

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

William Henrique Soares Antonio

**Detecção de Animais em Rodovias utilizando  
Câmeras e Aprendizado Supervisionado**

**Uberlândia, Brasil**

**2019**

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

William Henrique Soares Antonio

**Detecção de Animais em Rodovias utilizando Câmeras e  
Aprendizado Supervisionado**

Trabalho de conclusão de curso apresentado à Faculdade de Computação da Universidade Federal de Uberlândia, Minas Gerais, como requisito exigido parcial à obtenção do grau de Bacharel em Sistemas de Informação.

Orientador: Prof. Dr. Jefferson Rodrigo de Souza

Universidade Federal de Uberlândia – UFU

Faculdade de Computação

Bacharelado em Sistemas de Informação

Uberlândia, Brasil

2019

William Henrique Soares Antonio

## **Detecção de Animais em Rodovias utilizando Câmeras e Aprendizado Supervisionado**

Trabalho de conclusão de curso apresentado à Faculdade de Computação da Universidade Federal de Uberlândia, Minas Gerais, como requisito exigido parcial à obtenção do grau de Bacharel em Sistemas de Informação.

Trabalho aprovado. Uberlândia, Brasil, 09 de julho de 2019:

---

**Prof. Dr. Jefferson Rodrigo de Souza**  
Orientador

---

**Prof. Dr. Rodrigo Sanches Miani**

---

**Profa. Dra. Maria Adriana Vidigal de Lima**

Uberlândia, Brasil  
2019

# Agradecimentos

Agradeço a Deus por ter me dado sabedoria e sustento todos esses anos.

Agradeço aos meus pais, Amarildo Antonio e Lucimar Soares Antonio que me incentivaram e me deram total suporte no período em que estive na faculdade.

Ao meu orientador, Jefferson Rodrigo de Souza pelo apoio, sua dedicação, amizade, compreensão e encorajamento contínuo na pesquisa.

Agradeço a Fundação de Amparo à Pesquisa de MG pelo apoio durante um ano.

E por fim a Universidade Federal de Uberlândia pelo apoio institucional, evolução pessoal e profissional.

*“O Senhor é a minha força e o meu escudo; nele o meu coração confia, e dele recebo ajuda. Meu coração exulta de alegria, e com o meu cântico lhe darei graças.”*

- Salmos 28:7

# Resumo

A detecção de animais é fundamental em nossa sociedade, onde se pode detectar e rastrear animais e preveni-los de colisões com os veículos nas rodovias. As abordagens tradicionais incluem a construção de passagens de fauna, implantação de cercas reais ou virtuais, vigilância por vídeo e sistemas *break-the-beam*. Com todas essas abordagens, é crucial destacar a importância de se ter uma validação eficiente para reduzir o número de falsa detecção. A partir de dados levantados e pontos já identificados de presença constante de animais, os mesmos denominados de pontos quentes (hotspots), foi implementado um algoritmo, que utilizando recursos de processamento de imagens e métodos de aprendizado de máquina, através de imagens, possibilita classificar o objeto detectado como um animal e se este animal venha ser um perigo para segurança do veículo em movimento na rodovia, como também a própria segurança do animal, assim o condutor do veículo será alertado da presença deste possível animal próximo a sua localização atual, dando oportunidade ao motorista de reagir a alguma situação perigosa e evitar possíveis acidentes de trânsito.

**Palavras-chave:** Aprendizado, Detecção, Acidente, Algoritmo, Rodovia, Animal.

# Lista de ilustrações

Figura 1 – Regiões que morrem animais brasileiros. Extraído do portal (CBEE, 2017). . . . .	11
Figura 2 – Porcentagem dos acidentes com morte registrada pelo agente da Polícia Rodoviária Federal nas rodovias federais. Extraído do relatório (PRF/IPEA, 2015). . . . .	12
Figura 3 – Primeira etapa de construção do LBP é selecionar oito pixels vizinhos ao redor de um pixel central para gerar o conjunto de oito dígitos binários. Extraído de (ROSEBROCK, 2015). . . . .	19
Figura 4 – Obtendo oito bits vizinhos do pixel central e convertendo a informação em número decimal. Extraído de (ROSEBROCK, 2015). . . . .	20
Figura 5 – O valor de LBP calculado é guardado então em uma matriz de saída com a mesma largura e altura da imagem original. Extraído de (ROSEBROCK, 2015). . . . .	20
Figura 6 – Exemplo de um KNN. Círculo vermelho é uma nova consulta classificada como quadrado $K = 3$ e outra como pentágono $K = 5$ . Fonte: (SOUZA et al., 2015). Imagem: Elaborada pelo autor. . . . .	22
Figura 7 – Floresta Aleatória. Vários subconjuntos das árvores são criados e o resultado é uma combinação das saídas de todas as árvores. Fonte: (SOUZA et al., 2015). Imagem: Elaborada pelo autor. . . . .	23
Figura 8 – Metodologia. O fluxo de dados é representado por setas. Imagem: Elaborada pelo autor. . . . .	24
Figura 9 – Cinco abordagens distintas são proposta. Imagem: Elaborada pelo autor. . . . .	25
Figura 10 – Groud Truth produzido. A cor branca (255) identifica o animal e a cor cinza (127) identifica o que não é animal. Imagem: Elaborada pelo autor. . . . .	28
Figura 11 – Banco de imagens de animais capturadas por uma câmera trap. Fonte: Imagens cedidas pelo LEMA (Laboratório de Ecologia de Mamíferos) da Universidade Federal de Uberlândia. . . . .	30
Figura 12 – Banco de imagens de animais fornecido por Heydar Maboudi Afkham. Extraído de (AFKHAM, 2008). . . . .	31
Figura 13 – Comparação das duas melhores abordagens. . . . .	32

Figura 14 – (a) Cavalo, (b) Vaca, (c) Cão 1, (d) Cão 2, e (e) Cobra (dados de treinamento). (f) Capivara (dados de teste). (g) O primeiro melhor resultado da Tabela 2 sobre as imagens de teste. (h) O segundo melhor resultado da Tabela 2 sobre as imagens de teste. Os pixels pintados em verde mostram onde o algoritmo ML classificou como animal e acertou. Os pixels pintados de azul apresentam onde o algoritmo ML classificou como animal, mas errou. E a parte pintada de vermelho mostra a área demarcada como um animal no Ground Truth. . . . . 33



# Lista de tabelas

Tabela 1 – Medida <b>F</b> das abordagens ConB usando KNN. . . . .	28
Tabela 2 – Medida <b>F</b> das abordagens ClaB usando KNN. . . . .	29
Tabela 3 – Medida <b>F</b> das abordagens ConB usando RF. . . . .	29
Tabela 4 – Medida <b>F</b> das abordagens ClaB usando RF. . . . .	30

# Lista de abreviaturas e siglas

AM	Aprendizado de Máquina
KNN	<i>K-Nearest Neighbors</i>
FA	Florestas Aleatórias
NM	Nanômetro
ClaB	Bloco de Classificação
ConB	Bloco Contextual

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>11</b>
1.1	Motivação	11
1.2	Justificativa	13
1.3	Objetivos	14
1.3.1	Objetivo Geral	14
1.3.2	Objetivos Específicos	14
1.4	Organização da Tese	14
<b>2</b>	<b>TRABALHOS CORRELATOS</b>	<b>15</b>
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>18</b>
3.1	Espaço de Cores	18
3.2	Descritor de Textura	19
3.2.1	Local Binary Patterns	19
3.3	Algoritmo de Segmentação	21
3.3.1	Entropy	21
3.4	Aprendizado de máquina	21
3.4.1	K Vizinhos mais Próximos	22
3.4.2	Floresta Aleatória	23
<b>4</b>	<b>METODOLOGIA PROPOSTA</b>	<b>24</b>
4.1	Abordagens	24
4.2	Conjunto de treinamento e testes	26
<b>5</b>	<b>RESULTADOS</b>	<b>27</b>
5.1	Detecção de animais	27
5.2	Treinamento e seleção de modelos	27
5.3	Melhores abordagens	32
<b>6</b>	<b>CONCLUSÃO</b>	<b>34</b>
Conclusão		34
	<b>REFERÊNCIAS</b>	<b>36</b>

# 1 Introdução

## 1.1 Motivação

O comprimento das estradas brasileiras cada dia que se passa está maior. Com essa expansão contínua das rodovias, traz consigo um desenvolvimento importante para a sociedade brasileira. A (CNT/SEST/SENAT, 2017) avaliou 105.814 km de rodovias federais e estaduais em todo o país. Ademais, as estradas são relevantes para o funcionamento do país, conseqüentemente para o desenvolvimento da vida humana.

Segundo (BANDEIRA; FLORIANO, 2004), as rodovias são estruturas complexas usadas como meio de transporte terrestre, permitindo o deslocamento de produtos e pessoas entre cidades, estados e países. Por meio delas são transportados os produtos agrícolas, industriais, máquinas, combustíveis e produtos minerais.

Apesar do desenvolvimento de rodovias gerar condições melhores ao homem, elas são responsáveis por diversos danos à natureza. O atropelamento de animais silvestres é uma das conseqüências que o avanço de construções de rodovias geram. O Sudeste é a região que mais ocorrem atropelamentos de animais (Figura 1). Estimativas apresentam que 475 milhões de animais selvagens são atropelados anualmente no Brasil (CBEE, 2017). As estimativas da (CBEE, 2017) é de que morrem 430 milhões de animais pequenos, 45 milhões que sobram, dividem-se em 40 milhões de animais de médio porte (e.g. lebres e macacos) e 5 milhões de animais de grande porte (e.g. onça-pintada e capivaras).

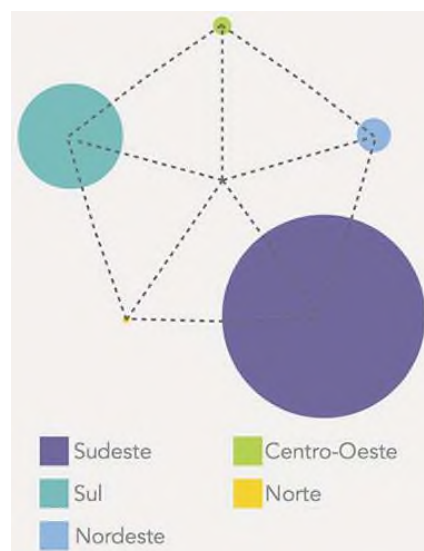


Figura 1 – Regiões que morrem animais brasileiros. Extraído do portal (CBEE, 2017).

Devido o atropelamento desses animais por veículos, este traz sérios riscos à vida dos motoristas, bem como dos passageiros. Nos Estados Unidos, calcula-se que ocorrem 2 milhões de colisões entre veículos e mamíferos de grande porte (HUIJSER MARCEL P.; DUFFIELD, 2009). Dados de acidentes pela (PRF, 2017) apresentam que de um total geral de 89.318 acidentes, 2.003 acidentes foram por motivo de atropelamento com animais, ocasionando 1.428 pessoas feridas e 83 mortes.

Da mesma forma que esses atropelamentos produzem mortes nas rodovias e danos psicológicos à família e ao acidentado, outro ponto que deve ser considerado são os custos financeiros para os brasileiros. Segundo (PRF/IPEA, 2015), cerca de 170 mil acidentes de trânsitos ocorreram nas rodovias brasileiras no ano de 2014, gerando custos para a sociedade de R\$ 12,3 bilhões. Desse montante, 64,7% estavam relacionados às vítimas dos acidentes, e os 34,7% estavam associados aos veículos por danos materiais e perda de cargas. Além do custo da operacionalidade para remoção dos veículos envolvidos no acidente. Figura 2 mostra a proporção de acidentes fatais causados por animais nas rodovias.

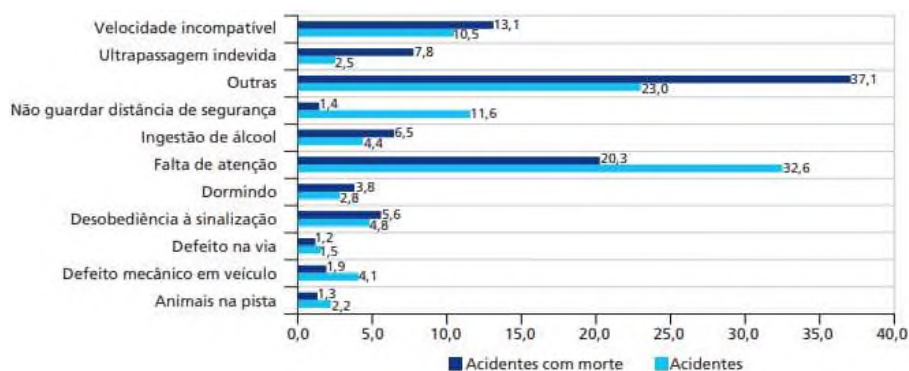


Figura 2 – Porcentagem dos acidentes com morte registrada pelo agente da Polícia Rodoviária Federal nas rodovias federais. Extraído do relatório (PRF/IPEA, 2015).

Com isso é perceptível a necessidade de desenvolver uma solução para evitar acidentes com animais e veículos, visando a preservação da fauna e segurança humana. (CBEE, 2017) em 2012 criou um aplicativo denominado Sistema Urubu, em que o propósito é que os usuários capturem fotos dos animais atropelados nas rodovias e enviem ao sistema. Desta forma, alimentando um banco de dados de registros de casos. Apesar de ser uma solução que integra informação, não combate em tempo real o problema do atropelamento, esta contribui e auxilia o governo na tomada de decisão para a redução desses impactos.

O objetivo de desenvolver um sistema de detecção de animais mostra-se viável, pois esse assunto ainda está sendo investigado em nossa sociedade. Assim, esse trabalho combaterá acidentes que envolvam veículos e animais. Pretende-se usar técnicas de Aprendizado de Máquina (AM) (SULLIVAN, 2017) para a detecção de animais presentes nas rodovias.

Espera-se fornecer um sistema que venha detectar animais nas rodovias brasileiras a partir de imagens obtidas por câmeras, oferecendo uma maior segurança para todas as pessoas que se locomovem pelas malhas viárias nacionais. O trabalho servirá para que empresas, governos estaduais ou governo federal tenham interesse em investir em um sistema que traga mais segurança a vidas humanas e preservação da fauna local.

## 1.2 Justificativa

O Brasil possui uma malha viária muito extensa distribuída por todo seu território nacional, e a maior parte fazem dela sua principal forma de se locomover. Com isso surge um problema, que é animais se deslocando nessas vias. E dependendo da gravidade do acidente ocasionado, o gasto que se despende para a solução do mesmo fica maior. Observa-se assim, a geração de grandes custos para os cofres públicos, decorrente a esses fatos, tanto no socorro de pessoas e também no resgate de animais feridos nas vias. E esses animais que sofrem acidentes fatais em vias, ocasionam um grande impacto na fauna da região. Com a finalidade de solucionar o problema descrito, o objetivo deste projeto de pesquisa é aplicar algoritmos para detecção de animais próximos a rodovias, através de imagens obtidas por câmeras instaladas nas proximidades da rodovia, para a redução de acidentes entre pessoas e animais, assim minimizar custos aos cofres públicos, que poderão ser aplicados à outras finalidades.

Desta forma, este projeto busca atender a detecção de animais próximos à rodovia no trecho da BR-050 entre Uberlândia e Uberaba, onde se tem pontos já identificados de constante presença de animais em movimentação potencialmente perigosa para motoristas. O objetivo principal é utilizar as imagens capturadas pelas câmeras na rodovia e realizar a identificação, se é um animal ou não presente na rodovia, a fim de reduzir os acidentes entre essas duas cidades.

## 1.3 Objetivos

### 1.3.1 Objetivo Geral

O desenvolvimento de um sistema automático usando imagens capturadas de câmeras e técnicas de AM supervisionado para a detecção de animais nas rodovias.

### 1.3.2 Objetivos Específicos

- 1) Gerar dados acerca das espécies usando câmeras que estarão na área onde o sistema de detecção for implantado nas rodovias.
- 2) Estudar técnicas de AM supervisionado e visão computacional.
- 3) Desenvolver um algoritmo usando AM supervisionado para detectar os animais.

## 1.4 Organização da Tese

Este trabalho encontra-se organizado em capítulos. O capítulo 2 apresenta os trabalhos correlatos, capítulo 3 a fundamentação teórica, capítulo 4 apresenta-se o desenvolvimento da pesquisa, capítulo 5 mostra os resultados obtidos. Por fim, o capítulo 6 discorre sobre a conclusão e trabalhos futuros.

## 2 Trabalhos Correlatos

(SHARMA; SHAH, 2017) propuseram um sistema automático de detecção de animais usando uma câmera de alta resolução nas rodovias indianas. O objetivo deste trabalho foi detectar o animal e encontrar a distância aproximada entre o animal e o veículo. Eles utilizaram uma combinação entre os classificadores HOG (*Histogram of Oriented Gradients*) e o cascata para a detecção de animais. Todas as técnicas de processamento de imagem foram implementadas usando OpenCV. Eles coletaram as informações de uma vaca para treinar o sistema, e calcularam a distância do animal detectado por meio da conversão de pixels para metros. Os resultados obtidos foram de uma revocação de 80,4% e precisão de 82,5%. O animal foi detectado na imagem e a distância em metros foi apresentada desse animal para o veículo. Eles verificaram que o treinamento e testes em grandes conjuntos de dados melhoraram a taxa de detecção e a precisão do classificador. O classificador HOG-cascade proveu melhores resultados comparado ao HAAR-cascade e acreditamos que esse trabalho contribuiu para o nosso contexto.

(MATUSKA et al., 2014) desenvolveram um sistema para monitorar o movimento de animais, detectando e classificando-os. O objetivo foi determinar corredores de migração de animais selvagens na área designada. Eles escolheram dois métodos classificadores: *Bags of Visual Keypoint* e *Support Vector Machine* (SVM), dois descritores: o *Key Points Detector* e o *Key Points Descriptors*, que são usados para criar uma descrição do objeto. O treinamento foi dividido em cinco classes: raposa, veado, lobo, urso pardo e javali. Cada classe tem 60 imagens com animais e os dados de testes tem 50 imagens. Primeiro, os descritores de treino foram extraídos. Em seguida o vocabulário para esses descritores foi criado usando o método de *bag of key points*, onde o algoritmo *K-means* é usado para separar os descritores em grupos. Fizeram o uso de dois algoritmos para agrupar as comparações dos descritores, o *BruteForce* e o *FlannBased*. O extrator de descritor de imagem calcula um descritor de imagem usando o vocabulário visual definido. Esses dados foram usados no classificador SVM para criar um modelo de classificação. Nos resultados demonstram que a maior nota de classificação 94% foi alcançado pela combinação dos algoritmos SURF, SIFT e FlannBased. Então acreditamos que esse trabalho contribuiu para o nosso contexto de como realizar o preparo dos conjuntos de treino e teste.

RWork11 propuseram um sistema de detecção de animal usando câmeras e sinais de trânsito inteligentes. O objetivo é classificar os animais dentro de uma área monitorada e avaliar o nível de risco que trazem aos motoristas. Durante o treinamento dos classificadores, um conjunto de treino é usado para criar um modelo de classificação, o qual foi usado no reconhecimento de objetos. Para a representação do objeto foi escolhido descritores de características, como SIFT. O modelo de classificação é criado baseado



em algoritmos de AM. O método foi testado em sequências de imagens com objetos de animais em movimento. As classes que obtiveram uma melhor precisão foram as classes raposa, urso pardo, lobo e javali. Entretanto, a classe de cervos obteve um baixo nível de revocação (medida que determina a eficácia do classificador), causado pelo comportamento natural do cervo. Foram obtidos altos valores de precisão do detector a 100% com urso pardo e 98,83% com cervo. A menor precisão do detector foi de 60,87% para a classe das raposas, a razão desse valor baixo é a falsa detecção das árvores em movimento e suas folhas, e a mudança repentina da iluminação da cena. Como próximo passo querem realizar a classificação do objeto. Nessa etapa, o animal na cena precisa ser distinguido de outros objetos em movimento, como carros ou motos. Acreditamos que esse trabalho contribuíra para o planejamento das fases de treinamento e testes, avaliar o risco que o animal detectado traz ao motorista e de que modo será o nosso sinal de aviso aos usuários.

Forslund e Bjarkefur (FORSLUND; BJÄRKEFUR, 2014) propuseram uma detecção de animais utilizando visão noturna. O objetivo foi desenvolver os princípios de classificação entendendo as limitações de hardware. O princípio é de que um grande número de classificadores fracos é combinado em um classificador forte. Uma estrutura em cascata é empregada, onde um candidato pode ser rejeitado após um pequeno número de características não for semelhante a um animal. Os autores reduziram a complexidade computacional significativamente. Os dados foram rotulados e utilizados por algoritmos de AM projetados para extrair informações discriminativas de forma eficiente. Os resultados mostram que devido à baixa quantidade de falsos positivos gerado pelo sistema, é necessário um grande conjunto de testes para avaliar a taxa de detecções falsas com uma significância estatística. Além de avaliações estatísticas, o sistema foi testado extensivamente com carros em todo o mundo pela Autoliv e seus clientes Audi, BMW e Daimler. A detecção de animais é de até 200 metros de distância do carro e usando o sistema de visão noturna Autoliv, o motorista tem todas as oportunidades para reagir a situações perigosas e evitar possíveis acidentes. Acreditamos que esse trabalho nos auxilie para a detecção de animais no período noturno, desenvolver um algoritmo compreendendo as limitações de hardware e auxiliar em novas abordagens para percorrer as imagens capturadas.

(ZHOU, 2014) exploraram o desempenho de diferentes características de imagens e algoritmos de classificação em aplicações de detecção de animais. O objetivo é a criação de um sistema em tempo real seguindo três critérios: precisão da detecção, tempo de detecção e consumo de energia do sistema. Eles usaram *Haar-like*, *HOG*, *Local Binary Patterns* (LBP) e HSV para extração de características. Para classificar os dados foi utilizado o AdaBoost, SVM e HOG SVM. As métricas utilizadas para avaliação do sistema foram a precisão, tempo e consumo de energia. Os resultados indicaram que o detector *Haar + AdaBoost* consome mais tempo comparado com os outros dois detectores e o HOG feature é o que apresenta melhor desempenho. Foi verificado que o detector *HOG + Adaboost* possui os recursos mais econômicos. Então acreditamos que esse trabalho

contribuirá para o nosso contexto nesse ponto, analisando o desempenho dos diferentes algoritmos de classificação que foram explorados pelo autor para aplicar em nosso caso.

Os trabalhos descritos foram cruciais para a elaboração da metodologia utilizada. A seleção das técnicas e criação de um conjunto de imagens para treinamento e testes se assemelha com as diversas propostas anteriormente, como também o uso do sistema que pode ser aplicado em outros países de acordo com o contexto real de cada um deles. A diferença entre os trabalhos está em diferentes tipos de classificadores escolhidos, o uso de descritores para criar uma descrição do objeto e as implementações das técnicas de processamento de imagem, alguns utilizaram da biblioteca OpenCV. Outros trabalhos tiveram o objetivo no desenvolvimento de um sistema com foco na detecção de animais em ambientes noturnos, (ZHOU, 2014) realizaram experimentos de consumo de energia gasto com a execução do sistema em diferentes dispositivos móveis, um ponto importante é que precisamos construir um sistema que não consuma muito processamento, assim gerando mais autonomia.

Outra semelhança aos trabalhos anteriormente descritos é o tema. Assim como nos trabalhos de (SHARMA; SHAH, 2017; MATUSKA et al., 2014; MATUSKA et al., 2016; FORSLUND; BJÄRKEFUR, 2014; ZHOU, 2014), o estudo é centrado no objetivo de detectar animais nas rodovias, cada qual voltado para ao seu contexto. No (MATUSKA et al., 2014) o estudo é voltado em observar a migração da fauna local. O (MATUSKA et al., 2016) realizaram duas etapas na metodologia, o treinamento e os testes assim como é realizado neste trabalho. Outro ponto a destacar é a necessidade de todos os trabalhos optarem por usar um grande conjunto de dados, pois conseguem melhorar a taxa de detecção, a precisão do classificador e possuir uma taxa com significância estatística.

## 3 Fundamentação Teórica

### 3.1 Espaço de Cores

Segundo (PLATANIOTIS; VENETSANOPOULOS, 2000) a percepção de cor é crucial para os seres humanos, uma vez que eles usam rotineiramente os recursos de cores. Cor é o resultado perceptual da luz na região visível do espectro eletromagnético, tendo comprimentos de onda na ordem de 400nm a 700nm, incidente sobre a retina do olho humano. O ramo da ciência da cor relacionado com a descrição e especificação apropriada de uma cor é colorimetria. Portanto, uma cor pode ser especificada por um vetor de três componentes. O conjunto de todas as cores formam um espaço vetorial chamado espaço de cores. Os três componentes de uma cor podem ser definidos de várias maneiras.

A intensidade de uma cor (geralmente denotada como  $I$ ), brilho ( $Br$ ), luminância ( $Y$ ), leveza ( $L^*$ ), tonalidade ( $H$ ) e saturação ( $S$ ). Para utilizar a cor em Processamento de Imagens, é necessário um método apropriado para representar o sinal de cor. Os diferentes espaços de cores atendem a essa necessidade. Eles fornecem uma especificação e ordem para exibir efetivamente as cores do objeto consideradas. O processo de selecionar a melhor representação de cores envolve saber como os sinais de cor são gerados e quais informações são necessárias a partir desses sinais. Em particular, os espaços de cores podem ser usados para definir cores, discriminar cores, julgar a similaridade entre cores e identificar categorias de cores para diversas aplicações.

Existem diversos espaços de cores, como por exemplo, o espaço de cor RGB (COLOR..., 2000), mais comum para imagens em um computador padrão porque a tela do computador está usando a combinação das cores primárias (vermelho, verde, azul). Cada pixel da tela é composto de três pontos estimulados por vermelho, verde e azul. No entanto, o espaço RGB não é adequado para lidar com sombras e escuridão. Portanto, preferiu-se transformar os dados de imagem do RGB em outro espaço uniforme.

LAB (SCHWIEGERLING, 2004) é uma segunda tentativa de fornecer um espaço de cor uniforme, nele a distância entre dois pontos indica como as cores são diferentes em luminância, croma e matriz. Outra maneira de caracterizar uma cor é relativa ao modelo do HSV (SHIPMAN, 2012). A matriz, no inglês *Hue* ( $H$ ) de uma cor refere-se a qual cor se parece. A saturação ( $S$ ) da cor descreve como a cor é branca. O valor ( $V$ ) de uma cor, leveza, descreve quanto a cor é escura.

*Grayscale* (ROUSE, 2018) é uma gama de tons de cinza sem cor aparente. O tom mais escuro é preto e o mais claro é a branca. Os tons intermediários de cinza são representados por níveis iguais de brilho das três cores primárias (vermelho, verde e

azul) para a luz transmitida, ou quantidades iguais dos três pigmentos primários (ciano, magenta e amarelo) para a luz refletida.

## 3.2 Descritor de Textura

### 3.2.1 Local Binary Patterns

O LBP, *Local Binary Patterns* (ROSEBROCK, 2015), multiresolução em escala cinza e rotação de classificação de textura invariante com padrões locais. Ele calcula uma representação local da textura. Essa representação local é construída comparando cada pixel com sua vizinhança de pixels. A primeira etapa na construção do descritor de textura LBP é converter a imagem em escala cinza. Para cada pixel na imagem cinza, é selecionado uma vizinhança de tamanho  $r$  ao redor do pixel central. Um valor de LBP é então calculado para este pixel central e armazenado na matriz 2D de saída com a mesma largura e altura que a imagem de entrada. Por exemplo, tem-se um descritor LBP original, que opera em uma vizinhança fixa de pixels  $3 \times 3$ , seleciona o pixel central e limita ele contra sua vizinhança de 8 pixels. Se a intensidade do pixel central for maior ou igual a seu vizinho, então é definido o valor como 1; caso contrário, é definido como 0. Com 8 pixels adjacentes, temos um total de 2 elevado a 8, que é igual a 256 combinações possíveis de códigos LBP. Como é mostrado na Figura 3.




Figura 3 – Primeira etapa de construção do LBP é selecionar oito pixels vizinhos ao redor de um pixel central para gerar o conjunto de oito dígitos binários. Extraído de (ROSEBROCK, 2015).

Então calcula o valor de LBP para o pixel central. Inicia-se a partir de qualquer pixel vizinho e trabalha no sentido horário ou anti-horário, contudo a ordenação deve ser mantida consistente para todos os pixels da imagem apresentada e todas as imagens do conjunto de dados obtida. A partir da vizinhança de  $3 \times 3$ , tem-se oito vizinhos nos quais deve realizar um teste binário. Os resultados deste teste binário são armazenados em uma matriz de 8 bits, que depois é convertida em decimal, conforme a Figura 4




Figura 4 – Obtendo oito bits vizinhos do pixel central e convertendo a informação em número decimal. Extraído de (ROSEBROCK, 2015).

Figura 4, inicia-se no ponto superior direito e trabalha com ele no sentido horário acumulando a string binária à medida que avança. Convertendo esta string binária em decimal, produzindo um valor de 23. Esse valor é armazenado no array LBP 2D de saída, como a Figura 5.




Figura 5 – O valor de LBP calculado é guardado então em uma matriz de saída com a mesma largura e altura da imagem original. Extraído de (ROSEBROCK, 2015).

Esse processo de limiar acumulando cadeias binárias e armazenando o valor decimal de saída na matriz LBP é então repetido para cada pixel na imagem de entrada.

## 3.3 Algoritmo de Segmentação

### 3.3.1 Entropy

Entropia (DE; SIL, 2012) é calculado formando uma matriz de características ( $\mathbf{M}$ ) com o número de linhas que corresponde ao número de imagens de treinamento e o número de colunas que representam a dimensão de cada característica. A informação em cada característica é obtida usando a entropia de Shannon (GONZALEZ; WOODS; EDDINS, 2004) como:

$$E_j = -(p_j \log p_j),$$

onde  $p_j$  representa a probabilidade da ocorrência da característica de  $p^{th}$  em uma imagem de treino. Para calcular a entropia de cada característica, a matriz de característica  $\mathbf{M}$  é considerada uma imagem e cada elemento de  $\mathbf{M}$  denota o valor de pixel da imagem. A matriz  $\mathbf{M}$  foi digitalizada a partir do pixel do canto superior esquerdo para o pixel do canto inferior direito, cada pixel é considerado como um pixel de referência que corresponde a uma imagem em particular.

## 3.4 Aprendizado de máquina

AM é uma das áreas que mais cresce na ciência da computação. Segundo (SHALEV-SHWARTZ; BEN-DAVID, 2014a), ela vem com o objetivo de programar computadores para que eles possam “aprender” a partir da entrada disponível para eles. Assim sendo, nesse contexto de aprendizado; a entrada para um algoritmo de aprendizado é um conjunto de treinamento, representando uma experiência e a saída é uma avaliação. Conseqüentemente, o campo do AM ramifica-se em diversos subcampos que lidam com diferentes tipos de tarefas de aprendizagem.

Uma parte importante do processo de AM é o treinamento, no qual uma máquina é fornecida com dados sobre eventos históricos que ajudam a máquina a antecipar quaisquer eventos. Esse tipo de aprendizado é conhecido como AM supervisionado, no qual os dados consistem em exemplos de treino. Esses exemplos são entradas e saídas desejadas. A máquina então usa esse aprendizado e cria uma função inferida que é usada para prever qualquer evento. Se as saídas são discretas, a função é chamada de classificador, se as saídas são contínuas é uma regressão. Esse algoritmo é usado para gerar um método generalizado para alcançar os dados de saída que foram alimentados como entrada. Esse tipo de aprendizado usa um algoritmo fixo. Alguns algoritmos de aprendizado supervisionado são usados com frequência e cada um deles tem seus pontos fortes e fracos. Como não há algoritmo definitivo que possa ser usado para todas as instâncias, a seleção do algoritmo de aprendizado é um passo crucial para desenvolver esse trabalho de conclusão de curso.

### 3.4.1 K Vizinhos mais Próximos

Segundo (SHALEV-SHWARTZ; BEN-DAVID, 2014b) o K Vizinhos mais Próximos (do Inglês, *K-Nearest Neighbors* - *KNN*) é um aprendizado baseado em instância, em que a função é aproximada e toda a computação é adiada até a classificação. O KNN é o mais simples de todos os algoritmos, classifica uma amostra de teste de acordo com a classe de suas amostras de treinamento  $K$  mais próximas (Figura 6). KNN é definido de acordo com uma métrica de distância (no caso, distância euclidiana).




Figura 6 – Exemplo de um KNN. Círculo vermelho é uma nova consulta classificada como quadrado  $K = 3$  e outra como pentágono  $K = 5$ . Fonte: (SOUZA et al., 2015). Imagem: Elaborada pelo autor.

Para medir a igualdade entre dois pontos em uma espaço euclidiano é útil calcular a distância entre os pontos. KNN armazena todos os exemplos de treino, e quando surge um novo objeto a ser classificado, ele calcula a distância euclidiana entre o novo objeto em relação a todos os outros armazenados. Assim, a classe que este novo objeto pertencerá é igual a classe do objeto já memorizado que apresentou a menor distância calculada.

### 3.4.2 Floresta Aleatória

Segundo (SHALEV-SHWARTZ; BEN-DAVID, 2014b) a Floresta Aleatória (do Inglês, *Random Forest - RF*) geram uma aleatoriedade para o modelo quando as árvores crescem. RF procura o melhor entre um subconjunto aleatório de recursos. Esse procedimento cria uma ampla diversidade, que na maioria dos casos resulta em um modelo melhor. A Figura 7 mostra o RF para classificação de múltiplas classes.

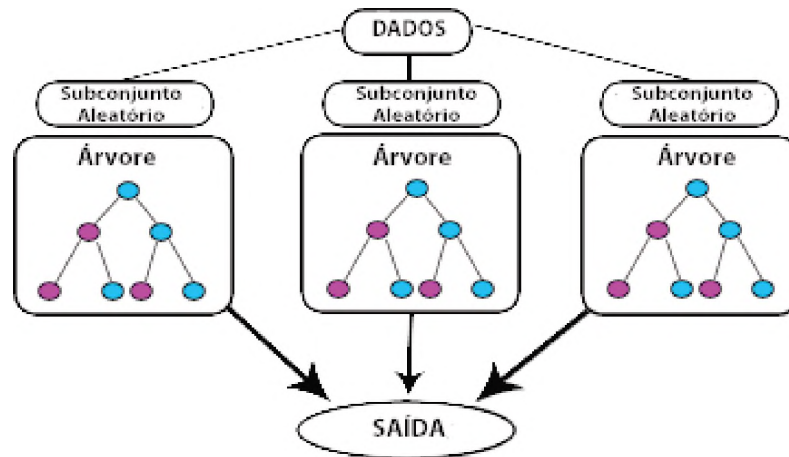


Figura 7 – Floresta Aleatória. Vários subconjuntos das árvores são criados e o resultado é uma combinação das saídas de todas as árvores. Fonte: (SOUZA et al., 2015). Imagem: Elaborada pelo autor.

O RF usa árvores de decisão (do inglês, *Decision trees*), mas adota um abordagem diferente. Ao invés de armazenar uma única árvore, a partir de dados de entrada, ele depende da agregação da produção de muitas árvores "rasas" que são podadas. Objetivo é que os erros das árvores "rasas" sejam eliminados quando agregados e então conduzirão uma previsão precisa, gerando como saída um modelo ideal para a classificação.



## 4 Metodologia Proposta

Este capítulo descreve o método para identificar um animal na rodovia utilizando imagens. A Figura 8 mostra a metodologia desenvolvida em duas etapas principais.

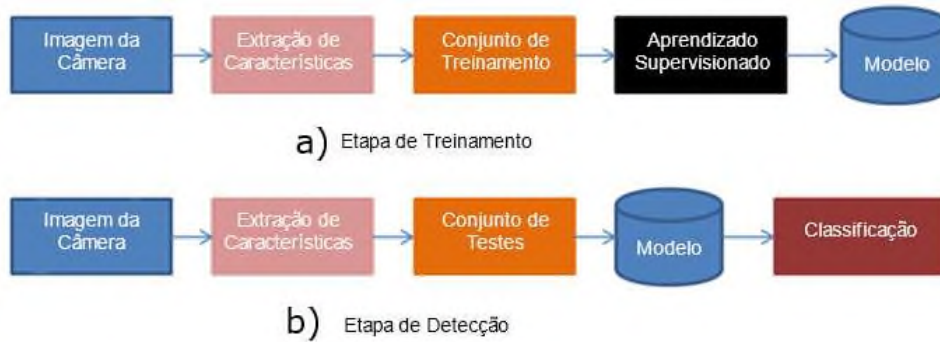


Figura 8 – Metodologia. O fluxo de dados é representado por setas. Imagem: Elaborada pelo autor.

A primeira etapa tem como função ensinar o algoritmo, a partir de características extraídas de um conjunto de imagens de treinamento selecionado, juntamente com o uso de uma técnica de AM supervisionado escolhido, que no final gera um modelo para classificação. Na segunda etapa ao invés de um conjunto de treinamento, é utilizado um conjunto de imagens de teste, que é processado com o modelo resultante obtido da etapa anterior para que se obtenha a classificação.

### 4.1 Abordagens

Cinco abordagens como mostra a Figura 9, foram desenvolvidas com base em blocos propostas em (SOUZA et al., 2015), nas quais os recursos são extraídos de áreas quadradas e alimentam o modelo. Essas cinco abordagens diferentes foram criadas para percorrer a imagem de ponta a ponta, de modo que o tamanho e forma do bloco de classificação e do contexto variaram para investigar qual abordagem consegue extrair melhor as características das imagens. O resultado é usado para a classificação das áreas quadradas (animais ou não animais). Aplicando um par de blocos de diferentes tamanhos: um menor sobreposta, conhecido como bloco de classificação (ClaB), cuja área é classificada pelo modelo, e um bloco contextual maior (ConB), cujas características são esperadas para produzir pistas ou dicas contextuais. Os mesmos recursos são extraídos em ambos os blocos e concatenados como entrada para um modelo.




Figura 9 – Cinco abordagens distintas são proposta. Imagem: Elaborada pelo autor.

A abordagem I é baseada no bloco normal de áreas quadradas: uma menor que é a ClaB (cor amarela) e uma maior que é a ConB (cor vermelha). A abordagem 2 foi desenvolvida baseada em uma cruz, uma área quadrada menor na ClaB e uma maior em um formato de cruz para produzir as pistas contextuais. A abordagem 3 foi desenvolvida com áreas quadradas nas borda, o ConB, para extrair as sugestões contextuais, e a ClaB permanece inalterada. As três abordagens iniciais não tiveram alteração no ClaB, apenas no formato ConB. A abordagem 4 foi desenvolvida utilizando o formato de uma cruz no ClaB e no ConB a área restante para extrair o contexto. A abordagem 5 foi desenvolvida utilizando o formato de um alvo no ClaB e a área restante para o ConB. Para todos, os blocos contextuais são maiores e o bloco de classificação está no centro. O ClaB é limitado a 5x5 pixels, e o ConB é limitado a uma área de 15x15 pixels para encontrar os melhores resultados de classificação de animais. Todo o sistema proposto de detecção de animais foi implementado usando a linguagem de programação Python 2.7.

## 4.2 Conjunto de treinamento e testes

Para realizar a construção de uma base de dados de amostra, as imagens foram classificadas manualmente e apenas as características obtidas dos pares de blocos em que cada bloco de classificação pertence à mesma classe (usando o bloco de classificação 5x5, todos os 25 pixels devem ser igualmente classificados). Em seguida, ocorre uma divisão no conjunto de dados inicial, em que as quantidades específicas de imagens são separadas para treinamento e testes. A combinação dos espaços cores, descritor de textura e entropia é feita através de um laço de repetição que realiza as combinações, executa o código e ao término da execução inicia-se a próxima combinação, até finalizar todas combinações entre os elementos declarados dentro de um vetor.

Assim, verificando que, usando o conjunto de treinamento, é possível classificar uma nova entrada de imagem. Isso demonstra a diferença significativa entre o conjunto de treinamento e os testes. As amostras são obtidas com a seguinte fórmula:

$$f_{norm} = \frac{f - m(\mathbf{f})}{std(\mathbf{f})}$$

onde  $f_{norm}$  é o valor de normalização,  $f$  são os valores de características,  $\mathbf{f}$  é o vetor que contém todos os valores de treinamento de uma determinada característica e  $m$  e  $std$  retornam a média e o desvio padrão de um vetor, respectivamente. O conjunto de testes é normalizado pelos mesmos parâmetros  $m$  e  $std$  calculados no conjunto de treinamento. Foram selecionados dois algoritmos de aprendizado supervisionados com base em seus desempenhos de generalização precisos: *K-Nearest Neighbors* e *Random Forest*. No qual o conjunto de treinamento e testes foram submetidos a essas técnicas e a um algoritmo que foi construído em python 2.7.

## 5 Resultados

Esta seção descreve os resultados experimentais do sistema de detecção de animais utilizando dois algoritmos de AM de forma supervisionada.

### 5.1 Detecção de animais

Foi implementado o sistema descrito e realizados testes de desempenho usando as imagens sintéticas com um software de edição de imagens, para avaliar a capacidade e o desempenho da metodologia. Imagens sintéticas foram criadas a partir de imagens selecionadas de espécies de animais que ocorrem na região do Triângulo Mineiro, todas produzidas com uma resolução de 984x656 pixels. Também foram utilizadas imagens reais (preto e branco) de câmeras trap fornecidas pela Prof.<sup>a</sup> Dr.<sup>a</sup> Ana Elizabeth Iannini Custódio do Laboratório de Ecologia de Mamíferos - LEMA da Universidade Federal de Uberlândia. E por último foi utilizado um banco de imagens públicas de animais silvestres ([AFKHAM, 2008](#)), essas são imagens coloridas disponibilizadas em seu respectivo site.

### 5.2 Treinamento e seleção de modelos

O conjunto de dados consiste em 20 imagens sintéticas produzidas manualmente, uma por uma através de um programa de edição de imagem, um conjunto de imagens noturnas capturadas por uma câmera trap e por fim um conjunto de imagens disponibilizadas publicamente ([AFKHAM, 2008](#)) na internet. As imagens sintéticas foram separadas em cinco imagens para treinamento e uma imagem para teste. As características são extraídas de todos os blocos, sendo classificadas de acordo com um classificador e o resultado é uma imagem resultante classificada. A avaliação é realizada usando o Ground Truth, para diferenciar quais pixels são animais e o que não é um animal, o qual foram realizados três principais experimentos.




Figura 10 – Groud Truth produzido. A cor branca (255) identifica o animal e a cor cinza (127) identifica o que não é animal. Imagem: Elaborada pelo autor.

O conjunto de dados de treinamento e testes foram aplicados para cada combinação de espaços de cores, um algoritmo de segmentação de imagem, um descritor de textura e cada uma das abordagens. Dois algoritmos de AM foram empregados, com todas as quatro melhores combinações de espaços de cores, ENTROPY, LBP e as cinco abordagens contextuais. Os primeiros experimentos se concentraram em encontrar um modelo que obtivesse o maior resultado de medida  $f$ . Em todos, utilizaram-se um bloco contextual 15x15 e um bloco de classificação 5x5. O KNN, usou-se os  $k$ -vizinhos definidos iguais a três e o número de árvores do RF igual a cem. O desempenho preditivo de KNN e RF é mostrado nas Tabelas 1, 2, 3 e 4.

A Tabela 1 refere-se ao KNN usando três abordagens no bloco contextual (ConB). O bloco contextual normal oferece a melhor medida  $F$  no conjunto de testes.

Tabela 1 – Medida  $F$  das abordagens ConB usando KNN.

KNN	Contextual Block		
	Normal	Cross	Edges
Color spaces			
GRAY+ENTROPY	<b>0.6113</b>	0.5525	0.5823
LAB+RGB+HSV+ENTROPY	0.5092	0.5112	0.4747
LAB+RGB+ENTROPY	0.5055	0.5169	0.4587
GRAY+LAB+RGB+ENTROPY	0.5011	0.5120	0.4548
GRAY+LAB+RGB+HSV+ENTROPY	0.5003	0.5037	0.4623

A Tabela 2 refere-se ao KNN usando três abordagens no bloco de classificação (ClaB). O bloco de classificação de alvo ofereceu a melhor medida  $\mathbf{F}$  no conjunto de testes.

Tabela 2 – Medida  $\mathbf{F}$  das abordagens ClaB usando KNN.

KNN Color spaces	Classification Block		
	Normal	Cross	Target
GRAY+ENTROPY	0.6133	0.6219	<b>0.6243</b>
LAB+RGB+HSV+ENTROPY	0.5092	0.5278	0.5199
LAB+RGB+ENTROPY	0.5055	0.5215	0.5144
GRAY+LAB+RGB+ENTROPY	0.5011	0.5196	0.5196
GRAY+LAB+RGB+HSV+ENTROPY	0.5003	0.5190	0.5162

A Tabela 3 refere-se ao RF usando três abordagens no ConB. O bloco contextual normal ofereceu a melhor medida  $\mathbf{F}$  no conjunto de testes.

Tabela 3 – Medida  $\mathbf{F}$  das abordagens ConB usando RF.

RF Color spaces	Contextual Block		
	Normal	Cross	Edges
GRAY+ENTROPY	<b>0.5601</b>	0.5204	0.4702
LAB+RGB+HSV+ENTROPY	0.1555	0.2232	0.1299
LAB+RGB+ENTROPY	0.4013	0.3809	0.1670
GRAY+LAB+RGB+ENTROPY	0.3189	0.2902	0.2110
GRAY+LAB+RGB+HSV+ENTROPY	0.1707	0.2086	0.1165

A Tabela 4 refere-se ao RF usando três abordagens no ClaB. O bloco de classificação em cruz ofereceu a melhor medida  $\mathbf{F}$  no conjunto de testes.

Tabela 4 – Medida  $\mathbf{F}$  das abordagens ClaB usando RF.

RF Color spaces	Classification Block		
	Normal	Cross	Target
GRAY+ENTROPY	0.5601	<b>0.5891</b>	0.5845
LAB+RGB+HSV+ENTROPY	0.1555	0.1999	0.1693
LAB+RGB+ENTROPY	0.4013	0.3274	0.3612
GRAY+LAB+RGB+ENTROPY	0.3189	0.2345	0.4852
GRAY+LAB+RGB+HSV+ENTROPY	0.1707	0.1756	0.1430

Após o primeiro experimento, foi realizado um segundo, com o conjunto de imagens da câmera trap, como mostra a Figura 11. Foram processadas com o descritor de textura LBP combinado cada uma das cinco abordagens e usando os algoritmos supervisionados KNN e RF.



Figura 11 – Banco de imagens de animais capturadas por uma câmera trap. Fonte: Imagens cedidas pelo LEMA (Laboratório de Ecologia de Mamíferos) da Universidade Federal de Uberlândia.

Após rodar o algoritmo com esse conjunto de imagens, não obteve-se resultado de medida  $\mathbf{F}$  satisfatório, concluindo que imagens preta e branco não são úteis para o contexto do experimento, pois o algoritmo realiza extração de características através de cores 3RGB.

No terceiro e último experimento foi utilizado um conjunto de imagens públicas reais (Figura 12) e coloridas de diferentes animais. Este banco de imagens foi processado utilizando LBP com o número de quatro vizinhos e raio um, sendo utilizado uma quantidade maior de imagens para treinar o algoritmo do que nos experimentos anteriores. Após o final do processamento do código a maior medida  $\mathbf{F}$  obtida foi 0,5.

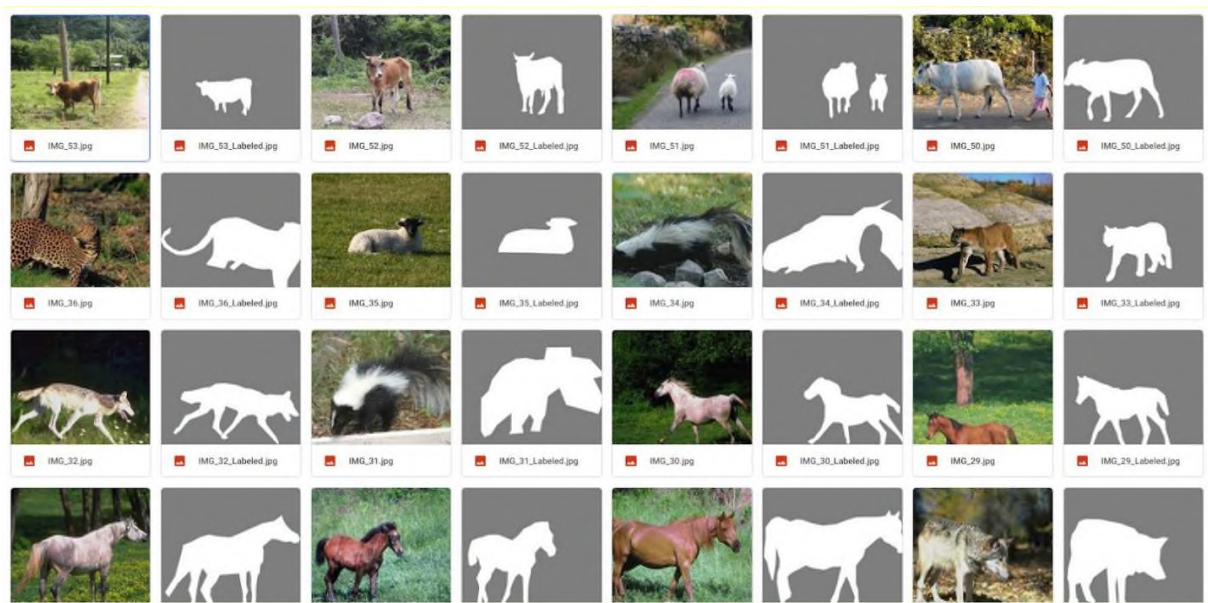


Figura 12 – Banco de imagens de animais fornecido por Heydar Maboudi Afkham. Extraído de (AFKHAM, 2008).



### 5.3 Melhores abordagens

Cinco abordagens diferentes foram desenvolvidas para a extração de características sobre as imagens, junto com quatro diferentes combinações de espaços de cores, um descritor de textura, um algoritmo de segmentação de imagem e dois algoritmos de aprendizado supervisionado. Depois de realizar todos os três experimentos, as duas melhores abordagens que obtiveram uma medida  $F$  mais considerável foram representadas na Figura 13. Os resultados experimentais foram melhores quando elaborados novos tipos de abordagens no ClaB. Abordagem 5 obteve a melhor medida  $F$  de **0,6243** (GRAY + ENTROPY, ClaB de alvo usando KNN) e a segunda posição foi a abordagem 4 com uma medida  $F$  de 0,6219. A Figura 14 apresenta os resultados para as duas melhores abordagens de classificação.

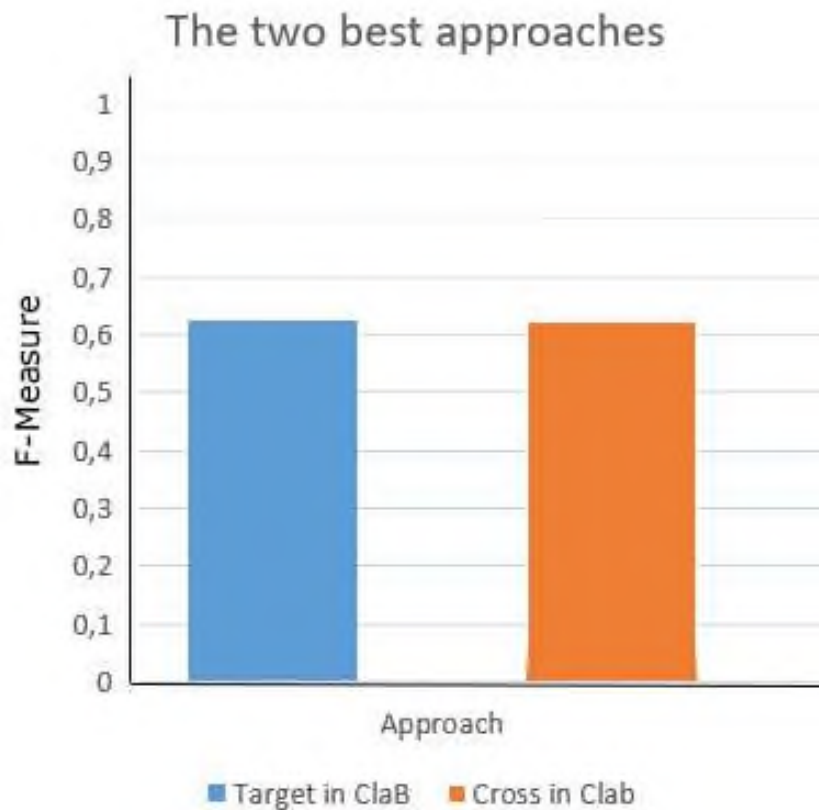


Figura 13 – Comparação das duas melhores abordagens.

A abordagem 5 com um formato de alvo no bloco de classificação foi eficiente para nosso caso. Depois das experiências com cada algoritmo, o KNN mostrou a melhor medida  $F$ . Nota-se que certamente há relevância das novas abordagens que foram apresentadas nesse trabalho baseadas no par de blocos, pois obtiveram um melhor desempenho comparado a abordagem tradicional para obter uma medida  $F$  mais precisa.

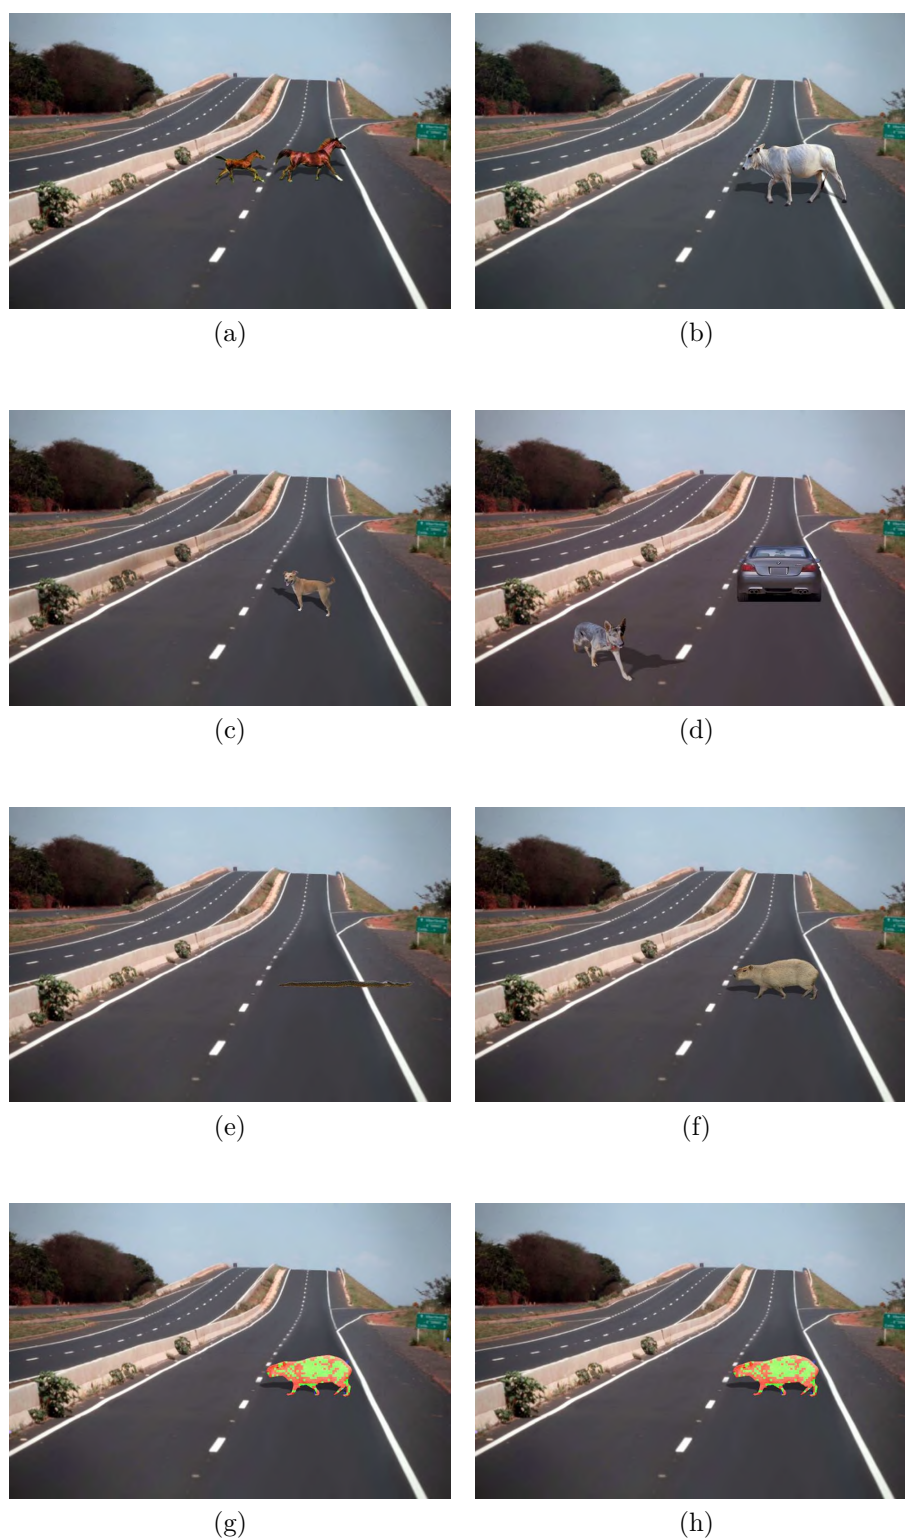


Figura 14 – (a) Cavalo, (b) Vaca, (c) Cão 1, (d) Cão 2, e (e) Cobra (dados de treinamento). (f) Capivara (dados de teste). (g) O primeiro melhor resultado da Tabela 2 sobre as imagens de teste. (h) O segundo melhor resultado da Tabela 2 sobre as imagens de teste. Os pixels pintados em verde mostram onde o algoritmo ML classificou como animal e acertou. Os pixels pintados de azul apresentam onde o algoritmo ML classificou como animal, mas errou. E a parte pintada de vermelho mostra a área demarcada como um animal no Ground Truth.

## 6 Conclusão

Assim, sabendo que a cada ano que passa os índices de atropelamento de animais e acidentes envolvendo animais e automóveis só aumentam, podemos esperar que o governo, empresas privadas ou órgãos não governamentais venham ter interesse por este tema, unindo-se com a tecnologia a fim de combater e diminuir estes índices daqui para frente. A idéia central de propor novos modelos de abordagem para percorrer as imagens junto com o algoritmos de aprendizado supervisionado foi atendida, sendo explorada com combinações de inúmeras tecnologias de espaços cores, algoritmo de segmentação de imagem e descritor de textura, trazendo um resultado melhor do que as abordagens tradicionais já abordadas por diversas literaturas. É um problema que se aplicado no mundo real, trará mais segurança para os motoristas e preservação da fauna local. Assim sendo um tema acadêmico que traz um benefício imediato para a sociedade brasileira e um crescimento pessoal para todas as pessoas envolvidas, pois aborda preservação de vidas humanas e conservação de espécies de animais, assuntos nobres que ao primeiro sinal de resultados efetivos, todas as pessoas envolvidas terão um crescimento interpessoal valioso.

O foco do desenvolvimento era obter uma medida  $f$  mais próximo de 1.0. Com todos os experimentos realizados, o melhor resultado obtido foi de 0,6243, combinação essa do espaço cor GRAY, o algoritmo de segmentação de imagem ENTROPY, o algoritmo de AM KNN e a imagem sendo percorrida com a abordagem de alvo no bloco de classificação, produzindo um valor que pode-se afirmar que a identificação do animal tem uma confiabilidade acima dos 50%. Como trabalho futuro, será explorado mais técnicas e classificadores mencionados nos trabalhos relacionados, como Haar-like, HOG, HSV e deep learning, a fim de encontrar uma possível metodologia que melhor se enquadra para o cenário deste trabalho para encontrar um resultado mais preciso.

Outro fator de grande relevância para uma próxima pesquisa, é a instalação de câmeras na rodovia para obtenção de imagens reais, para gerar um grande banco de imagens própria, para gerar mais dados estatísticos. Este animal após identificado, o sistema desenvolvido pretende-se comunicar via API com o aplicativo Waze e gerar um alerta para os motoristas usuários do aplicativo, assim testando com uma aplicação real que já está no mercado a muito tempo, será de grande importância para validar o sistema de detecção de animais. Além disso será feito casos de testes para conseguir identificar o animal em tempo real, por exemplo, colocar as câmeras a uma certa distância antes da estrada para dar tempo da identificação e emitir o alerta, otimizar o algoritmo, trocar a linguagem utilizada para a outra que seja mais rápida em questão de processamento.

Contudo, mesmo sendo um tema popular no mundo acadêmico global, com inúmeros estudos sendo realizados nesta linha de pesquisa a fim de uma melhor identificação antecipada de um animal na estrada para evitar colisão com um veículo, será realmente que é dada a devida atenção para este tema? A muito a se pesquisar ainda, trazendo formas e algoritmos mais otimizados que venham ser cada vez mais preciso, eficiente e que tragam informações em tempo real, de modo que não precisemos daqui uns anos ver notícias de onças pintadas sendo mortas na beira das rodovias brasileiras.

## Referências

- AFKHAM, H. M. *KTH - Animals*. Estocolmo, Suécia: [s.n.], 2008. Disponível em: <<http://www.csc.kth.se/~heydarma/Datasets.html>>. Citado 3 vezes nas páginas 6, 27 e 31.
- BANDEIRA, C.; FLORIANO, E. P. *Avaliação de Impacto Ambiental de Rodovias*. 2004. Disponível em: <<http://rodoviasverdes.ufsc.br/files/2010/03/Avaliaç~ao-de-impacto-ambiental-de-rodovias.pdf>>. Citado na página 11.
- CBEE. *Atropelômetro*. 2017. Disponível em: <<http://cbee.ufba.br/portal/index.php>>. Citado 3 vezes nas páginas 6, 11 e 12.
- CNT/SEST/SENAT. *Pesquisa CNT de rodovias 2017: relatório final*. Brasília, DF: [s.n.], 2017. 406 p. Disponível em: <[http://pesquisarodoviascms.cnt.org.br//Relatorio\Pesquisa\\_CNT\\_\(2017\)\\_BAIXA.pdf](http://pesquisarodoviascms.cnt.org.br//Relatorio\Pesquisa_CNT_(2017)_BAIXA.pdf)>. Citado na página 11.
- COLOR Feature Extraction. In: *PERSPECTIVES on Content-Based Multimedia Systems*. Boston, MA: Springer US, 2000. p. 49–67. ISBN 978-0-306-47033-2. Disponível em: <[https://doi.org/10.1007/0-306-47033-0\\_3](https://doi.org/10.1007/0-306-47033-0_3)>. Citado na página 18.
- DE, I.; SIL, J. Entropy based fuzzy classification of images on quality assessment. *Journal of King Saud University - Computer and Information Sciences*, v. 24, n. 2, p. 165 – 173, 2012. ISSN 1319-1578. Citado na página 21.
- FORSLUND, D.; BJÄRKEFUR, J. Night vision animal detection. In: *2014 IEEE Intelligent Vehicles Symposium Proceedings*. [S.l.: s.n.], 2014. p. 737–742. ISSN 1931-0587. Citado 2 vezes nas páginas 16 e 17.
- GONZALEZ, R. C.; WOODS, R. E. R. E.; EDDINS, S. L. *Digital Image processing using MATLAB*. [S.l.]: Pearson Prentice Hall, 2004. xiv + 609 p. ISBN 0-13-008519-7. Citado na página 21.
- HUIJSER MARCEL P.; DUFFIELD, J. W. C. A. P. A. R. J. M. P. T. Cost–benefit analyses of mitigation measures aimed at reducing collisions with large ungulates in the united states and canada: A decision support tool. *Ecology and Society*, v. 14, 2009. Disponível em: <<http://hdl.handle.net/10535/5379>>. Citado na página 12.
- MATUSKA, S. et al. A novel system for automatic detection and classification of animal. In: *2014 ELEKTRO*. [S.l.: s.n.], 2014. p. 76–80. Citado 2 vezes nas páginas 15 e 17.
- MATUSKA, S. et al. A video camera road sign system of the early warning from collision with the wild animals. *Civil and Environmental Engineering*, v. 12, n. 1, p. 42 – 46, 2016. Disponível em: <<https://content.sciendo.com/view/journals/cee/12/1/article-p42.xml>>. Citado na página 17.
- PLATANIOTIS, K. N.; VENETSANOPOULOS, A. N. *Color Image Processing and Applications*. Berlin, Heidelberg: Springer-Verlag, 2000. ISBN 3-540-66953-1. Citado na página 18.

PRF. *Balanco PRF*. 2017. Disponível em: <<https://www.prf.gov.br/portal/sala-de-imprensa/releases-1/balanco-prf-2017/view>>. Citado na página 12.

PRF/IPEA. *Acidentes de Trânsito nas Rodovias Federais Brasileiras: caracterização, tendências e custos para a sociedade*. 2015. Disponível em: <[http://www.ipea.gov.br/portal/images/stories/PDFs/relatoriopesquisa/150922\\\_relatorio\\\_acidentes\\\_transito.pdf](http://www.ipea.gov.br/portal/images/stories/PDFs/relatoriopesquisa/150922\_relatorio\_acidentes\_transito.pdf)>. Citado 2 vezes nas páginas 6 e 12.

ROSEBROCK, A. *Local Binary Patterns with Python e OpenCV*. 2015. Disponível em: <<https://www.pyimagesearch.com/2015/12/07/local-binary-patterns-with-python-opencv>>. Citado 3 vezes nas páginas 6, 19 e 20.

ROUSE, M. *Grayscale*. 2018. Disponível em: <<https://whatis.techtarget.com/definition/grayscale>>. Citado na página 18.

SCHWIEGERLING, J. *Field Guide to Visual and Ophthalmic Optics*. [S.l.]: Society of Photo Optical, 2004. (Proceedings of SPIE Series). ISBN 9780819456281. Citado na página 18.

SHALEV-SHWARTZ, S.; BEN-DAVID, S. *Understanding Machine Learning: From Theory to Algorithms*. New York, NY, USA: Cambridge University Press, 2014. ISBN 1107057132, 9781107057135. Citado na página 21.

SHALEV-SHWARTZ, S.; BEN-DAVID, S. *Understanding Machine Learning: From Theory to Algorithms*. NY, USA: Cambridge Uni. Press, 2014. ISBN 1107057132, 9781107057135. Citado 2 vezes nas páginas 22 e 23.

SHARMA, S. U.; SHAH, D. J. A practical animal detection and collision avoidance system using computer vision technique. *IEEE Access*, v. 5, p. 347–358, 2017. Citado 2 vezes nas páginas 15 e 17.

SHIPMAN, J. W. *Introduction to color theory*. 2012. Disponível em: <<http://infohost.nmt.edu/tcc/help/pubs/colortheory/web/hsv.html>>. Citado na página 18.

SOUZA, J. R. et al. Automatic detection of ceratocystis wilt in eucalyptus crops from aerial images. In: *ICRA*. IEEE, 2015. p. 3443–3448. ISBN 978-1-4799-6923-4. Disponível em: <<http://dblp.uni-trier.de/db/conf/icra/icra2015.html#SouzaMGVCRW15>>. Citado 4 vezes nas páginas 6, 22, 23 e 24.

SULLIVAN, W. *Machine Learning Beginners Guide Algorithms: Supervised & Unsupervised Learning, Decision Tree & Random Forest Introduction*. CreateSpace Independent Publishing Platform, 2017. (1 Series). ISBN 9781975632328. Disponível em: <<https://books.google.com.br/books?id=GHJ8swEACAAJ>>. Citado na página 12.

ZHOU, D. *Real-time Animal Detection System for Intelligent Vehicles*. University of Ottawa, 2014. Disponível em: <<https://books.google.com.br/books?id=gYcBrgEACAAJ>>. Citado 2 vezes nas páginas 16 e 17.