

DENIS SATO

**Sistema de detecção de animais nas rodovias com aprendizado de
máquina e visão computacional**

São Paulo

2022

DENIS SATO

Sistema de detecção de animais nas rodovias com aprendizado de máquina e visão computacional

VERSÃO CORRIGIDA

Tese apresentada ao Programa de Pós-Graduação em Epidemiologia Experimental Aplicada às Zoonoses da Faculdade de Medicina Veterinária e Zootecnia da Universidade de São Paulo para obtenção do título de Doutor em Ciências.

Departamento:

Departamento de Medicina Veterinária Preventiva e Saúde Animal

Área de concentração:

Epidemiologia Experimental Aplicada às Zoonoses

Orientador: Prof. Dr. Adroaldo José Zanella

Coorientador: Prof. Dr. Ernane José Xavier Costa

São Paulo

2022

Autorizo a reprodução parcial ou total desta obra, para fins acadêmicos, desde que citada a fonte.

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO

(Biblioteca Virginie Buff D'Ápice da Faculdade de Medicina Veterinária e Zootecnia da Universidade de São Paulo)

4237
FMVZ

Sato, Denis
Sistema de detecção de animais nas rodovias com aprendizado de máquina e visão computacional / Denis Sato. – 2022.
68 f. : il.

Tese (Doutorado) – Universidade de São Paulo. Faculdade de Medicina Veterinária e Zootecnia. Departamento de Medicina Veterinária Preventiva e Saúde Animal, São Paulo, 2022.

Programa de Pós-Graduação: Epidemiologia Experimental Aplicada às Zoonoses.

Área de concentração: Epidemiologia Experimental Aplicada às Zoonoses.

Orientador: Prof. Dr. Adroaldo José Zanella.

Coorientador: Prof. Dr. Ernane José Xavier Costa.

1. Visão computacional. 2. Colisões veículos-animais. 3. Inteligência artificial. I. Título.



Comissão de Ética no Uso de Animais

Faculdade de Medicina Veterinária e Zootecnia
Universidade de São Paulo

São Paulo, 21 de outubro de 2020

CEUA N 4526170418

(ID 007082)

Ilmo(a). Sr(a).

Responsável: Adroaldo José Zanella

Área: Epidemiologia Experimental Aplicada As Zoonoses

Título da proposta: "Mapeamento computacional de Capivaras com uso de câmeras térmicas parasistema de detecção nas rodovias".

CERTIFICADO (Relatório Parcial versão de 31/agosto/2020)

A Comissão de Ética no Uso de Animais da Faculdade de Medicina Veterinária e Zootecnia da Universidade de São Paulo, no cumprimento das suas atribuições, analisou e **APROVOU** o Relatório Parcial (versão de 31/agosto/2020) da proposta acima referenciada.

Resumo apresentado pelo pesquisador: "1. Qual o estágio do estudo no momento? Resp: O Denis Sato está com a parte computacional pronta. Ele vai submeter a qualificação nas próximas 4 semanas. 2. Por quanto tempo mais o estudo se estenderá? Resp: 24 meses 3. Resultados parciais ou totais apresentados em congresso? Resp: A primeira submissão vai acontecer nesta semana para o Congresso Iberoamericano de Infraestrutura Viária e Biodiversidade (<https://www.cibiv2020.com.br/>). 4. Resultados parciais ou totais já publicados? Resp: Não".

Comentário da CEUA: O projeto está sendo desenvolvido conforme o acordado com esta CEUA. Foi informado que o estudo se estenderá por mais de 24 meses que extrapola o prazo previsto inicialmente. Para regularizar, solicitamos que juntamente com o próximo relatório parcial seja incluída uma alteração (emenda) para alterar a vigência do projeto.

Prof. Dr. Marcelo Bahia Labruna
Coordenador da Comissão de Ética no Uso de Animais
Faculdade de Medicina Veterinária e Zootecnia da Universidade
de São Paulo

Camilla Mota Mendes
Vice-Coordenadora da Comissão de Ética no Uso de Animais
Faculdade de Medicina Veterinária e Zootecnia da Universidade
de São Paulo

FORMULÁRIO DE AVALIAÇÃO

Autor: Denis Sato

Título: Sistema de detecção de animais nas rodovias com aprendizado de máquina e visão computacional

Tese apresentada ao Programa de Pós-Graduação em Epidemiologia Experimental Aplicada às Zoonoses da Faculdade de Medicina Veterinária e Zootecnia da Universidade de São Paulo para obtenção do título de Doutor em Ciências.

Data: ____/____/____

Membros da Banca de Avaliação

Professor: _____

Instituição: _____ Decisão: _____

Professor: _____

Instituição: _____ Decisão: _____

Professor: _____

Instituição: _____ Decisão: _____

Professor: _____

Instituição: _____ Decisão: _____

Professor: _____

Instituição: _____ Decisão: _____

Professor: _____

Instituição: _____ Decisão: _____

AGRADECIMENTOS

Agradeço aos meus pais Osvaldo Hiroshi Sato e Maria de Fátima dos Santos Sato pelo apoio em minha busca pelo conhecimento.

Aos meus irmãos Deivis e Ayane pelo que aprendemos a compartilhar nesta vida.

À minha companheira Martha H. Zaninetti pelo amor, luta, fé em mim, alegria e paciência. Amo você.

Ao Professor e amigo Adroaldo José Zanella pela orientação neste trabalho e o crescimento intelectual que sua companhia proporcionou durante estes anos de trabalho.

Ao Professor e amigo Ernane José Xavier Costa pela amizade gentil e suporte técnico/acadêmico todos estes anos.

Aos meus amigos Leandro Sabei, Marisol Parada, Sharacely Farias, André Nogueira e todos os integrantes do CECSBE – muito obrigado!

Aos meus amigos Thiago Bernardino de Almeida e Patrícia Tatemoto – minha admiração e amizade sempre.

Agradeço à Universidade de São Paulo, Faculdade de Medicina Veterinária e Zootecnia, e Faculdade de Zootecnia e Engenharia de alimentos por todos estes anos de crescimento pessoal trabalhando no *Campus* “Fernando Costa”.

Meus sinceros agradecimentos à Prefeitura do Campus “Fernando Costa” – USP de Pirassununga pelo total apoio ao trabalho desenvolvido.

Ao Sr. José Roberto Devitto pelo apoio em todos os experimentos, amizade e agradável convivência diária.

Agradeço à Fundação Medicina Veterinária – FUMVET pelos recursos investidos neste trabalho.

Agradeço a Polícia Militar Rodoviária pelo apoio ao projeto todos estes anos.

Agradecimentos especiais ao Grupo Arteris – Intervias pelo suporte tecnológico e recursos destinados a esta pesquisa.

Special thanks to The Donkey Sanctuary organization for supporting this research and continuing to believe that this detection system can improve animal welfare.

RESUMO

Sato, D **Sistema de detecção de animais nas rodovias com aprendizado de máquina e visão computacional**. 2022. 68 p. Tese (Doutorado em Ciências) – Faculdade de Medicina Veterinária e Zootecnia, Universidade de São Paulo, Pirassununga, 2022.

A criação da infraestrutura rodoviária, necessária para a comunicação de grandes centros urbanos, resultou em consequências negativas para espécies de animais selvagens. Dentre os principais efeitos nocivos, destacam-se a perda de variabilidade genética, o desequilíbrio das relações ecológicas e as colisões de animais com veículos automotores que causam a perda de vidas humanas e de animais todos os anos. Medidas de mitigação de acidentes como: cercas, passagens verdes, dispositivos eletrônicos, óticos e odoríferos; têm sido aplicadas em diversas regiões pelo mundo. No primeiro capítulo desta tese apresentamos uma revisão sobre os sistemas de mitigação de acidentes nas rodovias envolvendo animais. A seguir, treinamos um sistema de detecção utilizando duas variações do algoritmo de detecção de objetos Yolo para dois grupos de animais: capivaras e equídeos. Os testes foram realizados em 147 imagens e os resultados de acurácia obtidos foram de 84,87% e 79,87% para o YoloV4 e YoloV4-tiny respectivamente. No terceiro capítulo apresentamos os resultados do sistema de detecção em tempo real em uma via pavimentada. O modelo YoloV4-Puraa apresentou 37,25% e 14,26% de precisão para as classes *equidae* e *capivara* respectivamente. Os modelos puderam detectar os objetos de interesse até cem metros de distância da câmera. Um sistema de alerta luminoso para detecções positivas foi desenvolvido e este sistema de alerta da presença de animais nas rodovias utilizando visão computacional é um promissor agente de mitigação de acidentes rodoviários envolvendo animais selvagens e domésticos.

Palavras-chave: *Visão computacional; colisões veículo-animais; inteligência artificial.*

ABSTRACT

Sato, D. **Animal detection system on highways with machine learning and computer vision**. 2022. 68 p. Tesis (PhD in Science) – Faculdade de Medicina Veterinária e Zootecnia, Universidade de São Paulo, Pirassununga, 2022.

The creation of road infrastructure, necessary for the communication of large urban centers, has resulted in negative consequences for wild animal species. Among the main harmful effects are the loss of genetic variability, the imbalance of ecological relationships and the collisions of animals with motor vehicles that cause the loss of human and animal lives every year. Accident mitigation measures such as: fences, green passages, electronic, optical and odoriferous devices; have been applied in different regions around the world. In the first chapter of this thesis, we present a review of accident mitigation systems involving animals on highways. Next, we trained a detection system using two variations of the Yolo object detection algorithm for two groups of animals: capybaras and equines. The tests were performed on 147 images and the accuracy results obtained were 84.87% and 79.87% for Yolov4 and Yolov4-tiny, respectively. In the third chapter we present the results of the real-time detection system on a paved road. The Yolov4-Puraa model showed 37.25% and 14.26% accuracy for the equine and capybara classes, respectively. The models could detect objects of interest up to 100 meters away from the camera. A light alert system for positive detections was developed and this system of alerting the presence of animals on roads using computer vision is a promising agent for mitigating road accidents involving wild and domestic animals.

Keywords: Computer vision, animal-vehicle collisions, artificial intelligence.

LISTA DE FIGURAS

Figura 1 – Exemplo de imagem digital em escala de cinza.....	24
Figura 2 Composição de uma imagem digital RGB.....	25
Figura 3 – Tarefas de detecção realizadas por algoritmos de visão computacional.	26
Figura 4– Rotulagem do objeto de interesse em uma imagem.	28
Figura 5 – Intersecção sobre União.	30
Figura 6 – Montagem do sistema.	31
Figura 7 – Virtualização do sistema de detecção nas rodovias.....	31
Figura 8 – Resultados comparativos de detecção entre os modelos Yolov4 e Yolov4-tiny.....	32
Figura 9 – Exemplos de falso positivos e falso negativos (objetos não detectados).	33
Figura 10 – Resultados comparativos de precisão dos modelos Yolov4 e Yolov4-tiny.	34
Figura 11 – Alerta luminoso para detecções positivas.	35
Figura 12 - Modelo de detecção da rede Yolo.....	45
Figura 13 - Arquitetura da convnet Yolo.....	46
Figura 14 - Via pavimentada utilizada para os testes de detecção.	48
Figura 15 - Placa de sinalização rodoviária com instalação de sinal luminoso.	48
Figura 16 - Diagrama de conexões do sistema detector.	49
Figura 17 - Estrutura experimental em PVC para acomodação do hardware.	50
Figura 18 - Condução de um cavalo pela via demarcada.	51
Figura 19 - Capivaras na via pavimentada durante os testes de detecção.	51
Figura 20 – Resultados mAP e gráfico Precisão x Recuperação para o modelo Yolov4-Puraa – classe equidae (n=186).	54
Figura 21 – Detecções e número de objetos não detectados – Yolov4-Puraa classe equidae (n=186).	54
Figura 22 - Detecção de equino a 30 metros com Yolov4-Puraa.	55
Figura 23 - Detecção de equino a 70 metros com Yolov4-Puraa.	55
Figura 24 - Detecção não computada por limiar de IoU.	56
Figura 25 - Resultados mAP e gráfico Precisão x Recuperação para o modelo Yolov4-Puraa – classe capivara.	57
Figura 26 - Quadros com resultados de detecção do Yolov4-Puraa para a classe capivara.....	57
Figura 27 - Quadros de detecção do Yolov4-Puraa para a classe capivara.	58
Figura 28 - Detecções e número de objetos não detectados – Yolov4-Puraa classe capivara.....	58
Figura 29 - Detecções com o Yolov4-msCOCO.....	59
Figura 30 - Detecções do Yolov4-COCO para a classe <i>equidae</i>	60
Figura 31 - Alerta luminoso para detecção positiva.....	61
Figura 32 - SP 330 - Universidade de São Paulo - mapa.....	62

LISTA DE TABELAS

Tabela 1 – Amostragem de quadros para avaliação da detecção.....	52
Tabela 2 - Resultados de detecção no modelo Yolov4-msCOCO classe equidae....	59

SUMÁRIO

1. Introdução.....	11
2. Capítulo 1 – Mitigação de acidentes rodoviários envolvendo animais – Uma revisão.....	12
2.1. Introdução	12
2.2. Colisões entre veículos automotores e animais	13
2.3. Medidas mitigatórias	14
2.3.1. Passagens e cercas	15
2.3.2. Repelentes odoríferos	15
2.3.3. Dispositivos luminosos	16
2.3.4. Dispositivos detectores de presença.....	16
2.4. Conclusão.....	17
3. CAPÍTULO 2 – Classificação computacional de animais para sistema de detecção nas rodovias.....	23
3.1. Introdução	23
3.4. Materiais e métodos.....	27
3.4.1. Treinamento do modelo.....	27
3.4.2. Avaliação da performance.....	29
3.5. Resultados e discussão	32
3.6. Conclusões.....	36
4. CAPÍTULO 3 – Detecção de animais em tempo real para mitigação de acidentes rodoviários.	43
4.1. Introdução	43
4.2. Detecção de objetos com visão computacional.....	43
4.3. Materiais e métodos.....	47
4.3.1. Localização do experimento.....	47
4.3.2. Hardware e software	48
4.3.3. Testes de detecção	50
4.3.4. Avaliação estatística.....	52
4.4. Resultados e discussões	53
4.5. Conclusões.....	62
4.6. REFERÊNCIAS	64

1. Introdução

Os ecossistemas essenciais para a manutenção da vida selvagem têm sido reduzidos drasticamente com o crescimento demográfico das populações humanas. A necessidade de infraestrutura para as cidades e para o agronegócio tem contribuído para o isolamento de diversas espécies de animais silvestres em pequenos espaços que não são suficientes para seu desenvolvimento fisiológico e reprodutivo (SOANES et al., 2013).

Apesar da recente preocupação com a manutenção de corredores verdes para que espécies de animais possam se locomover entre áreas de conservação, a mortalidade de animais silvestres e acidentes fatais envolvendo humanos representam um grave problema a ser resolvido (KEKEN et al., 2016).

O entendimento dos impactos nos ecossistemas resultou no desenvolvimento de uma nova ciência, a “Ecologia das Estradas”, que têm colaborado para o planejamento sustentável das rodovias e o planejamento de medidas de mitigação de acidentes rodoviários envolvendo animais (FORMAN, 2003).

Um método promissor para a detecção de animais nas rodovias é a utilização de algoritmos baseados em inteligência artificial (IA). Através de técnicas de visão computacional e aprendizado de máquina em redes neurais artificiais, há a possibilidade do desenvolvimento de um sistema de alerta para a presença de animais no meio viário. Algoritmos de detecção de objetos, executados em um sistema embarcado, podem ser instalados em diferentes locais ao longo da via, de acordo com a necessidade avaliada através de dados de acidentes rodoviários obtidos ao longo de um período.

Esta tese apresenta um sistema de detecção de animais nas rodovias baseado em visão computacional e aprendizado de máquina. Acreditamos que a aplicação deste sistema detector nas rodovias e o constante reforço do treinamento dos modelos pode contribuir para a redução dos acidentes rodoviários envolvendo animais.

2. Capítulo 1 – Mitigação de acidentes rodoviários envolvendo animais – Uma revisão

2.1. Introdução

A extensão somada de rodovias na Terra já é superior a 37 milhões de quilômetros¹, um pouco mais de 96 vezes a distância entre a Terra e a Lua (CENTRAL INTELLIGENCE AGENCY - USA, 2019). Nos anos 2000, a utilização de transporte por veículos automotores foi estimada em 32 trilhões de passageiros e em 2050 a previsão é que este valor atinja 105 trilhões, dos quais cerca de 42% serão de usuários de carros (VAN DER REE; SMITH; GRILO, 2015).

As preocupações com os efeitos das rodovias no ambiente começaram a ser adotadas após a década de 1970 com os resultados das discussões da Primeira Conferência Mundial sobre o Homem e o Meio Ambiente, promovida pela Organização das Nações Unidas em Estocolmo no ano de 1972 (FORMAN, 2003). No Brasil, através das Portarias Interministeriais nº 420 e nº 423 em outubro de 2011, foi instituído o Programa de Rodovias Federais Ambientalmente Sustentáveis que objetiva regularizar ambientalmente 55.000 km de rodovias até o ano de 2031. Em 2012, o Departamento Nacional de Infraestrutura de Transportes apresentou um relatório sobre o Programa de Monitoramento e Mitigação dos Atropelamentos de Fauna com informações sobre as ações governamentais relativas ao assunto (DNIT, 2012).

Os efeitos nocivos da construção rodoviária na fauna foram avaliados em muitos estudos ecológicos (BOARMAN; SAZAKI, 2006; CAI; WU; CHENG, 2013; EIGENBROD; HECNAR; FAHRIG, 2009; FORMAN; DEBLINGER, 2000; SAUNDERS *et al.*, 2002) sendo os principais citados: mortalidade rodoviária em acidentes, perda de habitat e conectividade reduzida. Outra importante consequência são os acidentes envolvendo animais nas rodovias causando prejuízos e perdas de vidas humanas.

¹ Dados de 215 países (estradas pavimentadas e não pavimentadas) com datas de informação variada - (CENTRAL INTELLIGENTE AGENCY - USA).

2.2. Colisões entre veículos automotores e animais

Os acidentes de veículos com animais silvestres criam um forte impacto negativo nas populações de diversas espécies, reduzindo a conectividade entre os corredores verdes e, assim, resultando em endogamia e perda de variabilidade genética (ASCENSÃO *et al.*, 2013).

Estão envolvidos em acidentes rodoviários animais domésticos como bovinos, equinos, asininos, muares e inúmeras espécies silvestres. Uma estimativa informa que há cerca de 14,7 milhões de animais atropelados todos os anos nas rodovias federais do Brasil (DORNAS *et al.*, 2012). Um estudo realizado entre março e setembro de 2011 na rodovia MS-080 (Mato Grosso do Sul) computou 257 animais atropelados de 52 espécies diferentes, resultando em uma taxa de 0,13 animais mortos por quilômetro (CARVALHO; BORDIGNON; SHAPIRO, 2014).

No Brasil, a capivara (*Hydrochoerus hydrochaeris*) tem grande destaque devido à sua grande massa corporal e abundância de indivíduos, a colisão da espécie com veículos automotores causa sérios acidentes resultando inclusive em vítimas fatais. De acordo com um estudo, em sete rodovias paulistas totalizando 786 km monitoradas por cinco anos, foram computados 1.627 animais atropelados, sendo que 28% (462) foram capivaras (HUIJSER; DELBORGO ABRA; DUFFIELD, 2013).

Dados da Polícia Militar Rodoviária do Estado de São Paulo informam que entre 2005 e 2013 ocorreram 23.858 acidentes envolvendo animais em rodovias, totalizando a morte de 194 pessoas. Dados da empresa Intervias, administradora da rodovia SP 330 na região de Pirassununga-SP, informam que em 2016 foram realizados 720 atendimentos envolvendo Capivaras nos quais as equipes de inspeção afugentaram 1.508 Capivaras e recolheram 339 mortas (POLÍCIA MILITAR RODOVIÁRIA DO ESTADO DE SÃO PAULO; GRUPO ARTERIS; UNIVERSIDADE DE SÃO PAULO, 2018). A gravidade de tais acidentes pode ser constatada por um acidente na rodovia SP-191 envolvendo capivaras que resultou na morte de 07 pessoas em 2011 (EPTV, 2011).

Nos Estados Unidos estimativas indicam que há cerca de 1 milhão de mortes de vertebrados por dia e acredita-se que ocorra cerca de 1 a 2 milhões de acidentes com grandes animais com aproximadamente 200 mortes humanas por ano devido aos acidentes nas rodovias, causando prejuízos de 8,4 bilhões de dólares (OLSON *et al.*,

2014). Também foi verificado um aumento de 104% no índice de vítimas humanas fatais em acidentes com animais entre os anos de 1990 e 2008 (SULLIVAN, 2011). Em 2016, 264.000 colisões com veados e/ou javalis foram relatadas na Alemanha, gerando perdas econômicas de cerca de 682 milhões de euros (GDV, 2017). Dados anteriores sobre acidentes por toda Europa relatam cerca de meio milhão de acidentes, danos materiais da ordem de 1 bilhão de dólares e mais de 300 perdas de vidas humanas por ano (BRUINDERINK; HAZEBROEK, 1996).

No Brasil, outro animal que se destaca em relação aos acidentes nas rodovias é o jumento (*Equus africanus asinus*). Estima-se que haja cerca de 1 milhão de jumentos soltos na natureza no país (THE DONKEY SANCTUARY, 2019). Isso se deve principalmente ao abandono dos animais que têm sido substituídos por veículos automotores e máquinas agrícolas, principalmente na região nordeste do Brasil. Nas estradas federais da região, foram relatados 8.050 acidentes com animais de 2012 a agosto de 2016, com 1.647 feridos graves e 259 mortes (BITTENCOURT, 2016). Com o objetivo de diminuir tais impactos da malha viária na fauna e reduzir acidentes, foram propostas diversas medidas mitigatórias.

2.3. Medidas mitigatórias

Ações de infraestrutura, visando minimizar o impacto das rodovias sobre a fauna, foram propostas e implantadas. Estas medidas buscam minimizar os efeitos de barreira e impedir acidentes com animais em pontos mais suscetíveis. Diaz-Varela et al. (2011) ressaltaram que os dados sobre acidentes nas rodovias envolvendo animais permitem identificar os pontos críticos e quais as espécies apresentam maior número de ocorrências, sendo uma importante ferramenta para a escolha dos métodos mitigadores.

Lao et al. (2011) apresentaram uma modelagem matemática considerando o fator humano e interações com espécies específicas de animais como uma ferramenta para a avaliação de risco de acidentes com animais. Outras pesquisas têm focado na análise temporal dos eventos que culminam em acidentes para compreender a dinâmica dos eventos em locais específicos (HOTHORN *et al.*, 2015; RODRÍGUEZ-MORALES; DÍAZ-VARELA; MAREY-PÉREZ, 2013).

2.3.1. Passagens e cercas

Passagens superiores e inferiores são obras de engenharia específicas com objetivo de proporcionar condições de deslocamento da fauna, pré-concebidas ou adaptadas a estruturas já existentes. Dodd et al. (2004) verificaram uma queda de 65% nos atropelamentos de animais em uma rodovia da Flórida (EUA) após a construção de barreiras e uma passagem inferior para fauna.

Realizar um planejamento prévio para a construção de tais estruturas é essencial para obter melhores resultados. Um modelo de planejamento de estruturas de passagens deve considerar questões importantes como tamanho e tipo da estrutura, espécies envolvidas, localização e condições para manutenção (RYTWINSKI *et al.*, 2015).

Mata et al. (2008) verificaram que em muitos casos faz-se necessária a implantação de diferentes tipos de estruturas de passagem, visto que apenas um tipo de passagem não é utilizado por todas as espécies. Tal questão pode ser constatada em um estudo que verificou que a construção de uma estrutura de proteção em uma rodovia do sudeste do Brasil reduziu o número de acidentes rodoviários apenas para uma espécie animal (BAGER; FONTOURA, 2013). Ainda, foi relatado que construção de apenas um tipo de passagem pode aumentar os índices predatórios sendo necessário o desenvolvimento de estruturas específicas para algumas espécies (TISSIER *et al.*, 2016).

2.3.2. Repelentes odoríferos

Neste método odores são usados para repelir animais da área da rodovia. Estes dispositivos utilizam odores de predadores e odores considerados fétidos. A utilização deste método é controversa com estudos apresentando redução no número de acidentes de 37% (KUŠTA *et al.*, 2015) e de 26 a 43% (BÍL *et al.*, 2018) e outros relatando sua ineficácia (ELMEROS *et al.*, 2011; SCHLAGETER; HAAG-WACKERNAGEL, 2012). Uma consideração importante é que os animais podem se acostumar com o cheiro, além de ser relativamente caro de usar em grandes áreas (TRANSPORT CANADA SAFETY AND SECURITY, 2003).

2.3.3. Dispositivos luminosos

Dispositivos refletores de luz foram considerados uma ferramenta promissora para reduzir o número de acidentes com animais nas rodovias. Os refletores são espelhos montados em postes ao longo do lado das estradas, espalhando o farol dos carros na margem da estrada, possivelmente alertando os animais dos veículos que se aproximam. Apesar de terem sido instalados em diversos países, pesquisas relatam que tais dispositivos são ineficazes e alguns estudos apresentados para corroborar seu uso, relataram falhas de design experimental (ANGELO *et al.*, 2006; BENTEN *et al.*, 2018; D'ANGELO; VAN DER REE, 2015).

2.3.4. Dispositivos detectores de presença

Alguns sistemas de detecção utilizam radiofrequências, sensores infravermelhos ou coleiras em animais para detectar a presença de grandes animais nas estradas públicas. Esses sistemas alertam os motoristas através de placas luminosas que piscam luzes quando um animal é detectado na rodovia. A tecnologia envolvida é baseada em uma rede de sensores sem fio. Diversos sistemas relacionados a sensores de presença têm sido elaborados, mas a sua eficácia ainda carece de estudos a campo (ABRA, 2017; GRACE; SMITH; NOSS, 2017; VENKATESAN; FAROOQ; IMRAAN, 2013).

Dispositivos para detecção da presença de animais com a utilização de algoritmos de visão computacional e aprendizado de máquina são agora aplicados em diversas áreas de pesquisa. Um algoritmo para detecção de animais com câmeras baseado na técnica de histograma de objetos orientados foi proposto um estudo com o objetivo de prevenir acidentes com animais em áreas residenciais (RANGDA; HANCHATE, 2014). Utilizando um sistema de detecção com uso de uma câmera térmica, um estudo apresentou uma precisão de 84,7% a uma altitude de 3 a 10 metros e 75,2% a uma altitude de 10 a 20 metros, para um futuro sistema de remoção de animais selvagens antes de operações de colheita (CHRISTIANSEN *et al.*, 2014).

Em outro sistema de detecção por imagens, baseado na técnica de histograma de gradientes orientados, obteve 82,5% de acurácia na detecção de mais de 20 fenótipos de bovinos espalhados por diversos estados da Índia (SHARMA;

SHAH, 2017). Outro estudo com técnica semelhante relatou acurácia de 91,2% na detecção de veados com velocidade de 22,4 quadros por segundo utilizando uma câmera térmica de baixa resolução (ZHOU, 2013). Um sistema de detecção de animais em rodovias com uso de radar e visão computacional utilizando câmera térmica foi apresentado em uma conferência no Canadá (SIELECKI, 2017). Tais sistemas também têm sido aplicados para detecção de pedestres e veículos no trânsito rural (BARBA-GUAMAN; EUGENIO NARANJO; ORTIZ, 2020).

O uso de visão computacional também tem sido aplicado melhorar a segurança de carros autônomos (MAMMERI; ZHOU; BOUKERCHE, 2016; SHUBHAM *et al.*, 2020), com uso de câmeras termográficas (MAMMERI; ZHOU; BOUKERCHE, 2016; MUNIAN; MARTINEZ-MOLINA; ALAMANOTIS, 2020) e para monitorar geograficamente alertando a presença de animais em regiões de rodovias (ROOPASHREE *et al.*, 2021).

2.4. Conclusão

O grande desafio dos métodos de mitigação de acidentes com animais nas rodovias está relacionado aos diferentes tamanhos, espécies animais e interações ecológicas de acordo com a região de estudo. A tecnologia escolhida para pesquisa e desenvolvimento de tais sistemas deve levar consideração a todas as espécies envolvidas. Para serem eficazes, os sistemas de detecção de animais devem detectar animais grandes e pequenos.

Algumas tecnologias de mitigação como refletores luminosos e dispositivos odoríferos, têm sido avaliados apresentando baixa eficácia. Apesar de haver muitas tecnologias de detecção da presença de animais nas rodovias em teste atualmente, ainda não há dados suficientes para confirmar sua total eficácia e vantagens da sua aplicação em relação ao uso de passagens superiores e inferiores.

As obras de infraestrutura (passagens e cercas) têm demonstrado maior eficácia na redução de acidentes rodoviários com animais.

2.5. REFERÊNCIAS

- ABRA, F. D. **Desenvolvimento de sistema de detecção animal antiatropelamento em rodovias - “Passa Bicho”**. Disponível em: <<http://www.bv.fapesp.br/pt/auxilios/93334/desenvolvimento-de-sistema-de-deteccao-animal-antiatropelamento-em-rodovias-passa-bicho/>>. Acesso em: 12 mar. 2018.
- ANGELO, G. J. D.; WARNELL, D. B.; RESOURCES, N.; D'ANGELO, G. J. J. G. J.; D'ANGELO, J. G.; GALLAGHER, G. R.; OSBORN, D. a; MILLER, K. V; WARREN, R. J. Evaluation of Wildlife Warning Reflectors for Altering White-Tailed Deer Behavior Along Roadways. **Wildlife Society** ..., v. 34, n. 4, p. 1175–1183, 2006. Disponível em: <[http://onlinelibrary.wiley.com/doi/10.2193/0091-7648\(2006\)34\[1175:EOWWRF\]2.0.CO;2/abstract%5Cn%3CGo](http://onlinelibrary.wiley.com/doi/10.2193/0091-7648(2006)34[1175:EOWWRF]2.0.CO;2/abstract%5Cn%3CGo) to ISI%3E://WOS:000243173600036>.
- ASCENSÃO, F.; CLEVENGER, A.; SANTOS-REIS, M.; URBANO, P.; JACKSON, N. Wildlife-vehicle collision mitigation: Is partial fencing the answer? An agent-based model approach. **Ecological Modelling**, v. 257, p. 36–43, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.ecolmodel.2013.02.026>>.
- BAGER, A.; FONTOURA, V. Evaluation of the effectiveness of a wildlife roadkill mitigation system in wetland habitat. **Ecological Engineering**, v. 53, p. 31–38, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.ecoleng.2013.01.006>>.
- BARBA-GUAMAN, L.; EUGENIO NARANJO, J.; ORTIZ, A. Deep Learning Framework for Vehicle and Pedestrian Detection in Rural Roads on an Embedded GPU. **Electronics**, v. 9, n. 4, p. 589, 31 mar. 2020. Disponível em: <<https://www.mdpi.com/2079-9292/9/4/589>>.
- BENTEN, A.; HOTHORN, T.; VOR, T.; AMMER, C. Wildlife warning reflectors do not mitigate wildlife–vehicle collisions on roads. **Accident Analysis and Prevention**, v. 120, n. February, p. 64–73, 2018. Disponível em: <<https://doi.org/10.1016/j.aap.2018.08.003>>.
- BÍL, M.; ANDRÁŠIK, R.; BARTONIČKA, T.; KŘIVÁNKOVÁ, Z.; SEDONÍK, J. An evaluation of odor repellent effectiveness in prevention of wildlife-vehicle collisions. **Journal of Environmental Management**, v. 205, p. 209–214, 2018.
- BITTENCOURT, M. **Churrasco, queijo nobre e até ‘jegueterapia’: Nordeste tenta resolver problema dos jumentos soltos nas estradas**. Disponível em: <<https://www.bbc.com/portuguese/brasil-37478910>>. Acesso em: 19 set. 2019.
- BOARMAN, W. I.; SAZAKI, M. A highway’s road-effect zone for desert tortoises (*Gopherus agassizii*). **Journal of Arid Environments**, v. 65, n. 1, p. 94–101, 2006.
- BRUINDERINK, G. W. T. A. G.; HAZEBROEK, E. Ungulate Traffic Collisions in Europe. **Conservation Biology**, v. 10, n. 4, p. 1059–1067, 1996.
- CAI, X.; WU, Z.; CHENG, J. Using kernel density estimation to assess the spatial pattern of road density and its impact on landscape fragmentation. **International Journal of Geographical Information Science**, v. 27, n. 2, p. 222–230, 2013.
- CARVALHO, N. C. de; BORDIGNON, M. O.; SHAPIRO, J. T. Fast and furious: a look

at the death of animals on the highway MS-080, Southwestern Brazil. **Iheringia. Série Zoologia**, v. 104, n. 1, p. 43–49, 2014. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0073-47212014000100006&lng=en&tlng=en>.

CENTRAL INTELLIGENCE AGENCY - USA. **Country Comparison - Roadways**. Disponível em: <<https://www.cia.gov/library/publications/resources/the-world-factbook/fields/385rank.html>>. Acesso em: 17 ago. 2019.

CHRISTIANSEN, P.; STEEN, K. A.; JØRGENSEN, R. N.; KARSTOFT, H. Automated detection and recognition of wildlife using thermal cameras. **Sensors (Switzerland)**, v. 14, n. 8, p. 13778–13793, 2014.

D'ANGELO, G.; VAN DER REE, R. Use of Reflectors and Auditory Deterrents to Prevent Wildlife-Vehicle Collisions. *In*: **Handbook of Road Ecology**. Chichester, UK: John Wiley & Sons, Ltd, 2015. p. 213–218.

DIAZ-VARELA, E. R.; VAZQUEZ-GONZALEZ, I.; MAREY-PÉREZ, M. F.; ÁLVAREZ-LÓPEZ, C. J. Assessing methods of mitigating wildlife-vehicle collisions by accident characterization and spatial analysis. **Transportation Research Part D: Transport and Environment**, v. 16, n. 4, p. 281–287, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.trd.2011.01.002>>.

DNIT. **Monitoramento e Mitigação de Atropelamentos de Fauna**. [s.l.: s.n.]. Disponível em: <<http://www.dnit.gov.br/download/meio-ambiente/colecao-estrada-verde/monitoramento-e-mitigacao-de-atropelamento-de-fauna.pdf>>.

DODD, C. K.; BARICHIVICH, W. J.; SMITH, L. L. Effectiveness of a barrier wall and culverts in reducing wildlife mortality on a heavily traveled highway in Florida. **Biological Conservation**, v. 118, n. 5, p. 619–631, 2004.

DORNAS, R.; KINDEL, A.; BAGER, A.; FREITAS, S. Avaliação da mortalidade de vertebrados em rodovias no Brasil. *In*: **Ecologia de Estradas: tendências e pesquisas**. Lavras/MG: Universidade Federal de Lavras, 2012. p. 139–152.

EIGENBROD, F.; HECNAR, S. J.; FAHRIG, L. Quantifying the road-effect zone: Threshold effects of a motorway on anuran populations in Ontario, Canada. **Ecology and Society**, v. 14, n. 1, 2009.

ELMEROS, M.; WINBLADH, J. K.; ANDERSEN, P. N.; MADSEN, A. B.; CHRISTENSEN, J. T. Effectiveness of odour repellents on red deer (*Cervus elaphus*) and roe deer (*Capreolus capreolus*): A field test. **European Journal of Wildlife Research**, v. 57, n. 6, p. 1223–1226, 2011.

EPTV. **Capivara causa acidente com 7 mortes em rodovia que liga Araras a Rio Claro em SP**. Disponível em: <<https://oglobo.globo.com/brasil/capivara-causa-acidente-com-7-mortes-em-rodovia-que-liga-araras-rio-claro-em-sp-2844472>>. Acesso em: 18 fev. 2018.

FORMAN, R. T. T. Road ecology: Science and Solutions. **Island Press**, p. 504, 2003. Disponível em: <https://www.researchgate.net/publication/37717562_Road_Ecology_Science_And_Solutions>.

FORMAN, R. T. T.; DEBLINGER, R. D. The Ecological Road-Effect Zone of a Massachusetts (U . S . A .) Suburban Highway. v. 14, n. 1, p. 36–46, 2000.

GDV. **Täg-lich kracht es 720 Mal.** Disponível em: <<https://www.gdv.de/de/themen/news/taeglich-kracht-es-720-mal-25556>>. Acesso em: 10 maio. 2022.

GRACE, M. K.; SMITH, D. J.; NOSS, R. F. Reducing the threat of wildlife-vehicle collisions during peak tourism periods using a Roadside Animal Detection System. **Accident Analysis and Prevention**, v. 109, n. August, p. 55–61, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.aap.2017.10.003>>.

HOTHORN, T.; MÜLLER, J.; HELD, L.; MÖST, L.; MYSTERUD, A. Temporal patterns of deer-vehicle collisions consistent with deer activity pattern and density increase but not general accident risk. **Accident Analysis and Prevention**, v. 81, p. 143–152, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.aap.2015.04.037>>.

HUIJSER, M. P.; DELBORGO ABRA, F.; DUFFIELD, J. W. Mammal road mortality and cost–benefit analyses of mitigation measures aimed at reducing collisions with capybara (*Hydrochoerus hydrochaeris*) in São Paulo state, Brazil. **Oecologia Australis**, v. 17, n. 171, p. 129–146, 2013. Disponível em: <<http://dx.doi.org/10.4257/oeco.2013.1701.11>>.

KEKEN, Z.; KUŠTA, T.; LANGER, P.; SKALOŠ, J. Landscape structural changes between 1950 and 2012 and their role in wildlife–vehicle collisions in the Czech Republic. **Land Use Policy**, v. 59, p. 543–556, 2016.

KUŠTA, T.; KEKEN, Z.; JEŽEK, M.; KŮTA, Z. Effectiveness and costs of odor repellents in wildlife-vehicle collisions: A case study in Central Bohemia, Czech Republic. **Transportation Research Part D: Transport and Environment**, v. 38, p. 1–5, 2015.

LAO, Y.; ZHANG, G.; WU, Y. J.; WANG, Y. Modeling animal-vehicle collisions considering animal-vehicle interactions. **Accident Analysis and Prevention**, v. 43, n. 6, p. 1991–1998, 2011.

MAMMERI, A.; ZHOU, D.; BOUKERCHE, A. Animal-Vehicle Collision Mitigation System for Automated Vehicles. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, v. 46, n. 9, p. 1287–1299, set. 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7378997/>>.

MATA, C.; HERVÁS, I.; HERRANZ, J.; SUÁREZ, F.; MALO, J. E. Are motorway wildlife passages worth building? Vertebrate use of road-crossing structures on a Spanish motorway. **Journal of Environmental Management**, v. 88, n. 3, p. 407–415, 2008.

MUNIAN, Y.; MARTINEZ-MOLINA, A.; ALAMANIOTIS, M. Intelligent System for Detection of Wild Animals Using HOG and CNN in Automobile Applications. In: 2020 11th International Conference on Information, Intelligence, Systems and Applications (IISA, 2020, [...]). IEEE, 2020. p. 1–8.

OLSON, D. D.; BISSONETTE, J. A.; CRAMER, P. C.; GREEN, A. D.; DAVIS, S. T.; JACKSON, P. J.; COSTER, D. C. Monitoring wildlife-vehicle collisions in the Information Age: How smartphones can improve data collection. **Journal of Wildlife Rehabilitation**, v. 34, n. 3, p. 7–16, 2014.

POLÍCIA MILITAR RODOVIÁRIA DO ESTADO DE SÃO PAULO; GRUPO ARTERIS; UNIVERSIDADE DE SÃO PAULO. **PURAA - Plataforma única de resposta à acidentes com animais.** Pirassununga. 2018.

RANGDA, M. B.; HANCHATE, D. B. Animal Detection Using Histogram Oriented

Gradient. **International Journal on Recent and Innovation Trends in Computing and Communication**, v. 2, n. 2, p. 178–183, 2014.

RODRÍGUEZ-MORALES, B.; DÍAZ-VARELA, E. R.; MAREY-PÉREZ, M. F. Spatiotemporal analysis of vehicle collisions involving wild boar and roe deer in NW Spain. **Accident Analysis and Prevention**, v. 60, p. 121–133, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.aap.2013.07.032>>.

ROOPASHREE, Y. A.; BHOOMIKA, M.; PRIYANKA, R.; NISARGA, K.; BEHERA, S. Monitoring the Movements of Wild Animals and Alert System using Deep Learning Algorithm. In: 2021 International Conference on Recent Trends on Electronics, Information, Communication & Technology (RTEICT), 2021, [...]. IEEE, 2021. p. 626–630.

RYTWINSKI, T.; VAN DER REE, R.; CUNNINGTON, G. M.; FAHRIG, L.; FINDLAY, C. S.; HOULAHAN, J.; JAEGER, J. A. G.; SOANES, K.; VAN DER GRIFT, E. A. Experimental study designs to improve the evaluation of road mitigation measures for wildlife. **Journal of Environmental Management**, v. 154, p. 48–64, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.jenvman.2015.01.048>>.

SAUNDERS, S.; MISLIVETS, M.; CHEN, J.; CLELAND, D. Effects of roads on landscape structure within nested ecological units of the Northern Great Lakes Region, USA. **Biological Conservation**, v. 103, n. 2, p. 209–225, 2002. Disponível em: <[citeulike-article-id:3023506%5Cnhttp://dx.doi.org/10.1016/s0006-3207\(01\)00130-6](http://dx.doi.org/10.1016/S0006-3207(01)00130-6)>.

SCHLAGETER, A.; HAAG-WACKERNAGEL, D. Evaluation of an odor repellent for protecting crops from wild boar damage. **Journal of Pest Science**, v. 85, n. 2, p. 209–215, 2012.

SHARMA, S. U.; SHAH, D. J. A Practical Animal Detection and Collision Avoidance System Using Computer Vision Technique. **IEEE Access**, v. 5, n. February 2014, p. 347–358, 2017.

SHUBHAM; REZA, M.; CHOUDHURY, S.; DASH, J. K.; ROY, D. S. An AI-based Real-Time Roadway-Environment Perception for Autonomous Driving. In: 2020 IEEE International Conference on Consumer Electronics - Taiwan (ICCE-Taiwan), 2020, [...]. IEEE, 2020. p. 1–2.

SIELECKI, L. Wildlife Detection Systems, Highway 3, British Columbia: Real-time warning systems for protecting wildlife and drivers. In: TAC 2017: Investing in Transportation: Building Canada's Economy - - 2017 Conference and Exhibition of the Transportation Association of Canada, 2017, Ontario. [...]. Ontario: Transportation Association of Canada (TAC), 2017.

SULLIVAN, J. M. Trends and characteristics of animal-vehicle collisions in the United States. **Journal of Safety Research**, v. 42, n. 1, p. 9–16, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.jsr.2010.11.002>>.

THE DONKEY SANCTUARY. **Feral Donkeys**. Disponível em: <<https://www.thedonkeysanctuary.org.uk/what-we-do/issues/feral-donkeys>>. Acesso em: 12 set. 2019.

TISSIER, M. L.; JUMEAU, J.; CROGUENNEC, C.; PETIT, O.; HABOLD, C.; HANDRICH, Y. An anti-predation device to facilitate and secure the crossing of small mammals in motorway wildlife underpasses. (I) Lab tests of basic design features.

Ecological Engineering, v. 95, p. 738–742, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.ecoleng.2016.07.012>>.

TRANSPORT CANADA SAFETY AND SECURITY. **Overview of Technologies Aimed at Reducing and Preventing Large Animal Strikes Preventing Large Animal Strikes**. [s.l: s.n.].

VAN DER REE, R.; SMITH, D. J.; GRILO, C. The Ecological Effects of Linear Infrastructure and Traffic. *In*: **Handbook of Road Ecology**. [s.l.] John Wiley & Sons, Ltd, 2015. p. 1–9.

VENKATESAN, L.; FAROOQ, S.; IMRAAN, J. Animals and Vehicle Collision Avoidance Using Wireless Sensor Actuator Network. **Ijser.Org**, v. 4, n. 5, p. 1856–1858, 2013. Disponível em: <<http://www.ijser.org/researchpaper/Animals-and-Vehicle-Collision-Avoidance-Using-Wireless-Sensor-Actuator-Network.pdf>>.

ZHOU, D. **Thermal Image-Based Deer Detection to Reduce Accidents Due to Deer-Vehicle Collisions**. [s.l: s.n.]. Disponível em: <<https://conservancy.umn.edu/handle/11299/144870>>.

3. CAPÍTULO 2 – Classificação computacional de animais para sistema de detecção nas rodovias.

3.1. Introdução

A classificação de imagens consiste em organizar um banco de dados de imagens com objetos de interesse devidamente rotulados de forma a registrar tais informações computacionalmente. A tarefa de classificação de imagens envolve o pré-processamento, extração de características, o treinamento e o registro da informação final (KAMAVISDAR; SALUJA; AGRAWAL, 2013).

Algoritmos de classificação e detecção de objetos têm sido aplicados em diversas áreas da ciência e indústria. Por exemplo, para a contagem de células (LOH *et al.*, 2021), na medicina em diagnóstico de imagens (ABEDINI *et al.*, 2015) e controle de qualidade na indústria (AHMAD; RAHIMI, 2022). Tais algoritmos também podem ser aplicados para ajudar na mitigação de acidentes rodoviários com animais.

Vários estudos demonstram que as colisões entre veículos e animais são um problema global. Os acidentes mais graves envolvem animais de maior tamanho corporal de espécies nativas e naturalizadas, como suínos selvagens e diferentes espécies de veados na Europa e nos Estados Unidos (HOTHORN *et al.*, 2015; PYNN; PYNN, 2004; RODRÍGUEZ-MORALES; DÍAZ-VARELA; MAREY-PÉREZ, 2013; SULLIVAN, 2011), lobos no leste do Canadá (LESMERISES; DUSSAULT; ST-LAURENT, 2013), elefantes na Malásia (WADEY *et al.*, 2018), camelos em países Árabes (AL-GHAMDI; ALGADHI, 2004; AL-SEBAI; AL-ZAHRANI, 1997), e jumentos no Nordeste do Brasil (PEROZZI GAMEIRO; CLANCY; ZANELLA, 2022).

Esses acidentes são responsáveis por lesões e mortes de pessoas e animais todos os anos. Além disso, as perdas monetárias chegam a bilhões de dólares (BRUINDERINK; HAZEBROEK, 1996; HUIJSER; DELBORGO ABRA; DUFFIELD, 2013; OLSON *et al.*, 2014; SULLIVAN, 2011). Um estudo anterior estabeleceu que, de 2010 a 2016, ocorreram 25.075 acidentes envolvendo fauna nas rodovias federais brasileiras, resultando em 613 óbitos humanos registrados, 2.933 ferimentos graves e 7.559 ferimentos leves (TAVARES *et al.*, 2017).

Para reduzir os acidentes, várias ações mitigadoras têm sido propostas. A infraestrutura de passagens inferiores e superiores (DODD; BARICHIVICH; SMITH,


2004; TISSIER *et al.*, 2016), dispositivos eletrônicos com sensores de presença (ABRA, 2017; GRACE; SMITH; NOSS, 2017) e dispositivos de iluminação e odor (BÍL *et al.*, 2018; D'ANGELO; VAN DER REE, 2015; KUŠTA *et al.*, 2015) são alguns exemplos.

3.2. Imagem digital

Uma imagem digital é uma representação discreta ² de dados que processam informações espaciais (plano) e de intensidade (cor/luminosidade) (SOLOMON; BRECKON, 2013a). Imagens digitais coloridas são transcritas computacionalmente como matrizes de três dimensões que alocam três valores numéricos para cada pixel de acordo com o *espaço de cores* (PETERS, 2014; SOLOMON; BRECKON, 2013b).

Quando no formato bidimensional em escala de cinza (Figura 1), pode ser representada por uma função de intensidade de luz $I(x,y)$, onde x e y são coordenadas espaciais (linhas e colunas), e o valor de I é proporcional à intensidade de luz captada por um sensor óptico, gravada em cada ponto (*pixel*³) (PETERS, 2017; SOLOMON; BRECKON, 2013a).

Figura 1 – Exemplo de imagem digital em escala de cinza.



Fonte: <https://towardsdatascience.com/understanding-images-with-skimage-python-b94d210afd23>. Acesso em 13/02/2020. Cada ponto (x,y) na imagem é formado por um valor de intensidade de luz (I).

² “Discreta” aqui se refere à característica matemática de funções não variáveis.

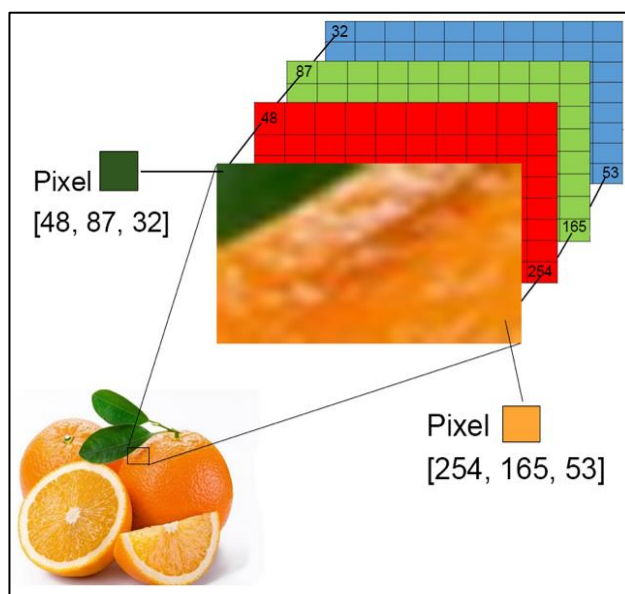
³ Um pixel é o menor elemento de uma imagem digital.

3.2.1. Espaço de cores

As cores são organizadas de acordo com um padrão denominado *espaço de cores* e a maneira pela qual uma cor é representada é chamada de *modelo de cores*. O *modelo de cores* descreve como as cores podem ser representadas, matematicamente, por um conjunto de números. Verificou-se que são necessários três diferentes estímulos para gerar toda a gama de cores visíveis ao olho humano (MAXWELL, 1861; PEDDIE, 1925; YOUNG, 1801), por isso a maioria dos padrões de *espaço de cores* possuem 3 combinações de valores. Com a evolução da ciência nesta área, diversos padrões de *espaço de cores* foram estabelecidos (ex. *XYZ*, *RGB*, *LAB*, *HSV*, etc) (GEVERS *et al.*, 2012; PETERS, 2014; SINGH, 2019).

Por exemplo, uma imagem digital no espaço de cores RGB é gerada matematicamente por uma matriz de três dimensões, onde os valores de cada pixel são formados pelo conjunto de 3 valores intervalo de 0 a 255 (8 bits). Tal composição pode ser melhor compreendida na Figura 2.

Figura 2 Composição de uma imagem digital RGB



Fonte: adaptado de <https://www.geeksforgeeks.org/matlab-rgb-image-representation/>. Acesso em 10/01/2020. Cada pixel de uma imagem digital RGB é formado a partir dos valores do pixel em cada um dos planos componentes. No detalhe, dois exemplos da composição numérica dos pixels verde e laranja.

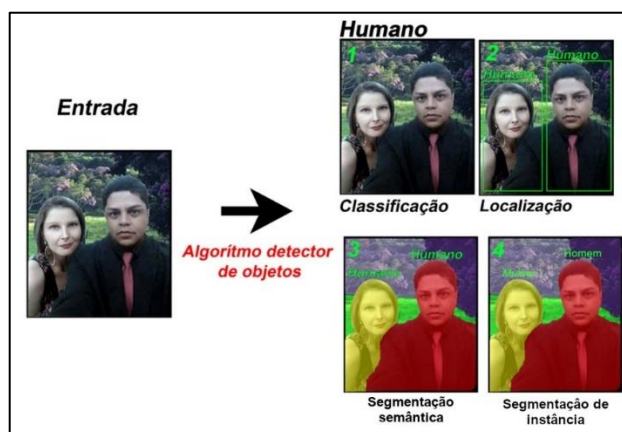
3.3. Tarefas de visão computacional

Na visão computacional, a terminologia *Detecção de Objetos* pode ser utilizada para uma área de pesquisa que lida com as tarefas de classificação, localização e segmentação de objetos presentes em imagens. No entanto, perceba-se que o termo é utilizado também para se referir a tarefa de localização, como pode ser observado em algumas revisões (LIU *et al.*, 2020; VERSCHAE; RUIZ-DELSOLAR, 2015; XIAO *et al.*, 2020; ZHAO *et al.*, 2019).

O Dicionário Houaiss da Língua Portuguesa (HOUAISS; VILLAR, 2001), apresenta o significado de detectar: *revelar, tornar perceptível ao ouvido ou à vista, perceber (um objeto buscado) ou com ele estabelecer contato por meio visual, ou de radar, de sonar, de rádio*. Percebe-se que, apesar de parecer confuso, utilizar o termo *detecção de objetos* para definir uma das tarefas específicas não é incorreto.

A Figura 3 apresenta as tarefas de detecção mais comuns realizadas por algoritmos de visão computacional.

Figura 3 – Tarefas de detecção realizadas por algoritmos de visão computacional.



Fonte: autoria própria. **1. Classificação** – Informar qual é a classe do objeto; **2. Localização** – informar a posição de cada objeto na imagem; **3. Segmentação semântica** – Informar qual é a classe de cada pixel; **4. Segmentação de instância** – informar qual é a classe de cada pixel e as instâncias de cada objeto.

Sistemas de visão computacional para detecção de animais têm sido aplicados para diferentes propósitos (CHRISTIANSEN *et al.*, 2014; RANGDA; HANCHATE, 2014; SHARMA; SHAH, 2017). Considerando atividades de transporte, sistemas de detecção de animais por visão computacional foram desenvolvidos para

carros (AGRAWAL; SINGH, 2020; REPORTS, 2020) e redes ferroviárias (YE *et al.*, 2018; YU; YANG; WEI, 2018). Conforme a evolução do poder computacional e das redes neurais convolucionais, os algoritmos agora são capazes de realizar a detecção de objetos em tempo real com o uso de câmeras de vídeo. Por exemplo, o Japão está usando cerca de 13.000 câmeras de vídeo e inteligência artificial para monitorar rodovias para detectar problemas de tráfego e aumentar a segurança (FUJITSU, 2019).

Um vídeo é uma sequência de imagens estáticas em movimento definido de acordo a resolução temporal em *quadros por segundo (qps)*. Assim, é importante que os algoritmos de detecção de objetos usados para esta finalidade sejam rápidos para computar muitas detecções por segundo. Em meados da década passada, o desenvolvimento de algoritmos detectores de objetos como o *Yolo* (REDMON *et al.*, 2016), *Mask R-CNN* (HE *et al.*, 2017) e o *Single Shot Multibox Detector* (LIU *et al.*, 2016), tornaram a detecção em tempo real possível de ser realizada com velocidade acima de 10 quadros por segundo. Aqui descrevemos um sistema desenvolvido para detectar a presença de animais em rodovias usando visão computacional e aprendizado de máquina.

3.4. Materiais e métodos

Este projeto foi analisado e aprovado pelo Comitê de Ética da Faculdade de Medicina Veterinária e Zootecnia sob o número CEUA N° 4526170418.

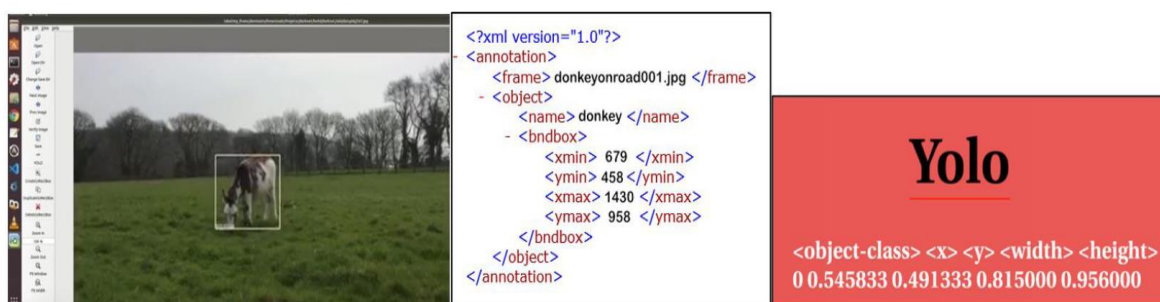
3.4.1. Treinamento do modelo

Para o treinamento do modelo, 2.000 imagens de capivaras e equinos (jumentos e cavalos) foram baixadas do site Google Images, 1.000 imagens de cada grupo, usando uma extensão de download em lote (FATKUN BATCH DOWNLOAD IMAGE – GOOGLE CHROME, 2019). Os objetos de interesse (animais) foram rotulados em cada imagem utilizando o software *Labellmg* (TZUTALIN, 2015) sendo definido o nome de classe *capivara* para as capivaras e nome de classe *equidae* para equinos. O processo de rotulagem para detecção de objetos consiste em delimitar os pixels que representam o objeto de interesse na imagem e atribuir a ele um nome de

classe. Depois de desenhar uma caixa delimitadora ao redor do objeto, o software de etiqueta grava as coordenadas de pixel do objeto em um arquivo externo.

A Figura 4 apresenta uma visualização do processo de rotulagem e coordena o conteúdo do arquivo gerado.

Figura 4– Rotulagem do objeto de interesse em uma imagem.



Fonte: autoria própria. Após desenhar uma caixa delimitadora ao redor do objeto de interesse (quadro esquerdo), o software de rotulagem gera um arquivo com suas coordenadas. O formato do arquivo depende dos requisitos do algoritmo escolhido. Por exemplo, o quadro central apresenta o conteúdo de um arquivo de coordenadas no formato xml (*Extensible Markup Language*) e o quadro da direita no formato txt (*Text*).

O conjunto de dados foi dividido em dois grupos: treinamento ($n = 1800$) e validação ($n = 200$). A rede neural convolucional artificial (convnet) Yolov4 (BOCHKOVSKIY; WANG; LIAO, 2020) foi selecionada para o treinamento de classificação. O software utilizado para realizar e configurar o treinamento foi o *Darknet* (BOCHKOVSKIY, 2019^a). Foram realizadas duas sessões de treinamento diferentes para até 8.000 iterações para cada modelo. A versão completa, que denominamos Yolov4 e uma versão mais leve denominada Yolov4-tiny, utilizando modelos pré-treinados (BOCHKOVSKIY, 2018). A Yolov4 foi treinada no ambiente de computação em nuvem Google Colab (GOOGLE, 2020) que fornece uma GPU Nvidia Tesla k80 de 24GB de memória RAM. A Yolov4-tiny foi treinada em um computador desktop (AMD Ryzen 2700x, 16GB RAM, GPU Nvidia GTX 1050ti 4GB), até 8.000 iterações para cada modelo.

3.4.2. Avaliação da performance

Após o treinamento, 147 imagens foram usadas para avaliar o desempenho do detector. Estas imagens não foram utilizadas no treinamento e foram rotuladas usando o software *Labellmg* (TZUTALIN, 2015). Esta rotulagem é realizada para gerar os arquivos da verdade básica (*ground-truth*) que armazenam as coordenadas da localização do objeto de interesse em cada imagem. Os resultados da detecção são então comparados com estas coordenadas definidas nos arquivos da verdade básica.


Os resultados comparativos entre as detecções e as coordenadas de referência foram computados com o software *mAP* (CARTUCHO, 2015; CARTUCHO; VENTURA; VELOSO, 2018) seguindo as métricas definidas no *Pascal VOC Challenge 2012* (EVERINGHAM; WINN, 2012). Além dos gráficos de resultados de precisão, o software *mAP* registra caixas delimitadoras comparativas em cada imagem para análise visual. Configuramos o software *mAP* para apresentar caixas delimitadoras verde no caso de detecções verdadeiro-positivas, vermelhas como falso-positivos e amarelas para objetos não detectados (falso-negativos). As caixas delimitadoras de verdade básica são apresentadas em azul.

Os resultados da detecção são classificados por nível de confiança decrescente e comparados com os dados de referência (*ground-truth*). O resultado da detecção é considerado positivo quando o valor de Interseção sobre União (IoU) for maior ou igual a 0,1 ($\text{IoU} \geq 10\%$). Várias detecções para o mesmo objeto foram computadas como falso-positivos. A IoU é calculada pela Equação 1:

$$\text{IoU} = \frac{B_p \cap B_{gt}}{B_p \cup B_{gt}} \geq 0,1 \quad (1)$$

, onde B_p é a área da caixa delimitadora prevista e B_{gt} a área da caixa delimitadora definida na verdade básica (*ground-truth*). A Figura 5 fornece uma explicação visual da IoU.

Figura 5 – Intersecção sobre União.



Fonte: autoria própria. Intersecção sobre União é uma métrica de avaliação usada para medir a precisão de um detector de objetos em um conjunto de dados específico. No numerador, a área de sobreposição entre a caixa delimitadora prevista (verde) e a caixa delimitadora de referência (azul) é calculada. O denominador é a área de união, que é a soma da área de ambas as caixas delimitadoras.

A partir dos resultados de IoU , é calculada uma curva de precisão/recall com o valor de precisão diminuído monotonamente definindo a precisão para recall r para a precisão máxima obtida para qualquer recall $r' > r$. A precisão média (PM) para cada classe é calculada como a área sob esta curva por integração numérica. Nenhuma aproximação está envolvida, pois a curva é constante por partes. A precisão do modelo (ambas as classes) é apresentada como *mean average precision (mAP)*, calculada pela média de todos os valores de precisão média (PM).

O valor de acurácia (Ac) dos modelos é calculado de acordo com a Equação 2:

$$Ac = \frac{TP_{det}}{Gt + FP_{det}} \quad (2)$$


onde TP_{det} é o número total de verdadeiro-positivos detectados, Gt é o número total de objetos nos dados de verdade básica e FP_{det} é o número total de falsos positivos detectados.

O teste de velocidade foi realizado com vídeos gravados para capivaras e jumentos em um computador desktop com GPU GTX 1050Ti e são apresentados em quadros por segundo.

3.4.3. Sistema embarcado

O sistema embarcado é composto por uma câmera de vídeo, uma unidade de processamento Nvidia Jetson TX2, uma placa de trânsito com sinal luminoso adaptado e uma fonte de alimentação por painel solar. Para a função de alerta luminoso, foi feita uma modificação no algoritmo `darknet_video.py` (BOCHKOVSKIY, 2020) utilizando a biblioteca PyFirmata (BRUIJN, 2019), para estabelecer comunicação com uma placa de desenvolvimento Arduino 2560. Durante os testes em arquivos de vídeo, o funcionamento do alerta de luz foi observado experimentalmente usando diodos emissores de luz (LED – *Light Emitting Diode*). A Figura 6 apresenta o esquema de montagem e a Figura 7 uma visão virtual do sistema proposto.

Figura 6 – Montagem do sistema.



Fonte: autoria própria.

Figura 7 – Virtualização do sistema de detecção nas rodovias.




Fonte: autoria própria. Criado com o software Autodesk® Fusion 360 (licença educacional).

3.5. Resultados e discussão

Os resultados comparativos de detecção são apresentados na Figura 8.

Figura 8 – Resultados comparativos de detecção entre os modelos Yolov4 e Yolov4-tiny.




Fonte: própria autoria. **VP** – verdadeiro positivos; **FP** – falso positivos; **FN** – Falso negativos; Gt capivara – número de objetos na verdade básica para a classe *capivara* (*ground truth*). Gt equidae – número de objetos na verdade básica para a classe *equidae* (*ground truth*). Dados gerados com o software *mAP* ($IoU \geq 0,1$) (CARTUCHO, 2015).

Considerando ambos os modelos, a classe *capivara* apresentou maior número de falsos positivos ($n = 49$) em relação a classe equídeos ($n = 31$). Isso pode estar relacionado ao maior número de indivíduos no grupo e que podem não ter sido rotulados nos dados da verdade básica, mas foram detectados durante os testes.

Podemos considerar objetos não detectados o principal problema de um sistema de alerta para a presença de animais nas rodovias. Neste caso, a classe *equidae* apresentou maior número de objetos não detectados (40) em comparação com a classe *capivara* (7). No entanto, analisando as detecções quadro a quadro, na maioria das imagens com objetos não detectados (falsos negativos – FNs), há também detecções de VP. Assim, do ponto de vista de alertar para a presença de animais na rodovia, tais ocorrências em tempo real não resultariam em problema de ausência de alerta se houvesse pelo menos uma detecção positiva no local. Além disso, é possível verificar que a maioria das detecções de falso-positivo (FP) ocorreu em quadros com detecções de verdadeiro-positivo (VP). Dois exemplos dessas ocorrências são apresentados na Figura 9.

Figura 9 – Exemplos de falso positivos e falso negativos (objetos não detectados).



Fonte: autoria própria. Caixas delimitadoras verdes = VP (verdadeiro positivos); vermelhas = FP (falso positivos); amarelas = FN (falso negativos, não detectado). Gerado com o software mAP (CARTUCHO, 2015).


Diferentes desafios, como oclusão, condições variadas de iluminação, posição espacial e escala, devem ser tratados pelo algoritmo durante a detecção de objetos. Os falsos positivos geralmente ocorrem devido a erro de localização, confusão com o plano de fundo ou objetos semelhantes e uma quantidade insuficiente de sobreposição (IoU). Um falso negativo pode ser resultado de baixa confiança atribuída ao objeto, oclusões, truncamento, tamanho pequeno ou ponto de vista incomum (HOIEM; CHODPATHUMWAN; DAI, 2012; PATHAK *et al.*, 2018; PONCE *et al.*, 2006).

A métrica usada nos desafios de detecção de objetos para avaliar o desempenho do modelo é baseada na localização do objeto na imagem de acordo com o limite de *IoU* (COCO, 2020; PASCAL VOC PROJECT, 2012; RUSSAKOVSKY *et al.*, 2015). Nesta avaliação foi definido um valor menor ($IoU \geq 0,1$) ao recomendado no *Pascal VOC Challenge 2012* ($IoU \geq 0,5$) de forma a aumentar a sensibilidade. Assim, detecções de verdadeiro-positivos são computadas mesmo quando apenas parte do corpo do animal é detectada. Posteriormente, a métrica de avaliação de desempenho do sistema deve ser modificada para considerar como verdadeiro positivo todo o quadro caso algum objeto de interesse seja detectado.

Erros de detecção podem ser minimizados ajustando os hiperparâmetros de treinamento (ancoragem, resolução, otimizadores), normalizando o conjunto de dados, usando amostras negativas e aumentando o volume de amostras por classe (ALSHALALI; JOSYULA, 2018; CHU *et al.*, 2016). Além disso, o Yolov4 apresenta uma lista desses ajustes que podem ser configurados para melhorar a precisão de detecção de modelos personalizados (BOCHKOVSKIY, 2019b).

Ambos os modelos apresentaram desempenho de precisão semelhante, com uma pequena vantagem para a versão completa do Yolov4. Os resultados da precisão média por classe (AP) e a precisão média do detector (mAP) de cada modelo são apresentados na Figura 10.

Figura 10 – Resultados comparativos de precisão dos modelos Yolov4 e Yolov4-tiny.



Fonte: autoria própria. mAP – *mean average precision* dos modelos. PM – precisão média por classe nos modelos Yolov4 e Yolov4-tiny. Dados gerados com o software mAP (IoU $\geq 0,1$) (CARTUCHO, 2015).

Considerando a métrica de avaliação do desempenho adotada, os resultados de precisão para ambas as classes, em ambos os modelos, foram satisfatórios (84,87% e 79,87% para Yolov4 e Yolov4-tiny respectivamente). Analisando o conjunto de dados utilizado para o treinamento, embora o mesmo número de imagens tenha sido selecionado para cada classe, um número maior de objetos da classe capivara ($n = 2412$) foram rotulados comparativamente aos objetos da classe equídeos ($n = 1541$). Isso poderia explicar as diferenças nos resultados de detecção entre as classes. Uma das etapas mais importantes para a classificação de imagens é o gerenciamento dos dados para o aprendizado (MUNAPPY *et al.*, 2019). Durante os testes em uma rodovia, é possível aumentar o conjunto de dados obtendo novas imagens e promovendo o aprendizado reforçado. Além disso, outras espécies de animais podem ser adicionadas ao treinamento de acordo com a necessidade local.

Embora exista muitos conjuntos de dados disponíveis para download na internet (ABU-EL-HAIJA *et al.*, 2016; FEI-FEI; DENG; LI, 2010; HUANG *et al.*, 2007; KHOSLA *et al.*, 2011; LIN *et al.*, 2014), encontrar um grande número de imagens para classes específicas é um desafio significativo. Durante o treinamento, os dados aprendidos são armazenados em arquivos denominados pesos (*weights*). Os modelos

foram treinados a partir de pesos pré-treinados, uma técnica chamada de aprendizado por transferência. O aprendizado de transferência é o uso de informações de um domínio e sua transferência para outro domínio relacionado. Essa técnica é usada quando a construção do conjunto de dados pode ser difícil ou cara (WEISS; KHOSHGOFTAAR; WANG, 2016; ZHUANG *et al.*, 2019).

Embora tenha sido demonstrado que resultados preditivos podem ser obtidos com alta precisão em um modelo de classificação de imagens sem o uso de pesos pré-treinados (He *et al.*, 2019), um grande volume de amostras foi usado para treinamento e validação (35.000 imagens para treinamento e 5.000 imagens para validação). Em uma avaliação de detecção de objetos utilizando um número de imagens semelhantes ao apresentado neste trabalho, ocorreu excesso de ajuste no modelo devido ao número limitado de amostras, reduzindo o valor médio de precisão nas previsões. Além disso, o aprendizado de transferência exigiu menos tempo de espera para convergir os pesos para um ponto assintótico, e um número consideravelmente menor de amostras pode ser usado para treinamento (CHOLLET, 2016; RAWAT; WANG, 2017).

Os resultados de velocidade foram 40 qps usando Yolo4-tiny e 28 qps usando Yolov4. Durante os testes de vídeo, o alerta luminoso pôde ser verificado por um *LED* branco para classe equídeos e um *LED* vermelho para classe capivara conforme apresentado na Figura 11. As diferentes cores do alerta luminoso utilizadas apenas em caráter experimental.

Figura 11 – Alerta luminoso para detecções positivas.



Fonte: autoria própria. **Imagem da esquerda** – um led branco pisca durante a detecção da classe *equidae*. **Imagem da direita** – um led vermelho pisca durante a detecção da classe *capivara*.

3.6. Conclusões

Os modelos apresentaram alta precisão na detecção dos objetos testados. Apesar de ambas as classes apresentarem altos níveis de detecção de verdadeiros positivos, a classe *equidae* apresentou maior número de objetos não detectados (falsos negativos) em comparação com a classe *capivara*. A questão relacionada aos objetos não detectados é a mais importante a ser considerada em um sistema de prevenção de colisões em rodovias e precisa ser ajustada adequadamente.

Os resultados de precisão para a classe *equidae* foram inferiores aos da classe *capivara* devido ao menor número de amostras que foram utilizadas para classificação no treinamento. No entanto, os testes foram realizados em imagens estáticas e arquivos de vídeo. Ajustes no conjunto de dados para novos treinamentos e experimentação em situações de tempo real poderão colaborar para diminuir os erros de detecção.

Outras espécies animais poderão ser incluídas e testes em tempo real em vários níveis de luz e visibilidade serão realizados na pista experimental localizada próximo ao Departamento de Medicina Veterinária Preventiva e Saúde Animal (Universidade de São Paulo - Pirassununga/SP).

O sistema proposto neste trabalho tem o potencial de contribuir para a melhoria do bem-estar animal e da segurança viária devido a acidentes envolvendo animais.

3.7. REFERÊNCIAS

- ABEDINI, M.; CODELLA, N. C. F.; CONNELL, J. H.; GARNAVI, R.; MERLER, M.; PANKANTI, S.; SMITH, J. R.; SYEDA-MAHMOOD, T. A generalized framework for medical image classification and recognition. **IBM Journal of Research and Development**, v. 59, n. 2/3, p. 1:1-1:18, 2015. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7094962>>.
- ABRA, F. D. **Desenvolvimento de sistema de detecção animal antiatropelamento em rodovias - “Passa Bicho”**. Disponível em: <<http://www.bv.fapesp.br/pt/auxilios/93334/desenvolvimento-de-sistema-de-deteccao-animal-antiatropelamento-em-rodovias-passa-bicho/>>. Acesso em: 12 mar. 2018.
- ABU-EL-HAIJA, S.; KOTHARI, N.; LEE, J.; NATSEV, P.; TODERICI, G.; VARADARAJAN, B.; VIJAYANARASIMHAN, S. YouTube-8M: A Large-Scale Video Classification Benchmark. 27 set. 2016. Disponível em: <<http://arxiv.org/abs/1609.08675>>.
- AGRAWAL, R.; SINGH, N. Lane Detection and Collision Prevention System for Automated Vehicles. (B. Iyer, A. M. Rajurkar, V. Gudivada) In: Applied Computer Vision and Image Processing, 2020, Singapore. [...]. Singapore: Springer Singapore, 2020. p. 46–59.
- AHMAD, H. M.; RAHIMI, A. Deep learning methods for object detection in smart manufacturing: A survey. **Journal of Manufacturing Systems**, v. 64, p. 181–196, jul. 2022. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0278612522001066>>.
- AL-GHAMDI, A. S.; ALGADHI, S. A. Warning signs as countermeasures to camel-vehicle collisions in Saudi Arabia. **Accident Analysis and Prevention**, v. 36, n. 5, p. 749–760, 2004.
- AL-SEBAI, M. W.; AL-ZAHRANI, S. Cervical spinal injuries caused by collision of cars with camels. **Injury**, v. 28, n. 3, p. 191–194, 1997.
- ALSHALALI, T.; JOSYULA, D. Fine-tuning of pre-trained deep learning models with extreme learning machine. **Proceedings - 2018 International Conference on Computational Science and Computational Intelligence, CSCSI 2018**, p. 469–473, 2018.
- BÍL, M.; ANDRÁŠIK, R.; BARTONIČKA, T.; KŘIVÁNKOVÁ, Z.; SEDONÍK, J. An evaluation of odor repellent effectiveness in prevention of wildlife-vehicle collisions. **Journal of Environmental Management**, v. 205, p. 209–214, 2018.
- BOCHKOVSKIY, A. **Yolo pre-trained models**. Disponível em: <<https://github.com/AlexeyAB/darknet#pre-trained-models>>. Acesso em: 15 fev. 2020.
- BOCHKOVSKIY, A. **Darknet - Yolo-V4 and Yolo-v3/v2 for Windows and Linux**. Disponível em: <<https://github.com/AlexeyAB/darknet>>. Acesso em: 14 jun. 2019a.
- BOCHKOVSKIY, A. **How to improve object detection**. Disponível em: <<https://github.com/AlexeyAB/darknet#how-to-improve-object-detection>>. Acesso em: 20 maio. 2020b.
- BOCHKOVSKIY, A. **darknet_video.py**. Disponível em: <https://github.com/AlexeyAB/darknet/blob/master/darknet_video.py>. Acesso em: 15 jul. 2020.

- BOCHKOVSKIY, A.; WANG, C.-Y.; LIAO, H.-Y. M. YOLOv4: Optimal Speed and Accuracy of Object Detection. 2020. Disponível em: <<http://arxiv.org/abs/2004.10934>>.
- BRUIJN, T. de. **PyFirmata**. Disponível em: <<https://github.com/tino/pyFirmata>>. Acesso em: 20 jul. 2020.
- BRUINDERINK, G. W. T. A. G.; HAZEBROEK, E. Ungulate Traffic Collisions in Europe. **Conservation Biology**, v. 10, n. 4, p. 1059–1067, 1996.
- CARTUCHO, J. **mAP**. Disponível em: <<https://github.com/Cartucho/mAP>>. Acesso em: 18 set. 2019.
- CARTUCHO, J.; VENTURA, R.; VELOSO, M. Robust Object Recognition Through Symbiotic Deep Learning In Mobile Robots. In: 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2018, [...]. IEEE, 2018. p. 2336–2341.
- CHOLLET, F. **Building powerful image classification models using very little data**. Disponível em: <<https://blog.keras.io/building-powerful-image-classification-models-using-very-little-data.html>>. Acesso em: 20 maio. 2020.
- CHRISTIANSEN, P.; STEEN, K. A.; JØRGENSEN, R. N.; KARSTOFT, H. Automated detection and recognition of wildlife using thermal cameras. **Sensors (Switzerland)**, v. 14, n. 8, p. 13778–13793, 2014.
- CHU, B.; MADHAVAN, V.; BEIJBOM, O.; HOFFMAN, J.; DARRELL, T. Best practices for fine-tuning visual classifiers to new domains. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, v. 9915 LNCS, p. 435–442, 2016.
- COCO. **COCO 2020 Object Detection Task**. Disponível em: <<https://cocodataset.org/#detection-2020>>. Acesso em: 15 abr. 2020.
- D'ANGELO, G.; VAN DER REE, R. Use of Reflectors and Auditory Deterrents to Prevent Wildlife-Vehicle Collisions. In: **Handbook of Road Ecology**. Chichester, UK: John Wiley & Sons, Ltd, 2015. p. 213–218.
- DODD, C. K.; BARICHIVICH, W. J.; SMITH, L. L. Effectiveness of a barrier wall and culverts in reducing wildlife mortality on a heavily traveled highway in Florida. **Biological Conservation**, v. 118, n. 5, p. 619–631, 2004.
- EVERINGHAM, M.; WINN, J. **The PASCAL Visual Object Classes Challenge 2012 (VOC2012) Development Kit**. Disponível em: <http://host.robots.ox.ac.uk/pascal/VOC/voc2012/devkit_doc.pdf>. Acesso em: 13 abr. 2020.
- FATKUN BATCH DOWNLOAD IMAGE - GOOGLE CHROME. **Fatkun Batch Download Image - Chrome extension**[s.d.] Disponível em: <<https://chrome.google.com/webstore/detail/fatkun-batch-download-ima/nnjjahlikiabnchcpehpcpkdeckfgnohf>>.
- FEI-FEI, L.; DENG, J.; LI, K. ImageNet: Constructing a large-scale image database. **Journal of Vision**, v. 9, n. 8, p. 1037–1037, 2010.
- FUJITSU. **How Fujitsu is using AI to make Japan's roads and rivers safe**. Disponível em: <<https://blog.global.fujitsu.com/fgb/2019-11-20/how-fujitsu-is-using-ai-to-make-japans-roads-and-rivers-safer/#:~:text=Today%2C in order to monitor,national highways across the country.>>. Acesso em: 21 set. 2020.
- GEVERS, T.; GIJSENIJ, A.; WEIJER, J. van de; GEUSEBROEK, J.-M. Color Spaces. In: **Color in Computer Vision: Fundamentals and Applications**. 1. ed. New Jersey:

John Wiley & Sons, Inc., 2012. p. 36–44.

GOOGLE. **Colaboratory**. Disponível em: <<https://colab.research.google.com/>>. Acesso em: 12 fev. 2020.

GRACE, M. K.; SMITH, D. J.; NOSS, R. F. Reducing the threat of wildlife-vehicle collisions during peak tourism periods using a Roadside Animal Detection System. **Accident Analysis and Prevention**, v. 109, n. August, p. 55–61, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.aap.2017.10.003>>.

HE, K.; GKIOXARI, G.; DOLLAR, P.; GIRSHICK, R. Mask R-CNN. **Proceedings of the IEEE International Conference on Computer Vision**, v. 2017- Octob, p. 2980–2988, 2017.

HOIEM, D.; CHODPATHUMWAN, Y.; DAI, Q. Diagnosing error in object detectors. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, v. 7574 LNCS, n. PART 3, p. 340–353, 2012. Disponível em: <https://dhoiem.web.engr.illinois.edu/publications/eccv2012_detanalysis_derek.pdf>.

HOTHORN, T.; MÜLLER, J.; HELD, L.; MÖST, L.; MYSTERUD, A. Temporal patterns of deer-vehicle collisions consistent with deer activity pattern and density increase but not general accident risk. **Accident Analysis and Prevention**, v. 81, p. 143–152, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.aap.2015.04.037>>.

HOUAISS, A.; VILLAR, M. de S. **Dicionário Houaiss da Língua Portuguesa**. Rio de Janeiro: Objetiva, 2001. 2925 p.

HUANG, G. B.; RAMESH, M.; BERG, T.; LEARNED-MILLER, E. **Labeled Faces in the Wild: A database for studying face recognition in unconstrained environments** Technical Report 07-49. [s.l: s.n.].

HUIJSER, M. P.; DELBORGO ABRA, F.; DUFFIELD, J. W. Mammal road mortality and cost–benefit analyses of mitigation measures aimed at reducing collisions with capybara (*Hydrochoerus hydrochaeris*) in São Paulo state, Brazil. **Oecologia Australis**, v. 17, n. 171, p. 129–146, 2013. Disponível em: <<http://dx.doi.org/10.4257/oeco.2013.1701.11>>.

KAMAVISDAR, P.; SALUJA, S.; AGRAWAL, S. A survey on image classification approaches and techniques. **International Journal of Advanced ...**, v. 2, n. 1, p. 1005–1009, 2013. Disponível em: <<http://ijarcce.com/upload/january/22-A Survey on Image Classification.pdf>>.

KHOSLA, A.; JAYADEVAPRAKASH, N.; YAO, B.; FEI-FEI, L. Novel dataset for fine-grained image categorization. **Proc. IEEE Conf. Comput. Vision and Pattern Recognition**, 2011. Disponível em: <<http://vision.stanford.edu/aditya86/ImageNetDogs/>>.

KUŠTA, T.; KEKEN, Z.; JEŽEK, M.; KŮTA, Z. Effectiveness and costs of odor repellents in wildlife-vehicle collisions: A case study in Central Bohemia, Czech Republic. **Transportation Research Part D: Transport and Environment**, v. 38, p. 1–5, 2015.

LESMERISES, F.; DUSSAULT, C.; ST-LAURENT, M. H. Major roadwork impacts the space use behaviour of gray wolf. **Landscape and Urban Planning**, v. 112, n. 1, p. 18–25, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.landurbplan.2012.12.011>>.

LIN, T. Y.; MAIRE, M.; BELONGIE, S.; HAYS, J.; PERONA, P.; RAMANAN, D.; DOLLÁR, P.; ZITNICK, C. L. Microsoft COCO: Common objects in context. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial**

Intelligence and Lecture Notes in Bioinformatics), v. 8693 LNCS, n. PART 5, p. 740–755, 2014.

LIU, L.; OUYANG, W.; WANG, X.; FIEGUTH, P.; CHEN, J.; LIU, X.; PIETIKÄINEN, M. Deep Learning for Generic Object Detection: A Survey. **International Journal of Computer Vision**, v. 128, n. 2, p. 261–318, 2020. Disponível em: <<https://doi.org/10.1007/s11263-019-01247-4>>.

LIU, W.; ANGUELOV, D.; ERHAN, D.; SZEGEDY, C.; REED, S.; FU, C. Y.; BERG, A. C. SSD: Single shot multibox detector. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, v. 9905 LNCS, p. 21–37, 2016.

LOH, D. R.; YONG, W. X.; YAPETER, J.; SUBBURAJ, K.; CHANDRAMOHANADAS, R. A deep learning approach to the screening of malaria infection: Automated and rapid cell counting, object detection and instance segmentation using Mask R-CNN. **Computerized Medical Imaging and Graphics**, v. 88, p. 101845, mar. 2021. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0895611120301403>>.

MAXWELL, J. C. On the Theory of Three Primary Colours. *In*: NIVEN, W. D. **The Scientific Papers of James Clerk Maxwell**. Cambridge: Cambridge University Press, 1861. p. 445–450.

MUNAPPY, A.; BOSCH, J.; OLSSON, H. H.; ARPTEG, A.; BRINNE, B. Data Management Challenges for Deep Learning. **Proceedings - 45th Euromicro Conference on Software Engineering and Advanced Applications, SEAA 2019**, n. August, p. 140–147, 2019.

OLSON, D. D.; BISSONETTE, J. A.; CRAMER, P. C.; GREEN, A. D.; DAVIS, S. T.; JACKSON, P. J.; COSTER, D. C. Monitoring wildlife-vehicle collisions in the Information Age: How smartphones can improve data collection. **Journal of Wildlife Rehabilitation**, v. 34, n. 3, p. 7–16, 2014.

PASCAL VOC PROJECT. **The PASCAL Visual Object Classes Challenge 2012 - 4 Detection Task**. Disponível em: <http://host.robots.ox.ac.uk/pascal/VOC/voc2012/html/doc/devkit_doc.html#SECTION00050000000000000000>.

PATHAK, A. R.; PANDEY, M.; RAUTARAY, S.; PAWAR, K. Assessment of object detection using deep convolutional neural networks. **Advances in Intelligent Systems and Computing**, v. 673, p. 457–466, 2018.

PEDDIE, W. Helmholtz's Treatise on Physiological Optics. **Nature**, v. 116, n. 2907, p. 88–89, 1 jul. 1925. Disponível em: <<http://www.nature.com/articles/116088a0>>.

PEROZZI GAMEIRO, M. B.; CLANCY, C.; ZANELLA, A. J. Between Freedom and Abandonment: Social Representations of Free-Roaming Donkeys in the Brazilian Northeast. **Anthrozoös**, v. 35, n. 3, p. 335–354, 4 maio 2022. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/08927936.2021.1999607>>.

PETERS, J. F. Colour Spaces. *In*: **Foundations of Computer Vision**. Cham: Springer International Publishing, 2014. p. 30.

PETERS, J. F. **Foundations of Computer Vision**. Cham: Springer International Publishing, 2017. v. 124

PONCE, J.; BERG, T. L.; EVERINGHAM, M.; FORSYTH, D. A.; HEBERT, M.; LAZEBNIK, S.; MARSZALEK, M.; SCHMID, C.; RUSSELL, B. C.; TORRALBA, A.; WILLIAMS, C. K. I.; ZHANG, J.; ZISSERMAN, A. Dataset Issues in Object Recognition. *In*: PONCE, J.; HEBERT, M.; SCHMID, C. **Toward Category-Level Object**

Recognition. Lecture Notes in Computer Science. Berlin, Heidelberg: Springer, 2006. p. 29–48.

PYNN, T. P.; PYNN, B. R. Moose and other large animal wildlife vehicle collisions: Implications for prevention and emergency care. **Journal of Emergency Nursing**, v. 30, n. 6, p. 542–547, 2004.

RANGDA, M. B.; HANCHATE, D. B. Animal Detection Using Histogram Oriented Gradient. **International Journal on Recent and Innovation Trends in Computing and Communication**, v. 2, n. 2, p. 178–183, 2014.

RAWAT, W.; WANG, Z. Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. **Neural Computation**, v. 29, n. 9, p. 2352–2449, set. 2017. Disponível em: <http://www.mitpressjournals.org/doi/abs/10.1162/neco_a_00990>.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: Unified, real-time object detection. **Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition**, v. 2016- Decem, p. 779–788, 2016.

REPORTS, C. **Cars With Advanced Safety Systems**. Disponível em: <<https://www.consumerreports.org/car-safety/cars-with-advanced-safety-systems/>>. Acesso em: 20 jun. 2020.

RODRÍGUEZ-MORALES, B.; DÍAZ-VARELA, E. R.; MAREY-PÉREZ, M. F. Spatiotemporal analysis of vehicle collisions involving wild boar and roe deer in NW Spain. **Accident Analysis and Prevention**, v. 60, p. 121–133, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.aap.2013.07.032>>.

RUSSAKOVSKY, O.; DENG, J.; SU, H.; KRAUSE, J.; SATHEESH, S.; MA, S.; HUANG, Z.; KARPATHY, A.; KHOSLA, A.; BERNSTEIN, M.; BERG, A. C.; FEI-FEI, L. ImageNet Large Scale Visual Recognition Challenge. **International Journal of Computer Vision**, v. 115, n. 3, p. 211–252, 2015.

SHARMA, S. U.; SHAH, D. J. A Practical Animal Detection and Collision Avoidance System Using Computer Vision Technique. **IEEE Access**, v. 5, n. February 2014, p. 347–358, 2017.

SINGH, H. Color Spaces. *In: Practical Machine Learning and Image Processing*. Allahabad: Apress, 2019. p. 13–21.

SOLOMON, C.; BRECKON, T. 1.1 O que é uma imagem? *In: Fundamentos de Processamento Digital de Imagens: uma abordagem prática com exemplos em Matlab*. 1. ed. Rio de Janeiro: LTC, 2013a. p. 1.

SOLOMON, C.; BRECKON, T. 1.4 Espaços de cor. *In: Fundamentos de Processamento Digital de Imagens: uma abordagem prática com exemplos em Matlab*. Rio de Janeiro: LTC, 2013b. p. 8–9.

SULLIVAN, J. M. Trends and characteristics of animal-vehicle collisions in the United States. **Journal of Safety Research**, v. 42, n. 1, p. 9–16, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.jsr.2010.11.002>>.

TAVARES, D. M.; COELHO, I. B.; CARDOSO, P. H. de O.; LIMA, R. P. de;; STEIN, P. P. **CENÁRIO DOS ACIDENTES POR ATROPELAMENTO DE FAUNA NAS RODOVIAS** Anais do XXXI Congresso de Pesquisa e Ensino em Transportes. [s.l: s.n.]. Disponível em: <https://www.researchgate.net/publication/320840468_CENARIO_DOS_ACIDENTE_S_POR_ATROPELAMENTO_DE_FAUNA_NAS_RODOVIAS_FEDERAIS_BRASILEIRAS_E_A_MORTALIDADE_DOS_HUMANOS_ENVOLVIDOS>.

TISSIER, M. L.; JUMEAU, J.; CROGUENNEC, C.; PETIT, O.; HABOLD, C.;

- HANDRICH, Y. An anti-predation device to facilitate and secure the crossing of small mammals in motorway wildlife underpasses. (I) Lab tests of basic design features. **Ecological Engineering**, v. 95, p. 738–742, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.ecoleng.2016.07.012>>.
- TZUTALIN, D. **Labellmg**. Disponível em: <<https://github.com/tzutalin/labellmg>>. Acesso em: 8 fev. 2018.
- VERSCHAE, R.; RUIZ-DEL-SOLAR, J. Object detection: Current and future directions. **Frontiers Robotics AI**, v. 2, n. NOV, p. 1–7, 2015.
- WADEY, J.; BEYER, H. L.; SAABAN, S.; OTHMAN, N.; LEIMGRUBER, P.; CAMPOS-ARCEIZ, A. Why did the elephant cross the road? The complex response of wild elephants to a major road in Peninsular Malaysia. **Biological Conservation**, v. 218, n. November 2017, p. 91–98, 2018. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0006320717315501>>.
- WEISS, K.; KHOSHGOFTAAR, T. M.; WANG, D. D. **A survey of transfer learning**. [s.l.] Springer International Publishing, 2016. v. 3
- XIAO, Y.; TIAN, Z.; YU, J.; ZHANG, Y.; LIU, S.; DU, S.; LAN, X. A review of object detection based on deep learning. **Multimedia Tools and Applications**, 12 jun. 2020. Disponível em: <<http://link.springer.com/10.1007/s11042-020-08976-6>>.
- YE, T.; WANG, B.; SONG, P.; LI, J. Automatic railway traffic object detection system using feature fusion refine neural network under shunting mode. **Sensors (Switzerland)**, v. 18, n. 6, 2018.
- YOUNG, T. II. The Bakerian Lecture. On the mechanism of the eye. **Philosophical Transactions of the Royal Society of London**, v. 91, p. 23–88, 31 dez. 1801. Disponível em: <<https://royalsocietypublishing.org/doi/10.1098/rstl.1801.0004>>.
- YU, M.; YANG, P.; WEI, S. Railway obstacle detection algorithm using neural network. **AIP Conference Proceedings**, v. 1967, n. May, 2018.
- ZHAO, Z. Q.; ZHENG, P.; XU, S. T.; WU, X. Object Detection with Deep Learning: A Review. **IEEE Transactions on Neural Networks and Learning Systems**, v. 30, n. 11, p. 3212–3232, 2019.
- ZHUANG, F.; QI, Z.; DUAN, K.; XI, D.; ZHU, Y.; ZHU, H.; XIONG, H.; HE, Q. A Comprehensive Survey on Transfer Learning. p. 1–31, 6 nov. 2019. Disponível em: <<http://arxiv.org/abs/1911.02685>>.

4. CAPÍTULO 3 – Detecção de animais em tempo real para mitigação de acidentes rodoviários.

4.1. Introdução

As colisões entre grandes mamíferos e veículos representam um grave problema para a vida selvagem e para os seres humanos. As rodovias são consideradas uma das maiores ameaças à vida selvagem em todo o mundo (FRANÇA BALBINO DA SILVA; FERNANDO SARAIVA DE MENEZES; RODRIGUES OLIVEIRA SANTOS, 2022; LAURANCE *et al.*, 2014; TROMBULAK; FRISSELL, 2000). As colisões envolvendo animais grandes são os maiores responsáveis por acidentes fatais com humanos (EPTV, 2011; G1, 2022; GRACE; SMITH; NOSS, 2015).

A mortalidade de animais selvagens devido aos acidentes rodoviários afeta a persistência das populações levando ao seu declínio acentuado ou gradual. Com áreas de preservação cada vez mais fragmentadas por extensas malhas rodoviárias, é necessário o desenvolvimento de métodos para melhorar a proteção e a viabilidade a longo prazo das populações de vida selvagem e a integridade ecológica de ecossistemas (JACKSON, 2021).

A utilização de passagens superiores e inferiores, cercas, sinalização, sistemas de detecção nos automóveis e nas estradas, políticas de educação do trânsito e sinalização estão entre os principais métodos de mitigação de acidentes utilizados no mundo todo (WILKINS; KOCKELMAN; JIANG, 2019). Dispositivos afugentadores, como refletores luminosos (BEILHARZ STRABENANAUSRÜSTUNG INC, 2018) e/ou repelentes odoríferos têm sido relatados (BÍL *et al.*, 2018; KUŠTA *et al.*, 2015) mas sua eficácia é controversa (BENTEN *et al.*, 2018; ELMEROS *et al.*, 2011; SCHLAGETER; HAAG-WACKERNAGEL, 2012).

Uma abordagem promissora é a utilização de algoritmos de visão computacional para detecção de objetos que podem ser aplicados para gerar um alerta da presença de animais nas rodovias (CHRISTIANSEN *et al.*, 2014; MINISTRY OF TRANSPORTATION AND INFRASTRUCTURE - BRITISH COLUMBIA - CANADA, 2022; RANGDA; HANCHATE, 2014; SHARMA; SHAH, 2017; ZHOU, 2013).

4.2. Detecção de objetos com visão computacional

O principal objetivo da visão computacional é reconstruir e interpretar informações de imagens capturadas por câmeras digitais (KHAN *et al.*, 2018; NILSSON, 2009; OLAGUE, 2016; PETERS, 2017). Através da visão os humanos processam uma imensa quantidade de informações tridimensionais do mundo. Estas informações ao serem compactadas pelas camadas do córtex visual permitem uma interpretação abstrata de uma pequena quantidade de dados (DAVIES, 2018). Dessa forma, os algoritmos de visão computacional baseados em redes neurais convolucionais foram inspirados pela forma como o cérebro humano processa as informações visuais.

Em 2001, o primeiro algoritmo de detecção em tempo real com resultados competitivos foi apresentado por Paul Viola e Michael Jones (VIOLA; JONES, 2001). O algoritmo foi desenvolvido para a detecção de faces humanas e rodava a 15 quadros por segundo, uma velocidade inédita naquela época. Algum tempo depois, surgiram competições anuais para determinar o melhor desempenho de algoritmos para classificação, localização e detecção computacional de objetos (EVERINGHAM *et al.*, 2010; LIN *et al.*, 2014; RUSSAKOVSKY *et al.*, 2015).

Em 2012, os pesquisadores Geoffrey Hinton, Ilya Sutskever e Alex Krizhevsky da Universidade de Toronto (EUA), submeteram ao desafio *ImageNet* uma arquitetura de rede neural convolucional profunda ao qual denominaram *AlexNet* (KRIZHEVSKY; SUTSKEVER; HINTON, 2012) vencendo a competição com acurácia 41% maior que o segundo colocado naquele ano. A rede *AlexNet* foi baseada na *LeNet* combinada com novos recursos como: *image data argumentation*⁴, *ReLU*⁵, *dropout*⁶ e implementação de unidade de processamento gráfico com memória dedicada (*Graphics Processing Unit – GPU*).

Esta competição inaugurou uma nova era para o reconhecimento de objetos em larga escala, visto que redes neurais artificiais profundas entraram em cena (RUSSAKOVSKY *et al.*, 2015; XIAO *et al.*, 2020). De fato, com o advento do *Big Data*

⁴ Uma técnica usada para expandir artificialmente o tamanho de um conjunto de dados de treinamento criando versões modificadas de imagens do conjunto de dados.

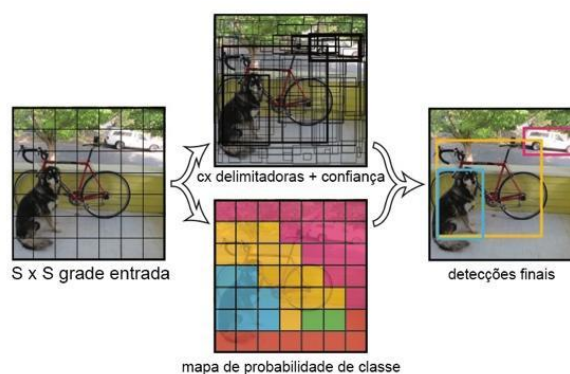
⁵ *Rectified Linear Unit (ReLU)* - função de ativação utilizada em muitos tipos de redes neurais devido à facilidade de treinar e bom desempenho.

⁶ Técnica para evitar excesso de ajuste durante o treinamento da rede.

e *Deep Learning*, a acurácia de tais sistemas aumentou de 71,8% em 2010 para 97,3% em 2017 (GERSHGORN, 2017).

Uma abordagem de tratar a detecção computacional de objetos como um problema de regressão, para caixas delimitadoras separadas espacialmente e probabilidades de classe associadas, foi apresentada com o algoritmo detector de objetos *Yolo – You only look once (Você só olha uma vez)* (REDMON *et al.*, 2016). Primeiramente a imagem de entrada é dividida em uma grade ($S \times S$). Se o centro de um objeto estiver presente em uma célula da grade, essa célula é responsável por detectar esse objeto (Figura 12).


Figura 12 - Modelo de detecção da rede Yolo.



Fonte: adaptado de REDMON, J. et al. You only look once: Unified, real-time object detection. **Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition**, v. 2016 - Dezembro, 2016. p. 780. A imagem é dividida em uma grade e, para cada célula da grade, o algoritmo prevê caixas delimitadoras, valor de confiança para essas caixas e probabilidades da classe.

Cada caixa delimitadora consiste em 5 previsões: x , y , w , h e grau de confiança. As coordenadas (x , y) representam o centro da caixa em relação aos limites da célula. A largura e a altura (w , h) são previstas em relação à imagem inteira. A primeira versão do *Yolo* apresentou a vantagem de detecções em tempo real com velocidades de até 145 qps e as desvantagens de não funcionar bem para objetos pequenos, baixa capacidade de generalização e problemas com função de perda (XIAO *et al.*, 2020). A Figura 13 apresenta a arquitetura da rede.

Figura 13 - Arquitetura da convnet Yolo.



Fonte: Adaptado de REDMON, J. et al. You only look once: Unified, real-time object detection. **Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition**, v. 2016- Decem, p. 781. A rede possui 24 camadas convolucionais (numeração azul), seguidas por 2 camadas (numeração verde) totalmente conectadas.

A segunda versão do *Yolo*, denominada *Yolo 9000* ou *Yolov2* (REDMON; FARHADI, 2017), introduziu normalização em lote e ancoragem no *Faster R-CNN* diminuindo o problema de generalização, possibilitando o treinamento com imagens de alta resolução e detecção com maior estabilidade (XIAO *et al.*, 2020). A terceira versão da rede – *Yolov3* (REDMON; FARHADI, 2018) – apresentou um melhor equilíbrio entre precisão e velocidade combinando bloco residual, rede piramidal de características e função de perda entropia cruzada (*log loss*), possibilitando a detecção de objetos de maior complexidade.

Em 2020 a quarta versão da rede – *Yolov4* (BOCHKOVSKIY; WANG; LIAO, 2020) – foi apresentada adicionando recursos para melhorar a precisão da detecção como: Conexões Residuais Ponderadas (SHEN; GAN; ZENG, 2017), Conexões Parciais entre Estágios (WANG *et al.*, 2019), Normalização Cruzada de Mini Lote (YAO *et al.*, 2020), Treinamento Auto Negativo (SZEGEDY *et al.*, 2014) e Ativação Mish (MISRA, 2019) obtendo 43,5% AP (65,7% AP 50) para o conjunto de dados MS COCO a uma velocidade de aproximadamente 65 qps com utilização de uma GPU Tesla V100.

Nota-se que a cada novo desenvolvimento, as pesquisas subsequentes foram apresentando algoritmos compostos por uma mistura de arquiteturas, assimilando e melhorando as técnicas apresentadas anteriormente. A partir do uso de aprendizado profundo no campo da visão computacional, as redes neurais convolucionais

(convnets) para detecção de objetos acabaram dividindo-se em 2 grupos principais: algoritmos de detecção de objetos de um estágio dois estágios.

Os algoritmos de dois estágios utilizam abordagem baseada na proposta regional (*region-based proposal*), conforme exemplo da rede R-CNN, lidando com tarefa de localização e classificação em diferentes etapas. Primeiro as características são extraídas das regiões de interesse e, numa segunda etapa, classificadores específicos são usados para determinar os rótulos. A vantagem é uma maior acurácia, mas com menor performance em velocidade. Os algoritmos de um estágio podem prever diretamente as probabilidades de classe e as coordenadas das caixas delimitadoras encapsulando todo o cálculo em uma única rede. Apresenta alta velocidade, mas perde em precisão quando comparados aos algoritmos de dois estágios (LIU *et al.*, 2020; XIAO *et al.*, 2020).

Revisões de literatura sobre o desenvolvimento das redes neurais artificiais para detecção de objetos, com diferentes abordagens classificatórias das tecnologias envolvidas, podem ser encontradas nas referências a seguir (ANDREOPOULOS; TSOTSOS, 2013; LIU *et al.*, 2020; XIAO *et al.*, 2020).

O presente estudo apresenta os resultados dos testes em tempo real de um sistema de detecção de animais em rodovias com uso de visão computacional e aprendizado de máquina (SATO; ZANELLA; COSTA, 2021).

4.3. Materiais e métodos

Este projeto foi analisado e aprovado pelo Comitê de Ética da Faculdade de Medicina Veterinária e Zootecnia sob o número CEUA Nº 4526170418.

4.3.1. Localização do experimento

O experimento foi realizado no *Campus* “Fernando Costa” da Universidade de São Paulo – Pirassununga/SP na via pavimentada entre o Laboratório de Eficiência Energética e Simulação de Processos (LEESP/ZEB) e o Setor de Suinocultura da Prefeitura do *Campus* (21°57'04.3"S 47°27'12.1"W). Para a realização dos testes de detecção em tempo real, a via pavimentada foi marcada a cada 10 metros com tinta branca conforme apresentado na Figura 14

Figura 14 - Via pavimentada utilizada para os testes de detecção.



Fonte: autoria própria – **A:** marcações no pavimento com tinta branca. **B:** Adaptado de Google Maps – no detalhe amarelo = trecho de 100 metros utilizado no experimento.

4.3.2. Hardware e software

O sistema de detecção foi instalado em um computador desktop com processador AMD Ryzen5 2600X, 8GB de memória RAM, placa gráfica Gigabyte GTX 1050ti 4GB e armazenamento Kingston® SSD 480GB. O sistema operacional utilizado foi o Linux Ubuntu versão 20.04. Foi configurado um ambiente virtual de desenvolvimento (*Virtualenv*) na linguagem *Python* (versão 3.10) e foi instalada a *framework darknet* conforme instruções do desenvolvedor (BOCHKOVSKIY, 2019a).

Uma fita de LEDs (*light emitting diodes*) 12 volts foi adaptada a uma placa de sinalização rodoviária (Animais Selvagens/A-36 Resolução Contran Nº 243 06/2007) conforme apresentado na Figura 15.

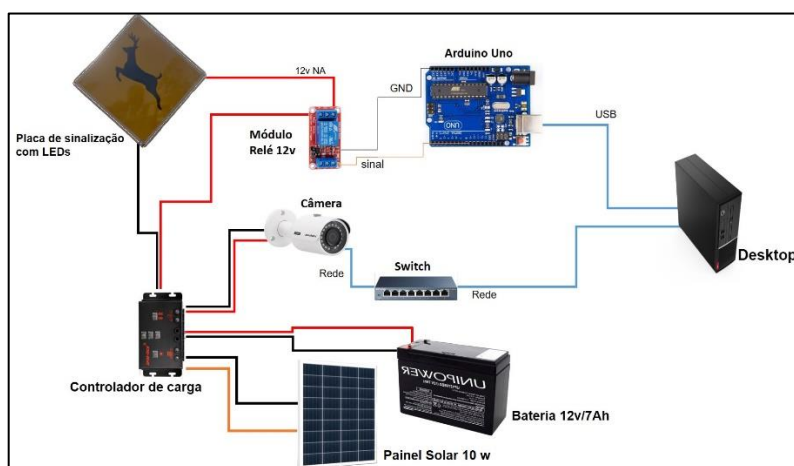
Figura 15 - Placa de sinalização rodoviária com instalação de sinal luminoso.



Fonte: autoria própria. A placa de sinalização foi modificada pela instalação de uma fita de luz.

A comunicação entre a placa de sinalização rodoviária e o computador foi configurada através de um Arduino Uno conectado a um módulo relé 12v. Foi utilizada uma Câmera IP Intelbrás® VHD 3230 B conectada a um Switch TP-Link® TL-SG108 como sensor de entrada. A câmera foi instalada a uma altura de 3,5 metros do chão. A Figura 16 apresenta o diagrama de conexões do sistema.

Figura 16 - Diagrama de conexões do sistema detector.



Fonte: autoria própria. O sensor de entrada (câmera IP) envia as imagens para o desktop através da rede. Quando há uma detecção verdadeira positiva, o sistema detector ativa a porta digital n.º 9 do Arduino Uno (HIGH). O módulo relé então fecha o circuito de alimentação 12v acendendo a placa de sinalização. O sensor de entrada (câmera), a placa de sinalização, o Arduino Uno e o módulo relé 12v foram alimentados pelo sistema de energia solar (bateria 12v/7Ah, painel solar e controlador de carga UPNe-Tech - genérico).

O painel solar, a bateria, o controlador de carga e o Arduino foram montados em uma estrutura de policloreto de vinila (cano PVC) em caráter experimental conforme apresentado na Figura 17.

Figura 17 - Estrutura experimental em PVC para acomodação do hardware.



Fonte: autoria própria. O suporte em PCV abriga a bateria 12v/7Ah na caixa inferior e o módulo controlador de carga, o módulo relé e o Arduino Uno na caixa superior.

4.3.3. Testes de detecção

Foram utilizados dois modelos pré-treinados da rede neural convolucional Yolov4 para os testes: Yolov4-Puraa (SATO; ZANELLA; COSTA, 2021) e o modelo Yolov4-msCOCO (BOCHKOVSKIY; WANG; LIAO, 2020). Para o modelo Yolov4-Puraa foram computadas as detecções das classes *capivara* e *equidae* para os grupos animais de capivaras e equídeos respectivamente. Para a versão pré-treinada Yolov4-msCOCO foi realizado teste de detecção apenas para o grupo de equinos e foram computadas as detecções das classes *horse* e *cow* como verdadeiro positivas. O modelo foi treinado para 80 classes (BOCHKOVSKIY, 2017).

Para os testes com a classe *equidae*, um cavalo foi conduzido pela via pavimentada (0-100 metros) por um colaborador com o auxílio de um cabresto. A cada 10 metros o animal foi posicionado perpendicularmente ao sentido da via conforme apresentado na Figura 18.

Figura 18 - Condução de um cavalo pela via demarcada.



Fonte: autoria própria. O animal foi conduzido gentilmente na via com parada a cada 10 metros.

O teste de detecção com as capivaras foi realizado no horário de permanência natural dos animais no local do experimento (19 horas – horário de Brasília). Não houve interferência humana na movimentação dos animais. Dessa forma, a distância máxima avaliada para a classe *capivara* foi de 30 metros conforme apresentado na Figura 19.

Figura 19 - Capivaras na via pavimentada durante os testes de detecção.



Fonte: autoria própria.

Em ambos os modelos, o teste foi registrado em vídeo a 60 quadros por segundo (qps) e uma amostragem de quadros foi realizada utilizando o algoritmo *ffmpeg* (FFMPEG.ORG) de forma a reduzir o erro de medidas repetidas temporais, conforme apresentado na Tabela 1.

Tabela 1 – Amostragem de quadros para avaliação da detecção.

Modelo	Classe	Tempo de vídeo (minutos)	Amostragem (quadros)
Yolov4-Puraa	<i>capivara</i>	03:33	73
Yolov4-Puraa	<i>equidae</i>	01:44	186
Yolov4-msCoco	<i>equidae</i>	01:20	100

Fonte: autoria própria.

4.3.4. Avaliação estatística

Os resultados comparativos entre as detecções e as coordenadas reais no modelo Yolov4-Puraa foram computados com o software *mAP* (CARTUCHO, 2015; CARTUCHO; VENTURA; VELOSO, 2018) e de acordo com as métricas do *Pascal VOC Challenge 2012* modificadas (EVERINGHAM; WINN, 2012). Além dos gráficos de resultados de precisão, o software *mAP* registra caixas delimitadoras comparativas em cada imagem para análise visual. O *mAP* apresenta caixas delimitadoras verdes para o caso de detecções verdadeiro-positivas, vermelhas como falso-positivos e rosa para objetos não detectados (falso-negativos). As caixas delimitadoras de verdade básica são apresentadas em azul.

Os resultados da detecção são classificados por nível de confiança decrescente e comparados com os dados da verdade básica (*ground-truth*). O resultado da detecção é considerado positivo quando o valor de Intersecção sobre União (IoU) for maior ou igual a 0,1 (IoU \geq 10%). Várias detecções para o mesmo objeto foram computadas como falso-positivos. A IoU é calculada pela Equação 3:

$$A = \frac{B_p \cap B_{gt}}{B_p \cup B_{gt}} \geq 0,1 \quad (3)$$

, onde B_p é a área da caixa delimitadora prevista e B_{gt} a área da caixa delimitadora definida na verdade básica (*ground-truth*).

O valor de acurácia (Ac) dos modelos é calculado de acordo com a Equação 4:

$$Ac = \frac{TP_{det}}{Gt + FP_{det}} \quad (4)$$

, onde TP_{det} é o número total de verdadeiro-positivos detectados, Gt é o número total de objetos nos dados de verdade básica e FP_{det} é o número total de falsos positivos detectados.

O modelo Yolov4-msCOCO foi avaliado pelos valores de precisão média (PM), Recuperação (*Recall* - Rec) e F1 Score. A Precisão média foi calculada de acordo com a Equação 5:

$$PM = \frac{VP}{VP+FP} \quad (5)$$

, onde TP é o número de verdadeiro positivos e FP o número de falso positivos.

A Recuperação (Rec) é a razão entre o número de verdadeiros positivos para o número total de objetos reais (*ground-truth*) e é calculada de acordo com a Equação 6:

$$Rec = \frac{VP}{VP+FN} \quad (6)$$

, onde TP é o número de verdadeiro positivos e FN o número de falso negativos (objetos de interesse não detectados).

O F1 Score é uma média ponderada dos valores de precisão e de recuperação variando de 0 a 1, onde o valor de 1 equivale a máxima acurácia. O F1 Score é calculado de acordo com a Equação 7:

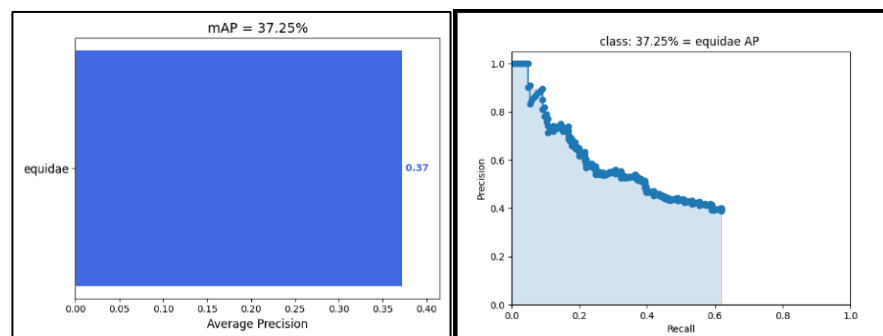
$$F1Score = \frac{PM*Rec}{\frac{PM+Rec}{2}} \quad (7)$$

, onde PM é o valor de precisão média e Rec é o valor de revocação (recall).

4.4. Resultados e discussões

Os resultados da detecção utilizando o modelo Yolov4-Puraa para a classe *equidae* (n=186) são apresentados na Figura 20.

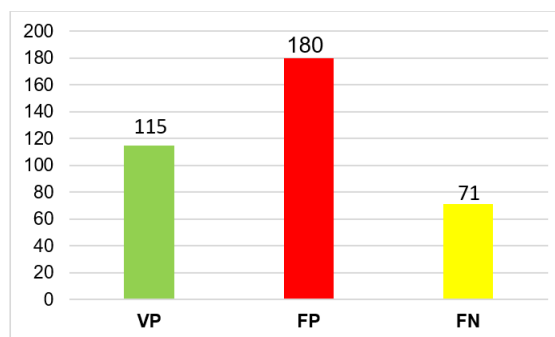
Figura 20 – Resultados *mAP* e gráfico *Precisão x Recuperação* para o modelo Yolov4-Puraa – classe *equidae* (n=186).



Fonte: autoria própria. **mAP** – mean average precision. Dados gerados com o software *mAP* (IoU $\geq 0,1$) (CARTUCHO, 2015).

A precisão média de detecção do Yolov4-Puraa para a classe *equidae* foi de 37,25%. O modelo pode detectar 115 dos 186 objetos de interesse presentes nos arquivos de referência. A Figura 21 apresenta os valores de detecção e número de objetos não detectados.

Figura 21 – Detecções e número de objetos não detectados – Yolov4-Puraa classe *equidae* (n=186).



Fonte: autoria própria. VP – Verdadeiro positivos; FP – Falso positivos; FN – Falso negativos.

A velocidade de detecção para o Yolov4-Puraa (classe *equidae*) foi de 12 quadros por segundo. O modelo apresentou detecções positivas de elevado grau de confiança a distância de 30 metros (Figura 22) e detecções positivas a mais de 70 metros da câmera (Figura 23).

Figura 22 - Detecção de equino a 30 metros com Yolov4-Puraa.



Fonte: autoria própria.

Figura 23 - Detecção de equino a 70 metros com Yolov4-Puraa.



Fonte: autoria própria.

Apesar do elevado número de falso positivos na detecção, ao analisarmos as detecções quadro a quadro verificamos 48 detecções não computadas por insuficiência do valor de *IoU* (*intersection-over-union*). Um exemplo pode ser visualizado na Figura 24.

Figura 24 - Detecção não computada por limiar de *IoU*.



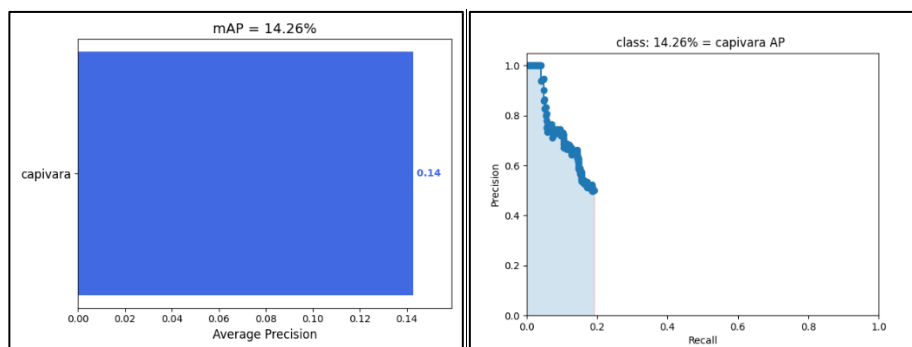
Fonte: própria autoria. Algumas caixas delimitadoras em vermelho são computadas como falso positivos apesar de identificar parte do objeto de interesse.

Ajustando-se os valores de *IoU* e computando os falso-positivos incorretamente detectados, obtivemos um valor de precisão média de $PM = 47,52\%$, recuperação $Rec = 69,65\%$ e $F1score = 56,49\%$ para a classe *equidae* utilizando o modelo Yolov4-Puraa.

O conjunto de dados utilizado no treinamento também pode ser responsável pelo grande número de falso positivos nas detecções. Apesar de o número de imagens dos objetos de interesse ser o mesmo para as duas classes, verificou-se que houve um número significativamente maior de objetos da classe *capivara* ($n = 2412$) no treinamento que os objetos da classe *equidae* ($n=1541$) (SATO; ZANELLA; COSTA, 2021).

Os resultados de detecção do Yolov4-Puraa para a classe *capivara* são apresentados na Figura 25.


Figura 25 - Resultados mAP e gráfico *Precisão x Recuperação* para o modelo Yolov4-Puraa – classe *capivara*.



Fonte: autoria própria. **mAP** – mean average precision. Dados gerados com o software mAP (IoU $\geq 0,1$) (CARTUCHO, 2015).

A precisão média para o modelo foi de 14,26% e pode detectar apenas 71 dos 371 objetos presentes na verdade básica. No entanto, avaliando as detecções quadro a quadro, em apenas 28 quadros não houve detecção de objetos de interesse. As capivaras são animais que andam em grupos. Neste caso basta que haja a detecção de apenas 1 indivíduo para que o sistema de alerta seja ativado. A Figura 26 apresenta dois quadros de detecção de exemplo.

Figura 26 - Quadros com resultados de detecção do Yolov4-Puraa para a classe *capivara*.



Fonte: autoria própria. **A** – Detecções verdadeiro positivas em verde, falso-positivas em vermelho e objetos não detectados em rosa. **B** – Quadro sem detecção (FN).

Em alguns quadros houve alto número de detecções positivas e também na presença de objetos não treinados como apresentado na Figura 27.


Figura 27 - Quadros de detecção do Yolov4-Puraa para a classe *capivara*.



Fonte: autoria própria. **A** – Detecção de grande número de objetos de interesse; **B** – detecção do animal na presença de veículo automotivo.

Também há a questão da câmera que possui tecnologia de visão noturna para até 30 metros. Não foram realizados testes em condições de luminosidade baixa devido não ser possível desativar a iluminação da via. A Figura 28 apresenta os resultados das detecções e número de objetos não detectados.

Figura 28 - Detecções e número de objetos não detectados – Yolov4-Puraa classe *capivara*.



Fonte: autoria própria. **VP** – verdadeiro positivos; **FP** – Falso positivos; **FN** – Falso negativos.

Os resultados da detecção com o modelo Yolov4-msCOCO são apresentados na Tabela 2.


Tabela 2 - Resultados de detecção no modelo Yolov4-msCOCO classe *equidae*.

Yolov4-msCOCO teste de detecção – classe <i>equidae</i>								
	Até 10 m	10-20 m	20-30 m	30-40 m	40-50 m	50-60 m	60-70 m	Média
VP	10	15	10	8	5	6	6	8,57
FP	1	0	0	0	0	0	4	0,71
FN	0	2	4	9	9	6	10	5,71
Precisão	90%	100%	100%	100%	100%	100%	60%	0,93
Recall	100%	88,23%	71,42%	47,05%	35,71%	50%	37,50%	0,61
F1score	94,73%	93,74%	83,32%	64%	52,63%	66,66%	46,15%	0,72

VP – Verdadeiro positivos; FP – Falso positivos; FN – Falso negativos. (n = 100 número de objetos nos arquivos da verdade básica – *ground-truth*).

O modelo apresentou os melhores resultados (considerando como VP os objetos das classes *horse* e *cow*). O modelo foi capaz de detectar diferentes objetos de interesse na cena com poucas detecções cruzadas. Exemplos de detecções com o modelo podem ser apreciadas nas Figuras 29 e 30.


Figura 29 - Detecções com o Yolov4-msCOCO.



Fonte: autoria própria. Caminhão, cavalo e carro (FP) detectados.

Após 60 metros de distância do sensor, as detecções do cavalo foram rotuladas com a classe *cow*. Na imagem 26 pode-se notar que a partir de 60 metros o objeto de interesse perde bastante resolução.

Figura 30 - Detecções do Yolov4-COCO para a classe *equidae*.



Fonte: autoria própria. Após 60 metros o objeto de interesse perde resolução.

É importante salientar que as métricas aqui aplicadas são indicadores para avaliar as tarefas de localização e rastreamento dos objetos de interesse nos algoritmos de visão computacional (COCO, 2020; EVERINGHAM; WINN, 2012; RUSSAKOVSKY *et al.*, 2015). Para uma aplicação de alerta ao motorista da presença de um animal na rodovia, basta uma detecção positiva. O alerta luminoso também poderia ser instalado em uma posição anterior à localização da câmera aumentando assim a janela de resposta do motorista para o caso de uma detecção positiva. De qualquer forma, o sistema pode detectar o equino a mais de 70 metros de distância da câmera.

Considerando rodovias que cortam grandes áreas de preservação onde há inúmeros acidentes entre veículos e animais, um estudo da aplicação do sistema com múltiplas câmeras em trechos específicos, utilização de câmeras de alta resolução e/ou câmeras térmicas, câmeras com movimento (*PTZ – pan, tilt, zoom*) deve ser considerado. Acidentes com animais em grandes áreas geográficas de proteção têm sido relatados (GANDIWA *et al.*, 2020; WILKINS; KOCKELMAN; JIANG, 2019).

A decisão por métodos de mitigação de acidentes em uma área não deve ser realizada sem um estudo aprofundado das interações ecológicas em questão. Deve-se avaliar quais as espécies estão envolvidas, se há restrições nos métodos selecionados, se é interessante a aplicação de mais de um método mitigatório (ASCENSÃO *et al.*, 2013; BAGER; FONTOURA, 2013; WANG *et al.*, 2017).

Os testes com o alerta luminoso demonstraram a eficácia da utilização do sistema em situações onde há curvas acentuadas na rodovia alertando o motorista da presença de animais após o ponto de visualização do alerta. A figura 31 apresenta o alerta luminoso para uma detecção positiva.

Figura 31 - Alerta luminoso para detecção positiva.




Fonte: autoria própria.

É importante que os dados para treinamento do sistema de detector sejam constantemente alimentados no algoritmo para elevar os níveis de precisão. Imagens dos objetos de interesse em diferentes posições espaciais no local de aplicação podem elevar a acurácia e reduzir os erros. A utilização de exemplos negativos e alterações de resolução na entrada dos dados para treinamento também podem melhorar os índices de precisão, mas eleva-se o custo computacional (BOCHKOVSKIY, 2020b).

Muitos acidentes ocorrem em uma extensão de rodovia que corta alguma área de floresta preservada. Por exemplo, o Campus “Fernando Costa” da Universidade de São Paulo em Pirassununga/SP apresenta áreas de preservação de tamanho significativo cortadas por uma importante rodovia do estado de São Paulo – a SP 330 conforme pode ser apreciado na Figura 32.

Figura 32 - SP 330 - Universidade de São Paulo - mapa.



Fonte: autoria própria. No detalhe em azul área de preservação florestal.

Um exemplo da utilização de um sistema semelhante em grandes áreas geográficas é o aplicado na província Canadense da Columbia Britânica (MINISTRY OF TRANSPORTATION AND INFRASTRUCTURE - BRITISH COLUMBIA - CANADA, 2022; SIELECKI, 2017). Utilizando tecnologias de radar e câmeras térmicas, o Ministério do Transporte e Infraestrutura da província está obtendo bons resultados na mitigação de atropelamentos de animais em ferrovias e rodovias.

4.5. Conclusões

Os modelos Yolov4-Puraa e Yolov4-msCOCO apresentaram baixos valores de precisão nas métricas de avaliação das tarefas de localização e rastreamento. No entanto, os modelos foram capazes de detectar equinos acima de 70 metros de distância.

Os testes com capivaras foram realizados no período noturno e em até 30 metros de distância da câmera e com bons resultados de alerta luminoso;

Para melhorar os índices de precisão, deve-se treinar os modelos com mais dados de animais nas condições de aplicação do alerta luminoso e aplicação de amostras negativas.

O sistema proposto tem o potencial de colaborar para redução de acidentes em rodovias elevando a segurança viária e o bem-estar animal.

4.6. REFERÊNCIAS

- ANDREOPOULOS, A.; TSOTSOS, J. K. 50 Years of object recognition: Directions forward. **Computer Vision and Image Understanding**, v. 117, n. 8, p. 827–891, 2013.
- ASCENSÃO, F.; CLEVINGER, A.; SANTOS-REIS, M.; URBANO, P.; JACKSON, N. Wildlife-vehicle collision mitigation: Is partial fencing the answer? An agent-based model approach. **Ecological Modelling**, v. 257, p. 36–43, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.ecolmodel.2013.02.026>>.
- BAGER, A.; FONTOURA, V. Evaluation of the effectiveness of a wildlife roadkill mitigation system in wetland habitat. **Ecological Engineering**, v. 53, p. 31–38, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.ecoleng.2013.01.006>>.
- BEILHARZ STRABENANAUSRÜSTUNG INC. **Reflektoren Programmübersicht**. Disponível em: <<https://www.beilharz.eu/de/wildwarnreflektor.html>>. Acesso em: 6 mar. 2022.
- BENTEN, A.; HOTHORN, T.; VOR, T.; AMMER, C. Wildlife warning reflectors do not mitigate wildlife–vehicle collisions on roads. **Accident Analysis and Prevention**, v. 120, n. February, p. 64–73, 2018. Disponível em: <<https://doi.org/10.1016/j.aap.2018.08.003>>.
- BÍL, M.; ANDRÁŠIK, R.; BARTONIČKA, T.; KŘIVÁNKOVÁ, Z.; SEDONÍK, J. An evaluation of odor repellent effectiveness in prevention of wildlife-vehicle collisions. **Journal of Environmental Management**, v. 205, p. 209–214, 2018.
- BOCHKOVSKIY, A. **Coco classes names**. Disponível em: <<https://github.com/AlexeyAB/darknet/blob/master/cfg/coco.names>>. Acesso em: 20 mar. 2019.
- BOCHKOVSKIY, A. **Darknet - Yolo-V4 and Yolo-v3/v2 for Windows and Linux**. Disponível em: <<https://github.com/AlexeyAB/darknet>>. Acesso em: 14 jun. 2019a.
- BOCHKOVSKIY, A. **How to improve object detection**. Disponível em: <<https://github.com/AlexeyAB/darknet#how-to-improve-object-detection>>. Acesso em: 20 maio. 2020b.
- BOCHKOVSKIY, A. **Coco Yolo trained weights**2020. Disponível em: <https://github.com/AlexeyAB/darknet/releases/download/darknet_yolo_v3_optimal/yolov4.weights>.
- BOCHKOVSKIY, A.; WANG, C.-Y.; LIAO, H.-Y. M. YOLOv4: Optimal Speed and Accuracy of Object Detection. 2020. Disponível em: <<http://arxiv.org/abs/2004.10934>>.
- CARTUCHO, J. **mAP**. Disponível em: <<https://github.com/Cartucho/mAP>>. Acesso em: 18 set. 2019.
- CARTUCHO, J.; VENTURA, R.; VELOSO, M. Robust Object Recognition Through Symbiotic Deep Learning In Mobile Robots. In: 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2018, [...]. IEEE, 2018. p. 2336–2341.
- CHRISTIANSEN, P.; STEEN, K. A.; JØRGENSEN, R. N.; KARSTOFT, H. Automated detection and recognition of wildlife using thermal cameras. **Sensors (Switzerland)**, v. 14, n. 8, p. 13778–13793, 2014.

COCO. **COCO 2020 Object Detection Task**. Disponível em: <<https://cocodataset.org/#detection-2020>>. Acesso em: 15 abr. 2020.

DAVIES, E. R. Images and imaging operations. *In: Computer Vision*. London: Academic Press, 2018. p. 19–37.

ELMEROS, M.; WINBLADH, J. K.; ANDERSEN, P. N.; MADSEN, A. B.; CHRISTENSEN, J. T. Effectiveness of odour repellents on red deer (*Cervus elaphus*) and roe deer (*Capreolus capreolus*): A field test. **European Journal of Wildlife Research**, v. 57, n. 6, p. 1223–1226, 2011.

EPTV. **Capivara causa acidente com 7 mortes em rodovia que liga Araras a Rio Claro em SP**. Disponível em: <<https://oglobo.globo.com/brasil/capivara-causa-acidente-com-7-mortes-em-rodovia-que-liga-araras-rio-claro-em-sp-2844472>>. Acesso em: 18 fev. 2018.

EVERINGHAM, M.; VAN GOOL, L.; WILLIAMS, C. K. I.; WINN, J.; ZISSERMAN, A. The pascal visual object classes (VOC) challenge. **International Journal of Computer Vision**, v. 88, n. 2, p. 303–338, 2010.

EVERINGHAM, M.; WINN, J. **The PASCAL Visual Object Classes Challenge 2012 (VOC2012) Development Kit**. Disponível em: <http://host.robots.ox.ac.uk/pascal/VOC/voc2012/devkit_doc.pdf>. Acesso em: 13 abr. 2020.

FRANÇA BALBINO DA SILVA, A. C.; FERNANDO SARAIVA DE MENEZES, J.; RODRIGUES OLIVEIRA SANTOS, L. G. Roadkill risk for capybaras in an urban environment. **Landscape and Urban Planning**, v. 222, p. 104398, jun. 2022. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0169204622000470>>.

G1. **Motorista morre em Pirassununga após atropelar boi na Rodovia Anhanguera**. Disponível em: <<https://g1.globo.com/sp/sao-carlos-regiao/noticia/2022/02/16/motorista-morre-em-pirassununga-apos-atropelar-boi-na-rodovia-anhanguera.ghtml>>. Acesso em: 10 jun. 2022.

GANDIWA, E.; MASHAPA, C.; MUBOKO, N.; CHEMURA, A.; KUVAOGA, P.; MABIKA, C. T. Wildlife-vehicle collisions in Hurungwe Safari Area, northern Zimbabwe. **Scientific African**, v. 9, p. e00518, set. 2020. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S2468227620302568>>.

GERSHGORN, D. **The data that transformed AI research—and possibly the world**. Disponível em: <<https://qz.com/1034972/the-data-that-changed-the-direction-of-ai-research-and-possibly-the-world/>>. Acesso em: 13 mar. 2018.

GRACE, M. K.; SMITH, D. J.; NOSS, R. F. Testing alternative designs for a roadside animal detection system using a driving simulator. **Nature Conservation**, v. 11, p. 61–77, 28 jul. 2015. Disponível em: <<http://natureconservation.pensoft.net/articles.php?id=4420>>.

[HTTPS://FFMPEG.ORG/](https://ffmpeg.org/). **FFMPEG**[s.d.] Disponível em: <<https://ffmpeg.org/>>.

JACKSON, S. D. Wildlife Crossings and Barriers. *In: International Encyclopedia of Transportation*. [s.l.] Elsevier, 2021. p. 297–304.

KHAN, S.; RAHMANI, H.; SHAH, S. A. A.; BENNAMOUN, M. A Guide to Convolutional Neural Networks for Computer Vision. **Synthesis Lectures on Computer Vision**, v. 8, n. 1, p. 1–207, 13 fev. 2018. Disponível em:

<<http://www.morganclaypool.com/doi/10.2200/S00822ED1V01Y201712COV015>>.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. **Advances in neural information processing systems**, v. 25, n. 2, p. 84–90, 24 maio 2012. Disponível em: <<http://dl.acm.org/citation.cfm?doid=3098997.3065386>>.

KUŠTA, T.; KEKEN, Z.; JEŽEK, M.; KÚTA, Z. Effectiveness and costs of odor repellents in wildlife-vehicle collisions: A case study in Central Bohemia, Czech Republic. **Transportation Research Part D: Transport and Environment**, v. 38, p. 1–5, 2015.

LAURANCE, W. F.; CLEMENTS, G. R.; SLOAN, S.; O'CONNELL, C. S.; MUELLER, N. D.; GOOSEM, M.; VENTER, O.; EDWARDS, D. P.; PHALAN, B.; BALMFORD, A.; VAN DER REE, R.; ARREA, I. B. A global strategy for road building. **Nature**, v. 513, n. 7517, p. 229–232, 11 set. 2014. Disponível em: <<http://www.nature.com/articles/nature13717>>.

LIN, T. Y.; MAIRE, M.; BELONGIE, S.; HAYS, J.; PERONA, P.; RAMANAN, D.; DOLLÁR, P.; ZITNICK, C. L. Microsoft COCO: Common objects in context. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, v. 8693 LNCS, n. PART 5, p. 740–755, 2014.

LIU, L.; OUYANG, W.; WANG, X.; FIEGUTH, P.; CHEN, J.; LIU, X.; PIETIKÄINEN, M. Deep Learning for Generic Object Detection: A Survey. **International Journal of Computer Vision**, v. 128, n. 2, p. 261–318, 2020. Disponível em: <<https://doi.org/10.1007/s11263-019-01247-4>>.

MINISTRY OF TRANSPORTATION AND INFRASTRUCTURE - BRITISH COLUMBIA - CANADA. **Wildlife Detection System**. Disponível em: <<https://www.tranbc.ca/tag/wildlife-detection-system/>>. Acesso em: 10 jun. 2022.

MISRA, D. Mish: A Self Regularized Non-Monotonic Neural Activation Function. n. 1, 23 ago. 2019. Disponível em: <<http://arxiv.org/abs/1908.08681>>.

NILSSON, N. J. Computer Vision. *In: The Quest for Artificial Intelligence*. Cambridge: Cambridge University Press, 2009. p. 125–140.

OLAGUE, G. **Evolutionary Computer Vision**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016. 411 p.

PETERS, J. F. What is Computer Vision? *In: Foundations of Computer Vision*. Intelligent Systems Reference Library. Cham: Springer International Publishing, 2017. p. 2.

RANGDA, M. B.; HANCHATE, D. B. Animal Detection Using Histogram Oriented Gradient. **International Journal on Recent and Innovation Trends in Computing and Communication**, v. 2, n. 2, p. 178–183, 2014.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: Unified, real-time object detection. **Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition**, v. 2016- Decem, p. 779–788, 2016.

REDMON, J.; FARHADI, A. YOLO9000: Better, faster, stronger. **Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017**, v. 2017- Janua, p. 6517–6525, 2017.

REDMON, J.; FARHADI, A. YOLOv3: An Incremental Improvement. 2018. Disponível em: <<http://arxiv.org/abs/1804.02767>>.

RUSSAKOVSKY, O.; DENG, J.; SU, H.; KRAUSE, J.; SATHEESH, S.; MA, S.; HUANG, Z.; KARPATY, A.; KHOSLA, A.; BERNSTEIN, M.; BERG, A. C.; FEI-FEI, L. ImageNet Large Scale Visual Recognition Challenge. **International Journal of Computer Vision**, v. 115, n. 3, p. 211–252, 2015.

SATO, D.; ZANELLA, A. J.; COSTA, E. X. Computational classification of animals for a highway detection system. **Brazilian Journal of Veterinary Research and Animal Science**, v. 58, n. Special Issue, p. e174951, 15 maio 2021. Disponível em: <<https://www.revistas.usp.br/bjvras/article/view/174951>>.

SCHLAGETER, A.; HAAG-WACKERNAGEL, D. Evaluation of an odor repellent for protecting crops from wild boar damage. **Journal of Pest Science**, v. 85, n. 2, p. 209–215, 2012.

SHARMA, S. U.; SHAH, D. J. A Practical Animal Detection and Collision Avoidance System Using Computer Vision Technique. **IEEE Access**, v. 5, n. February 2014, p. 347–358, 2017.

SHEN, F.; GAN, R.; ZENG, G. Weighted residuals for very deep networks. **2016 3rd International Conference on Systems and Informatics, ICSAI 2016**, p. 936–941, 2017.

SIELECKI, L. Wildlife Detection Systems, Highway 3, British Columbia: Real-time warning systems for protecting wildlife and drivers. In: TAC 2017: Investing in Transportation: Building Canada's Economy - - 2017 Conference and Exhibition of the Transportation Association of Canada, 2017, Ontario. [...]. Ontario: Transportation Association of Canada (TAC), 2017.

SZEGEDY, C.; ZAREMBA, W.; SUTSKEVER, I.; BRUNA, J.; ERHAN, D.; GOODFELLOW, I.; FERGUS, R. Intriguing properties of neural networks. **2nd International Conference on Learning Representations, ICLR 2014 - Conference Track Proceedings**, p. 1–10, 2014.

TROMBULAK, S. C.; FRISSELL, C. A. Review of Ecological Effects of Roads on Terrestrial and Aquatic Communities. **Conservation Biology**, v. 14, n. 1, p. 18–30, fev. 2000. Disponível em: <<http://doi.wiley.com/10.1046/j.1523-1739.2000.99084.x>>.

VIOLA, P.; JONES, M. Rapid object detection using a boosted cascade of simple features. In: Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001, 2001, Kauai. [...]. Kauai: IEEE Comput. Soc, 2001. v. 1, p. I-511–I-518.

WANG, C.-Y.; LIAO, H.-Y. M.; YEH, I.-H.; WU, Y.-H.; CHEN, P.-Y.; HSIEH, J.-W. CSPNet: A New Backbone that can Enhance Learning Capability of CNN. 2019. Disponível em: <<http://arxiv.org/abs/1911.11929>>.

WANG, Y.; GUAN, L.; PIAO, Z.; WANG, Z.; KONG, Y. Monitoring wildlife crossing structures along highways in Changbai Mountain, China. **Transportation Research Part D: Transport and Environment**, v. 50, p. 119–128, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.trd.2016.10.030>>.

WILKINS, D. C.; KOCKELMAN, K. M.; JIANG, N. Animal-vehicle collisions in Texas: How to protect travelers and animals on roadways. **Accident Analysis and Prevention**, v. 131, n. January, p. 157–170, 2019. Disponível em:

<<https://doi.org/10.1016/j.aap.2019.05.030>>.

XIAO, Y.; TIAN, Z.; YU, J.; ZHANG, Y.; LIU, S.; DU, S.; LAN, X. A review of object detection based on deep learning. **Multimedia Tools and Applications**, 12 jun. 2020. Disponível em: <<http://link.springer.com/10.1007/s11042-020-08976-6>>.

YAO, Z.; CAO, Y.; ZHENG, S.; HUANG, G.; LIN, S. Cross-Iteration Batch Normalization. 2020. Disponível em: <<http://arxiv.org/abs/2002.05712>>.

ZHOU, D. **Thermal Image-Based Deer Detection to Reduce Accidents Due to Deer-Vehicle Collisions.** [s.l.: s.n.]. Disponível em: <<https://conservancy.umn.edu/handle/11299/144870>>.