

Universidade Católica Dom Bosco

Curso de Bacharelado em Engenharia de Computação

Combinação de Atributos de Superpixels para Classificação de Larvas Necrofágicas

Eudamara Barbosa da Silva Acosta

Orientador: Prof. Dr. Hemerson Pistori Coorientadora: Me. Ariadne Barbosa Gonçalves

Relatório Final apresentado à Coordenação do Curso de Bacharelado em Engenharia de Computação da Universidade Católica Dom Bosco como parte dos requisitos para a obtenção do título de Bacharel em Engenharia de Computação.

UCDB - Campo Grande - MS - Novembro/2016

Agradecimentos

Primeiramente, gostaria de agradecer a Deus, por ser presente em minha vida, por me conduzir, pelas bençãos, enfim, por ser meu Mantenedor e Salvador. Aos meus familiares que me apoiam, incentivam e investem em mim, especialmente a minha mãezinha Marta, vó Mara, irmã Naiara (maninha) e tia Ana, vocês são minhas queridas para sempre. Obrigada por acreditarem em mim.

Ao meu eterno namorado, obrigada pelo amor, companheirismo, dedicação, pelos conhecimentos, mesmo a distância vivenciou cada minuto comigo durante esta faculdade, não foi uma leucemia que nos separou. Só tenho a dizer *I Love You!*

Agradeço ao meu orientador, professor Hemerson Pistori devido a enorme paciência, confiança e dedicação que teve comigo. Por todos seus conhecimentos, ensinamentos e todas as coisas positivas que me passou e me tornou hoje a menina que sou. Eu simplesmente te admiro. A minha coorientadora Ariadne, pela confiança e dedicação.

A todo pessoal do INOVISAO, pela amizade, companheirismo, pelos momentos de muitas risadas. Especialmente ao Alessandro pela GIGANTE paciência e dedicação em me explicar o mesmo código várias vezes, em responder meus enormes emails tardes da noite, nem sei como agradecer, com certeza cheguei aqui com a tua ajuda.

A Gercina (Gê) que considero muito, obrigada pelas conversas, por ter se tornado uma grande amiga, ao Pedro Albuquerque (Pedrinho) pela amizade, dedicação, pelo companheirismo principalmente na hora janta, haha. Ao Lucas Lima, pelos ensinamentos de biologia, pela paciência e disposição em tirar minhas dúvidas sobre nossas queridas "larvinhas", rsrs.

A todos os meus amigos que torceram por mim, a Carolini Rodrigues (Carol), ao Rafael Melo (Rafa) e ao Alexandro Garcia (Ale). A minha turma que me ajudou muitoooo em várias matérias. A todas as pessoas que direta ou indiretamente contribuíram para a minha formação.

A todos os professores, pelos ensinamentos e experiências que me trouxeram, principalmente ao Marcos Alves que admiro muito. Enfim, a todos, incluso ou não nesses agradecimentos, só tenho a dizer MUITO OBRIGADA!

Resumo

É um grande desafio o reconhecimento das larvas, pois elas exibem uma grande variação de características, tamanhos, morfologia e cor, e consequentemente, tornando o processo de identificação, uma ação demorada para a Entomologia Forense. A partir das informações relevantes do ciclo biológico dos insetos é possível contribuir para soluções de crime e com objetivo de auxiliar os peritos, este projeto visa criar a partir de algoritmos de extração de atributos e técnicas de superpixels, um sistema de visão computacional, capaz de classificar automaticamente espécies de larvas necrofágicas usando imagens microscópicas de larvas. Para o desenvolvimento do software foram feitos testes a partir do banco de imagens de larvas necrofágicas. As larvas foram obtidas realizando um experimento com um suíno durante 12 dias, e neste período coletou-se as larvas. Após a coleta, realizou-se a triagem, método que tem por finalidade separar as larvas, de acordo com sua espécie e obtendo as imagens usando um microscópio. Foi aprimorada uma ferramenta desenvolvida pelo INOVISÃO¹, que extrai atributos de imagens, faz a segmentação em superpixels e classifica a espécie da larva.

¹Grupo de Pesquisa, Desenvolvimento e Inovação em Visão Computacional da UCDB.

Conteúdo

1	Introdução 9								
2	Trabalhos Correlatos 1								
3	Fun	damentação teórica 13	3						
	3.1	Entomologia Forense	3						
		3.1.1 Dípteros $\ldots \ldots 14$	4						
		3.1.2 Características Visuais das Larvas	õ						
	3.2	Visão Computacional	3						
		3.2.1 Segmentação de Imagens	9						
		3.2.2 Segmentação em Superpixels	9						
		3.2.3 SLIC)						
	3.3	Extração de Atributos	1						
		3.3.1 Bancos de Filtros de Gabor	2						
		3.3.2 Atributos Categóricos	3						
	3.4	Aprendizagem Automática	3						
		3.4.1 Random Forest $\ldots \ldots \ldots \ldots \ldots \ldots \ldots \ldots \ldots \ldots 2^{2}$	4						
		3.4.2 J48 \ldots 24	4						
		3.4.3 Random Tree $\ldots \ldots \ldots \ldots \ldots \ldots \ldots \ldots \ldots 2^{4}$	4						
4	Mat	ceriais e Métodos 26	3						
	4.1	Construção de um banco de imagens de larvas	3						
	4.2	Desenvolvimento do Software	7						
	4.3	Modelo Proposto Baseado em Superpixel	7						
		4.3.1 Aprendizagem	3						
		4.3.2 Geração dos ARFFs	9						
		4.3.3 Classificação)						
	4.4	Classes dos Superpixels	C						
		4.4.1 Primeiro ARFF	C						
		4.4.2 Segundo ARFF	1						

5	Res	ultados, Análise e Discussão	33						
	5.1	.1 Análise da Taxa de Acerto							
		5.1.1 Primeiro ARFF	33						
		5.1.2 Segundo ARFF	34						
	5.2	Análise geral de resultados	34						
		5.2.1 Primeiro ARFF	34						
		5.2.2 Segundo ARFF	36						
	5.3	Desempenho das Métricas	37						
	5.4	Primeiro ARFF	38						
		5.4.1 Algoritmo J48	38						
		5.4.2 Algoritmo Random Forest	38						
		5.4.3 Algoritmo Random Tree	38						
	5.5	Segundo ARFF	39						
		5.5.1 Algoritmo J48	39						
		5.5.2 Algoritmo Random Forest	39						
		5.5.3 Algoritmo Random Tree	39						
	5.6	Comparação e Avaliação	40						
		5.6.1 ANOVA	40						
	5.7	Conclusão dos Resultados	41						
6	Con	siderações Finais	44						
٨	Ima	gong	15						
A		Berta da Banco da Imagona	40						
	A.1	A 1 1 Espécie Atheriana Orientalia	40						
		A.1.2 Espécie Chrysomag Albiana	40						
		A.1.2 Espécie University Albiceps	40						
		A.1.4 Especie memuluculu Segmentaria	40						
	٨٩	A.1.4 Fallina Sarcophagidae	47						
	A.2	A 2.1 Classer Tubároulo	47						
		A.2.1 Classe: Tuberculo	41						
		A.2.2 Classe: Fulldo \dots A.2.2 Classe: Fulldo \dots	40						
		A.2.5 Classe: Espiraculo	40						
		A.2.4 Classe: Segmento	49						

Lista de Figuras

3.1	Imagem Ilustrativa de uma Díptera da Família Calliphoridae.	
	Fonte: Glaucia, 2016	14
3.2	Segmentos de larva generalizado, vista lateral. (PC) Segmento	
	ppseudocefálico. (T) Segmentos torácicos. (A) Segmentos ab-	
	dominais. Fonte: Oliveira-Costa, 2013.	15
3.3	Larva generalizada de Díptera. (a) Banda de espinhos com-	
	pletos - se encerram na região dorsal. (b) Banda de espinhos	
	incompletos - se encerram na região lateral. (c) Banda de	
	espinhos incompletos - se encerram na área ventral. Fonte:	
	Oliveira-Costa, 2013	15
3.4	Espiráculos de Diptera Generalizados. (a) Larva em L1. (b)	
	Larva em L2. (c) Larva em L2. Fonte: Oliveira-Costa, 2013.	16
3.5	Espiráculos de Diptera Generalizados. (a) Peritrema com-	
	pleto. (b) Peritrema incompleto. Fonte: Oliveira-Costa, 2013.	16
3.6	Larva Atherigona orientalis. (a) Espiráculos posteriores. (b)	
	Vista lateral. Fonte: Grzywacz, 2014	17
3.7	Larva Chrysomya albiceps. (a) Ultimo segmento. (b) Vista	
	lateral. Fonte: Oliveira-Costa, 2013	17
3.8	Larva Hemilucilia segmentaria. (a) Ultimo segmento. (b)	
	Vista lateral. Fonte: Oliveira-Costa, 2013	17
3.9	Larva Sarcophagidae. (a) Ultimo segmento. (b) Vista lateral.	
	Fonte: Oliveira-Costa, 2013	18
3.10	Imagem segmentada em superpixel SLIC	20
3.11	Espaço de cor CIELAB.	21
3.12	Representação de uma função Gaussiana através de imagens	
	em tons de cinza. A - Em duas dimensões; B - Em três di-	
	mensões. Fonte: PISTORI, 2015	22
3.13	Representação de uma senoide através de imagens em tons de	
	cinza. A - Em duas dimensões; B - Em três dimensões. Fonte:	
	PISTORI, 2015	23

3.14	Representação de Gabor através de imagens em tons de cinza. A- Em duas dimensões; B- Em três dimensões. Fonte: PIS- TORI, 2015	23
4.1	Experimento usando suíno de 10Kg	26
4.2	Interface do software.	28
4.3	Aprendizagem - Imagem segmentada	29
$4.4 \\ 4.5$	Aprendizagem - Imagem com todos superpixels marcados Imagem da larva Chrysomya Albiceps classificada manual-	29
4.6	mente com todas as classes presentes	31
	mente com apenas duas classes presentes	32
$5.1 \\ 5.2$	Classe predominante da imagem: segmento	36
	zando a métrica Precisão para as classes tubérculo, fundo, es-	
	piráculo e segmento.	41
5.3	Gráfico Boxplot expondo desempenhos dos algoritmos utili- zando a métrica Precisão para as classes <i>Orientalis</i> , <i>Albiceps</i> ,	
	Segmentaria e Sarcophagidae	41
$5.4 \\ 5.5$	Imagem da larva Chrysomya Albiceps classificada manualmente. Imagem da larva Chrysomya Albiceps classificada automati-	42
	camente	43
Δ 1	Imagens microscónicas de larvas da espécie Atherigona Orien-	
11.1	talis.	45
A.2	Imagens microscópicas de larvas da espécie Chrysomya Albiceps.	46
A.3	Imagens microscópicas de larvas da espécie Hemilucilia Seg-	
	mentaria	46
A.4	Imagens microscópicas de larvas da família Sarcophagidae	47
A.5	Imagens de Superpixels representando a classe Tubérculo	47
A.6	Imagens de Superpixels representando a classe Fundo	48
A.7	Imagens de Superpixels representando a classe Espiráculo	48
A.8	Imagens de Superpixels representando a classe Segmento	49

Capítulo 1 Introdução

A entomologia forense é o estudo de insetos e outros artrópodes que se aplica a procedimentos legais como investigações médico criminais [10], que contribui em elucidações de crime a partir das informações relevantes do ciclo biológico e da diversidade dos grupos taxonômicos [33]. Para a entomologia forense existe uma carência de um banco de dados que possa ser referência para investigações criminais e estimativas de intervalo pós-morte. É um grande desafio o reconhecimento de larvas, pois estas são altamente articuladas, exibem um grau elevado de variações no tamanho, morfologia e cor, e algumas espécies são difíceis de distinguir visualmente [33].

A ordem Diptera, equivalente das moscas, mosquitos e afins, faz parte dos grupos de insetos mais diversos, tanto ecologicamente quanto em termos de riquezas de espécies. Este grupo de insetos são os maiores responsáveis pela decomposição de um corpo, somente quando o corpo está muito ressecado que outros grupos de insetos são atraídos para continuar o processo da decomposição [41].

Neste projeto almeja-se estudar técnicas de visão computacional especificamente técnicas de segmentação de imagens por superpixels para a identificação de larvas necrofágicas. A coleta das larvas a partir da carcaça de um suíno junto à captura de imagens das espécies usando um microscópio óptico, tornará possível a criação de um programa capaz de identificar a espécie da larva, para posteriormente auxiliar o perito em sua análise sobre o crime, já que manualmente é uma tarefa demorada e muito cansativa para a entomologia forense, e por esse motivo, erros na identificação podem ocorrer devido ao desgaste humano.

A coleta de larvas foi realizada utilizando um suíno de 10kg num período de 12 dias. Após coletadas, ocorreu a higienização das larvas num laboratório, em seguida, com um microscópio óptico ZEISS Axio Scope A1 foram identificadas e classificadas quanto ao estágio de desenvolvimento larval e espécie. Posteriormente, usando o mesmo microscópio foram capturadas imagens das estruturas das larvas, dessa maneira foi construído o banco de imagens. O banco contém imagens de três espécies e uma família, sendo elas *Chrysomya Albiceps, Hemilucilia Segmentaria, Atherigona Orientalis* e Sarcophagidae². Estas imagens foram a entrada do software.

No programa aprimorado houve a aplicação das técnicas de segmentação de imagens e extração de atributos. A primeira técnica consiste em segmentar a imagem por superpixel e a segunda extrair características como cor, textura, forma e gradiente de cada superpixel, e os resultados são usados como treinamento para algoritmos de aprendizagem de máquina. Com isso, o programa é capaz de classificar cada superpixel. Posteriormente, os resultados dessa classificação são usados para treinar os algoritmos novamente e por fim, o programa classifica uma imagem inteira. A vantagem de fazer dois treinamentos é que os algoritmos recebem mais informações e podem classificar com mais precisão.

Nos experimentos realizados neste programa os algoritmos usados foram J48, Random Forest e Random Tree em razão de serem algoritmos que aceitam atributos categóricos. Os resultados da classificação de cada superpixel seguida da classificação da imagem inteira foram a maioria das imagens identificadas como a espécie correta.

 $^{^{2}}$ Sarcophagidae não está escrito em itálico pois é nome de família, a regra é para nomenclatura binomial [8].

Capítulo 2

Trabalhos Correlatos

A classificação automática de larvas necrófagas foi proposta em [12] onde são utilizadas larvas dípteras. O objetivo do trabalho foi analisar o desempenho dos classificadores para determinar instar, visão e espécie com o propósito de desenvolver um programa baseado em visão computacional capaz de realizar a identificação de estruturas de larvas necrofágicas em imagens microscópicas, com a intenção de auxiliar a entomologia forense otimizando o trabalhos dos peritos. No trabalho [12] os algoritmos classificadores utilizados foram SMO, Random Forest, Random Tree e Adaboost. As métricas utilizadas para mensurar o desempenho dos classificadores foram a porcentagem de acerto, área sob a curva ROC e medida F.

O problema da classificação automática de grãos de pólen é abordado em [27], a técnica de Histogramas de Palavras Visuais é o método proposto para resolver o problema, também chamado de Bag of Words (BOW), refere-se a um vetor de atributos que é extraído de determinada imagem ou conjunto de imagens. Para a extração de atributos são usadas técnicas auxiliares denominadas SIFT e SURF. Na classificação de pólen, as imagens são divididas de acordo com cada espécie sendo que os pontos de interesse das imagens são associados a cada palavra visual, de acordo com a menor distância entre o ponto analisado e a média de cada grupo. Segundo [27] para o problema de classificação de grãos de pólen os algoritmos SVM e KNN são os mais indicados, em relação ao desempenho em porcentagem de acerto, Área sob a curva ROC e Média Ponderada da medida F, o algoritmo SVM obteve melhor resultado.

Outro projeto, desta vez desenvolvido por [19], apresenta a implementação de Filtros de Gabor para auxiliar na classificação automática de larvas necrófagas. Foram utilizados três algoritmos de aprendizagem, SVM, AdaBoost e Random Forest. Neste trabalho também houve experimentos comparando o desempenho dos algoritmos sem e com o extrator baseado em textura Filtros de Gabor. [19] utilizou 603 imagens em seu banco de imagens, obteve como resultado 409 imagens classificadas corretamente. Neste trabalho conclui-se que os resultados são aparentemente melhores sem a inclusão do extrator, mas explica que sem a inserção do Gabor, a técnica com números de resultados mais elevados extraiu a cor para identificar do que se tratava cada imagem. Deste modo, não foram apenas características do objeto em análise identificadas, mas também envolveu questões de iluminação e cor de fundo. O projeto de [19] também tem como objetivo validar um programa baseado em visão computacional com a intenção de facilitar em investigações criminais.

As pegadas são uma importante fonte de informação para a investigação criminal, detectar de maneira rápida a marca e o fabricante do calçado é valioso para detetives em qualquer investigação criminal. No trabalho [14] é apresentado métodos automatizados de reconhecimento de pegadas. Os métodos são testados com três conjuntos de dados de diferentes qualidades de pegadas e sua capacidade de reconhecer é avaliada. [14] conclui que o desempenho dos algoritmos de reconhecimento de pegadas automatizado é altamente dependente da qualidade das impressões.

Capítulo 3

Fundamentação teórica

3.1 Entomologia Forense

Em termos de abundância de espécies, os insetos são o maior grupo taxonômico dentre os animais. Há mais de um milhão de espécies de insetos descritas, encontradas em considerável diversidade de habitats [34]. Os corpos em decomposição apresentam-se ricos em matéria orgânica, essencial ao desenvolvimento dos insetos necrófagos [3]. Portanto, os insetos podem ser vistos como participantes do processo de decomposição dos corpos [2].

A entomologia forense é uma subárea da medicina legal que utiliza fundamentos zoológicos para auxiliar em investigações criminais. Na maior parte dos casos emprega-se a estimativa do intervalo pós-morte, através do conhecimento do ciclo de vida de insetos encontrados em cadáveres [2].

Desde o século 13 aplica-se o estudo dos insetos para investigações no contexto da medicina legal na China [38]. Mesmo parecendo um longo tempo de estudos, e acúmulos de conhecimento, em tempos remotos havia baixa compreensão sobre o assunto entre os especialistas por não existirem formalmente conexões entre a entomologia e a medicina legal. Atualmente existe esta conexão e tem sido aceita em diversos países como ferramenta importante para a medicina legal [4].

Com base no ciclo de vida do inseto, principalmente larvas de dípteros é possível estimar o intervalo pós-morte (IPM), ou seja, o tempo decorrido desde o óbito até a descoberta do corpo. A entomologia forense também pode inferir o local de óbito, já que a diferença entre a composição de insetos presentes no corpo e a composição de espécies situadas na região geográfica onde o corpo foi descoberto, pode fornecer evidências de que a vítima foi deslocada [15]. Logo, a presença das larvas necrofágicas em conjunto com outras evidências pode esclarecer o tempo e o local onde a ocorrência pode ter acontecido.

3.1.1 Dípteros

Com o objetivo de procurar alimento ou de um local apropriado para postura, os dípteros se deslocam rapidamente a grandes distâncias. O odor da decomposição dos corpos após a morte, atrai grande parte de suas espécies [20]. Por consequência, a Diptera representa a Ordem de mais importância forense, sendo as famílias Calliphoridae, Muscidae e Sarcophagidae as primeiras colonizadoras de um cadáver [33] e esta foi a ordem estudada neste trabalho (Figura 3.1). A análise das características morfológicas é o procedimento que é usado para identificar a maioria das espécies. Porém, em alguns casos, a identificação das diferenças morfológicas se torna quase impossível [20].





As moscas pertencentes a família Calliphoridae são cosmopolitas, tem distribuição geográfica mundial, existem mais de 1000 espécies e cerca de 150 gêneros conhecidos. No território brasileiro, 12 espécies de califorídeos são alvos de interesse para a Entomologia Forense: *Chrysomya albiceps* (Wiedemann), *Chrysomya megacephala* (Fabricius), *Chrysomya putoria* (Wiedemann), *Cochliomyia macellaria* (Fabricius), *Hemilucilia segmentaria* (Fabricius), *Hemilucilia semidiaphana* (Rondani), *Phaenicia cuprina* (Wiedemann), *Phaenicia eximia* (Wiedemann), *Phaenicia sericata* (Meigen), *Mesembrinella bellardiana* (Aldrich), *Paralucilia fulvinota* (Bigot) e Sarconesia chlorogaster (Wiedemann) [20].

Em larvas da família Calliphoridae os três instares larvais são muitos semelhantes entre si e determinados principalmente pelo número de fendas do espiráculo posterior. As principais mudanças que sucedem ao longo do desenvolvimento estão relacionadas ao tamanho, às estruturas do esqueleto cefalofaríngeo e ao desenvolvimento dos espiráculos [21].

3.1.2 Características Visuais das Larvas

As espécies estudadas foram Atherigona orientalis, Chrysomya albiceps, Hemilucilia segmentaria e umas espécies pertencentes a família Sarcophagidae.

Uma das formas de identificar o instar das larvas, ou seja, o estágio larval, é através dos espiráculos. Os espiráculos são aberturas externas do sistema respiratório que podem estar presentes em um ou mais segmentos corporais (Figura 3.2), geralmente assume uma posição posterior ou dorsal (Figura 3.3) e localiza-se no último segmento corporal.



Figura 3.2: Segmentos de larva generalizado, vista lateral. (PC) Segmento ppseudocefálico. (T) Segmentos torácicos. (A) Segmentos abdominais. Fonte: Oliveira-Costa, 2013.



Figura 3.3: Larva generalizada de Díptera. (a) Banda de espinhos completos - se encerram na região dorsal. (b) Banda de espinhos incompletos - se encerram na região lateral. (c) Banda de espinhos incompletos - se encerram na área ventral. Fonte: Oliveira-Costa, 2013.

No interior dos espiráculos encontram-se as fendas espiraculares, que são as aberturas respiratórias que, de acordo com sua quantidade, indica o instar. Uma fenda indica larva em 1º instar ou L1, duas fendas para o 2º instar ou L2 e três fendas para 3º instar ou L3 (Figura 3.4). Ao redor dos espiráculos existe uma linha esclerotizada, o peritrema, que pode ser completo quando circunda toda a extremidade ou incompleto quando circunda uma grande parte, mas não há a junção de suas pontas (Figura 3.5).



Figura 3.4: Espiráculos de Diptera Generalizados. (a) Larva em L1. (b) Larva em L2. (c) Larva em L2. Fonte: Oliveira-Costa, 2013.



Figura 3.5: Espiráculos de Diptera Generalizados. (a) Peritrema completo. (b) Peritrema incompleto. Fonte: Oliveira-Costa, 2013.

Atherigona orientalis (Figura 3.6) possui um corpo finamente perfurado na região dorsal e distintamente esclerotizada na região ventral, ou seja, endurecida e escurecida. Os espiráculos posteriores apresentam peritrema completo e fortemente pigmentado com aberturas espiraculares curvadas e não paralelas. O intervalo entre os espiráculos é maior do que as outras espécies estudadas [9].

Chrysomya albiceps (Figura 3.7) possui coloração variando do creme ao castanho claro. Os espiráculos posteriores apresentam peritrema incompleto, grosso e fortemente pigmentado com aberturas espiraculares bem compridas e paralelas [21].



Figura 3.6: Larva Atherigona orientalis. (a) Espiráculos posteriores. (b) Vista lateral. Fonte: Grzywacz, 2014.



Figura 3.7: Larva Chrysomya albiceps. (a) Ultimo segmento. (b) Vista lateral. Fonte: Oliveira-Costa, 2013.

Hemilucilia segmentaria (Figura 3.8) possui coloração do branco leitoso à rosácea. O esqueleto cefalofaringeano é fortemente esclerotizado. O espiráculo posterior apresenta peritrema fortemente pigmentado e incompleto. É possível observar espinhos pigmentados por toda a larva e a região anal é bem aparente e desenvolvida com espinhos castanhos e fortemente esclerotizados [21].



Figura 3.8: Larva Hemilucilia segmentaria. (a) Ultimo segmento. (b) Vista lateral. Fonte: Oliveira-Costa, 2013.

A família Sarcophagidae (Figura 3.9) apresentam doze segmentos bem definidos e alguns segmentos podem apresentar em maior quantidade na região ventral. O par de espiráculos posterior localiza-se no último segmento abdominal em uma profunda e larga depressão da cavidade espiracular, que é capaz de esconde-los quando em vista dorsal [21].



Figura 3.9: Larva Sarcophagidae. (a) Ultimo segmento. (b) Vista lateral. Fonte: Oliveira-Costa, 2013.

3.2 Visão Computacional

A Visão Computacional é a área da Computação que tem como objetivo o estudo de imagem digital, a partir das imagens capturadas por câmeras, filmadoras, entre outros dispositivos. Estas imagens são transformadas por algoritmos para obter informações importantes, modelos, equações matemáticas através de um sistema computacional capaz de interpretar essas imagens de forma automática ou semiautomática [42].

Pode-se dizer também que a Visão Computacional é a área da Computação que se empenha em reproduzir em programas, a habilidade do ser humano em identificar ou resolver problemas através da visão. Para o ser humano é trivial identificar objetos a partir de imagens, mas, adaptar essa realidade para o mundo computacional não é uma tarefa muito trivial [6].

Atualmente aplica-se visão computacional em diversas áreas, como por exemplo: reconhecimento óptico de caracteres, fotogrametria, imagens médicas, segurança automativa, captura de movimento, vigilância, reconhecimento de impressão digital e biometria, detecção de faces, autenticação visual entre outros [36].

As principais etapas de um sistema de visão computacional são: aquisição de imagens, pré-processamento, extração de atributos, detecção e segmentação, e processamento de alto nível. O primeiro passo trata-se de aquisição de imagem ou um conjunto de imagens a partir de sensores de câmeras. Pré-processamento é o processo onde se aplica técnicas que facilitem a identificação de objetos, como por exemplo, bordas, contornos. O objetivo da extração de atributos é extrair características que compõem uma imagem, como textura. Em detecção destacam-se regiões relevantes da imagem. Finalmente ocorre a classificação dos objetos obtidos em diferentes categorias no processamento de alto nível [23], [17].

3.2.1 Segmentação de Imagens

Segmentar, em processamento digital de imagens, significa extrair subconjuntos de pixels com propriedades semelhantes a partir de uma imagem, sendo que o nível de detalhes em que a subdivisão é realizada depende do problema a ser resolvido [13]. Os principais algoritmos propostos para a segmentação de imagens, são os baseados em limiarização ou histogramas, segmentação por agrupamento e segmentação por ajustes de modelos [32].

Espera-se como resultado da segmentação um número finito de regiões homogêneas, que individualizam as diferentes regiões contidas numa imagem, assim, a imagem seria formada por um conjunto de regiões, ligadas por suas bordas e que não se sobrepõe de maneira que cada pixel da imagem pertence unicamente a uma determinada região [29].

Para o ser humano, a segmentação é um processo natural, pois a partir de um conjunto de informações que são combinadas e processadas em paralelo no cérebro reconhecemos e interpretamos os objetos. Computacionalmente o processo de reproduzir com exatidão esse reconhecimento e interpretação é complexo, mas existem casos que a visão computacional pode compensar as deficiências da visão humana, como por exemplo, na identificação de frequências mais altas ou mais baixas de imagens [30].

3.2.2 Segmentação em Superpixels

Superpixels são agrupamentos de pixels em regiões com características semelhantes [20] [40]. Os superpixels precisam agrupar uma considerável quantidade de pixels para ter uma boa segmentação da imagem, de modo que seja possível identificar uma mesma região em partes diferentes da imagem. Para ter um aumento substancial em relação a velocidade de processamento da imagem é necessário que o número de superpixels não seja muito grande, de 25 a 2500 em média [18].

A desvantagem do uso dos superpixels se dá pela etapa de pré processamento, que exige um maior esforço computacional para construção das unidades, pelo risco de perder dados relativos a bordas da imagem colocando-as dentro de um superpixel. Portanto, é importante escolher corretamente os algoritmos que serão utilizados e seus parâmetros [1].

Existem várias maneiras de agrupar regiões similares em superpixel, a mais comum foi introduzida por Maik, utiliza-se o algoritmo Normalized Cut. Esse algoritmo particiona a imagem em regiões disjuntas com coerência dos atributos contorno e textura resultando em um mapa dos superpixels [31]. Normalized Cut utiliza as características da imagem de forma interligada obtendo um grafo ponderado, onde os pixels são os nós e o peso das arestas ligando os nós é definido por uma função de similaridade entre pixels [16].

Os métodos baseados em grafos são indicados para casos onde a precisão em relação a borda das formas na figura são de grande importância, mas o Nomalized Cut não possui eficiência tão boa em relação a precisão nas bordas e atualmente é um dos métodos mais lentos, principalmente para imagens grandes. Para o processamento nesse trabalho foi utilizado o método SLIC que é um método mais rápido e eficiente em relação ao uso de memória [1].



Figura 3.10: Imagem segmentada em superpixel SLIC.

3.2.3 SLIC

O SLIC (Simple Linear Iterative Clustering) é uma adaptação do algoritmo K-means para a geração de superpixel [1]. O algoritmo é simples, combina cor e proximidade espacial otimizando a detecção de bordas para gerar superpixels, durante esta combinação controla o tamanho e a quantidade de unidades (Figura 3.10).

SLIC realiza um agrupamento local dos pixels no espaço 5-D definido pelos valores da escala CIELAB de cor que são L, a, b e pelas coordenadas x e y dos pixels. Sua medição de distância impõe regularidade nas formas dos superpixels [1].

O espaço de cor CIELAB (Figura 3.11) é definido como uma aproximação de escala uniforme de cor, onde as diferenças no espaço correspondem a diferenças visuais, proposto pela Commission Internationale de l'Eclairage (CIE) que utiliza um espaço tridimensional com três eixos, L a b. Sua estrutura é formada por um eixo vertical denominado L e eixos horizontais a e b que não possuem valores numéricos, mas como referência tem valor de 60 unidades de cor. O valor de *a* positivo corresponde ao vermelho e negativo ao verde, já o valor de *b* positivo representa ao amarelo e negativo ao azul [30]. CIELAB é um espaço de cor uniforme para pequenas variações de cor. Suas unidades são geradas a partir de pixels agrupados baseados na sua semelhança e proximidade de cor no plano da imagem [1].



Figura 3.11: Espaço de cor CIELAB.

3.3 Extração de Atributos

Extração de atributos é uma das etapas de Visão Computacional em que consiste extrair informações úteis ou de interesse da imagem processada. Esta etapa é a responsável pela mensuração dos atributos dos objetos pertencentes à imagem em estudo, que são utilizados para identificar uma classe de padrão.

Para a extração das cores foram calculados os valores mínimo, médio, máximo e desvio padrão para cada um dos canais nos espaços de cores RGB, HSV e CIELab. Para extrair a textura o algoritmo é baseado em matrizes de coocorrência. O algoritmo HOG é um descritor de atributos que calcula o histograma da imagem a partir da orientação dos gradientes. O descritor final é uma matriz unidimensional de histogramas extraídos a partir da imagem. O algoritmo é baseado na forma e aparência do objeto local, que em uma imagem pode ser representado por gradientes de intensidade ou de direções de borda.

3.3.1 Bancos de Filtros de Gabor

Para entender Bancos de Filtros de Gabor precisa-se revisar alguns conceitos, entre eles Função Gaussiana e Senoide. Funções Gaussianas são modelos que descrevem o comportamento de vários fenômenos aleatórios. É importante saber reconhecer a representação de uma função através de imagens em tons de cinza como na Figura 3.12.A, nela existe um ponto central onde encontrase o valor mais alto da função, conforme se afasta do ponto o valor da função diminui exponencialmente. Na representação em tons de cinza, quanto mais branco mais alto é o valor da função, logo quanto mais perto do preto, mais baixo é o valor. Com a Figura 3.12.A nota-se que o centro da imagem onde a cor branca é mais forte é o ponto alto da função [24]. A representação da função em três dimensões pode ser observada na Figura 3.12.B.



Figura 3.12: Representação de uma função Gaussiana através de imagens em tons de cinza. A - Em duas dimensões; B - Em três dimensões. Fonte: PISTORI, 2015.

Uma senoide, ou função harmônica é caracterizada por suas repetições, aplicando em imagens, são elementos visuais que se repetem em uma determinada frequência e direção. Observando a Figura 3.13.B percebe-se que em uma senoide os valores vão aumentando até chegar no ponto máximo e diminuindo até chegar no ponto mínimo, pois existe uma variação do branco para o preto, a cor não troca de repente.

A partir desses conceitos pode-se dizer que Filtros de Gabor é a multiplicação de uma gaussina por uma senoide. Uma outra maneira de enxergar é dizer que os filtros bidimensionais de Gabor são grades senoidais complexas, moduladas por uma função Gaussiana bidimensional, formando funções de valor complexo [5]. A Figura 3.14 mostra o resultado dessa multiplicação.

Os filtros de Gabor têm sido utilizados para a representação de imagens. Através de um conjunto de classes de funções de Gabor é possível representar de forma completa qualquer tipo de imagem. Essas funções têm como objetivo extrair atributos para caracterizar diferentes tipos de texturas presentes na imagem, que são descritas pela frequência e orientação já definidas pelas



Figura 3.13: Representação de uma senoide através de imagens em tons de cinza. A - Em duas dimensões; B - Em três dimensões. Fonte: PISTORI, 2015.



Figura 3.14: Representação de Gabor através de imagens em tons de cinza. A- Em duas dimensões; B- Em três dimensões. Fonte: PISTORI, 2015.

funções senoidais. O envelope Gaussiano define as resoluções espaciais com que as estruturas de textura são caracterizadas [22].

3.3.2 Atributos Categóricos

Alguns problemas de classificação envolvem atributos nominais ou categóricos, ou seja, duas instâncias apresentam ou não o mesmo valor sem ordenação. Devem ser adotados métodos apropriados para classificar objetos utilizando atributos nominais. Dentre os principais métodos podemos citar a indução árvores de decisão, os métodos gramaticais, o reconhecimento com String, a inferência gramatical e a aprendizagem baseada em regras [35]. Dentre os algoritmos para a indução de árvores estão: ID3 [25], C4.5 [26] e IDR5 [39].

3.4 Aprendizagem Automática

O processo de aprendizagem automática ou aprendizado de máquina está relacionado a etapa de reconhecimento de padrões, que consiste no ato de identificar uma categoria de padrões, baseada em um conjunto de dados. Este processo é utilizado em diversas áreas, como por exemplo, identificação

de cadeias de DNA, reconhecimento de impressões digitais e reconhecimento de escrita manual [37]. Os algoritmos que realizam esse reconhecimento são chamados de classificadores, e um dos métodos utilizado na definição de características do classificador é o treinamento, ou seja, a utilização de instâncias (amostras) para treinar a identificação das classes [28].

A aprendizagem pode ser feita de forma supervisionada ou não supervisionada. Na forma supervisionada, exemplos de cada padrão em um conjunto de treinamento são fornecidos e essas amostras previamente classificadas são utilizadas durante o treinamento [37]. Neste trabalho foi utilizada a aprendizagem supervisionada e os algoritmos utilizados foram escolhidos na biblioteca de classificadores WEKA e serão descritos a seguir.

3.4.1 Random Forest

As Random Forests especificam uma instância usando um conjunto de Random Trees, o método harmoniza o resultado de cada árvore por um mecanismo de escolha. Cada árvore produz uma qualificação, concluindo a classe que obteve mais ganho em toda floresta, a classe correta para aquela instância. Para cada árvore formada é adotado um conjunto de treinamento diferente formado por instâncias definidas aleatoriamente, geralmente a quantidade de atributos para cada árvore deve ser bem menor que o total de atributos para que consiga ser geradas árvores diferentes, as quais serão combinadas para rotular uma determinada instância [7].

3.4.2 J48

O J48 separa os dados através de uma árvore de decisão, construída baseandose nos atributos do conjunto de treinamento. A cada relação o algoritmo seleciona o atributo que melhor diferencia os dados com base no ganho de informação e separa o conjunto em partes até que restem apenas folhas, ou seja, respostas de classificação. As árvores de decisão podem ser naturalmente entendidas e convertidas em regras de produção, permitindo uma avaliação rápida dos casos de teste [28].

3.4.3 Random Tree

A Random Tree é um modelo de árvore que reconhece n atributos designados aleatoriamente em cada nó da árvore. É um conceito de árvore de regressão induzido por amostras bootstrap (reamostragem) e é geralmente usado como base de outros métodos como Random Forests. Para cada nó de sua árvore são escolhidos aleatoriamente n atributos que irão conduzir o nó, com base na melhor distinção de classes do conjunto de treinamento em relação a alguma métrica. No projeto foi utilizado o modelo de Random Tree disponível na biblioteca do WEKA para a montagem do classificador [30].

Capítulo 4

Materiais e Métodos

4.1 Construção de um banco de imagens de larvas

Foi realizada a coleta de larvas necrofágicas utilizando um suíno de 10Kg (Figura 4.1) autorizado pela Comissão de Ética para o Uso de Animais (CEUA) da Universidade Católica Dom Bosco, o suíno foi adquirido morto de um estabelecimento comercial de Campo Grande. O processo de decomposição durou 12 dias. Após ser feita a coleta diária das larvas, elas foram armazenadas em tubo tipo Falcon contendo álcool 70% e levadas a um laboratório onde foram higienizadas. Em seguida, as larvas foram identificadas e classificadas quanto ao ínstar (estágio de desenvolvimento larval) e espécie, utilizando um microscópio óptico ZEISS Axio Scope A1 seguindo a literatura descrita por [33] e [21].



Figura 4.1: Experimento usando suíno de 10Kg.

Após feita a identificação das larvas, elas foram congeladas em um freezer

a -80° C. Posteriormente, as larvas passaram pelo processo de clarificação, que consistiu em seccionar as partes das larvas que são importantes na identificação, como os três últimos segmentos localizados na região caudal e foram fervidas em uma solução de 50 ml de água destilada e KHO à 0,5% por aproximadamente 15 minutos. Este processo tem o objetivo de retirar todo conteúdo interno presente nas larvas tornando possível o máximo de passagem de luz do microscópio, assim possibilitando uma melhor identificação das estruturas larvais.

Usando o microscópio óptico ZEISS Axio Scope A1 (lentes de aumento de 5x), foram capturadas imagens das estruturas presentes na região caudal das larvas, como espiráculos, tubérculos e segmentos das espécies Atherigona Orientalis, Chrysomya Albiceps, Hemilucilia Segmentaria e família Sarcophagidae. Totalizando um banco com 544 imagens de larvas necrofágicas, no terceiro instar. Não foram capturadas imagens das larvas em seu primeiro e segundo instar, por ser muito difícil analisar suas características nessas fases, devido suas estruturas ainda não estarem formadas.

As imagens foram organizadas dentro de uma pasta denominada Instar3, dentro desta foram criadas quatro pastas nomeadas com os nomes das espécies e família das larvas. Dentro de cada pasta foram criadas mais duas indicando a estrutura larval (caudal e cranial) seguido do plano de visão ao qual foi fotografada, dorsal e lateral.

4.2 Desenvolvimento do Software

O software foi desenvolvido na linguagem Python, seguindo as regras definidas pelo INOVISÃO, disponíveis no site do mesmo. Foram aproveitados códigos do programa python-superpixels que foi desenvolvido por este grupo, tem a finalidade de segmentar e classificar uma imagem, como será explicado na seção 4.2.1. A interface do programa pode ser vista na (Figura 4.2).

Neste software está acoplado o programa python-extrai-atributos que tem por objetivo extrair características de imagens, por exemplo, cor, textura, forma e gradiente. Este programa é composto por seis extratores de atributos, Momentos de Hu, Estatísticas de cores, Matriz de Coocorrência, HOG, LBP e Filtros de Gabor.

4.3 Modelo Proposto Baseado em Superpixel

O modelo proposto baseado em Superpixel foi dividido em três partes, na primeira foi feita a aprendizagem, onde o usuário treina o classificador for-



Figura 4.2: Interface do software.

necendo exemplos de instâncias e suas respectivas classes. Isso é feito pela identificação dos superpixels e marcação por parte do usuário de qual superpixel representa determinada classe, conforme será explicada na seção 4.3.1.

A segunda etapa realiza a geração de dois arquivos ARFF, primeiro em relação aos atributos extraídos de cada superpixels das imagens segmentadas da primeira etapa. E segundo, gera um arquivo ARFF dos superpixels da imagem que está sendo visualizada pelo usuário no programa, como será exemplificado na seção 4.3.2.

A última etapa consiste na classificação. O usuário seleciona uma imagem e em seguida classifica com algum dos classificadores que aceitam atributos categóricos, como será explicado na seção 4.3.3.

4.3.1 Aprendizagem

Utilizando a ferramenta desenvolvida, é possível cadastrar as classes que serão utilizadas no problema, neste caso são, fundo, espiráculo, tubérculo e segmento. A aprendizagem se inicia com a segmentação da imagem em superpixels, para isso o usuário deve escolher uma imagem que irá utilizar para fazer as marcações. O usuário ao selecionar uma imagem irá visualizar a imagem conforme a Figura 4.3.

Em seguida o usuário poderá fazer as marcações na imagem segmentada. É um processo que executa uma imagem por vez. Para realizar as marcações deve ser selecionada uma das classes e por fim clicar no superpixel que represente aquela classe e o mesmo será pintado, esse processo pode ser feito para quantos superpixels o usuário desejar.

Após marcados os representantes de uma das classes, deve-se selecionar



Figura 4.3: Aprendizagem - Imagem segmentada.

também os superpixels de outras classes, para isso basta clicar em outra classe e repetir o processo de marcação. Como resultado a imagem ficará com pixels coloridos (Figura 4.4). Cada superpixel selecionado se torna uma imagem que é armazenada na pasta referente a sua classe. Imagens dos superpixels podem ser visto no Anexo B.



Figura 4.4: Aprendizagem - Imagem com todos superpixels marcados.

4.3.2 Geração dos ARFFs

O ARFF é um arquivo no formato padrão do Waikato Environment for Knowledge Analysis (WEKA) onde são descritos todos os atributos e todas as classes, por fim são colocadas as instâncias, ou seja, valores correspondentes a cada atributo para um determinado dado e sua classe correspondente.

O primeiro arquivo ARFF contém as informações relativas aos superpixels que foram marcados na primeira etapa, ou seja, cada instância se refere a um superpixel, portanto a classe é uma das estruturas larvais definidas (tubérculo, fundo, espiráculo e segmento). Os atributos do primeiro ARFF são atributos numéricos, pois são os valores das funções dos extratores de atributos do programa python-extrai-atributos. Para gerar o arquivo, o usuário só precisa clicar no primeiro botão do canto direito.

O segundo ARFF contém informações referentes a imagem que está sendo visualizada pelo usuário no programa, cada instância se refere a uma imagem,

logo, as classes são as espécies das larvas, pois a finalidade do segundo ARFF é classificar uma imagem inteira. Essas classes não ficam visíveis na interface do programa, mas são passadas por parâmetro ao executa-lo. Importante abordar que os atributos deste ARFF são atributos categóricos, pois são as características larvais (classes do primeiro ARFF).

Para gerar o arquivo é necessário que o usuário tenha realizado a primeira etapa, que é a marcação dos superpixels e após selecionados todos superpixels, basta clicar no segundo botão do canto direito do programa. Este programa só executa uma imagem por vez, mesmo sendo um processo demorado, é necessário que o usuário repita a seleção com várias imagens, para que o classificador seja construído com um conjunto de instâncias com um número maior de dados, possibilitando que ele consiga identificar com mais precisão os superpixels.

4.3.3 Classificação

Com os superpixels treinados é possível classificar novas instâncias, ou seja, imagens que não foram utilizadas no treinamento. Nesta etapa o usuário não pode informar ao programa qual classe pertence a larva, pois o programa tem como objetivo classificar automaticamente. Para tornar esta classificação possível, é necessário que o usuário informe um classificador que aceite atributos categóricos, devido o segundo ARFF possuir este tipo de atributos.

O software WEKA está acoplado neste programa para que não seja necessário o usuário abri-lo separadamente. Ao clicar no terceiro botão do canto direito do programa iniciará a classificação automática, primeiramente o classificador receberá as informações do primeiro ARFF e em seguida do segundo, retornando com uma mensagem qual classe pertence a larva.

4.4 Classes dos Superpixels

Como foram realizadas duas classificações, temos dois conjuntos de classes. Serão abordadas essas classes para cada arquivo ARFF.

4.4.1 Primeiro ARFF

Para os atributos extraídos pelos extratores, as classes dos superpixels definidas foram estruturas presentes na região caudal da larva, como espiráculo, tubérculo, segmento 3 e a classe fundo, pois é fundamental que todos os

³Em biologia, segmentação são várias divisões pelo corpo do animal, logo, segmento está se referindo ao corpo da larva.

superpixels sejam marcados.

Durante os experimentos houveram casos que uma imagem apresentou todas as classes, por exemplo a Figura 4.5, os superpixels marcados de verde pertencem a classe tubérculo, vermelhos são espiráculos, azuis são os segmentos e os superpixels amarelos referem-se ao fundo da imagem.



Figura 4.5: Imagem da larva Chrysomya Albiceps classificada manualmente com todas as classes presentes.

Também ocorreu casos em que a imagem não apresentou todas as classes, como na Figura 4.6, que só possui duas classes, fundo em amarelo e segmento em azul.

4.4.2 Segundo ARFF

As classes do primeiro ARFF se tornam os atributos do segundo ARFF, pois agora o objetivo é classificar a imagem inteira e com isso, as classes são as espécies das larvas. O nome da classe e a espécie que esta representa pode ser visto na Tabela 4.1.

Classe	Espécie
Orientalis	Atherigona Orientalis
Albiceps	Chrysomya Albiceps
Segmentaria	Hemilucilia Segmentaria
Sarcophagidae	Sarcophagidae

Tabela 4.1: Nome das classes representando as espécies.



Figura 4.6: Imagem da larva Atherigona Orientalis classificada manualmente com apenas duas classes presentes.

Capítulo 5

Resultados, Análise e Discussão

Neste capítulo serão apresentados os resultados da identificação automática das larvas necrofágicas por meio dos testes utilizando aprendizagem supervisionada.

Os resultados da implementação dos extratores de atributos combinados com superpixels serão exibidos, sendo realizados ainda testes estatísticos para mostrar o desempenho desta técnica.

5.1 Análise da Taxa de Acerto

A técnica de superpixels foi associada com as demais técnicas de extração de atributos, que já haviam sido implementadas em um software desenvolvido pelo grupo INOVISÃO, para verificar se a junção destas técnicas contribuiriam para uma melhor classificação.

Para a realização dos testes de acerto com os classificadores foi utilizada a validação cruzada, onde há a separação entre conjunto de treinamento e conjunto de teste, de modo que não haja amostras repetidas.

Na validação cruzada, 10% do conjunto de treinamento é utilizado unicamente para teste e os outros 90% para treinar. Isso é repetido 10 vezes.

Utilizando os três algoritmos de aprendizagem já mencionados (J48, Random Forest e Random Tree) além das técnicas implementadas foi realizada a comparação entre os algoritmos de aprendizagem automática, que serão expostos a seguir.

5.1.1 Primeiro ARFF

Nesta parte da análise dos resultados foi verificada a primeira classificação que o programa faz utilizando o primeiro ARFF.

Algoritmo	Instâncias classificadas	Instâncias classificadas
	corretamente	incorretamente
J48	86.2166%	13.7834%
Random Forest	90.7642%	9.2358%
Random Tree	84.7164%	15.2836%

Tabela 5.1: Taxa de acerto dos algoritmos utilizando o primeiro ARFF.

5.1.2 Segundo ARFF

Estão expostos os resultados da taxa de acerto utilizando o segundo ARFF.

Algoritmo	Instâncias classificadas	Instâncias classificadas	
	corretamente	incorretamente	
J48	47.7273%	52.2727%	
Random Forest	63.6364%	36.3636%	
Random Tree	54.5455%	45.4545%	

Tabela 5.2: Taxa de acerto dos algoritmos utilizando o segundo ARFF.

5.2 Análise geral de resultados

Nesta seção serão explicados os resultados da classificação automática das larvas necrofágicas para cada arquivo ARFF.

5.2.1 Primeiro ARFF

Para verificar a eficiência do algoritmo foi analisada a matriz de confusão, que consiste em uma matriz que fornece informações sobre o percentual de classificação correta (PCC) de um determinado problema. Cada linha da matriz forma-se do nome da classe do problema, a diagonal principal desta matriz refere-se a quantas imagens de cada classe foram classificadas corretamente. Através da soma da diagonal obtém o total de quantas imagens foram classificadas corretamente, e finalmente a soma de todos valores da matriz resulta no total de imagens utilizadas.

Desta maneira, analisando a matriz de confusão gerada pelo algoritmo J48 (Tabela 5.3), pode ser observado que 3678 imagens foram classificadas de modo correto de um conjunto de imagens contendo 4266 imagens. A

А	В	С	D	Classificado como
43	1	9	120	A = tubérculo
2	912	0	133	$\mathbf{B} = \mathrm{fundo}$
13	0	67	39	C = espiráculo
99	137	35	2656	D = segmento

Tabela 5.3: Matriz de Confusão do algoritmo J48.

classe que foi melhor identificada foi segmento com 2656 imagens classificadas corretamente, e ainda observando essa linha "D", verifica-se que o algoritmo errou na classificação de 271 imagens, sendo que 99 foram identificadas como tubérculo, 137 imagens como Fundo e 35 classificadas erroneamente como Espiráculo.

А	В	С	D	Classificado como
17	0	1	155	A = tubérculo
0	941	0	106	$\mathbf{B} = \mathrm{fundo}$
1	0	55	63	C = espiráculo
0	67	1	2859	D = segmento

Tabela 5.4: Matriz de Confusão do algoritmo Random Forest.

Desta forma, continuamos a análise dos demais algoritmos. O conjunto de imagens mantem-se com 4266 imagens, e a matriz de confusão produzida pelo algoritmo Random Forest (Tabela 5.4), resulta em 3872 imagens classificadas corretamente. Mais uma vez a classe segmento é a classe com maior acerto, sendo 2859 imagens identificadas corretamente, 67 classificadas erroneamente como fundo e apenas uma imagem errada como espiráculo.

А	В	С	D	Classificado como
35	0	17	121	A = tubérculo
4	898	0	145	$\mathbf{B} = \mathrm{fundo}$
11	0	52	56	C = espiráculo
117	137	44	2629	D = segmento

Tabela 5.5: Matriz de Confusão do algoritmo Random Tree.

Para a matriz de confusão gerada pelo Random Tree, a classe segmento continua com o maior número de acerto (2629 imagens), isso porque é a

classe que possui mais imagens. Quanto maior for o número de instâncias de uma classe, maior será a possibilidade do classificador identificar com mais precisão. O motivo pelo qual a classe segmento possui mais imagens, é por ser a classe que representa o corpo da larva (Figura 5.1).



Figura 5.1: Classe predominante da imagem: segmento.

5.2.2 Segundo ARFF

Nesta seção serão discutidos os resultados dos algoritmos produzidos a partir do segundo ARFF, que compõe-se de atributos categóricos sendo estes atributos as classes do primeiro ARFF (tubérculo, fundo, espiráculo e segmento) e as classes são as espécies das larvas estudadas.

Analisando a matriz de confusão gerada pelo algoritmo J48 (Tabela 5.6), pode ser observado que 21 imagens foram classificadas corretamente de um conjunto de imagens contendo 44 imagens. A classe que foi melhor identificada foi *Orientalis* com 9 imagens classificadas corretamente, e observando nesta linha "A", verifica-se que o algoritmo classificou erroneamente somente uma imagem como *Hemilucilia Segmentaria*.

Para a matriz de confusão produzida pelo algoritmo Random Forest, a classe *Orientalis* também foi a melhor classificada, com dez imagens identificadas corretamente e nenhuma prevista erroneamente.

А	В	С	D	Classificado como
9	0	1	0	A = Orientalis
1	4	3	4	B = Albiceps
2	4	4	2	C = Segmentaria
1	2	3	4	D = Sarcophagidae

Tabela 5.6: Matriz de Confusão do algoritmo J48.

А	В	С	D	Classificado como
10	0	0	0	A = Orientalis
0	8	1	3	B = Albiceps
1	1	6	4	C = Segmentaria
1	3	2	4	D = Sarcophagidae

Tabela 5.7: Matriz de Confusão do algoritmo Random Forest.

Com o algoritmo Random Tree a classe *Albiceps* foi a melhor classificada corretamente, 9 imagens acertadas e 3 imagens identificadas erroneamente como Sarcophagidae. No total foram 24 imagens classificadas de modo correto.

А	В	\mathbf{C}	D	Classificado como
8	0	1	1	A = Orientalis
0	9	0	3	B = Albiceps
1	3	4	4	C = Segmentaria
1	5	1	3	D = Sarcophagidae

Tabela 5.8: Matriz de Confusão do algoritmo Random Tree.

5.3 Desempenho das Métricas

Serão mostrados os desempenhos dos algoritmos utilizados (J48, Random Forest e Random Tree) para as métricas precisão, medida F e curva ROC de acordo com cada arquivo ARFF.

5.4 Primeiro ARFF

5.4.1 Algoritmo J48

Classe	Precisão	Medida F	Curva ROC
Tubérculo	$27,\!40\%$	26,10%	$64,\!30\%$
Fundo	$86,\!90\%$	$87,\!00\%$	$92,\!10\%$
Espiráculo	$60,\!40\%$	$58,\!30\%$	$80,\!40\%$
Segmento	$90,\!10\%$	90,40%	$84,\!30\%$

Tabela 5.9: Desempenho das métricas utilizando o algoritmo J48.

5.4.2 Algoritmo Random Forest

Classe	Precisão	Medida F	Curva ROC
Tubérculo	$94,\!40\%$	$17,\!80\%$	$91,\!60\%$
Fundo	$93,\!40\%$	$91,\!60\%$	$99,\!10\%$
Espiráculo	$96{,}50\%$	$62,\!50\%$	$97,\!70\%$
Segmento	$89,\!80\%$	$93{,}60\%$	$96,\!10\%$

Tabela 5.10: Desempenho das métricas utilizando o algoritmo Random Forest.

5.4.3 Algoritmo Random Tree

Classe	Precisão	Medida F	Curva ROC
Tubérculo	$21,\!00\%$	$20,\!60\%$	58,50%
Fundo	$86,\!80\%$	$86,\!30\%$	$90,\!80\%$
Espiráculo	$46,\!00\%$	$44,\!80\%$	$71,\!11\%$
Segmento	$89,\!10\%$	$89{,}50\%$	$82,\!90\%$

Tabela 5.11: Desempenho das métricas utilizando o algoritmo Random Tree.

5.5 Segundo ARFF

5.5.1 Algoritmo J48

Classe	Precisão	Medida F	Curva ROC
Orientalis	$69,\!20\%$	$78,\!30\%$	$85,\!60\%$
Albiceps	40,00%	$36,\!40\%$	$62,\!40\%$
Segmentaria	$36,\!40\%$	$34,\!80\%$	$59,\!20\%$
Sarcophagidae	$40,\!00\%$	$40,\!00\%$	65,70%

Tabela 5.12: Desempenho das métricas utilizando o algoritmo J48.

5.5.2 Algoritmo Random Forest

Classe	Precisão	Medida F	Curva ROC
Orientalis	$83,\!33\%$	$90,\!90\%$	100%
Albiceps	66,70%	66,70%	$87,\!50\%$
Segmentaria	66,70%	$57,\!10\%$	$60,\!90\%$
Sarcophagidae	$36,\!40\%$	$38,\!10\%$	$73{,}80\%$

Tabela 5.13: Desempenho das métricas utilizando o algoritmo Random Forest.

5.5.3 Algoritmo Random Tree

Classe	Precisão	Medida F	Curva ROC
Orientalis	$80,\!00\%$	$80,\!00\%$	$86,\!80\%$
Albiceps	$52,\!90\%$	$62,\!10\%$	$72,\!90\%$
Segmentaria	66,70%	$44,\!40\%$	$62,\!50\%$
Sarcophagidae	$27,\!30\%$	$28{,}60\%$	$51,\!20\%$

Tabela 5.14: Desempenho das métricas utilizando o algoritmo Random Tree.

5.6 Comparação e Avaliação

5.6.1 ANOVA

A análise de variância visa comparar mais de 2 conjuntos e determinar se a diferença observada é causada apenas por variações aleatórias de uma amostra a outra ou se os dados vêm de populações onde as médias são de fato diferentes. A avaliação é feita verificando o quão diferentes são as médias e quanto as observações estão dispersas ao redor das respectivas médias. A ANOVA compara a variação resultante de fontes específicas com a variação entre indivíduos que deveriam ser semelhantes.

Na estatística, verifica-se um valor P que representa a probabilidade do resultado ser algo puramente ao acaso. Quando o valor P é baixo, podese dizer que é bastante provável que qualquer diferença entre os grupos é uma diferença real e não algo que aconteceu ao acaso. Quando P assume o valor de 0.05 significa que existe apenas 5% de chance do resultado ser uma casualidade. Valores menores de P significam maior confiabilidade no teste.

BoxPlots também conhecidos como Diagramas de Caixa e Bigode, são gráficos frequentemente usados para comparar dados em problemas estatísticos [11]. Explica-se: a caixa contém 50% dos dados. O limite superior da caixa indica 75% dos dados e o limite inferior representa 25%. A linha dentro da caixa, informa o valor medianos dos dados. Os extremos do gráfico revelam os valores mínimo e máximo, a menos que valores extremamente baixos ou altos estejam presentes.

Os valores estabelecidos para realizar o teste ANOVA foram os conjuntos de classes separados, os algoritmos e seus desempenhos utilizando a métrica Precisão. O primeiro teste foi realizado com as classes tubérculo, fundo, espiráculo e segmento. O resultado do valor P foi de 0,106 comparando todas as amostras de todas os algoritmos. Observando o gráfico BoxPlot (Figura 5.2), temos os valores na lateral que se referem aos desempenhos dos algoritmos em forma de porcentagem, analisando os limites inferior e superior podese dizer que o algoritmo Random Forest se destacou, mas estatisticamente temos uma insegurança de 10% para afirmar sobre seu desempenho.

As classes para o segundo teste foram, Orientalis, Albiceps, Segmentaria e Sarcophagidae. O resultado do valor P foi de 0,1264 também comparando todas as amostras de todos algoritmos. Considerando o gráfico Boxplot (Figura 5.3), vemos que os desempenhos dos algoritmos variaram entre 30 a 80, lembrando que estes valores se expressam em porcentagem. Comparando os algoritmos através da mediana, mais uma vez o Random Forest se destacou, mas ao analisar a partir dos limites inferior e superior das caixas, constatamos que os desempenhos dos algoritmos se encontram próximos, embora o



Figura 5.2: Gráfico Boxplot expondo desempenhos dos algoritmos utilizando a métrica Precisão para as classes tubérculo, fundo, espiráculo e segmento.

J48 demonstrar ter mais valores baixos que os demais.

Com isso verificamos que não existem evidências estatísticas de que os desempenhos sejam diferentes.



Figura 5.3: Gráfico Boxplot expondo desempenhos dos algoritmos utilizando a métrica Precisão para as classes *Orientalis*, *Albiceps*, *Segmentaria* e Sarcophagidae.

5.7 Conclusão dos Resultados

Verifica-se que o algoritmo que mostrou ter uma melhor precisão foi o Random Forest, sendo que no primeiro ARFF ele classificou 90,7642% das imagens como instâncias corretas, e no segundo ARFF foram 63,6364%. O único algoritmo que teve uma porcentagem maior de instâncias classificadas incorretamente foi o J48 no segundo ARFF, com 52,2727% e classificadas corretamente foram 47,7273. Acredita-se que com um número maior de instâncias para realizar a segunda classificação (ARFF 2), é possível obter melhores resultados, pois mesmo com apenas 44 imagens obtivemos mais resultados corretos.

Embora a quantidade de instâncias para o segundo ARFF parecer pequena, o programa classificou automaticamente imagens de larvas necrofágicas, com resultado satisfatório. A Figura 5.4 mostra a classificação da larva *Chrysomya Albiceps* manualmente durante a aprendizagem e a Figura 5.5 nos mostra o resultado da classificação automática, que de fato o programa acertou.



Figura 5.4: Imagem da larva Chrysomya Albiceps classificada manualmente.



Figura 5.5: Imagem da larva Chrysomya Albiceps classificada automaticamente.

Capítulo 6

Considerações Finais

Este trabalho partiu da proposta de que, com a combinação de extração de atributos e técnicas de superpixels, realizando uma classificação seguida de outra, é possível extrair informações relevantes em imagens de larvas necrofágicas para a identificação automática das espécies, com a finalidade de auxiliar peritos neste processo de identificação que é demorado manualmente. Para essa análise foi criado um banco de imagens que ainda poderá ser utilizado em outros projetos correlatos que envolvem larvas.

Através da implementação do método, a proposta obteve sucesso, pois foram extraídos atributos de cada superpixel e em seguida o resultado desta classificação foi a entrada para uma segunda classificação, e por fim o programa informa o resultado desse processo afirmando a espécie da larva.

Como melhorias futuras podem ser feitos ajustes nos algoritmos de aprendizagem supervisionada para obter maior precisão, avanços na interface do programa para facilitar a usabilidade com o usuário final, além de realizar outros experimentos em locais diferentes, para que o Banco de imagens possa ser enriquecido com outras espécies e em maior quantidade, para garantir melhores resultados.

O método implementado será utilizado também para outros projetos do grupo INOVISÃO a fim de facilitar a identificação e classificação em outros problemas, para isso pode ser adaptadas as classes conforme o problema estudado.

Apêndice A

Imagens

A.1 Parte do Banco de Imagens

A.1.1 Espécie Atherigona Orientalis



Figura A.1: Imagens microscópicas de larvas da espécie Atherigona Orienta-lis.



A.1.2 Espécie Chrysomya Albiceps

Figura A.2: Imagens microscópicas de larvas da espécie Chrysomya Albiceps.

A.1.3 Espécie Hemilucilia Segmentaria



Figura A.3: Imagens microscópicas de larvas da espécie Hemilucilia Segmentaria

A.1.4 Família Sarcophagidae



Figura A.4: Imagens microscópicas de larvas da família Sarcophagidae.

A.2 Imagens Segmentadas

A.2.1 Classe: Tubérculo



Figura A.5: Imagens de Superpixels representando a classe Tubérculo.

A.2.2 Classe: Fundo



Figura A.6: Imagens de Superpixels representando a classe Fundo.

A.2.3 Classe: Espiráculo



Figura A.7: Imagens de Superpixels representando a classe Espiráculo.

A.2.4 Classe: Segmento



Figura A.8: Imagens de Superpixels representando a classe Segmento.

Referências Bibliográficas

- Radhakrishna Achanta, Appu Shaji, Kevin Smith, Aurelien Lucchi, Pascal Fua, and Sabine Susstrunk. Slic superpixels compared to state-ofthe-art superpixel methods. *Pattern Analysis and Machine Intelligence*, *IEEE Transactions on*, 34(11):2274–2282, 2012.
- [2] Jens Amendt, Roman Krettek, and Richard Zehner. Forensic entomology. Naturwissenschaften, 91(2):51-65, 2004.
- [3] Gail S Anderson and Valerie J Cervenka. Insects associated with the body: their use and analyses. Advances in Forensic Taphonomy: Method, Theory, and Archaeological Perspectives, pages 173–200, 2002.
- [4] Gail S Anderson and Sherah L VanLaerhoven. Initial studies on insect succession on carrion in southwestern british columbia. *Journal of Forensic Science*, 41(4):617–625, 1996.
- [5] Neide Pizzolato Angelo. Aplicação de filtros de gabor no processo de classificação de imagens digitais com base em atributos de textura. 2000.
- [6] Dana Harry Ballard. Computer vision. 1982.
- [7] Leo Breiman. Random forests. *Machine learning*, 45(1):5–32, 2001.
- [8] Ana Paula Ulian de Araújo and Nelma Regina Segnini Bossolan. Noções de taxonomia e classificação introdução à zoologia. 2006.
- [9] Andrzej Grzywacz and Thomas Pape. Larval morphology of atherigona orientalis (schiner)(diptera: Muscidae)—a species of sanitary and forensic importance. Acta tropica, 137:174–184, 2014.
- [10] Robert D Hall and TE Huntington. Introduction: perceptions and status of forensic entomology. Forensic entomology: the utility of arthropods in legal investigations, pages 1–15, 2001.

- [11] Peter Kampstra et al. Beanplot: A boxplot alternative for visual comparison of distributions. *Journal of statistical software*, 28(1):1–9, 2008.
- [12] L Lima. Aplicação da visão computacional para identificação de estruturas morfológicas de larvas de moscas de importância forense. Workshop de Visão Computacional 2016 - publicação em andamento, 2016.
- [13] Oscar A.C. Linares. Segmentação de imagens de alta dimensão por meio de algoritmos de detecção de doenças da soja em imagens e super pixels. 2013.
- [14] Tapio Luostarinen and Antti Lehmussola. Measuring the accuracy of automatic shoeprint recognition methods. *Journal of forensic sciences*, 59(6):1627–1634, 2014.
- [15] Grella M. Chave taxonômica para espécies de dípteros califorídeos do brasil. 2011.
- [16] Jitendra Malik, Serge Belongie, Thomas Leung, and Jianbo Shi. Contour and texture analysis for image segmentation. *International journal of computer vision*, 43(1):7–27, 2001.
- [17] L. B. Milano D. D.; Honorato. Visão computacional. 2010.
- [18] Peer Neubert and Peter Protzel. Superpixel benchmark and comparison. In Proc. Forum Bildverarbeitung, pages 1–12, 2012.
- [19] G. R. A. Oliveira. Filtros de gabor para Analise de larvas necrófagas. Universidade Católica Dom Bosco. Monografia de conclusão de curso em Engenharia da Computação, 2016.
- [20] J Oliveira Costa. Entomologia forense quando os insetos são vestígios. 2011.
- [21] J Oliveira-Costa. Insetos "peritos", a entomologia forense no brasil, 2013.
- [22] Pasquali. Extração de características utilizando filtro de gabor aplicado à identificação de defeitos no couro bovino. 2007.
- [23] Pistori. Etapas de um sistema de visão computacional, 2013.
- [24] Pistori. Bancos de filtros de gabor, 2015.
- [25] J. Ross Quinlan. Induction of decision trees. Machine learning, 1(1):81– 106, 1986.

- [26] J Ross Quinlan. C4. 5: Programming for machine learning. Morgan Kauffmann, page 38, 1993.
- [27] Carolini Nascimento Martins Rodrigues, Ariadne Barbosa Gonçalves, GG Silva, and Hemerson Pistori. Evaluation of machine learning and bag of visual words techniques for pollen grains classification. *IEEE LATIN AMERICA TRANSACTIONS*, 13(10):3498–3504, 2015.
- [28] Ricardo C. B. Rodrigues and R. H. R Viana. Máquinas de vetores de suporte aplicadas à classificação de defeitos em couro bovino. Universidade Católica Dom Bosco. Relatório Final submetido como um dos requisitos para a obtenção do título de Bacharel em Engenharia de Computação, 2007.
- [29] Marcus FS Saldanha and Dr^a Corina da Costa Freitas. Segmentação de imagens digitais: Uma revisão. Divisão de Processamento de Imagens-Instituto Nacional de Pesquisas Espaciais (INPE), São Paulo, 2009.
- [30] Diogo S. Sarath. Medição automática do efeito de herbivoria em folhas de soja utilizando técnicas de segmentação e aprendizagem supervisionada. 2014.
- [31] Jianbo Shi and Jitendra Malik. Normalized cuts and image segmentation. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 22(8):888–905, 2000.
- [32] Gercina G. Silva. Superpixel e aprendizagem supervisionada para a identificação de doenças da soja em imagens obtidas por veículos aéreos não tripulantes. 2013.
- [33] Kenneth GV Smith et al. A manual of forensic entomology. 1986.
- [34] Martin R Speight, Mark D Hunter, Allan D Watt, et al. Ecology of insects: concepts and applications. Blackwell Science Ltd, 1999.
- [35] R.L. Stange and J.J. Neto. Reconhecimento de padrões em classificadores - comparação de técnicas e aplicações. *Machine learning*, 2010.
- [36] Richard Szeliski. *Computer vision: algorithms and applications*. Springer Science & Business Media, 2010.
- [37] Sergios Theodoridis and Konstantinos Koutroumbas. *Pattern recognition*, chapter 4.6. Academic Press, second edition, 2003.

- [38] Sung Tz'u. The washing away of wrongs: Forensic medicine in thirteenth-century china, trans. brian e. mcknight. Ann Arbor, MI: Center for Chinese Studies, University of Michigan, 1981.
- [39] Paul E Utgoff. Incremental induction of decision trees. Machine learning, 4(2):161–186, 1989.
- [40] John E Vargas, Priscila Saito, Alexandre X Falcao, Pedro J De Rezende, and Jefersson A Dos Santos. Superpixel-based interactive classification of very high resolution images. In *Graphics, Patterns and Images (SIB-GRAPI), 2014 27th SIBGRAPI Conference on*, pages 173–179. IEEE, 2014.
- [41] Oliveira W. Identificação de dna vertebrado a partir do conteúdo gastrointes-tinal de larvas de dípteros necrofágicas. 2004.
- [42] Patrick Henry Winston and Berthold Horn. The psychology of computer vision, volume 67. McGraw-Hill New York, 1975.