

PLANO DE TRABALHO

Orientador: Hemerson Pistori (pistori@ucdb.br)

Orientando: Felipe Silveira (eng.fe.silveira@gmail.com)

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

Curso: Engenharia de Computação

Semestre: 7

RA: 161231

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, além de rastrear os grãos em mapa geográfico. 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 para auxiliar na elucidação de crimes de modo simples, rápido e eficaz.

1 Antecedentes e Justificativa

Nas últimas décadas, a relação entre a estrutura econômica de um país e sua produtividade tem recebido muita atenção. De acordo com Fagerberg [15], países que investem em atividades tecnológicas tendem a ter um crescimento muito maior e mais rápido em comparação aos países que destinam pouco investimento à essa área. Jiang e Hosein [11] afirmam que existe um fenômeno observado nesse processo, de acordo com o investimento tecnológico determinados setores da sociedade tendem a se agrupar, como por exemplo universidades e empresas. Logo, quando o foco é universitário surge uma

crescente oferta de ideias inovadoras e de grande impacto para diversas áreas da sociedade, como por exemplo o trabalho a ser apresentado neste plano. Deste modo, este trabalho usa a natureza da ciência como chave para um futuro impacto social, a resolução de crimes a partir da palinologia forense.

Sebastiany [2] comenta que, a ciência forense tem como objetivo dar suporte à investigação criminalística, disponibilizando ao profissional forense técnicas para confirmar ou descartar a culpa ou inocência de suspeitos. Na Tabela 1 estão presentes quais são os comuns tipos de evidências encontradas em cenas de crime, logo pode-se compreender o porque da Ciência Forense ser uma área multidisciplinar, abrangendo por exemplo a química, física, biologia e diversas outras ciências.

Tipos de evidências	
1. Impressões Digitais	6. Toxicologia
2. Pegadas	7. Análise de rastreamento
3. Manchas de sangue	8. Questionário
4. Balística	9. Crime Virtual
5. Questionários	10. Biologia Forense

Table 1: Os tipos de evidências comuns encontradas em cenas de crime.

Na biologia forense, uma das evidências encontradas são os grãos de polens que, mesmo não vistos a olho nu possuem uma relevante importância em 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 de conhecimento se ramificaram, como por exemplo a melissopalynologia [4], imunologia [14], paleoecologia [27] e palinologia forense, para a resolução de crimes. Na palinologia forense, a partir da análise dos grãos provenientes de amostras coletadas nos objetos pertencentes a cenas de crime, como por exemplo a arma, é feita a análise e identificação dos grãos presentes, assim guiando os peritos a pistas de suma importância, como por exemplo a localização de vítimas e suspeitos. Carvalho [17] 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 entrou em contato, 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, assim elucidando a solução de crimes, como listado na Tabela 2.

Existem diversas maneiras de análise de grãos de pólen, como por exemplo a identificação por olho humano através de microscópio, identificação por

Tipos de crimes	
1. Assalto	4. Roubo
2. Assassinato	5. Suicídio
3. Estupro	6. Falsa Condenação

Table 2: Os tipos de crimes mais comuns na sociedade.

varredura eletrônica e identificação por partículas a laser. A identificação por olho humano através de microscópio é a mais comum, pois não há a necessidade de um grande investimento financeiro, apenas de lâminas palinológicas com amostras de grãos, de um microscópio e de um especialista da área. Em contrapartida, comumente muitos erros são cometidos, estes causados pelo desgaste exercido na realização desta tarefa. Outro ponto importante é a indispensabilidade de um especialista da área, criando uma dependência devido a existirem poucos profissionais qualificados para tal tarefa. Em resumo, a precisão da ferramenta utilizada é um dos principais requisitos para uma boa identificação e contagem dos grãos, porém, os métodos de classificação utilizados estão sujeitos à interferências externas, como a inviabilidade financeira ou erros humanos. Para sanar este problema, o trabalho apresentado 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 de amostras de crime a partir de imagens capturadas por microscópio.

O grupo de pesquisas Palinovic é o pioneiro em palinologia forense no Brasil, onde o maior objetivo presente é a implementação de um software capaz de ajudar a provar a culpa do criminoso, a inocência de alguém julgado erroneamente, e em casos fatais, se o corpo foi movido ou não de lugar, com a união de 4 áreas de estudo, sendo elas a ciência forense, a palinologia, a visão computacional e a aprendizagem de máquina. Assim sendo, 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 outras técnicas de identificação, contagem e rastreamento utilizadas em grãos de pólen.

2 Objetivos

2.1 Geral

O objetivo geral deste projeto é desenvolver um software de computador que realize a classificação, a contagem e localize no mapa as diferentes espécies de grãos de pólen existentes no Mato Grosso do Sul. O software será capaz de realizar suas tarefas de forma rápida e eficiente, resultando em um importante progresso sobre atual processo utilizado na Palinologia Forense para a resolução de crimes.

2.2 Específicos

Para atingir o objetivo geral foram estabelecidos os seguintes objetivos específicos:

- Desenvolvimento e implementação do módulo classificador/contador de grãos de pólen.
- Desenvolvimento e implementação do módulo de localização de grãos de pólen por mapa.
- Implementação do software final com interface interativa e de fácil manuseio.
- Validação do software final, através da execução de classificação, contagem e localização de grãos em amostras de cenas de crime.

3 Revisão da literatura

A Seção 3.1 resume todas 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 pelos peritos, a Seção 3.3 explica sobre as técnicas de visão computacional que serão implementadas e experimentadas, na Seção 3.4 é mostrado como funcionara o aprendizado de maquina, que refere-se ao programa de computador aprender a identificar os grãos de polen automaticamente e na Seção 3.5 é mostrado como sera utilizado o aprendizado profundo, que é o atual estado-da-arte em problemas complexos de classificação de imagens.

3.1 Técnicas utilizadas anteriormente

Durante seis 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 na 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 [13]. As técnicas já estudadas pelo projeto para o desenvolvimento do mesmo são mostradas na Tabela 3.

Técnicas
1. Floresta de Caminhos Ótimos (OPF)
2. Segmentação baseada em Textura e Watershed (SMC)
3. Bag of Words (BOW)
4. Transformada Wavelet
5. Cor, Forma e Textura (CST) + Bag of Words (BOW)

Table 3: Técnicas que já foram estudadas e experimentadas pelo projeto Palinovic (grupo Inovisão), para o desenvolvimento do modulo classificador de grãos de polen do software.

De acordo com Pistori et al. o problema de reconhecimento de padrões pode ser modelado para o uso de Floresta de Caminhos Ótimos em um grafo, definido em seu espaço os atributos. A partir de algoritmos de aprendizagem supervisionada (Tabela 4) o resultado foi determinado a partir de testes

estatísticos (Tabela 5) a fim de se obterem os atributos mais relevantes, porém, os algoritmos não apresentaram diferença estatística na classificação dos grãos. O melhor resultado utilizando essa técnica foi 75.27% de acerto utilizando o algoritmo C4.5 [22]. Posteriormente aos experimentos de reconhecimento de padrões, o objetivo de classificar as imagens de grãos de polen foi com a utilização da segmentação baseada em textura e Watershed. As imagens foram decompostas em sub-imagens, excluindo-se regiões que não são importantes, logo os segmentos de interesse das imagens foram utilizados para a extração de atributos. Os processos utilizados para extração de atributos nessa técnica foram: A extração de atributos de textura por descritores, desfocagem gaussiana e a utilização de processo de limiarização da imagem pelo método de seleção interativa. Essa técnica obteve como resultado final um percentual de classificação correta de 98,93% [23].

Semelhantemente, o uso da técnica Bag of Words, que faz extração de atributos de uma imagem, permite gerar um histograma de cada imagem contendo as suas respectivas características, sendo associada a sua classe com o auxílio de um algoritmo de aprendizagem supervisionada. Neste experimento, o BOW executou a extração de atributos de uma imagem gerando um histograma com suas características a partir dos pontos de interesse detectados, resultando em um dicionário de 2048 descritores para cada imagem, e a partir desses descritores foram executadas as classificações com os algoritmos de aprendizagem supervisionada. Como resultado final, o melhor desempenho foi obtido através do algoritmo SMO, que obteve 71% de acerto na métrica de percentual de classificação correta [10].

Algoritmos	
1. C4.5	6. SMO
2. SVM	7. IBK
3. KNN	8. J.48
4. Best-first	9. Ada Boost
5. CSVC	

Table 4: Algoritmos comumente utilizados em técnicas de aprendizagem de máquina.

Sob o mesmo ponto de vista, a aplicação da Transformada Wavelet na classificação de grãos de pólen teve como principal objetivo a redução de informações (atributos) desnecessárias da imagem para estágios posteriores. A redução desses atributos 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 informações geradas são demasiadas. Os algoritmos utilizados foram o C4.5 e o KNN, obtendo resultados

não muitos bons, principalmente para o atributo de forma onde obteve 57% de taxa na medida-F com o algoritmo C4.5, porém, quando combinado mais atributos extraídos, o resultado de classificação obteve uma melhora significativa, sendo 79% de taxa na medida-F. 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 grande [24]. Em contrapartida, de acordo com Quinta et. al, a melhor técnica que deve ser usada para automatizar a classificação de grãos de polens é a combinação dos atributos de cor, forma e textura com o Bag of Words, além de, com o classificador CSVC executar a classificação. Neste experimento, o algoritmo CST foi criado, seu nome é baseado nos atributos utilizados de cor, forma e textura e a medição de seu desempenho foi comparado com os seguintes grupos de experimentos: Cor Forma Textura (CST), Bag of Words (BOW) e CST combinado com BOW. A partir dos algoritmos de aprendizagem supervisionada, o melhor resultado obtido foi através do experimento CST+ BOW com o algoritmo SVM, obtendo 79% na métrica de percentual de classificação correta [25].

Métricas
1. Friedman
2. T-Students
3. Taxa de acerto
4. Percentual de classificação correta (PCC)
5. Coeficiente de Jaccard (CJ)
6. Coeficiente de Yule (CY)
7. Revocação
8. Precisão
9. Medida F
10. Área sobre a curva ROC

Table 5: Métricas mais utilizadas em experimentos de classificação com técnicas de aprendizagem de maquina.

3.2 Palinologia Forense

Segundo Castellar et al., 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 as diferentes amostras apreendidas [5].

Diversas técnicas podem ser aplicadas para a resolução de crimes, segundo Nunes e Campolina, 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 polens podem ser encontrados agarrados em qualquer objeto ou pessoa. São altamente resistentes à degradação mecânica, biológica e química, e encontrados em grandes números [21].

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. A resolução de crimes a partir da Palinologia Forense é uma das técnicas mais utilizadas para tal, ligando pistas para o rastreamento de suspeitos [5].

3.3 Visão Computacional

Segundo Quinta [16], 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 seres 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 está 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 [16, 12]. A seguir são listadas as etapas de visão computacional:

1. Captura de imagens
2. Segmentação
3. Extração de atributos

3.3.1 Captura de imagens

Em visão computacional a captura das imagens ou vídeos é realizada por um ou vários dispositivos como scanners, microscópios, ou câmeras digitais [28]. 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 [16], 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 1 mostra como uma imagem é analisada computacionalmente, sendo a imagem original e sobreposta a sua correspondente matriz, que possui os valores de cada um de seus pixels.

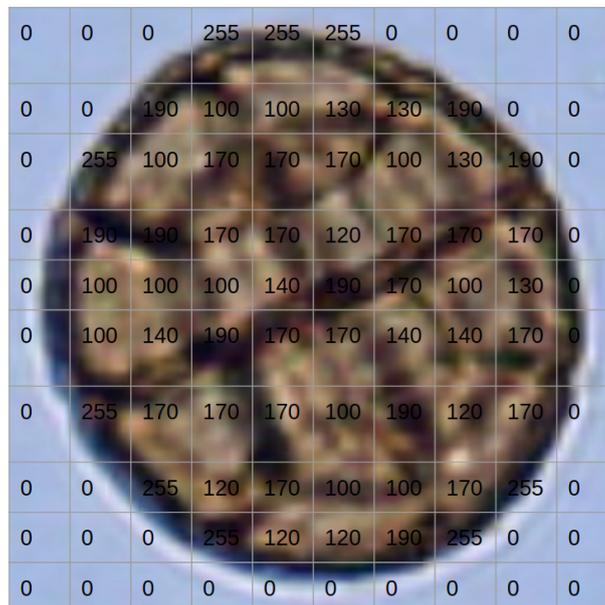


Figure 1: Esquema para ilustração da matriz de pixels de uma imagem. A matriz é uma estrutura de dados, onde nesse caso serve para anotar os valores correspondentes a cada um dos pixels, variando de 0 a 255, preto e branco respectivamente, onde cada valor equivale a uma cor.

De fato, por essa imagem ser colorida ela está nos canais RGB, vermelho, verde e preto respectivamente, sendo que para cada canal existe uma matriz com os valores dos pixels por conseguinte.

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 [9]. Segundo Marengoni et. al, 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 [19].

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 [26]. Na Figura 2 é dado um exemplo da segmentação realizada através do algoritmo SLIC, assim gerando os superpixels, ou seja, pequenos recortes dentro da imagem.

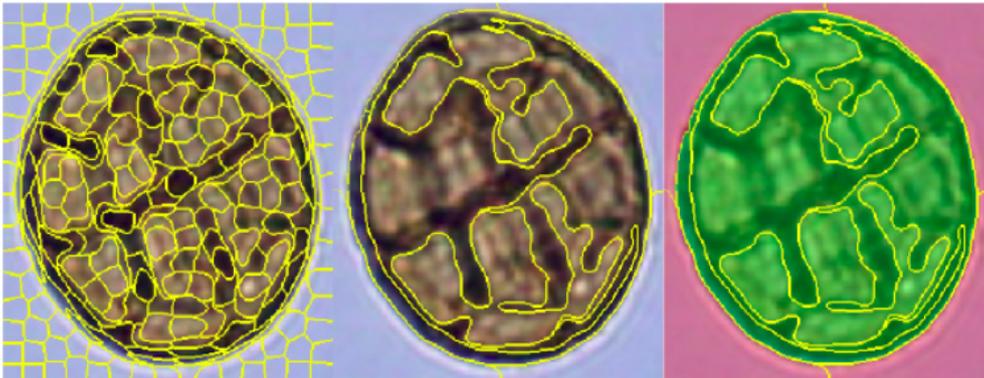


Figure 2: Imagem com 250 segmentos, imagem com 10 segmentos e imagem com superpixels selecionados da imagem com 10 segmentos, gerando duas classes: grão de pólen e fundo, respectivamente, em diferentes cores.

3.3.3 Extração de atributos

A extração de atributos é a etapa posterior a segmentação, devido que, para denotar cada grão de pólen é necessária a 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 [16]. 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.

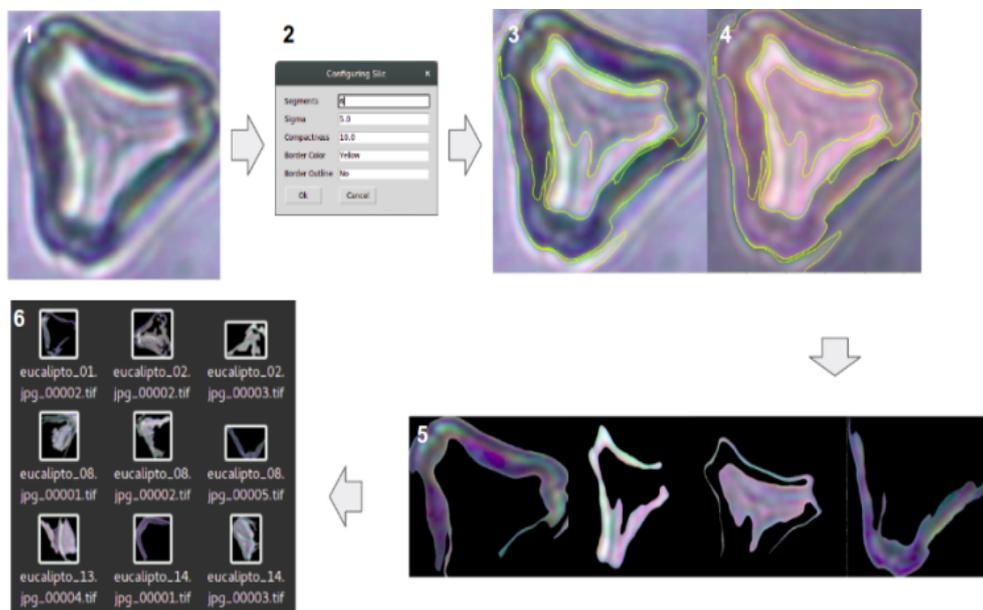


Figure 3: Processo da geração do banco de imagens de superpixels SLIC. 1) Imagem original; 2) Configuração dos parâmetros do algoritmo SLIC; 3) Imagem segmentada; 4) Imagem com os superpixels selecionados; 5) Imagem dos superpixels extraídos; 6) Banco de imagens de superpixels. Após esse processo, os segmentos estão prontos para a extração de atributos.

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. Porquanto, irá transformar os seg-

mentos das imagens que interessam, como visto na Figura 3, aos módulos de processamento posteriores em uma outra representação, geralmente um vetor de atributos [16, 26, 12].

Existem diversos extratores de atributos, como por exemplo cor, forma, textura, invariante a escala, translação e rotação, dissimilaridades, homogeneidades e filtros. 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 seleção de atributos, o resultado da classificação dos dados não sofre uma interferência negativa. Sendo assim, a classificação das informações permanece a mesma ou sofre uma alteração positiva [16].

3.4 Aprendizagem de Máquina

Segundo Monard e Baranauskas [20], 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. No software Weka por exemplo, a partir dos dados, ou seja, as 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.

Grupos de algoritmos	
1. Aprendizado Profundo	7. Bayesian
2. Ensemble	8. Arvores de Decisao
3. Redes Neurais	9. Reducao de Dimensao
4. Regularizacao	10. Instance Based
5. Rule System	11. Clusterizacao
6. Regressao	

Table 6: Diferentes grupos em que o aprendizado de maquina se ramifica. Obs: devido a poucos desses algoritmos serem utilizados na literatura portuguesa, alguns dos nomes são mantidos no original, em inglês.

Conforme Pistori [13], 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. Os grupos de algoritmos para a aprendizagem de máquina são mostrados na Tabela 6.

3.5 Aprendizado Profundo

O aprendizado profundo é um ramo do aprendizado de máquina, no qual torna-se especialista na utilização de grandes quantidades de dados a fim de treinar o computador a resolver problemas de percepção, como neste caso, reconhecer imagens. Surgiu como a principal ferramenta para resolver esse tipo de problema encontrado na era digital, sendo o estado-da-arte em tudo o que utiliza visão computacional. Diante disso, esse tipo de aprendizado se destaca quando o assunto é uma grande quantidade de dados e problemas complexos a serem resolvidos, sendo uma família de técnicas que se adaptam para qualquer tipo de dado e qualquer tipo de problema, sempre utilizando uma estrutura e linguagem comum para a descrição dos objetos [6].

Redes Neurais
Perceptron
Back-propagation
Hopfield Network
Radial Basis Function Network (RBFN)

Table 7: Conjunto de técnicas presentes na implementação de Redes Neurais.

Quando há o aprendizado profundo torna-se necessário o uso das Redes Neurais (Tabela 7), que voltaram a ser utilizadas em 2009 para o reconhecimento de voz, depois tiveram grande utilidade em 2012 com visão computacional e após isso em 2014, para a tradução feita por máquina, isso devido a grande quantidade de dados e placas de vídeo cada vez mais rápidas. A partir das Redes Neurais existentes no aprendizado profundo diferentes

métodos podem ser utilizados, como por exemplo, para problemas envolvendo visão computacional torna-se adequado a implementação de camadas convolucionais pela sua invariância translacional e conectividade local [6]. Segundo Vargas et al., 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 [31].

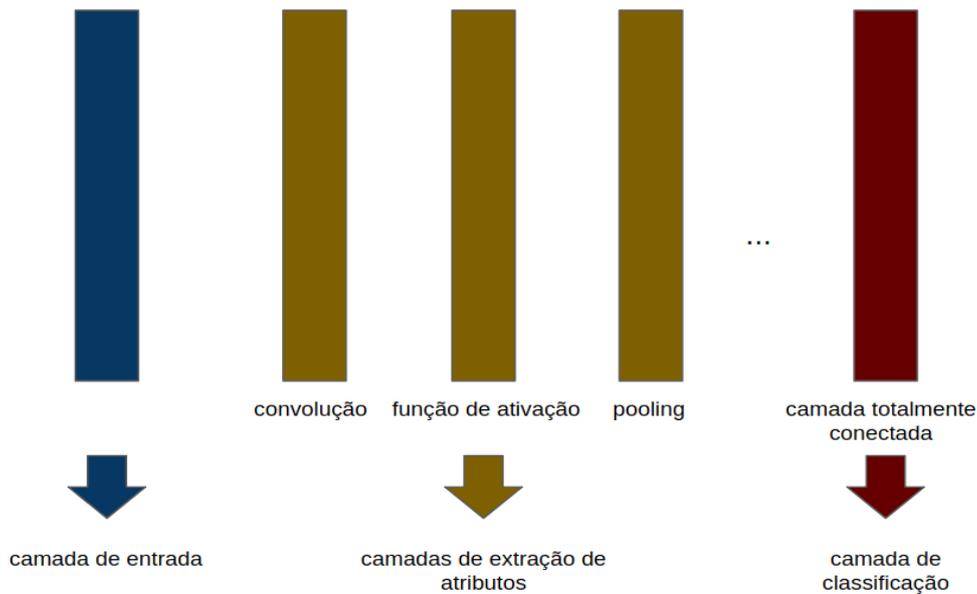


Figure 4: As CNN's transformam as imagens de entrada em dados (organizados, normalmente por vetores), desse modo, a primeira camada é a de entrada, depois passa pelas camadas intermediárias para a extração de atributos e posteriormente para a camada de saída, que classifica as imagens.

As redes implementadas no aprendizado profundo possuem normalmente 3 tipos de camadas, como mostrado na Figura 4. A camada de convolução serve para a aplicação de vários filtros nos dados, sendo que, para cada filtro utilizado ocorre a ligação de um neurônio 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 Convolutiva adaptativa em relação a diferentes representações que um padrão possa ter [7, 29, 18].

Outra camada presente nas CNN's é a camada de pooling, segundo Nielsen 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 [18]. 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 [8].

Aprendizado Profundo
Deep Boltzmann Machine (DBM)
Deep Belief Networks (DBN)
Rede Neural Convolutiva (CNN)
Stacked Auto-Encoders

Table 8: Conjunto de técnicas presentes na implementação do aprendizado profundo.

A camada totalmente conectada é uma rede neural clássica, onde o objetivo é a classificação. Cada neurônio da camada anterior está conectado a cada um dos neurônios 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 de extração de atributos 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 das imagens para realizar a classificação das entradas globais [8, 29, 7].

4 Metodologia

Para cada um dos objetivos específicos listados na Seção 2, serão apresentados a seguir os aspectos metodológicos que nortearão a execução desta proposta.

4.1 Desenvolvimento e implementação do módulo classificador/contador de grãos de pólen

A partir do banco de imagens polen70e serão executadas as etapas de visão computacional, onde os algoritmos de aprendizagem de máquina, como visto na Tabela 6, serão treinados para classificarem corretamente e de forma automática os grãos de pólen. O banco de imagens polen70e é o pioneiro no estado do Mato Grosso do Sul, contendo 70 espécies de grãos de pólen, sendo 35 imagens de cada espécie. O aprendizado de máquina divide-se em até três etapas:

1. Treino;
2. Validação;
3. Teste.

Essas etapas formam um ciclo de aprendizado, que tem como objetivo fazer o algoritmo adquirir conhecimento para as decisões automáticas, no caso deste projeto, classificar corretamente os grãos. Normalmente, essas três etapas são divididas em 60%, 20% e 20% respectivamente, sendo essa porcentagem um valor calculado a partir da quantidade total de imagens de grãos de pólen. Na etapa de treinamento, o algoritmo de aprendizado tem como objetivo aprender a classificar os grãos, passando pelos processos de visão computacional, como visto na Seção 3.3, e posteriormente os processos de aprendizado de máquina, neste caso, a Rede Neural Convolutiva. Na validação, tem-se como objetivo classificar as imagens que não foram utilizadas no treinamento, porém, ajusta-se os valores dos parâmetros para que, obtendo a melhor combinação desses valores a generalização do algoritmo se expanda e ele classifique corretamente a maior quantidade possível de grãos. Por fim, é executado o teste, que tem o intuito de verificar o quão bem está a classificação a partir de grãos de pólen totalmente desconhecidos, diretamente e indiretamente.

Quatro softwares de apoio serão utilizados para a análise desses algoritmos e execução das etapas necessárias para a verificação dos melhores algoritmos classificações:

- Pynovisão: É um software desenvolvido pelo grupo Inovisão, para a execução de experimentos utilizando visão computacional e aprendizado de máquina;
- Weka: O Weka é uma coleção de algoritmos de aprendizagem de máquina para tarefas de análise de dados [30];
- Jupyter Notebook: É uma aplicação web que permite a edição e execução de programas voltados para o aprendizado de máquina [1];
- Visual Studio: O Visual Studio é um ambiente poderoso e flexível para o desenvolvimento de aplicativos, tanto web como android [3].

No software Weka, a partir do arquivo ARFF gerado pela extração de atributos do banco polen70e, experimentos serão executados para a verificação dos melhores algoritmos classificadores e a melhor combinação de ajuste de parâmetros. Posteriormente, no software Pynovisão serão executados os testes, com novas imagens, diferentes das utilizadas no treinamento e na validação. Bem como, no Jupyter Notebook a partir do banco de imagens serão executados experimentos com as Redes Neurais Convolucionais para a classificação dos grãos de pólen. Esta técnica dispensa a utilização da extração de atributos, já que é realizada pela própria rede.

Softwares para a visualização de métricas, como por exemplo a taxa de acertos e o tempo de execução do processador também serão utilizados para a escolha do melhor algoritmo, sendo que, o software Weka e o Jupyter Notebook oferecem essa ferramenta. 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 classificador será implementado no Visual Studio.

A partir da classificação, ou seja, quando o software estiver apto a identificar 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 agrupamento. Esta etapa designa que, 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.

4.2 Desenvolvimento e Implementação do módulo de localização de grãos de pólen por mapa

A elucidação de crimes que o software dará aos peritos será feita a partir dos locais geográficos dos grãos de pólen presentes na cidade. Desse modo, problemas como: a culpa do criminoso, a inocência de alguém julgado erroneamente, e em casos fatais, se o corpo foi movido ou não de lugar serão facilmente esclarecidos.



Figure 5: Protótipo do software final, para acesso online por navegador web em computador, desenvolvido no software Balsamiq. Em sequência: 1) Identificação; 2) Contagem; 3) Rastreamento do grão; 4) Rastreamento de vários grãos.

Os grãos de pólen, mesmo que não vistos a olho nu estão presentes em todos os lugares, assim como um lugar é diferente de outro, os grãos de pólen também são, logo, a partir das vegetações, se algo entra em contato com algum grão este objeto passa a carregá-lo em si, vale ressaltar que até no ar estão presentes grãos de pólen. E mesmo que, fazendo uma higienização química para retirar os grãos de pólen presentes no corpo eles continuam presentes, mas internamente, muitas das vezes através das vias respiratórias. Em síntese, não existe escapatória para a prova de localização geográfica de determinado objeto ou pessoa a partir da coleta de grãos de pólen presentes. Portanto, no software poderá ser feita a checagem de quais grãos de pólen existem no local em que ocorreu algum delito e comparar com os que foram

coletados nos suspeitos ou vítimas (objetos por exemplo um carro, roupa), para assim conferir se este indivíduo esteve ou não no local. Por conseguinte, ligando vítimas e suspeitos para elucidar a solução do crime.

4.3 Implementação do software final com interface interativa e de fácil manuseio

Após a implementação do algoritmo classificador, do contador de grãos de pólen e do localizador de grãos no mapa, propostos neste plano de trabalho, os mesmos serão acrescidos a um software final a ser desenvolvido na linguagem de programação Python, para o back-end e o front-end será desenvolvido em HTML, permitindo que o software seja web.



Figure 6: Protótipo do software final com as quatro funcionalidades, desenvolvido no software Balsamiq. 1) Tela de login com usuário e senha; 2) Página principal com o menu de acesso às funcionalidades; 3) Identificação; 4) Contagem; 5) Rastreamento do grão; 6) Rastreamento de vários grãos, para ser acessado através do navegador web em celular.

Como visto nas Figuras 5 e 6, o acesso ao programa poderá feito através de computadores e também de celulares, assim sendo acessado pela internet.

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 formados na área da palinologia para a classificação dos grãos, facilitando o trabalho dos peritos.

4.4 Validação do software final, através da execução de classificação, contagem e localização de grãos em amostras de cenas de crime

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 auxílio em resolução de crimes.

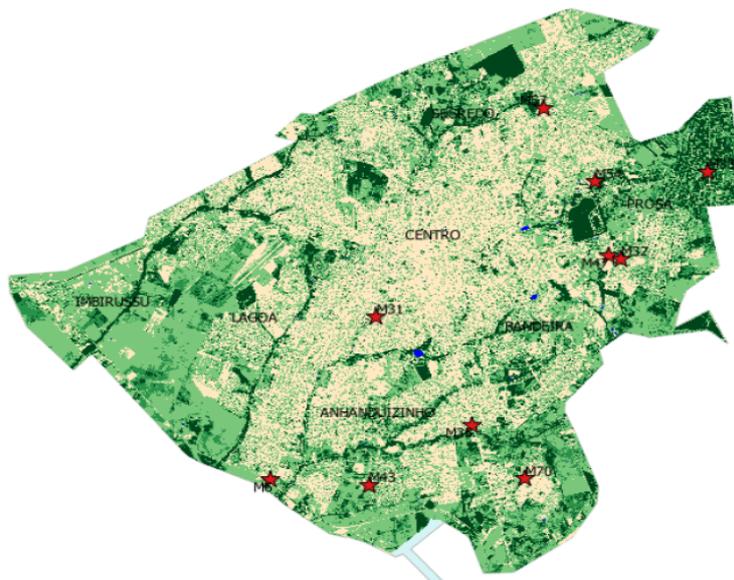


Figure 7: Mapa de Campo Grande-MS. As estrelas em vermelho correspondem a crimes fatais ocorridos na cidade. Durante 1 ano, o perito do grupo Palinovic coletou amostras de grãos de pólen nos cadáveres presentes, para posterior validação do software.

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. Posteriormente, após a validação do software ter uma taxa de classificação melhor que os profissionais da palinologia, o software será condicionado a elucidar os crimes já anotados, como visto na Figura 7.

5 Resultados Preliminares

Foram executados ao todo, 36 experimentos de classificação utilizando as seguintes redes neurais convolucionais:

- Inception V3;
- Resnet50;
- VGG16;
- VGG19 e;
- Xception.

Com a técnica de ajuste fino, ou seja, que já executou um prévio treinamento das redes em um banco de imagens genérico, como por exemplo o ImageNet, a rede ResNet50, que é um modelo de Rede Neural Convolutacional obteve a melhor taxa de acerto, sendo de 95.55% de acurácia, e o pior resultado foram das redes VGG16 e VGG19, que obtiveram o mesmo resultado, 92,41% de acurácia. Para futuros experimentos, os parâmetros das redes neurais convolucionais serão modificados para a obtenção da melhor combinação, e posteriormente o módulo classificador será implementado baseado nesse modelo, e assim será executado de forma eficiente no software final.

6 Cronograma de execução

Em resumo, as seguintes atividades serão realizadas:

1. Aprofundamento e atualização da revisão de literatura.
 - (a) Fazer revisão sistemática de artigos sobre visão computacional e aprendizado de máquina, como por exemplo: algoritmo SLIC, algoritmos de extração de atributos, teoria da Aprendizagem de Máquina com foco em aprendizagem supervisionada, Aprendizado Profundo, Redes Neurais e Convolução.
 - (b) Fazer revisão sistemática de artigos sobre palinologia e ciências forenses, pra atualização sobre os atuais métodos utilizados para resolução de crimes.
 - (c) Atualizar a revisão de literatura a partir das técnicas estudadas sobre classificação com Redes Neurais Convolucionais.
2. Realização de experimentos utilizando softwares de apoio.
 - (a) Realizar experimentos a partir do banco de imagens de grãos de polen Polen70e.
 - (b) A partir do software Weka, aplicar filtros para que apenas os atributos essenciais sejam utilizados na classificação.
 - (c) Executar testes de classificação com imagens dos grãos de pólen em diferentes valores de parâmetros e em diferentes escalas.
 - (d) No software Pynovisao executar as devidas validações para os ajustes de parâmetros.
 - (e) No Jupyter Notebook executar os processos de classificação utilizando as Redes Neurais Convolucionais.
3. Desenvolver e implementar o módulo classificador de grãos de pólen.
 - (a) A partir dos experimentos realizados nos softwares Weka, Pynovisão e Jupyter Notebook, e com base nas técnicas de Redes Neurais Convolucionais implementar no software Visual Studio o módulo classificador de grãos de pólen.
 - (b) Executar testes neste módulo para verificação da eficiência e performance.
4. Desenvolver e implementar o módulo contador de grãos de pólen.

- (a) A partir de técnicas de agrupamento de superpixels, implementar um algoritmo para a correta contagem de grãos de pólen de acordo com sua espécie, utilizando o software Visual Studio.
 - (b) Executar testes neste módulo para verificação da eficiência e performance.
5. Desenvolver e implementar o módulo localizador de grãos de pólen.
- (a) A partir de técnicas de programação em Python e utilizando o software Visual Studio, implementar o módulo localizador de grãos de pólen no mapa.
 - (b) Executar testes neste módulo para verificação da eficiência e performance.
6. Validação do software final, com interface interativa e de fácil manuseio.
- (a) Desenvolver um software web que integre os programas implementados para a classificação, contagem e localização de grãos de pólen numa interface interativa e amigável para o usuário final.
 - (b) Validar com o software desenvolvido, a elucidação dos crimes ocorridos em Campo Grande-MS.

Atividades	2018					2019						
	ago	set	out	nov	dez	jan	fev	mar	abr	mai	jun	jul
1.(a)	x	x	x									
1.(b)		x	x	x								
1.(c)			x	x	x							
2.(a)				x	x	x						
2.(b)				x	x	x						
2.(c)					x	x	x					
2.(d)						x	x	x				
2.(e)							x	x	x			
3.(a)							x	x	x			
3.(b)								x	x			
4.(a)								x	x			
4.(b)								x	x	x		
5.(a)								x	x	x		
5.(b)								x	x	x		
6.(a)										x	x	x
6.(b)										x	x	x

References

- [1] INGARGIOLA A. and CONTRIBUTORS. What is jupyter notebook?, 2015.
- [2] SEBASTIANY A.P, PIZZATO M. C., PINO J. C., and SALGADO T. D. M. A utilização da ciência forense e da investigação criminal como estratégia didática na compreensão de conceitos científicos. *Educación Química*, 24(1):49 – 56, 2013.
- [3] MICROSOFT CORPORATION. Visual studio as melhores ferramentas do setor para qualquer desenvolvedor, 2018.
- [4] OHE V. D., ODDO W., PERSANO L., PIANA M. L., MORLOT M., and PETER M. Harmonized methods of melissopalynology. *Apidologie*, 35(Suppl. 1):S18–S25, 2004.
- [5] BARBOSA A. P. CASTELLAR A. DAMAS M. A., JAMAR J. A. A botânica forense e a ciência farmacêutica no auxílio à resolução de crimes. *Revista Brasileira de Criminalística*, 2016.
- [6] ANDREW N. G. *Machine Learning Yearning: Technical Strategy for AI Engineers, In the Era of Deep Learning*. deeplearning.ai, 2018.
- [7] HAFEMANN L. G. An analysis of deep neural networks for texture classification. *Dissertação (Mestrado), Universidade Federal do Paraná*, 2014.
- [8] RIGHETTO G. O uso da rede neural convolucional como extrator de características aplicado ao problema de identificação de descritores. *Monografia (Bacharelado)*, 2016.
- [9] A. B. GONCALVES, J. S. SOUZA, G. G. da SILVA, M. P. CEREDA, A. POTT, M. H. NAKA, and H. PISTORI. Feature extraction and machine learning for the classification of brazilian savannah pollen grains. *Plos One*, 2016.
- [10] C. N. M.; CEREDA M.P.; PISTORI H. GONÇALVES, A. B.; RODRIGUES. Identificação computadorizada de tipos polínicos através de “bag of words”. *WVC 2016 - Workshop de Visão Computacional*, 2016.
- [11] JIANG H. and HOSEIN F. M. Dynamics of inventor networks and the evolution of technology clusters. *International Journal of Urban and Regional Research*, 38(6):2174–2200.

- [12] PISTORI H. Apostila do curso de visão computacional, 2015.
- [13] PISTORI H. Peculiaridade de precisão como fator de desenvolvimento local da região do alto taquari, 2017.
- [14] DELVES P. J., MARTIN S. J., BURTON D. R., and ROITT I. M. *Essential immunology*. John Wiley & Sons, 2017.
- [15] FAGERBERG J. Technological progress, structural change and productivity growth: a comparative study. *Structural Change and Economic Dynamics*, 11(4):393 – 411, 2000.
- [16] QUINTA L.N.B. Visão computacional aplicada na classificação de grãos de pólen. *Dissertação (mestrado em Biotecnologia) – Universidade Católica Dom Bosco - UCDB*, 2013.
- [17] MADUREIRA A. M. and CARVALHO. Palinologia forense, 2015.
- [18] NIELSEN M. Neural networks and deep learning, 2016.
- [19] MAURICIO MARENGONI and DENISE STRINGHINI. Tutorial: Introdução à visão computacional usando opencv. 06 2018.
- [20] BARANAUSKAS J.A MONARD M.C. *Conceitos de aprendizado de máquina*. 2003.
- [21] B. T NUNES, D. J.; CAMPOLINA. A importância da botânica forense na resolução de crimes. *64º Congresso Nacional de Botânica*, 2013.
- [22] CARVALHO M. H. CEREDA M.P. PISTORI H QUINTA L. N. B., AMORIM W. P. Floresta de caminhos Ótimos na classificação de pólen. *WVC 2012 - Workshop de Visão Computacional*, 2012.
- [23] GONÇALVES A. B. CEREDA M.P. PISTORI H QUINTA L. N. B., ANDRADE W. T. Segmentação baseada em textura e watershed aplicada a imagens de pólen. *SIBGRAPI 2012 - Workshop of Undergraduate Work - WUW-*, 2012.
- [24] GONÇALVES A. B. PISTORI H. BORTH M.R. QUINTA L. N. B., SILVA D. S. Application of wavelet transform in the classification of pollen grains. *Academic Journals, African Journal of Agricultural Research*, 2014.
- [25] GONÇALVES A. B. PISTORI H. BORTH M.R. QUINTA L. N. B., SILVA D. S. Feature extraction and machine learning for the classification of brazilian savannah pollen grains. *Plos One Journal*, 2016.

- [26] FERREIRA A. S. R. Redes neurais convolucionais profundas na detecção de plantas daninhas em lavoura de soja. *Tese (Doutorado)*, 2017.
- [27] JACKSON S. T. and WILLIAMS J. W. *Modern analogs in Quaternary paleoecology: here today, gone yesterday, gone tomorrow?*, volume 32. 2004.
- [28] GALO M. TOMMASELLI A.M.G., HASEGAWA J. K. Modernas tecnologias de aquisição de imagens em fotogrametria. *Boletim de Ciências*, 2000.
- [29] KARN U. An intuitive explanation of convolutional neural networks, 2016.
- [30] NEW ZEALAND UNIVERSITY OF WAIKATO. Weka 3: Data mining software in java, 2018.
- [31] A.; VASCONCELOS C. N VARGAS, A. C. G.; PAES. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. *SIBGRAPI - Conference on Graphics, Patterns and Images*, 2016.