentes pontos de visão a partir de uma lâmina palinológica, ou seja, uma lâmina com amostras de grãos de pólen pode gerar em média 100 diferentes imagens para sua visualização. A classificação dos grãos deve-se ao olho humano, portanto este processo é passível a diversos erros, já que a atividade é monótona e exaustiva. Por exemplo, o processo segue por especialistas da área visualizarem grão por grão a partir de diversos pontos de visão das lâminas, sendo que, uma pequena região geográfica como a cidade de Bonito-MS, gera em média cinquenta (50) lâminas com amostras dos grãos de pólen ali presentes.

Existem outros procedimentos, porém menos utilizados: a identificação por varredura eletrônica, que é um método muito preciso, mas o processo requer um microscópio especial e não são todas instituições que possuem recursos financeiros suficientes para a sua aquisição. E a identificação por partículas a laser, que além de ser uma técnica bastante precisa, o seu funcionamento garante uma boa identificação apenas com grãos esféricos e torna-se imprópia, pois existe uma vasta gama de espécies de grãos com diferentes formas.

Dos métodos para a classificação decritos, o mais comum é o primeiro pois não há a necessidade de um grande investimento financeiro, apenas de lâminas palinológicas com os grãos, de um microscópio e de um especialista da área. Os diversos erros humanos possíveis e o desgaste exercido são muito comuns na realização desta tarefa. Outro ponto importante é a indispensabilidade de um especialista da área, privando do estudo e de análise mais profunda sobre os grãos, leigos e amantes do assunto, por exemplo.

A precisão da ferramenta utilizada é um dos focos principais para uma boa identificação e contagem dos grãos. Os métodos para classificação descritos acima são usados, mas existem interferências por fatores externos, ou seja pela inviabilidade financeira, ou seja por erros humanos desnecessários em seu manuseio.

Este trabalho justifica-se no desenvolvimento do primeiro software de computador feito no Brasil capaz de automatizar a identificação, classificação e

realizar a correta contagem dos grãos de pólen a partir de suas imagens. Algoritmos fundamentais para o desenvolvimento do mesmo baseiam-se em Superpixels SLIC, Aprendizagem de Máquina Supervisionada e Redes Neurais Convolucionais. O software automatizará os processos existentes, permitindo a execução de suas tarefas de modo rápido, prático e eficaz, e criando a possibilidade de sua utilização por qualquer usuário, não apenas por especialistas da área, sobressaindo-se portando sobre as outras ténicas de classificação e contagem utilizadas em grãos de pólen para a Palinologia Forense.

### 2. Objetivos

#### 2.1 Geral

O objetivo geral desta proposta de projeto de Iniciação Científica é desenvolver um software de computador que realize a identificação e a contagem de diferentes espécies de grãos de pólen. A partir de técnicas de Visão Computacional e de Aprendizagem de Máquina a detecção e a contagem serão desenvolvidas. O software final será capaz de realizar seus objetivos de forma rápida e eficiente, causando uma melhora no atual processo (identificação e contagem) utilizado na Palinologia Forense para a resolução de crimes.

## 2.2 Específicos

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

- Implementação do banco de imagens polen23e e construção de um banco de imagens segmentadas.
- Desenvolvimento e implementação do módulo classificador de grãos de pólen.
- Desenvolvimento e implementação do módulo contador de grãos de pólen.
- Validação do software final, com interface interativa e de fácil manuseio.

### 3. Revisão de literatura

A Seção 3.1 resume toda as técnicas já desenvolvidas anteriormente e utilizadas para a implementação deste software pelo projeto Palinovic, a Seção 3.2 apresenta a área da Palinologia Forense, retratando o porquê do desenvolvimento e da utilidade deste software e a Seção 3.3 explana sobre as técnicas que serão implementadas e experimentadas.

### 3.1. O projeto Palinovic e técnicas anteriores

Durante cincos anos, ou seja, a partir de 2012, o projeto Palinovic, desenvolvido na Universidade Católica Dom Bosco, vem buscando criar um software para a classificação e contagem de grãos de pólen. Atualmente o projeto Palinovic é desenvolvido pelo grupo Inovisão.

O Inovisão é um grupo de estudantes, professores e pesquisadores criado em 2004 da Universidade Católica Dom Bosco (UCDB) e tem como principal objetivo a integração da pesquisa, o desenvolvimento regional e inovação tecnológica que permita contribuir para o desenvolvimento do estado do Mato Grosso do Sul (PISTORI, 2017).

Algumas das técnicas já estudadas pelo grupo para o desenvolvimento do mesmo foram: A técnica de Floresta de Caminhos Otimos (OPF). De acordo com Pistori et al. (2012), o problema de reconhecimento de padrões pode ser modelado para o uso de floresta de caminhos otimos em um grafo, definido em seu espaço o de atributos. Algoritmos de aprendizagem supervionada, tais como: C4.5, SVM e KNN geraram um resultado determinado a partir dos testes de Friedman e T-Students aplicados no resultado da taxa de acerto, recall, precision e f-score, também aplicado o algoritmo Best-first, a fim de se obterem os atributos mais relevantes, porém, os algoritmos nao apresentaram diferença estatística na classificação dos grãos.

Técnica de segmentação baseada em textura e Watershed. O objetivo de realizar a segmentação em problemas de classificação é decompor a imagem em sub-imagens, excluindo regiões que não são importantes e extraindo partes de interesse (PISTORI et al., 2012). O banco de imagens de grãos de pólen utilizado tinha um total de 333 imagens, sendo estas divididas em 4 classes de diferentes espécies: 60 imagens da espécie Fabaceae, 136 imagens de Schinus, 64 de Protium e 73 imagens de Serjania. A extração de atributos de textura por descritores, desfocagem gaussiana e a utilização do

processo de limiarização da imagem pelo método de seleção interativa foram os processos para esta técnica. A partir de métricas, como: PCC (percentual e classificação correta), CJ (coeficiente de Jaccard) e CY (coeficiente de Yule), o resultado final obteve uma taxa de acerto de 0,9893% na segmentação.

Identificação computadorizada de tipos polínicos através de Bag of Words. O uso da técnica de Bag of Words, que faz extração de atributos de uma imagem e é utilizada na área de visão computacional, permite gerar um histograma de cada imagem que contém as características da imagem, que é associada a sua respectiva classe com auxílio de um algoritmo de aprendizagem supervisionada (PISTORI et al., 2013). O BOW faz a extração de atributos de uma imagem, gerando um histograma com suas características. A partir dos pontos de interesse detectados um dicionário de 2048 descritores é gerado, para cada imagem, e a partir desses descritores são executados experimentos com algoritmos, por exemplo: SMO, IBK, J.48 e AdaBoost. Para o resultado as métricas Area Under Roc, User CPU Time Testing, Percent Correct e Weighted Average F Measure foram utilizadas. Como resultado final, o melhor desempenho foi obtido através do algoritmo SMO, que obteve 71% de acerto na métrica Percent Correct.

Aplicação da Transformada Wavelet na classificação de grãos de pólen. O principal alvo da detecção e segmentação dos pólens é reduzir a informação desnecessária da imagem para estágios posteriores (BORTH et al., 2014). A redução de atributos desnecessários é um processo fundamental, já que a partir de técnicas de pré-processamento, extração de atributos de forma, cor e textura e aplicação de Watershed para segmentação, as informação geradas são demasiadas. Os algoritmos utilizados foram o C4.5 e o KNN. Como resultado final, a Transformada Wavelet não possuiu bons resultados especificamente para o atributo de forma, porém ao combinar-se na execução vários atributos extraídos, o quadro melhora. A combinação da Transformada Wavelet juntamente com outros extratores gera um resultado melhor do que seria apenas o extrator, porém como ponto negativo, o tempo de execução torna-se bastante lento.

Extração de atributos e Aprendizagem de Máquina para a classificação de grãos de pólen da savana brasileira. A melhor técnica que deve ser usada para automatizar a classificação de pólen é CST + BOW com o classificador C-SVC (SILVA et al., 2016). O algoritmo CST foi criado, seu nome é baseado nos atributos utilizados de cor, forma e textura. A medição de seu desempenho foi

comparado com os seguintes grupos de experimentos: CorFormaTextura (CST), Bag of Words (BOW) e CST combinado com BOW. Quatro algoritmos de aprendizagem supervionada foram utilizados: SMO, SVM, J48 e KNN. O melhor resultado final obtido foi através do experimento CST+ BOW com o algoritmo SVM.

# 3.2. Palinologia Forense

Segundo Castellar et al (2016), muitos estudos comprovaram que a Botânica Forense pode desempenhar um papel importante nas investigações criminais. A identificação de estruturas da planta, da sua localização geográfica e da prevalência de determinada espécie em um local pode se configurar como peça-chave para a resolução de crimes. Além disso, através da identificação do perfil químico da droga apreendida pode-se confirmar a origem geográfica da planta utilizada para o seu refino, identificar as rotas de distribuição e comparar asdiferentes amostras apreendidas.

Diversas técnicas podem ser aplicadas para a resolução de crimes, segundo Nunes e Campolina (2013), a Palinologia é uma das mais utilizadas, pois pode ajudar a identificar o local de deposição do cadáver e ligar suspeitos e objetos em locais de crime. Os pólens podem ser encontrados agarrados em qualquer objeto ou pessoa. São altamente resistentes à degradação mecânica, biológica e química, e encontrados em grandes números.

A análise polínica consiste na identificação da espécie de planta e permite estimar o percentual de cada uma presente na amostra da prova. Depois de identificada a espécie a qual pertence o pólen, é feita a correlação da planta com o local do crime (CASTELLAR et al., 2016). A resolução de crimes a partir da Palinologia Forense é uma das técnicas mais utilizadas para tal, ligando pistas para o rastreamento de suspeitos.

### 3.3. Visão Computacional

Segundo Quinta (2013), na área da visão computacional, são desenvolvidos algoritmos para obtenção de informações a partir de imagens, algumas vezes, buscando a automatização de tarefas geralmente associadas à visão humana. Na visão humana, os olhos capturam as imagens e posteriormente o cérebro realiza a análise e identificação de seu conteúdo.

A visão computacional é tida como os olhos das máquinas, pois a partir de imagens, tem objetivo de extrair informações a fim de serem utilizadas para algum objetivo específico, no caso, classificar corretamente os grãos de pólen, gerando modelos e equações que visam corretas tomadas de decisão. Os serem humanos são capazes de, ao visualizarem qualquer coisa (macro imagens) identificarem os objetos ali presentes, definindo com extrema clareza, precisão e agilidade suas formas, cores e texturas, por exemplo.

O objetivo da visão computacional é desenvolver computacionalmente a habilidade que os seres humanos possuem, e que muitas vezes acaba tornando-se algo mais rápido e eficiente, a partir de algoritmos e técnicas computacionais já existentes e que também serão desenvolvidas. É uma área que relaciona o pré-processamento, a segmentação, a extração de atributos, o reconhecimento de padrões e por fim a detecção e o rastreamento de determinado objeto. Em resumo, esta área esta ligada em automatizar tarefas associadas a visão humana, no caso deste trabalho, visa automatizar a classificação e a contagem feita visualmente por especialistas da área da palinologia, corretamente e de forma mais rápida, mais barata e eficaz (PISTORI, 2013; QUINTA, 2013).

A seguir são descritas etapas de visão computacional juntamente com o modelo da ferramenta proposta e sua relação com a aprendizagem de máquina:

## 3.3.1. Obtenção de imagens

Em visão computacional a captura das imagens ou vídeos é realizada por um ou vários dispositivos como scanners, microscópios, ou câmeras digitais (TOMMASELLI et al., 2000). Após a captura de determinada imagem a mesma deve ser analisada computacionalmente, porém o computador não entende uma imagem visualmente e sim através dos valores de cada um dos

pixels ali presentes. Segundo Quinta (2013), a principal informação obtida refere-se à imagem a ser analisada. Uma imagem é composta por um conjunto de pixels. Cada um desses pixels pode fornecer uma série de informações. Dependendo do espaço de cor que esse pixel apresenta, um conjunto diferente de dados pode ser observado.

Como exemplo, a figura abaixo mostra como uma imagem é analisada computacionalmente, sendo a primeira imagem a original e a segunda uma matriz que possui os valores correspondentes a cada um de seus pixels:

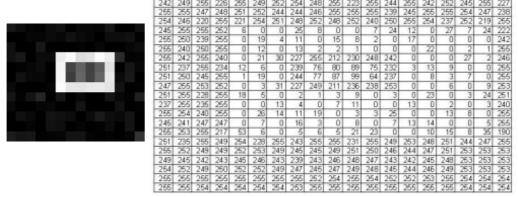


Figura 3.1 : Esquema ilustrando a matriz de pixels de uma imagem. Ao lado esquerdo uma imagem representativa e ao lado direito sua respectiva matriz de pixels.

# 3.3.2. Segmentação

Na etapa de segmentação, busca-se um particionamento da imagem em regiões de forma a separar elementos de interesse, para o problema a ser resolvido, de elementos que são irrelevantes para o problema. Em alguns casos, em problemas que envolvem contagem ou reconhecimento de múltiplos objetos, a segmentação, além de separar os elementos irrelevantes, separa os objetos de interesse em regiões distintas (PISTORI, 2013).

Marengoni e Stringhini (2009) afirmam que a segmentação dá-se através da partição de uma imagem em regiões ou objetos distintos. Esse processo é geralmente guiado por características do objeto ou região como a cor ou a proximidade.

A segmentação feita a partir de algoritmos de superpixels agrupa os pixels em regiões que podem ser utilizadas como substitutas da tradicional grade de pixels. Essa região é determinada a partir de características da imagem, gerando uma estrutura que diminui significativamente a complexidade das posteriores tarefas de pré processamento. Entre os algoritmos para

geração de superpixels, o algoritmo Simple Linear Iterative Clustering (SLIC) se destaca pela simplicidade de uso além de baixa utilização de memória e processamento (FERREIRA, 2017). Abaixo é dado um exemplo da segmentação padrão e da segmentação realizada através de superpixels SLIC:

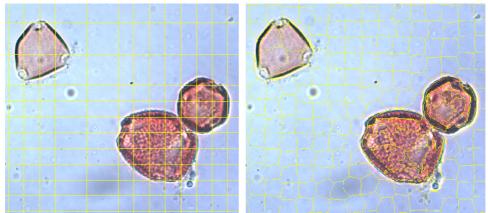


Figura 3.2 : Demonstração das diferenças da segmentação tradicional, ao lado esquerdo, e da segmentação pelo algoritmo SLIC, ao lado direito.

### 3.3.3. Extração de atributos

A extração de atributos é posterior a etapa de segmentação, já que para denotar cada grão de pólen baseia-se na obtenção de informações relevantes destes, seja por caracterizar uma determinada espécie ou por caracterizar o fundo da imagem, assim distinguindo os objetos de diferentes classes presentes (QUINTA, 2013). Em computação, uma classe é um agrupamento de informações de um mesmo objeto, nesse caso, uma classe pode ser representada como uma espécie de grão de pólen e as informações ali contidas são referentes a cada segmento pertencente a mesma.

Os dados a serem analisados são representados por um conjunto de características ou atributos e encontrar uma boa representação desses dados é algo específico que geralmente depende de especialistas da área, embora possa ser complementada por técnicas de extração automática. Conjuntos de informações dos pixels brutos relevantes são extraídos para cada classe, com objetivo de posterior identificação dos objetos ali presentes. A extração de atributos também serve para a redução da quantidade de informações ou para melhorar o desempenho do sistema. Em resumo, irá transformar o segmento (ou segmentos) da imagem que interessa aos módulos de processamento posteriores em uma outra representação, geralmente um vetor de atributos (PISTORI, 2013; QUINTA, 2013; FERREIRA, 2017).

A seleção de atributos verifica quais atributos são relevantes na caracterização de uma classe, desse modo apresenta uma lista de atributos relevantes e, com base nesses valores, um novo conjunto de atributos pode ser gerado. Esse novo conjunto irá conter o grupo de atributos selecionados pelos algoritmos. Em muitos casos, após a selecão de atributos, o resultado da classificação dos dados não sofre uma interferência negativa. Sendo assim, a classificação das informações permanece a mesma ou sofre uma alteração positiva (QUINTA, 2013). Exitem diversos extratores de atributos, como por exemplo: Atributos de cor RGB, HSV, Cielab (Mín., Máx., média e Desvio); Descritor de forma, invariante a escala, translação e rotação: 7 momentos de Textura - GLCM Atributos de (contrastes, dissimilaridades, Hu; homogeneidades, asm, energias, correlações); Forma e orientação: HOG; Atributos de textura: LPB; Filtros de Gabor.

# 3.3.4. Aprendizagem de Máquina

Segundo Monard e Baranauskas (2003), a aprendizagem de máquina é uma área da inteligência artificial cujo objetivo é o desenvolvimento de técnicas computacionais sobre o aprendizado bem como a construção de sistemas capazes de adquirir conhecimento de forma automática. A meta da aprendizagem de máquina é adquirir o aprendizado para tomada de decisões por meio de exemplos, analisados de forma automática, baseados em decisões bem sucedidas de problemas anteriores, ou seja, tem como finalidade ensinar o computador a obter a correta tomada de decisão, sem ser explicitamente programado para isso. A partir dos exemplos, informações que descrevem diversos grãos de pólen, a técnica de treinamento apresentada ao sistema gera um arquivo de informações, de extensão ARFF (Attribute-Relation File Format) para os posteriores processos de aprendizagem de máquina.

Conforme Pistori (2013), a aprendizagem de máquina pode ser organizada em 3 grandes grupos de técnicas. No primeiro grupo temos a aprendizagem supervisionada, quando o sistema tem acesso a amostras ou exemplos daquilo que ele precisa aprender, apresentando ao computador exemplos de entrada e saída desejados, ou seja, funciona como um professor, definindo qual é o exemplo correto. No segundo, chamado de aprendizagem não-supervisionada, temos os exemplos, mas eles não estão classificados ou marcados com a resposta que o sistema precisa dar, não oferece nenhum tipo

de resposta final ao computador, deixando-o sozinho para encontrar uma melhor forma de estrutura em sua entrada para definir uma correta resposta de saída e no terceiro grupo temos alguns exemplos marcados e outros não. Chamamos a este terceiro grupo de aprendizagem semi-supervisionada.

Algumas técnicas para a aprendizagem de máquina são: aprendizado baseado em Árvores de Decisão, aprendizado por Regras de Associação, Redes Neurais, Programação Indutiva, Clustering, Redes Bayesianas e aprendizado por Similaridade e Métrica.

# 3.3.5. Rede Neural Convolucional (CNN)

Segundo Vargas et al. (2016), a Rede Neural Convolucional é uma variação das redes de Perceptrons de Múltiplas Camadas, tendo sido inspiradas no processo biológico de processamentos de dados do sistema nervoso, ou seja, é um paradigma do aprendizado conexionista. As Redes Neurais Convolucionais causam a não necessidade de programação explicita, já que é claro nenhum ser humano ser apto a realizar tal tarefa. Um outro aspecto é em relação a configuração da rede e dos parâmetros a serem utilizados, já que não existem valores fixos para este ajuste, como também para a configuração da rede, desta forma é necessário basear-se na literatura.

Essas redes possuem camadas, uma delas é a camada convolucional, que serve para a aplicação de vários filtros nos dados. Para cada filtro utilizado, um neurônio é ligado a um dos subconjuntos de neurônios da camada anterior. Os filtros aplicados geram mapas das características de determinado objeto, realizando operações como detecção de borda, nitidez e suavização e apenas mudando os valores numéricos da matriz de filtro antes da operação de convolução. Diferentes filtros podem detectar diferentes informações contidas em uma imagem, a partir de uma pequena região chamada de campo receptivo local, onde cada neurônio é correspondente a intensidade de cada pixel da imagem, assim a rede detecta padrões que se repetem. As intensidades, isto é, os pesos compartilhados dentro da camada convolucional são os mesmos para cada campo receptivo local, assim os neurônios da primeira camada detectam o mesmo padrão. Esta é uma característica que torna a Rede Neural Convolucional adaptativa em relação a diferentes representações que um padrão possa ter. Em resumo, as camadas convolucionais aplicam filtros que

processam pequenos locais de uma imagem e os replica por toda a imagem (HAFEMANN, 2014; KARN, 2016; NIELSEN, 2016).

Outra camada presente na CNN é a Camada de Pooling, segundo Nielsen (2016) essa camada é utilizada posteriormente a camada de convolução e sua função é diminuir o tamanho da imagem para encontrar possíveis padrões, deixando-os evidentes. Um procedimento comum na camada de pooling é chamado de max-pooling, na qual é feita a ativação máxima na região de entrada. As camadas de pooling geram uma versão com menor resolução das camadas de convolução aplicando a ativação máxima do filtro em pequenas regiões da imagem, assim é adicionado mais tolerância para regiões específicas de um determinado objeto (RIGHETTO, 2016).

A camada Totalmente Conectada é uma rede neural clássica, onde o objetivo é a classificação. Cada neurônio da camada anterior está conectado a cada neurônio da próxima camada e os neurônios de saída correspondem as classes do problema. Todas as conexões das camadas não utilizam pesos compartilhados. Além disso, é necessário uma função de ativação para a realização da classificação. As camadas mais altas utilizam filtros que funcionam a partir de entradas de baixa resolução para processar as partes com maior complexidade da imagem. Por fim, a camada totalmente conectada combina as entradas de todas as posições para realizar a classificação das entradas globais (HAFEMANN, 2014; KARN, 2016; RIGHETTO, 2016).

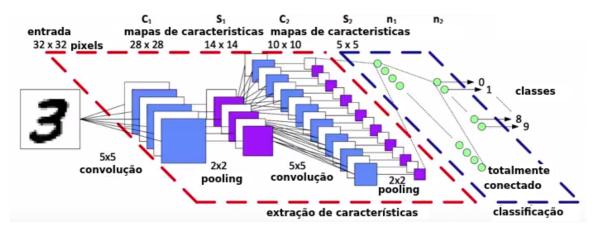


Figura 3.3 : Ilustração da representação clássica de uma Rede Neural Convolucional. As etapas seguem por extrair características dos objetos, aplicando convoluções e poolings e depois a classificação desses objetos, por uma rede totalmente conectada.

## 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. Implementação do banco de imagens *polen23e* e construção de um banco de imagens segmentadas

O primeiro banco de imagens de grãos de pólen focado em espécies do estado de Mato Grosso do Sul teve início em 2015, por Gonçalves. Este banco espécies de diferentes grãos de pólen, sendo possui elas: anadenanthera colubrina, arecaceae, arrabidaea florida, cecropia pachystachya, chromolaena laevigata, combretum discolor, croton urucurana, dipteryx alata, eucalyptus sp, faramea sp, hyptis sp, mabea fistulifera, matayba guianensis, mimosa distans, myrcia sp, poaceae, protium sp, schinus sp, qualea multiflora, senegalia plumosa, serjania sp, syagrus oleracea e tridax procumbens. Tal banco possui um total de 821 imagens.

As imagens deste banco, conhecido como *polen23e* serão utilizadas, porém novas serão acrescidas, através das lâminas palinológicas e do microscópio Carl Zeiss. A inclusão de novas imagens deve-se à inserção de espécies não existentes no banco e também à necessidade de imagens de um mesmo grão em diferentes escalas, tornando possível a classificação final mais eficiente.

Os grãos de pólen possuem visão tridimensional, logo é necessária a captura de várias imagens da mesma espécie em diferentes visões. A captura de várias imagens em diferentes visões e das imagens em diferentes escalas baseia-se nas lentes de aumento de 5x, 10x, 20x e 40x, que graças ao computador acoplado ao microscópio viabiliza a possibilidade da captura e do armazenamento das imagens visualizadas no microscópio.

As novas imagens a serem capturadas pelo microscópio Carl Zeiss serão obtidas no bloco Biosaúde da Universidade Católico Dom Bosco (UCDB). A partir das imagens tiradas de determinadas lâminas palinológicas, serão criadas pastas no computador para criteriosa organização dessas novas imagens, tais como a data, a espécie e a escala, respectivamente.

A partir das imagens de grão de pólen acima citadas, caso necessário alguns dos processos já descritos de visão computacional poderão ser aplicados, como por exemplo o pré-processamento, corte de um grão inteiro e/ou a suavização para a retiradas dos ruídos presentes. As imagens pré-processadas serão utilizadas em experimentos para verificação de possível melhora em sua classificação.

Com início nas imagens, pré-processadas ou não, é executada a segmentação, para criação de um novo banco. A segmentação da imagem é o processo de dividí-la em vários pedaços das regiões que a compõem, tais regiões devem representar as áreas importantes da imagem, como por exemplo formatos dos grãos de pólen, ruídos e fundo da imagem para posterior diferenciação dos objetos ali presentes. O principal objetivo da segmentação é decomposição da imagem em partes menores, assim facilitando a execução dos experimentos, já que ali estarão os atributos mais significativos. A técnica de segmentação a ser utilizada neste trabalho é a de superpixels SLIC, que cada vez mais se destaca pelo baixo custo de execução e pela alta qualidade de segmentação.

O algoritmo Simple Linear Iterative Clustering (SLIC) agrupa os pixels baseado em suas similaridades de cor e proximidade espacial. A partir do algoritmo SLIC será possível segmentar a imagem em diversos superpixels, para tal feito vários parâmetros devem ser definidos, como por exemplo a quantidade dos segmentos, o sigma e a compacidade. Portanto, partindo desses segmentos torna-se necessária a retirada das informações relevantes, sendo isso feito por algoritmos extratores de atributos (cor, forma e textura dos grãos, por exemplo). No arquivo arff gerado a partir da segmentação e da extração dos atributos estão presentes todas as informações relevantes do grão, necessárias para o treinamento da classificação dos mesmos. Este arquivo gerado é conhecido como arquivo de treinamento.

# 4.2. Desenvolvimento e implementação do módulo classificador de grãos de pólen

A partir das etapas de visão computacional listadas na Seção 3.3, vários algoritmos de Aprendizagem de Máquina serão treinados para classificarem corretamente os grãos de pólen. Dois softwares de apoio serão utilizados para a análise desses algoritmos e execução de testes necessários para a verificação de melhores classificações: Weka e Pynovisão.

- No software Weka, a partir do arquivo ARFF de treinamento gerado experimentos serão executados, pois há a existência de diversos recursos, como por exemplo dividir as informações presentes em 70% para o algoritmo aprender e 30% para o algoritmo testar.
- No software Pynovisão, será necessário a partir de uma nova imagem, diferente da utilizada no treinamento, executar o teste. A partir desta técnica um novo arquivo ARFF será gerado, conhecido como teste, contendo as informações da nova imagem utilizada para posterior comparação com o ARFF de treino e classificação dos grãos ali presentes. Esta execução é devido à escolha de um algoritmo de aprendizagem de máquina, portanto mais uma vez, a definição do algorimo não é algo fixo e uma série de experimentos será necessária para a escolha do mais eficiente.
- No Jupyter Notebook, a partir do banco de imagens executar experimentos com Redes Neurais Convolucionais para a classificação dos grãos de pólen. Esta técnica dispensa a utilização da extração de atributos, logo arquivos ARFF's serão desnecessários.

Softwares para a visualização de métricas, como por exemplo a taxa de acertos e o tempo de execução da CPU também serão utilizados para a escolha do melhor algoritmo. O Software Weka e o Jupyter Notebook oferecem essa ferramenta, porém para casos mais específicos outros softwares como o R serão utilizados. A partir da classificação dos grãos de pólen pelos algoritmos, o classificador escolhido deverá executar sua tarefa corretamente com diversas imagens de diferentes grãos de pólen e a partir de boas taxas de classificação o módulo contador será desenvolvido.

# 4.3. Desenvolvimento e implementação do módulo contador de grãos de pólen

A partir da classificação, ou seja, quando o software estiver apto a reconhecer corretamente os grãos de pólen das amostras, o segundo módulo será desenvolvido para realizar a contagem destes. A contagem automática dos grãos de pólen presentes nas amostras deverá ser realizada a partir dos algoritmos de Redes Neurais Convolucionais, para o desenvolvimento do cálculo da distribuição polínica. Outra técnica a ser utilizada é o agrupamento

de superpixels pertencentes a mesma classe, derivada do pós-processamento, por exemplo uma implementação do algoritmo Balde de Tinta, para agrupar todos os superpixels contíguos em um mesmo cluster.

Nesta etapa o software executará testes em imagens que contenham vários grãos de pólen para quantificar os tipos polínicos de cada umas das espécies presentes, apresentando por fim a exibição de suas respectivas quantidades.

# 4.4. Validação do software final, com interface interativa e de fácil manuseio

Após a implementação do algoritmo classificador e do contador de grãos de pólen, propostos neste plano de trabalho, os mesmos serão acrescidos a um software final, a ser desenvolvido na linguagem Python, com interface gráfica e já tendo como base o banco de imagens completo deste trabalho. O Software contará com uma interface interativa e de fácil utilização, para que desta maneira o produto possa ser utilizado por qualquer pessoa, não necessitando mais de profissionais da área para a classificação dos grãos.

Para a validação, o software será utilizado em aplicação na palinologia forense. A partir do convênio existente entre a Universidade Católica Dom Bosco com a Secretaria de Segurança Pública do Estado do Mato Grosso do Sul e em conjunto com a Coordenaria Geral de Perícia, será possível a realização desta aplicação, podendo ser de grande importância para a segurança pública a partir de seu auxilio em resolução de crimes. O desempenho do Software será validado em relação ao desempenho humano, peritos forenses da Secretaria de Segurança Pública do Estado de Mato Grosso do Sul serão convidados para a realização de testes, com objetivo de comparar o desempenho do software versus o desempenho de profissionais da área. Após a verificação dos erros e acertos obtidos, o desempenho será medido estatisticamente, para verificação da precisão do programa na identificação e na contagem dos grãos de pólen.

#### 5. Resultados Preliminares

Experimentos preliminares foram executados para a classificação de grãos de pólen. As imagens utilizadas foram obtidas a partir do banco de imagens Multipolens, no qual contém diferentes grãos de pólen na escala de 40x. O algoritmo de aprendizagem automática utilizado foi o SMO, obtendo taxa superior a 80% de acertos na classificação. Segue nas próximas subseções o detalhamento dos mesmos.

# 5.1. Banco de imagens e treinamento

No software Pynovisão, a partir de uma imagem com diferentes espécies de grãos de pólen foi realizada a segmentação a partir do algoritmo Simple Linear Iterative Clustering. O algoritmo Slic requer a configuração de uma série de parâmetros, sendo elas exibidas na figura a seguir:

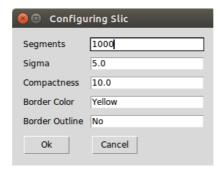


Figura 5.1 : Configuração do algoritmo Slic. Segments define a quantidade de segmentos a serem gerados na imagem; Sigma determina a variação do formato espacial do superpixel; Compactness indica a importância da cor, sendo um valor pequeno caso a cor seja mais importante que o espaço e vice-versa; Border Color e Border Outline são a cor e a intensidade da borda, respectivamente.

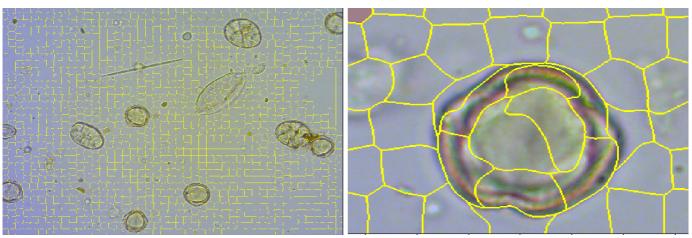


Figura 5.2 : Resultado da segmentação pelo algorimo SLIC. Diferente da segmentação tradicional, o algoritmo Slic divide a imagem de acordo com informações espaciais, tais como sua cor e forma.

A partir dos superpixels gerados na imagem pelo algorimo SLIC torna-se necessário a criação de classes. Uma classe serve para representar uma espécie de grão de pólen, é como uma pasta, onde cada superpixel ali direcionado é correspondente aos grãos desta. Portanto, cada um dos segmentos dos grãos foi separado corretamente a sua respectiva classe. Os superpixels não selecionados a nenhuma classe foram posteriormente identificados pelo algoritmo de aprendizagem supervisionada SMO.

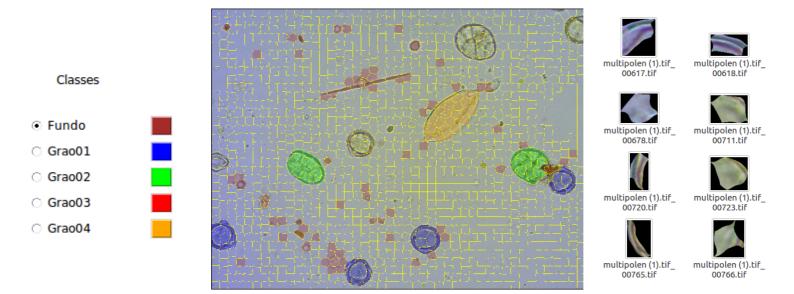


Figura 5.3 : Esquematização da segmentação por superpixels. A imagem A representa as classes definidas, a imagem B representa os superpixels selecionados a essas respectivas classes e a imagem C representa a criação do banco de segmentos, onde cada um desses superpixels foi extraído e designado para a sua pasta no banco de imagens.

Após cada superpixel ser encaminhado a sua devida classe foi executada a extração de atributos de cada uma das imagens presentes neste banco. Diversos atributos foram extraídos, sendo eles: atributos de cor RGB, HSV e Cielab; atributos de textura: GLCM (contrastes, dissimilaridades, homogeneidades, asm, energias, correlações) e atributos de forma e orientação: HOG. Após este processo, o arquivo training.arff foi gerado, pois na verdade o processo descrito até aqui é conhecido como treinamento.

```
@relation demo

@attribute M_01 numeric
@attribute Hu_0 numeric
@attribute cor_rmin numeric
@attribute cor_rmax numeric
@attribute glcm_cont_1_0 numeric
@attribute hog_0 numeric
@attribute hog_127 numeric
@attribute lop_16 numeric
@attribute lop_17 numeric
@attribute lop_17 numeric
@attribute Thet_2.356194_Sigma_3_Frequencia_0.25_Variance numeric
@attribute Thet_2.356194_Sigma_3_Frequencia_0.25_Variance numeric
@attribute classe {Grao01, Grao02, Grao03, Grao04, Fundo}

@data

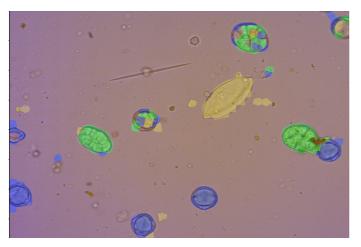
24813806.0,25254100.0,999958361.0,1215155482.0,1254613036.0,7.95980668045e-08,Grao04
18680582.0,16993326.0,596287288.0,827640524.0,695281666.0,5.32827471034e-08, Grao01
9432528.0,8214927.0,216498437.0,376646222.0,286552129.0,-1.88720150618e-09,-2.09115569305e-09,Grao03
19144641.0,24015870.0,831952697.0,785264053.0,1278173960.0,1.48433173308e-07,2.11912265513e-09,Grao02
17206311.0,16572313.0,539023836.0,704607495.0,680035163.0,Fundo
```

Figura 5.4 : Exemplo da estrutura de um arquivo de extensão ARFF. Este tipo de arquivo é basicamente divido em três partes, sendo cada divisão um espaço de linha em branco. O @relation relaciona-se com o nome do arquivo; @attribute define cada um dos atributos extraídos e abaixo do @data são os valores extraídos a partir de cada um desses atributos selecionados.

Os atributos selecionados (@attribute "nome") foram extraídos de cada superpixel gerando as instâncias, os exemplos. Cada uma das linhas abaixo do @data são exemplos correspondentes a cada um dos superpixels do banco de imagens descritos na Seção 5.1, onde cada coluna corresponde ao seu respectivo valor de atributo e a última coluna corresponde a sua correta classe. A partir desse arquivo, conhecido como training.arff, o algoritmo de aprendizagem supervisionada SMO foi executado, aprendendo como classificar os grãos de pólen com o intuito de agora, classificar corretamente os superpixels desconhecidos.

#### 5.2. Classificação dos grãos de pólen

Utilizando o software Pynovisão é possível ter uma resposta visual da classificação de determinada imagem. O método adotado na imagem A da Figura 5.5 não é aconselhável, pois a execução da classificação deve ser feita com imagens totalmente diferentes das do banco de treinamento, porém quatro grãos de pólen não foram pré-classificados e o resultado ilustrativo da execução pôde ser visto. Também foi executada a classificação na imagem B da Figura 5.5, imagem esta totalmente diferente das de treinamento. Os seguintes resultados foram obtidos:



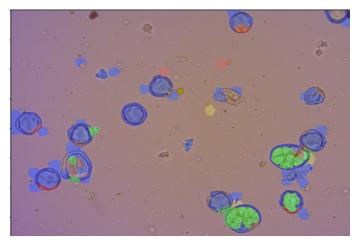


Figura 5.5 : Ao lado esquerdo (A) foi feita a classificação numa imagem onde 7 dos 11 grãos foram pré determinados no treinamento. Ao lado direito (B) a classificação foi feita numa imagem totalmente diferente do treinamento. Ambas as classificações foram executadas pelo algoritmo SMO.

Também há de se observar que a classificação de imagens do software Pynovisão é uma representação ilustrativa, não gera nenhum resultado rigoroso e não há comparação com nada, em outras palavras, o resultado obtido pode não ser confiável, podendo ser correto ou incorreto.

Utilizando o software Weka também é possível executar experimentos de classificação. A métrica de Divisão Percentual segue por dividir uma quantidade dos exemplos para o algoritmo aprender e o restante para ele testar, também pode-se definir a quantidade de repetições na execução pelo Controle de Iteração, para uma melhor taxa de confiança no resultado final.

Os experimentos executados na figura 5.6 foram ambos repetidos 10 vezes para uma melhor taxa de confiança. Na imagem (A) foram escolhidas 70% das instâncias para o algoritmo aprender e os 30% restantes foram para ele executar os testes. Na imagem (B), com 50% para o algoritmo aprender e os 50% restantes das instâncias para ele testar. Tendo como entrada o arquivo ARFF final, com todas as informações do banco de imagens completo, os seguintes resultados foram obtidos na métrica Divisão Percentual: imagem (A) obtendo 80% de exemplos classificados corretamente e imagem (B) obtendo 77.5% dos exemplos classificados corretamente.

=== Summary === === Summary ===

Correctly Classified Instances	284	80.226	%	Correctly Classified Instances	366
Incorrectly Classified Instances	70	19.774	%	Incorrectly Classified Instances	106
Kappa statistic	0.6471			Kappa statistic	0.6024
Mean absolute error	0.2528			Mean absolute error	0.2555
Root mean squared error	0.335			Root mean squared error	0.3386
Relative absolute error	111.8904 %			Relative absolute error	112.1906 %
Root relative squared error	100.7902 %			Root relative squared error	100.4929 %
Total Number of Instances	354			Total Number of Instances	472

Figura 5.6 : Na imagem (A), ao lado esquerdo, o resultado final foi de 80% das instâncias classificadas corretamente, utilizando 70% dos exemplos para o treinamento do classificador. Na imagem (B), ao lado direito, 77.5% das intâncias foram classificadas corretamente, utilizando 50% dos exemplos para o treinamento do classificador. Ambos os resultados foram obtidos através do algoritmo SMO.

A escala de todas as imagens atuais está em 40x. A partir do microscópio Carl Zeiss novas imagens já estão sendo tiradas para a execução de novos experimentos, agora em diferentes escalas: 5x, 10x, 20x e 40x,

respectivamente.



Figura 5.7 : Microscópio utilizado para a obtenção de novas imagens de grãos de pólen em diferentes escalas.

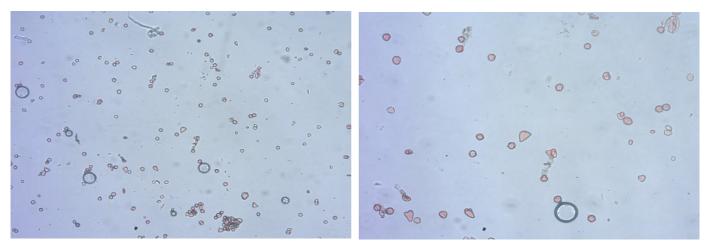


Figura 5.8 : Imagem da esquerda na escala de 5x e imagem da direita na escala de 10x.

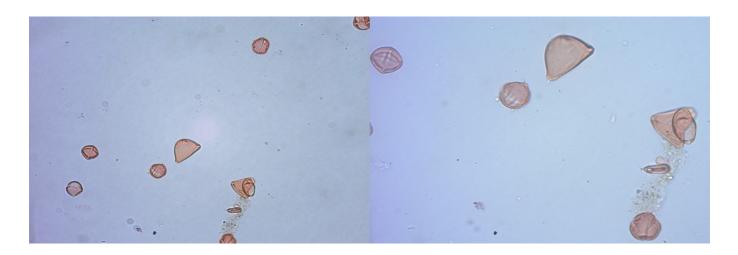


Figura 5.9 : Imagem da esquerda na escala de 20x e imagem da direita na escala de 40x, respectivamente.

Um dos aspectos a ser observado na classificação é o algoritmo ser capaz de tomar a correta decisão em imagens nas quais foram tiradas em diferentes escalas. A análise de diferenças visuais nos pólens conforme se aumenta o zoom torna-se clara, treinar com as imagens com aumento maior e testar em imagens com aumento menor será um dos próximos experimentos a ser realizado para determinação da melhor configuração de captura de imagem para a contagem dos grãos.

Em resumo, as seguintes atividades serão realizadas:

- 1. Aprofundamento e atualização da revisão de literatura.
  - Estudar artigos sobre os seguintes temas: algoritmo SLIC, algoritmos de extração de atributos, teoria da Aprendizagem de Máquina com foco em aprendizagem supervisionada, Deep Learning, Redes Neurais e Convolução.
  - Atualizar a revisão de literatura a partir das técnicas estudadas sobre
     Classificação com Redes Neurais Convolucionais.
- 2. Atualização do Banco de Imagens polen23e.
  - Obter novas imagens em diferentes visões da mesma espécie de grãos de pólen e em diferentes escalas a partir de um grão de pólen focado.
- 3. Realização de experimentos utilizando softwares de apoio.
  - Realizar experimentos a partir de imagens não pré-processadas e pré-processadas.
  - A partir do software Weka, aplicar filtros para que apenas os atributos essênciais seja utilizados na classificação.
  - Executar testes de classificação com imagens dos grãos de pólen em diferentes valores de parâmetros e em diferentes escalas.
- 4. Desenvolver e implementar o módulo classificador de grãos de pólen.
  - A partir dos experimentos realizados nos softwares Weka e Pynovisão, e com base nas técnicas de Redes Neurais Convolucionais implementar um algorimo classificador de grãos de pólen.
- 5. Desenvolver e implementar o módulo contador de grãos de pólen.
  - A partir de técnicas de agrupamento de superpixels, implementar um algoritmo para a correta contagem de grãos de pólen de acordo com sua espécie.
- 6. Validação do software final, com interface interativa e de fácil manuseio.
  - Desenvolver um software que integre os algoritmos implementados para a classificação e contagem de grãos de pólen numa interface interativa e amigável para o usuário final.

# 6. Cronograma

	2017					2018						
	08	09	10	11	12	01	02	03	04	05	06	07
Atividade 1.1.: Estudar artigos sobre os seguintes temas: algoritmo SLIC, algoritmos de extração de atributos, teoria da Aprendizagem de Máquina com foco em aprendizagem supervisionada, Deep Learning, Redes Neurais e Convolução.	X	X										
Atividade 1.2.: Atualizar a revisão de literatura a partir das técnicas estudadas sobre Classificação com Redes Neurais Convolucionais.			X									
Atividade 2.1.: Obter novas imagens em diferentes visões da mesma espécie de grãos de pólen e em diferentes escalas a partir de um grão de pólen focado.	X	X	X									
Atividade 3.1.: Realizar experimentos a partir de imagens não pré-processadas e pré-processadas.		X	X	X	Х	X	X	X	X			
Atividade 3.2.: A partir do software Weka, aplicar filtros para que apenas os atributos essênciais seja utilizados na classificação.	l			X	Х	X	X	X	X			
Atividade 3.3.: Executar testes de classificação com imagens dos grãos de pólen em diferentes valores de parâmetros e em diferentes escalas.					x	Х	X	X	X			
Atividade 4.1.: A partir dos experimentos realizados nos softwares Weka e Pynovisão, e com base nas técnicas de Redes Neurais Convolucionais implementar um algorimo classificador de grãos de pólen.					Х	Х	Х	X	X	×		
Atividade 5.1.: A partir de técnicas de agrupamento de superpixels, implementar um algoritmo para a correta contagem de grãos de pólen de acordo com sua espécie.						X	X	X	Х	X		
Atividada 6.1.: Desenvolver um software que integre os algoritmos implementados para a classificação e contagem de grãos de pólen numa interface interativa e amigável para o usuário final.									х	Х	X	Х

### 6. Referências Bibliográficas

- NUNES, D. J.; CAMPOLINA, B. T.; A importância da botânica forense na resolução de crimes. In: 64º Congresso Nacional de Botânica, 2013, Belo Horizonte.
- GONÇALVES, B, Ariadne. Validação de Métodos Baseados em Visão Computacional para Automação da Identificação e Contagem de Grãos de Pólen, jan. 2013. Dissertação (Mestrado em Biotecnologia) Universidade Católica Dom Bosco, Campo Grande, MS.
- RODRIGUES, C. N. M.; GONÇALVES, A. B.; SILVA, G. G. Evaluation of Machine Learning and Bag of Visual Words Techniques for Pollen Grains Classification. In: WVC 2012 Workshop de Visão Computacional, 27-30 Maio, Goiânia, Goiás, 2014.
- TAKETOMI, E. A.; SOPELE, M. C.; MOREIRA, P. F. S; VIEIRA, F. A. M. Doença alérgica polínica: polens alergógenos e seus principais alérgenos. Revista Brasileira Otorrinolaringol, São Paulo, v.72, n.4, jul./ago. 2006.
- DINIS, Ricardo. Palinologia Forense, Associação Portuguesa de Ciências Forenses, mai. 2015. Disponível em: <a href="http://apcforenses.org/?page\_id=502">http://apcforenses.org/?page\_id=502</a>.
- QUINTA, L. N. B.; AMORIM, W. P.; CARVALHO, M. H.; CEREDA, M.P.; PISTORI, H. Floresta de Caminhos Ótimos na Classificacação de Pólen. In: WVC 2012 Workshop de Visão Computacional, 27-30 Maio, Goiânia, Goiás, 2012.
- QUINTA, L. N. B.; ANDRADE, W. T.; GONÇALVES, A. B.; CEREDA, M.P.; PISTORI, H. Segmentacão baseada em Textura e Watershed aplicada a Imagens de Pólen. In: SIBGRAPI 2012 Workshop of Undergraduate Work (WUW) 22-25 Agosto, Ouro Preto, MG, 2012.
- GONÇALVES, A. B.; RODRIGUES, C. N. M.; CEREDA, M.P.; PISTORI, H. Identificação computadorizada de tipos polínicos através de "Bag of Words". In: WVC 2016 Workshop de Visão Computacional, 9-11 Novembro, Campo Grande, MS, 2016.
- QUINTA, L. N. B.; SILVA, D. S.; GONÇALVES, A. B.; PISTORI, H.; BORTH, M.R. Application of wavelet transform in the classification of pollen grains. In: Academic Journals, African Journal of Agricultural Research, 6 de Março, 2014.
- QUINTA, L. N. B.; SILVA, D. S.; GONÇALVES, A. B.; PISTORI, H.; BORTH, M.R. Feature Extraction and Machine Learning for the Classification of Brazilian Savannah Pollen Grains. In: Plos One Journal, 8 de Junho, 2016.
- DAMAS, M. A.; JAMAR, J. A.; BARBOSA, A. P.; CASTELLAR, A.; A Botânica Forense e a Ciência Farmacêutica no Auxílio à Resolução de Crimes. In: Revista Brasileira de Criminalística, v. 5, n. 1, p. 27-34, 2016.

FERREIRA, A. S. Redes Neurais Convolucionais Profundas na Detecção de Plantas Daninhas em Lavoura de Soja. Tese (Doutorado), Universidade Federal de Mato Grosso do Sul, UFMS. Março, 2017.

PISTORI, H. Visão Computacional. Apostila do curso de Visão Computacional, 2015. Disponível em: <a href="https://virtual.ucdb.br/moodle/file.php?">https://virtual.ucdb.br/moodle/file.php?</a> file=/2470/apostila visao computacional.pdf>.

KARN, U. An Intuitive Explanation of Convolutional Neural Networks. 2016. Disponível em: <a href="https://ujjwalkarn.me/2016/08/11/intuitive-explanation-convnets">https://ujjwalkarn.me/2016/08/11/intuitive-explanation-convnets</a>.

PISTORI, H. Pecuária de precisão como fator de desenvolvimento local da região do alto Taquari, 2017. Disponível em:<a href="http://www.gpec.ucdb.br/pistori/orientacoes/planos/gilberto2016.pdf">http://www.gpec.ucdb.br/pistori/orientacoes/planos/gilberto2016.pdf</a>>.

HAFEMANN, Luiz Gustavo. An Analysis of Deep Neural Networks for Texture Classification. Dissertação (Mestrado), Universidade Federal do Paraná, 2014.

QUINTA, L.N.B. Visão Computacional aplicada na classificação de grãos de pólen, jan. 2013. Dissertação (mestrado em Biotecnologia) – Universidade Católica Dom Bosco - UCDB. Campo Grande, MS.

NIELSEN, M. Deep learning. In: Neural Networks and Deep Learning. Michael Nielsen, 2016. cap. 6. Disponível em: <a href="http://neuralnetworksanddeeplearning.com/chap6.html">http://neuralnetworksanddeeplearning.com/chap6.html</a>>.

REZENDE, S.O. Sistemas Inteligentes. Editora Manole Ltda, 2003, 525 páginas.

RIGHETTO, Guilherme. O uso da rede neural convolucional como extrator de características aplicado ao problema de identificação de descritores. Monografia (Bacharelado), Campo Mourão, 2016.

VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um Estudo sobre Redes Neurais Convolucionais e sua Aplicação em Detecção de Pedestres. In: XXIX SIBGRAPI - Conference on Graphics, Patterns and Images, São José dos Campos – SP, outubro de 2016.