

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
CAMPUS ARARANGUÁ**

Thiago Matias Martins

**APLICAÇÃO DE TÉCNICAS DE INTELIGÊNCIA
ARTIFICIAL NA DETECÇÃO DO COMPORTAMENTO
TIPO-DEPRESSIVO EM CAMUNDONGOS ATRAVÉS
DO TESTE DE SUSPENSÃO PELA CAUDA**

Araranguá

2018

Thiago Matias Martins

**APLICAÇÃO DE TÉCNICAS DE INTELIGÊNCIA
ARTIFICIAL NA DETECÇÃO DO COMPORTAMENTO
TIPO-DEPRESSIVO EM CAMUNDONGOS ATRAVÉS
DO TESTE DE SUSPENSÃO PELA CAUDA**

Trabalho de Conclusão de Curso submetido à Universidade Federal de Santa Catarina para obtenção de grau em Bacharel em Engenharia de Computação.

Orientador: Prof. Dr. Tiago Oliveira Weber

Araranguá

2018

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Martins, Thiago Matias

Aplicação de técnicas de inteligência artificial na detecção do comportamento tipo-depressivo em camundongos através do teste de suspensão pela cauda / Thiago Matias Martins ; orientador, Tiago Oliveira Weber, 2018.

67 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Campus Araranguá, Graduação em Engenharia de Computação, Araranguá, 2018.

Inclui referências.

1. Engenharia de Computação. 2. Processamento de Imagem. 3. Inteligência Artificial. 4. Teste de Suspensão pela Cauda. I. Oliveira Weber, Tiago. II. Universidade Federal de Santa Catarina. Graduação em Engenharia de Computação. III. Título.

Thiago Matias Martins

**APLICAÇÃO DE TÉCNICAS DE INTELIGÊNCIA
ARTIFICIAL NA DETECÇÃO DO COMPORTAMENTO
TIPO-DEPRESSIVO EM CAMUNDONGOS ATRAVÉS
DO TESTE DE SUSPENSÃO PELA CAUDA**

Este Trabalho de Conclusão de Curso foi julgado aprovado para a obtenção do Título de "Engenharia de Computação", e aprovado em sua forma final pela Universidade Federal de Santa Catarina.

Araranguá, 29 de Novembro 2018.



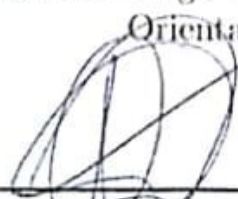
Profa. Dra. Eliane Pozzebon
Coordenador do Curso

Banca Examinadora:




Prof. Dr. Tiago Oliveira Weber

Orientador



Prof. Dr. Antonio Carlos Sobieranski



Prof. PhD. Rafael Cypriano Dutra

Este trabalho é dedicado ao meu avô, e seu filho.

AGRADECIMENTOS

Ao meu pai, Roque Mendes Martins, que serviu de inspiração e motivação para cada desafio completo nesta etapa. Também a minha mãe Dilmara Matias Martins, e minha irmã Júlia Matias Martins, que foram meu pilar emocional em toda essa caminhada. Ao meu orientador, Prof. Dr. Tiago Oliveira Weber, por aceitar o desafio, pela confiança, e por todo conhecimento transmitido.

Agradeço também ao Prof. PhD. Rafael Dutra, que forneceu infraestrutura necessária para o desenvolvimento deste projeto, e também aos membros de seu laboratório, LAIF - Laboratório de Autoimunidade e Imunofarmacologia. Especialmente para a Tauana Prestes Schmidt, mente brilhante que abriu as portas para este desafio, dedicou seu tempo, e compartilhou seu conhecimento, também como os videos de seus ratinhos.

Aos membros LAPIX - Image Processing and Computer Graphics Lab, pelo conhecimento compartilhado, e ao Prof. Antonio Sobieranski, que conduziu meu estágio, sempre sincero e compartilhando suas experiências.

Agradeço também aos meus amigos que colaboraram com o desenvolvimento deste trabalho. Eduardo Vianna foi indiscutivelmente magno, ortogando seus equipamentos para o processamento de dados, e também ao Gabis, que apresentou ferramentas ágeis para desenvolvimento, acelerando e potencializando o desenvolvimento deste trabalho.

Obrigado às minhas avós, que oraram muito por mim, para quem eu também já recorri em momentos de desamparo. E finalizo agradecendo a minha tia Fabiola Mendes Martins, a qual tem me acompanhado desde o exato primeiro dia acadêmico até o último; obrigado por tudo.

Nunca desmereça um menor cheio de sonho. (Xamã)

RESUMO

Segundo a Organização Mundial da Saúde, há pelo menos 300 milhões de pessoas com depressão no mundo; estimativas mostraram acréscimo de 15% de 2005 até 2015. Além das terapias psicológicas, pacientes sob uso de medicamentos apresentam melhora do quadro clínico. Estes medicamentos são avaliados por uma bateria de testes pré-clínicos para serem inseridos no mercado. Dentre os testes utilizados para a avaliação de candidatos para o controle da depressão, destaca-se o teste de suspensão pela cauda, objeto de estudo deste trabalho. Estes testes são realizados com camundongos, e requerem da percepção humana para a elaboração dos resultados quantitativos do teste. Entretanto, o fator humano é um agravante, apresentando variações dentre análises de um mesmo avaliador, ou para com outro. Neste trabalho, foi proposta a aplicação de um conjunto de técnicas de inteligência artificial em imagens do teste de suspensão pela cauda. Estas técnicas classificaram os movimentos dos camundongos e geraram resultados nos padrões utilizados em neste tipo pesquisa. Para o caso estudado, os resultados obtidos atingiram valores superiores a 90% de precisão em relação ao pesquisador usado como referência. Em relação com a detecção das patas, foram encontradas 87,7% das possíveis patas dentro do conjunto teste.

Palavras-chave: teste de suspensão pela cauda; inteligência artificial; processamento de imagem

ABSTRACT

According to the World Health Organization, there are at least 300 million people with depression in the world; estimates show an increase of 15% from 2005 to 2015. Beyond psychological therapies, patients under the use of drugs present clinical improvements. These drugs are evaluated by a wide set of preliminary tests before being placed on the market. Among the tests used for the evaluation of drugs to control depression, there is the tail suspension test, object of study of this work. These tests are performed with mices, requiring the human perception for the elaboration of the quantitative results of the test. However, the human factor is an aggravating factor, presenting variations between analyzes from the same appraiser, or from another one. In this work, it is proposed a set of artificial intelligence techniques applied to images of tail suspension test. These techniques are used to classify its movements and generating results with same patterns used in this kind of research. The results obtained reached values greater than 90% accuracy, using the researcher as reference. Regarding paw identification, 87.7% of possible paws were found within a test set.

Keywords: tail suspension test; artificial intelligence; image processing

LISTA DE FIGURAS

Figura 1	Fluxograma de câmera digital.....	27
Figura 2	Gráfico da relação a luz recebida pelo tempo em um sensor	29
Figura 3	Imagens comparativas da distância focal	30
Figura 4	Fluxograma de árvore aleatória.	34
Figura 5	Hiperplano com Margens	35
Figura 6	Fluxograma do projeto.....	41
Figura 7	Representação da aquisição de video em teste de suspensão pela cauda.....	44
Figura 8	<i>Software LabelImg.</i>	45
Figura 9	Detecção de 3 supostas patas.	46
Figura 10	Detecção de pata errada.	46
Figura 11	Comparação das variações.	48
Figura 12	Gráfico com a tendência gerada.....	51
Figura 13	Matrix confusão do dataset com 81.17% de acurácia....	58
Figura 14	Matrix confusão do dataset com 90.53% de acurácia....	59

LISTA DE TABELAS

Tabela 1	Configurações <i>Canon EOS Rebel T6</i> utilizadas nos experimentos.	43
Tabela 2	Arquivo <i>CSV</i> gerado após classificação de objetos.	45
Tabela 3	Relação de detecção de patas.	47
Tabela 4	Variação de posição das patas esquerda e direita, sem presença de valores faltantes.	50
Tabela 5	Variações de movimentos e informação de dados faltantes.	52
Tabela 6	Classificação realizada por especialista.	53
Tabela 7	Comparação de resultados do <i>SVM</i> com variações de parâmetros e conjunto de dados.	55
Tabela 8	Comparação de resultados do <i>KNN</i> com variações de parâmetros e conjunto de dados.	56
Tabela 9	Comparação de resultados do <i>Random Forest</i> com variações de parâmetros e conjunto de dados.	56
Tabela 10	Desempenho do sistema para o caso sem aplicação de filtro.	58
Tabela 11	Desempenho do sistema para o caso com aplicação de filtro.	60

SUMÁRIO

1 INTRODUÇÃO	21
1.1 PROBLEMÁTICA	22
1.2 OBJETIVO	22
1.2.1 Objetivo Geral	22
1.2.2 Objetivos Específicos	22
1.3 JUSTIFICATIVA	23
1.4 ESTADO DA ARTE	23
1.5 METODOLOGIA	24
2 REVISÃO TEÓRICA	27
2.1 AQUISIÇÃO DE QUADROS (<i>FRAMES</i>)	27
2.1.1 Ruídos em <i>Frames</i>	27
2.1.2 Velocidade do Obturador (<i>Shutter Speed</i>)	28
2.1.3 Abertura	30
2.1.4 <i>ISO</i>	31
2.2 APRENDIZADO DE MÁQUINA	31
2.2.1 Categorização do Aprendizado de Máquina	31
2.2.1.1 Supervisionado	32
2.2.1.2 Não-Supervisionado	32
2.2.1.3 Semi-Supervisionado	32
2.2.2 Técnicas de Classificação Supervisionada	33
2.2.2.1 Random Forest	33
2.2.2.2 Support Vector Machines	33
2.2.2.3 KNN	35
2.2.3 Técnicas para Detecção de Objetos	36
2.2.3.1 Arquitetura Single Shot MultiBox Detector	36
2.2.3.2 Arquitetura <i>Faster R-CNN</i>	36
2.2.3.3 Extrator de Parâmetros <i>Inception ResnetV2</i>	37
2.2.3.4 Extrator de Parâmetros <i>MobileNet</i>	37
2.3 TESTES DE FÁRMACOS E DEPRESSÃO	38
2.3.1 Depressão	38
2.3.2 Uso de animais	39
2.3.3 Tail Suspension Test	39
3 DESENVOLVIMENTO	41
3.1 AQUISIÇÃO DOS DADOS	42
3.1.1 Câmera	42
3.1.2 Gravações	43
3.1.3 <i>Labelling</i> : Etiquetando Objetos	43

3.1.4 Treinamento da Rede e Detecção	44
3.1.5 Pré-processamento dos dados	47
4 RESULTADOS	55
4.1 <i>SVM - SUPPORT VECTOR MACHINES</i>	55
4.2 <i>KNN - K-NEAREST NEIGHBOR</i>	55
4.3 RANDOM FOREST	56
4.4 FILTRO	56
5 CONCLUSÃO	61
REFERÊNCIAS	63

1 INTRODUÇÃO

A regulamentação de medicamentos no Brasil é exercida pela Agência Nacional de Vigilância Sanitária (ANVISA). Dentre os procedimentos para a aprovação de novos medicamento, são exigidos testes em animais, para conhecimento de efeitos, condições e profilaxia de doenças (ANVISA, 2018). Com isso, a ANVISA requer estudo prévio com a avaliação das propriedades biológicas e moleculares do composto. Após estudo prévio, os animais entram em testes para a avaliação de 5 quesitos relacionados a reações do composto com o sistema vivo, respondendo perguntas de como a droga é absorvida pelo organismo, como funciona a distribuição da droga no tecido muscular, como é a metabolização, como funciona a sua eliminação e quais os efeitos tóxicos no organismo.

O teste de suspensão pela cauda (*Tail Suspension Test*, em inglês), é um teste realizado através da suspensão de um camundongo pela cauda. A execução é realizada por profissional habilitado, suspendendo o animal por cinco minutos e observando seus comportamentos durante a suspensão. Para a análise da depressão e ansiedade do animal, o observador registra o tempo no qual o animal apresenta agitação, observando suas patas traseiras, e o tempo remanescente considera-se estado de depressão. Este teste é utilizado para a avaliação de compostos aplicados nos camundongos, e também para a análise geral do estado do animal.

Com o alto desempenho de computadores para processamento de dados, começaram a surgir mais soluções em diagnósticos assistidos por computadores. Estas soluções, também conhecidas por CAD (*computer-aided diagnosis*, em inglês), utilizam de processamento de imagem e técnicas de aprendizado de máquina, que reconhecem tons, tamanhos e padrões de doenças, e comportamentos.

As ferramentas de processamento de imagem possibilitam extrair características de vídeos e imagens, bem como uma rica análise dos detalhes das imagens. Estes dados coletados permitem ao programador formas consistentes de fazer reconhecimentos de padrões, e assim poder obter resultados desejados. Porém, com a execução de projetos mais difíceis, e com necessidade de classificações, atrelou-se o uso dos dados obtidos pelo processamento de imagem, com técnicas de inteligência artificial.

Após a Segunda Guerra Mundial, os modelos estatísticos evoluíram para modelos inteligentes, utilizando técnicas que tentavam re-

produzir a forma cognitiva humana. Estas técnicas, hoje amplamente usadas para processamento de dados, que visam obter relações, classificações ou previsões, também são utilizadas como ferramentas para soluções em visão computacional.

1.1 PROBLEMÁTICA

Os testes em animais não podem ser realizados mais de uma vez com o mesmo animal, na grande parte dos testes aplicados. Tornando cada experimento um dado muito importante para a análise das reações no animal que está sob efeito de novos compostos. Os testes realizados por especialistas da área possuem defasagem de resultados devido as restrições humanas. Esta percepção adquirida empiricamente pelos profissionais pode ser também ensinada ao computador por técnicas conhecidas como aprendizagem de máquina, as quais podem aprender e perceber padrões de dados e então replicarem para casos reais.

1.2 OBJETIVO

1.2.1 Objetivo Geral

Aplicar técnicas de processamento de imagem e aprendizado de máquina para automação do teste de suspensão pela cauda em camundongos, a fim de validar compostos no controle da depressão e da ansiedade.

1.2.2 Objetivos Específicos

Considerando o desenvolvimento do trabalho e o objetivo geral apresentado, destacam-se os seguintes objetivos específicos:

- Criar banco de dados de vídeos com duração de 6 minutos de camundongos suspenso pela cauda;
- Treinar rede neural convolucional para aquisição de padrões.
- Tratar dados faltantes decorrente da aquisição de dados.
- Identificação de padrões de mobilidade e imobilidade dos camundongos brancos.

1.3 JUSTIFICATIVA

O desenvolvimento de sistemas computacionais para diagnósticos médicos apresentam crescente desenvolvimento devido aos erros humanos, que apresentam fadiga, variações em níveis de concentração e padrões de análises advindo de diferentes observadores. A necessidade de precisão para diagnósticos médicos ou para desenvolvimentos de novos fármacos emerge junto ao avanço do potencial de processadores e, principalmente, das placas gráficas, que permitem processamento alto de dados.

1.4 ESTADO DA ARTE

O projeto proposto faz uma abordagem de três grandes áreas de estudos, processamento de imagem, detecção de objetos e tratamento de dados.

Para a detecção de objetos, os atuais detectores consistem em um sistema que funciona em duas etapas (LIN et al., 2018), como por exemplo, a R-CNN. Entretanto, na RetinaNet, uma rede única apresentou resultados melhores que Faster R-CNN, e também de outros modelos de um estágio como YOLOv2 e SSD (LIN et al., 2018). Já a extração de informações das imagens, traz Inception-Resnet-v2 com o melhor desempenho, próximo a 96.84% de precisão, dado um conjunto teste (TEICHMANN et al., 2018).

Após a detecção dos dados, a classificação é feita de modo supervisionado, porém existem alguns fatores relevantes, como a quantidade de características do conjunto de dados, e a distribuição treino/teste. A confiabilidade do conjunto resposta para as classificações também podem interferir, como neste trabalho, que a classificação do treino é elaborado por um humano passível de falhas, devido ao alto nível de abstração da análise.

Apesar destas possíveis variações, trabalhos mostram que a técnica de *k-nearest neighbor* apresenta maior precisão, sensibilidade, especificidade e acurácia (ABDULLAH; YAAKOB; IBRAHIM, 2018). Entretanto, em problemas próximos ao deste trabalho, tal como a previsão de doenças cardíacas, a classificação possui algumas variações dentro do seu conjunto. Devido a própria fisiologia humana, a classificação pode aparentar diferenças, e *Random Forest* apresentou melhores resultados na classificação das predições referentes a doenças cardíacas (HASAN et al., 2018). Esta técnica cria árvores com parcelas do conjunto de

dados original, e assim podendo ignorar algumas classificações erradas, ou desconsiderar pontos fora da curva.

Não é do conhecimento do autor trabalhos que testem mobilidade ou imobilidade em camundongos submetidos ao teste de suspensão pela cauda.

1.5 METODOLOGIA

Para atingir os objetivos apresentados neste trabalho, que visa o desenvolvimento de um software para processamento e análise de dados, provindos de vídeos de camundongos submetidos ao teste de suspensão pela cauda. Inicialmente foi realizado estudo bibliográfico sobre a execução de testes em camundongos suspensos pela cauda, e então foi criado o modelo do estudo.

A identificação de movimento é dependente do movimento das patas traseiras, e um software para catalogação foi desenvolvido, sendo criadas mais de 1.000 frames 640 pixels por 360 pixels. Com estas imagens, e utilizando *Faster R-CNN*, foi treinada uma rede neural para a aquisição da posição das patas, para posteriormente serem classificadas como movimento brusco ou não.

Foi desenvolvido um software para a aquisição das respostas quadro a quadro dos vídeos, em linguagem *Python*, para classificação, no qual foi utilizado árvore aleatória, (*Random Forest*, em inglês), uma técnica de aprendizado de máquina.

O desenvolvimento deste busca resolver os problemas de acurácia dos resultados, sem afetar a forma tradicional de análise do teste de suspensão pela cauda. Definiu-se a utilização de aprendizado de máquina como recurso, para permitir o computador discernir entre movimentos de agitação e ou imobilidade do animal. Os estados de agitação do animal são definidos principalmente pelas ações de suas patas traseiras, requerendo sobretudo reconhecimento do software do que representam as patas traseiras do camundongo.

Para o reconhecimento das patas traseiras, adotou-se a utilização de aprendizagem profunda, (*deep learning*, em inglês), para reconhecer os padrões que remetem às patas traseiras de camundongos, devido a alta capacidade das técnicas de *deep learning*, através de treinos reconhecer os padrões nos objetos em questão, e então apontar as posições dos membros inferiores dos animais. As redes neurais que fazem parte do método de aprendizado *deep learning* requerem números de imagens para aprendizado do objeto de acordo com a variação física que o ele-

mento pode apresentar. Para apresentar à rede neural o que são patas, foram escolhidas aleatoriamente 10.000 quadros de vídeos gravados, e então gerado arquivo *.csv* informando a posição do contorno das patas em cada quadro.

A implementação da rede neural para o treino do *software* foi realizado através de um conjunto de biblioteca, chamado *TensorFlow*. *TensorFlow* é uma biblioteca de código aberto de alta performance para computação numérica, que permite o desenvolvimento em várias plataformas, como *GPUs*, *TPUs* ou *CPUs*, como usado neste trabalho. Estabeleceu-se uma rede neural chamada *MobileNet SSD* para os testes iniciais devido à sua arquitetura simplificada, que usa convoluções separáveis profundas para construir redes neurais profundas leves, tornando o sistema mais leve para o processamento.

A localização das patas traseiras dos camundongos permite a progressão da solução do problema de classificação do estado dos animais. Como estes estados estão ligados com a posição e o grau de movimento que os mesmos apresentam, a abordagem tomada foi a geração de tabela com as posições *X* e *Y* de cada uma das patas e a diferença para com a última posição.

Essa tabela gerada com posições serviu de entrada para a segunda parte do programa, que busca classificar estes posicionamentos e suas variações como estado de movimento ou não. Contudo, para a classificação desses estados, é necessário ensinar para a máquina os parametros observados por profissionais durante a análise do testes de suspensão pela cauda julgam ser esses. Para isso, um reprodutor de vídeo, com configurações abertas ao utilizador, como seleção quadro a quadro e um botão classificador foi desenvolvido, permitindo ao técnico julgar qual o estado do camundongo a cada quadro do vídeo, gerando outra tabela de estados para servir como comparativo para os treinos da rede.

Este trabalho não trata a análise do pesquisador como uma regra de ouro, devido às interpretações que cabem ao problema, mas busca atender as regras da análise de teste com camundongos suspensos pela cauda, e através de algumas amostras encontrar uma padronização do pesquisador e estabelecer uma regra para o próprio sistema.


2 REVISÃO TEÓRICA

Este capítulo informa sobre a utilização de animais em testes com novos compostos, em específico sobre o procedimento do teste de suspensão pela cauda. Ainda, são explanadas as ferramentas e técnicas utilizadas no desenvolvimento deste trabalho.

2.1 AQUISIÇÃO DE QUADROS (*FRAMES*)

A aquisição de quadros de vídeo são realizados através de câmeras filmadoras digitais, e passam por algumas etapas até a definição final da intensidade dos valores de cada píxel do quadro gerado. Há três variações na configuração das câmeras que são abordadas neste trabalho: a velocidade do obturador, o ISO, e a abertura das lentes. Para cada uma dessas variáveis, há um impacto particular em cada quadro gerado e, em alguns casos, ruídos indesejáveis.

Figura 1 – Fluxograma de câmera digital.



Fonte: Adaptado de (TELLEEN et al., 2007).

2.1.1 Ruídos em *Frames*

Neste trabalho são abordados três formas de ruídos em imagens, o efeito borrado (*blur*, em inglês), o efeito fantasma e a granulação da imagem. O efeito borrado nas imagens ocorre devido a erro no foco, movimento do objeto ou vibração do operador da câmera, dentre outros (SU; LU; TAN, 2011). Para prevenir esse efeito, é necessário um menor tempo de exposição do sensor de captura (SCHLEICHER; ZAGAR, 2010). A ocorrência de *blur* também esta sujeita aos valores extremos de luminosidade que o ambiente pode apresentar, além da velocidade do objeto filmado (DABÓCZI, 2016).

O efeito fantasma, presente em algumas imagens é frequente-

mente gerado quando há presença de objetos em movimento (IM; LEE; PAIK, 2011), e apresentam a projeção do mesmo objeto em mais de um local. O fenômeno do movimento paralaxe ocorre devido a sensação de diferença de velocidade entre objetos em movimentos em relação ao observador (GRAHAM et al., 1948). Este fenômeno também acontece devido ao movimento e aparência 3D dos objetos.

Em casos com baixa luz e alta velocidade de obturador, há a presença do efeito granulação nas imagens. Este efeito ocorre devido a baixa intensidade de luz, e pouco tempo de abertura do obturador, havendo uma falta de informação completa da imagem. Este efeito granulado em imagens é geralmente apresentado através de partículas brilhantes semelhante a poeira e dificilmente discerníveis como grânulos individuais (LANGLEY et al., 2001). A redução desse efeito de granulação é apresentada quando há aumento da abertura da câmera (HUNG; LIANG, 1979).

2.1.2 Velocidade do Obturador (*Shutter Speed*)

A tecnologia empregada em câmeras permite ajustes em vários aspectos de fotos e vídeos. Hoje, câmeras de vídeo (inclusive as que são utilizadas neste trabalho) possuem opções de ajustes mais rebuscados, como alterações de exposição na iluminação e tempo de obturador. Profissionais da área de filmagem tendem a tratar seus problemas de *blur* (do inglês, borrão) com a fixação da câmera, ou então abrindo o *shutter* (do inglês, obturador) da câmera, dependendo do que está sendo filmado. A falta de ajuste permite um borrão em todo o quadro, ou apenas no objeto em movimento, dando uma sensação de ação em cada quadro. O erro no ajuste das funções da câmera podem deixar uma baixa exposição a luz e gerando imagens com alta granulação, e com pouca riqueza de detalhes. Isso acontece porque o sensor de luz integra toda luz recebida enquanto o obturador está aberto, e em caso de movimento há a integração de pontos em mais de um lugar, gerando o borrão.

Os vídeos apenas registram os quadros em intervalos discretos, e não de forma contínua, pois os quadros que compõem os vídeos respeitam o tempo do obturador para captar a luz e integrar em uma foto. A imagem é representada pela fórmula 2.1, na qual para cada pixel do sensor de imagem, a luz é integrada sobre um intervalo de tempo delimitado pelo valor do obturador, que começa no tempo T quando o obturador é aberto.


$$imagem(\vec{X}) = \int_T^{T+\Delta T} luz(t, \vec{X}) dt \quad (2.1)$$

A quantidade de luz recebida pelo sensor de luz no tempo t na posição \vec{X} é representado por $luz(t, X)$, o tempo do obturador por ΔT e o tempo inicial por T (TELLEEN et al., 2007).

O tempo de exposição do obturador está ligado a quantidade de ruído provindo de movimento, com um tempo considerado alto perante ao objeto em observação, a quantidade de fótons que chegam ao sensor podem causar duplas imagens e sensações de movimento na imagem final. E com a finalidade de não deixar uma alta exposição do sensor de luz, é possível diminuir o tempo de exposição e aumentar a quantidade de amostras, tal como a fórmula 2.2.

$$imagem(\vec{X}) = \sum_{k=0}^n \int_{T_k}^{T_k+\Delta T} luz(t, \vec{X}) dt \quad (2.2)$$

Figura 2 – Gráfico da relação a luz recebida pelo tempo em um sensor



Fonte: Adaptado de (TELLEEN et al., 2007).

A Figura 2 representa a diferença entre as aberturas do obturador pelo tempo, mostrando a aquisição contínua de dados, e também as segmenta, que recebem menos dados, e coletam mais amostras, permitindo assim menos borrões, e menos objetos duplas.

2.1.3 Abertura


A abertura da lente regula a quantidade de luz que é captada pelo sensor de luz da câmera. Essa variável de ajuste da câmera, a abertura, está diretamente relacionada à profundidade do campo; como exemplo, uma grande abertura resulta em uma redução dessa profundidade (MIAO; SIM, 2005), conforme a figura 3.

O valor f -número N , também conhecido por f -stop ou $f/\#$, apresentado nas câmeras com ajuste de abertura, é dado por (SCHLEICHER; ZAGAR, 2010):

$$N = \frac{f}{D} \quad (2.3)$$

Na fórmula 2.3, D é referente ao diâmetro da pupila de entrada, e f é a largura focal das lentes.

Figura 3 – Imagens comparativas da distância focal .



Fonte: Adaptação de (ELIZABETH, 2016).

2.1.4 *ISO*

O *ISO* descreve a sensibilidade absoluta de luz no sensor de imagem da câmera (BABU; SUNITHA, 2010). Em baixas condições de luz, a configuração *ISO* ajuda a captura de imagem, porém ter um alto *ISO* resulta em uma imagem ruidosa, por que também amplifica o ganho do ruído da imagem (BHASKAR; KHAN et al., 2016). Geralmente os valores *ISO* são divididos por um fator de 2, que implica com que fotos com *ISO* 100 levem metade do tempo para atingir o mesmo nível de exposição de uma imagem com *ISO* igual a 50 (BABU; SUNITHA, 2010).

2.2 APRENDIZADO DE MÁQUINA

Aprendizado de máquina é um campo de pesquisa dedicado ao estudo formal da aprendizagem de sistemas (BOUSQUET; LUXBURG; RÄTSCH, 2011). Na prática, o aprendizado de máquina é uma área da inteligência artificial que estima eventos futuros baseados em experiências obtidas a partir de informações anteriores (BÜLBÜL; ÖZKAN et al., 2011). Estas estimativas são geradas através de treinos realizados em conjunto de dados, com atributos dos elementos, podendo ser classificados, que competem ao aprendizado supervisionado, ou não ser classificados, sendo os não supervisionados.

Há muitos fatores que alteram o sucesso do aprendizado de máquina, como, por exemplo, a qualidade dos dados, dependendo da relevância ou redundância da informação, bem como se os dados são ruidosos ou não confiáveis (HALL, 1999). A medida de desempenho padrão da máquina de aprendizado é a precisão (KUBAT; HOLTE; MATWIN, 1998). Essa precisão é a porcentagem de exemplos classificados corretamente.

2.2.1 Categorização do Aprendizado de Máquina

As técnicas de aprendizado de máquina aprendem padrões através de conjuntos de dados fornecidos ao sistema, dependendo da modulação dos conjuntos de dados. O treino pode ser classificado em principalmente três tipos: treinos supervisionados, não-supervisionados, e semi-supervisionados.

2.2.1.1 Supervisionado

O aprendizado supervisionado necessita de conhecimento prévio do resultado para cada conjunto de atributos de um objeto. As técnicas de aprendizado supervisionado utilizam dos pares das entradas e saídas para efetuarem os treinos durante o período de treinamento. O treino supervisionado permite a avaliação dos padrões encontrados durante o treino. Durante o treino, a cada entrada, é gerada uma saída pelo classificador, e então a mesma é comparada com a saída fornecida pelo conjunto de treinamento, e avaliado se obteve sucesso. Estes conjuntos de dados são considerados muito caros, devido aos amplos conjuntos de dados que muitas vezes dependem de um humano detentor do conhecimento relacionado com a classificação (HÄNSCH; HELLWICH, 2009).

2.2.1.2 Não-Supervisionado

Diferente do aprendizado supervisionado, o não-supervisionado não contém a presença de etiquetas de classe. São utilizados apenas dados com atributos para descobrir a modulação do conjunto. Contrário ao supervisionado, o não-supervisionado não sabe exatamente o que vai aprender, e por isso utiliza todos os dados do conjunto, e gera a estrutura do aprendizado, porém não possuindo garantia dos resultados.

2.2.1.3 Semi-Supervisionado

Aprendizado semi-supervisionado tem atraído bastante interesse recentemente, e novas propostas tem sido apresentadas (ZHU; GHAHRAMANI; LAFFERTY, 2003). O conceito de integrar todos os dados, unindo dados classificados e não classificados são geralmente referenciados ao aprendizado semi-supervisionado (LI; LIAO; CARIN, 2009). Este estilo de classificação lida com métodos que exploram dados não classificados e também dados classificados que melhoram o seu desempenho (WU; LU; WANG, 2010).

2.2.2 Técnicas de Classificação Supervisionada

Neste tópico são apresentadas duas técnicas de classificação supervisionada que serão utilizadas neste trabalho.

2.2.2.1 Random Forest

Random Forest é um classificador combinatório, que utiliza de um método chamado *bootstrap* para criar subconjuntos dentro de conjuntos de dados originais, que são base da árvore de decisão para os treinamentos. A árvore de decisão utiliza de outros subconjuntos, gerados através da escolha aleatória de atributos de cada classe do *dataset*, para então haver uma maior diversidade no treinamento. Após o treino de cada um dos *sets* de treinamento, é estabelecida a classificação por meio de votos, conforme a figura 4.

Por definição, *random forest* é um classificador consistente de uma coleção de classificadores de árvores estruturadas. $\{h(x, \Theta_k), k=1, \dots\}$. Θ_k são vetores aleatórios independentes identicamente distribuídos, e cada árvore atribui um voto para a classe mais popular de uma entrada x (BREIMAN, 2001).

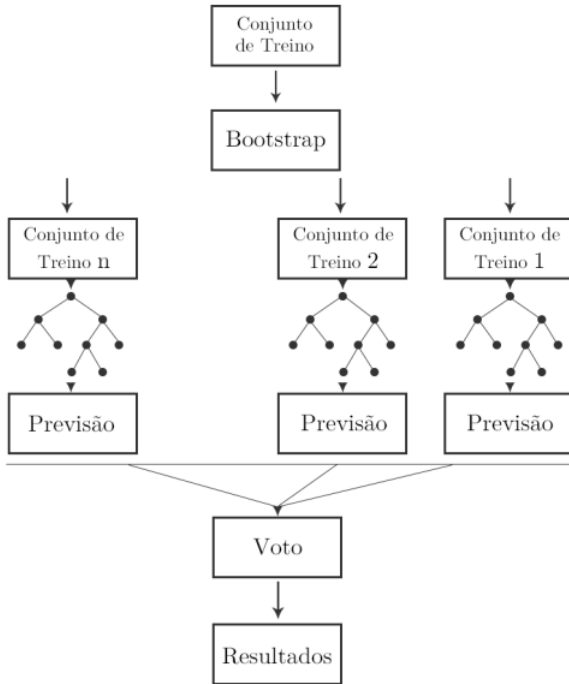
2.2.2.2 Support Vector Machines

Support Vector Machines (SVM) é uma técnica de classificação de dados que pretende produzir um modelo baseado nos dados de treinamento, que preveja os valores alvos dos dados de teste, dados apenas os atributos dos próprios dados de teste. Dado um conjunto de dados com pares classe-instância (x_i, y_i) , $i = 1, \dots, l$ onde $x_i \in \mathbb{R}^n$ e $y \in \{1, -1\}^l$, o SVM busca a solução para o seguinte problema de otimização (WANG; LU, 2006):

$$\begin{aligned} \min_{w, b, \xi} \quad & \frac{1}{2} w^T w + C \sum_{i=1}^l \xi_i \\ \text{subject to} \quad & y_i (w^T \phi(x_i) + b) \geq 1 - \xi_i, \\ & \xi_i \geq 0. \end{aligned} \quad (2.4)$$

Há um mapeamento no espaço dimensional dos vetores de treinamento x_i pela função ϕ . E então pela natureza da técnica, *SVM* encontra um hiperplano linear separador, com uma margem máxima no seu maior espaço dimensional, conforme figura 5. O parâmetro C

Figura 4 – Fluxograma de árvore aleatória.




Fonte: Adaptado de (MAN; JI; ZHANG, 2018).

> 0 refere a penalidade do erro. Outro parâmetro importante da técnica, são os *Kernels*, que apresentam diferentes resultados mediante ao problema proposto, os 4 básicos kernels compreendem aos:

- linear
- poly
- rbf
- sigmoid

Figura 5 – Hiperplano com Margens .



Fonte: Adaptado de (CORTES; VAPNIK, 1995).

2.2.2.3 KNN

O método *k-nearest neighbors (kNN)* é um dos mais simples e antigos para reconhecimentos de padrões. A classificação de um conjunto de treinamento neste método dado um elemento sem classe, ocorre através da maioria das classes k , vizinhas mais próximos. A performance do classificador *kNN* depende essencialmente da maneira que as distâncias são calculadas entre os diferentes exemplos. Em casos que não apresentem conhecimento prévio, são utilizados cálculos Euclidianos das distâncias.

A fórmula que descreve a equação Euclideana dado um conjunto X contendo m amostras, com cada amostra apresentando n atributos: $X_i = (x_{i1}, x_{i2}, \dots, x_{in}) \{i = (1, 2, \dots, m)\}$ para uma amostra Y a ser classificada: $Y = (y_1, y_2, \dots, y_n)$ (JIANG; DENG, 2010).

$$D(Y, X_i) = \sqrt{\sum_{j=1}^n (y_j - x_{ij})^2} \quad (2.5)$$

Este método funciona mediante aos vizinhos mais próximos. Sua classificação é definida através da classe da maioria dos k -vizinhos mais próximos. Contudo, em casos com apenas duas possíveis classificações, como neste trabalho, existem a possibilidade de empates e indefinições pelo algoritmo, então estabelece-se uma boa prática a utilização de

valores ímpares para a variável k .

2.2.3 Técnicas para Detecção de Objetos

2.2.3.1 Arquitetura Single Shot MultiBox Detector

A técnica *Single Shot MultiBox Detector* (*SDD*, do inglês) é um detector de imagem baseado em uma rede convolucional *feed-forward*, que atribui pontuações para a presença de cada categoria de objeto em cada caixa delimitadora (do inglês, *bouding box*) e gera ajustes nas caixas para melhor corresponder à forma do objeto (LIU et al., 2016). E também combina as previsões de vários *feature maps* de diferentes resoluções para lidar com objetos de variados tamanhos (SHYAM; KOT; ATHALYE, 2018).

SSD não reutiliza camadas já calculadas, mas constrói uma pirâmide a partir do topo da rede e então adiciona novas camadas (LIN et al., 2017). Para cada nova camada que opera em uma escala única do *feature map*, é utilizado um modelo convolucional diferente para prever as detecções (LIU et al., 2016).

Para elaboração final das caixas delimitadoras, é levado em consideração as detecções de proporções diferentes, em que por meio de pontuação é gerado as caixas delimitadoras no fim da detecção.

2.2.3.2 Arquitetura *Faster R-CNN*

Fast Region-based Convolutional Network method (*FastR-CNN*) é uma rede para detecção de objetos, que emprega inovações perante a rede *R-CNN*, apresentando maior velocidade de treinamento e testes, e também aumentando a precisão de detecção (GIRSHICK, 2015).

A rede recebe como entrada uma imagem inteira, e um conjunto de propostas de objetos. Então primeiramente a rede processa a imagem inteira com várias camadas convolucionais e camadas *max pooling* para gerar um *conv feature map*. Para cada proposta de objeto, uma camada de *pooling* da região de interesse (*region of interest, ROI*) extrai um vetor de tamanho fixo de características do *feature map*. Cada vetor de característica alimenta uma sequência de camadas completamente conectadas (em inglês *layers fully connected, fc*), gerando duas camadas de saída. Uma que estima a probabilidade *softmax* sobre K classes de objetos mais uma classe que pega todo o *background*, e outra

saída que gera os quatro valores reais, referente aos *bouding boxes* para cada K classe objeto.

2.2.3.3 Extrator de Parâmetros *Inception ResNetV2*

A técnica *ResNet* possui como ideia principal a adição de conexões residuais entre as camadas, para ajudar na otimização dos modelos muito profundos, do inglês *very-deep* (SUN et al., 2017). A *Inception ResNet-V2* apresentada com variação da *ResNet*, possui melhor performance com menos camadas (ZHANG et al., 2017). E combina os benefícios das conexões residuais, com a eficiência das unidades *Inception* (SZEGEDY et al., 2017).

Com a aplicação do módulo *Inception*, há uma maior variação estrutural em cada unidade. O método é baseado em adicionar conexões residuais entre as camadas. Segundo o autor (ZHANG et al., 2017), *Inception ResNet-V2* opera com diferentes resoluções de espaço, (35x35, 17x17,e 8x8), contendo respectivamente 5, 10 e 5 unidades residuais *Inception*.

2.2.3.4 Extrator de Parâmetros *MobileNet*

O modelo *MobileNet*, que foi projetado para dispositivos com recursos limitados (BUDIHARTO et al., 2018), é baseado em convoluções separáveis em profundidade, apresentado na forma de convoluções fatorizadas que fatorizam a convolução padrão em convoluções profundas e em convoluções 1x1, chamadas de convoluções pontuais, em inglês *pointwise* (HOWARD et al., 2017). Para as convoluções em profundidade, é aplicado um filtro distinto em canal de resposta (GAVAI et al., 2017).

Há uma fatoração em duas camadas para a redução do modelo e computação dos dados. Uma das camadas é utilizada para filtrar e outra para combinar, exceto pela primeira camada, que utilizada da convolução completa, do inglês, *full convolution*, *MobileNet* é construído em convoluções separáveis profundas, e tem sua arquitetura definida pela tabela X (HOWARD et al., 2017).

2.3 TESTES DE FÁRMACOS E DEPRESSÃO

2.3.1 Depressão

A depressão é um transtorno mental que, segundo a OMS, caracteriza-se por um estado melancólico persistente com perda de interesse na realização de atividades, sonolência e apetite alterado, cansaço e fadiga, baixa autoestima com sentimento de culpa e múltiplas queixas físicas idiopáticas. Em consequência, esse conjunto de sintomas leva a incapacidade de realizar atividades diárias, ausência de convívio social, familiar e afastamento das atividades ocupacionais. Em grau mais severo leva ao suicídio (ORGANIZATION et al., 2002).

É considerado um grave problema de saúde pública, estimando-se que 300 milhões de pessoas são afetadas globalmente pela depressão (OMS, 2017). No Brasil, segundo a Pesquisa Nacional por Amostra de Domicílios (PNAD), estima-se que a depressão atinja 7,6% da população brasileira em 2013 (SZWARCOWALD et al., 2016).

A depressão afeta tanto o indivíduo como a sociedade, e isso frequentemente é observado através de indicadores como o DALY (*Disability Adjusted Life of Years* – Anos de Vida Perdidos Ajustados por Incapacidade) que permite medir o impacto dos problemas de saúde que afetam a qualidade de vida dos indivíduos, ou sua incapacidade por anos de vida vividos com incapacidade YLD (*Years Lived with Disability*) (ORGANIZATION et al., 2017). Dados mostram que a depressão é a maior YLD no mundo (7,5%), e em sexto a ansiedade (3,4%) (ORGANIZATION et al., 2017).

Além de terapias psicológicas, o tratamento da depressão se dá através de medicamentos antidepressivos, que no geral não são a primeira terapia de escolha dado seus efeitos colaterais e sobrecarga em diversos outros sistemas do corpo que também podem estar comprometidos, visto que o indivíduo é um conjunto de sistemas interligados (TENG; HUMES; DEMETRIO, 2005).

Muito estuda-se a respeito do desenvolvimento de novos medicamentos eficazes com menos efeitos adversos. Esses medicamentos desenvolvidos em laboratório necessitam passar por diversos testes para confirmar sua eficácia e efeitos, e que são realizados por meio de experimentação animal.

2.3.2 Uso de animais

A pesquisa pré-clínica ou de experimentação animal é entendida como realização de intervenções em animais vivos ou recém-abatidos com o objetivo de beneficiar o conhecimento científico. É utilizada para avaliar a segurança, tolerabilidade e eficácia de novas drogas previamente desenvolvidas *in vitro*, e a partir deste estudar o mecanismo de ação, nos psicofármacos em questão, os mecanismos neurobiológicos envolvidos nos transtornos mentais como a depressão.(ANDREATINI, 2002; GUIMARÃES; FREIRE; MENEZES, 2016)

Muito ainda questiona-se em relação a utilização de animais em pesquisa, principalmente pela comunidade defensora dos animais, por isso em 2008 no Brasil, foi aprovada a Lei 11.794, chamada de Lei Arouca para normatização de procedimentos científicos com animais. Em conjunto com esta foram criados o Concelho Nacional de Controle de Experimentação Animal (CONCEA) e a Comissão de Ética para uso de animais (CEUA) presente obrigatoriamente em cada instituição de ensino que faça utilização de pesquisa experimental.(ANDREATINI, 2002)

2.3.3 Tail Suspension Test

O teste de suspensão pela cauda *TST* (*Tail Suspension Test*) foi descrito inicialmente por Steru, em 1985, para triagem de drogas antidepressivas, e até hoje é aceito e muito utilizado na prática laboratorial com animais (CRYAN; MOMBÉREAU; VASSOUT, 2005). O teste consiste em submeter o animal a suspensão pela cauda e quantifica o comportamento de fuga por ele adotado, quanto maior o tempo de imobilidade menor o comportamento de luta ou fuga indicativo de comportamento tipo-depressivo. O teste fornece informações sobre a capacidade de lidar com situações estressantes, e que pode ser alterado por manipulações farmacológicas (STERU et al., 1985; CRYAN; MOMBÉREAU; VASSOUT, 2005).

De acordo com Steru et al, o teste consiste na suspensão do animal pela cauda, preso com uma fita a 1 cm da ponta da cauda, com a distância do chão de 50 cm, por um tempo total de 6 minutos. É cronometrado o tempo de latência correspondente ao período em quem o animal levou para ficar imóvel pela primeira vez, o tempo de imobilidade que corresponde ao tempo em que o animal ficou imóvel dentro do tempo total e o número de vezes em que o animal ficou

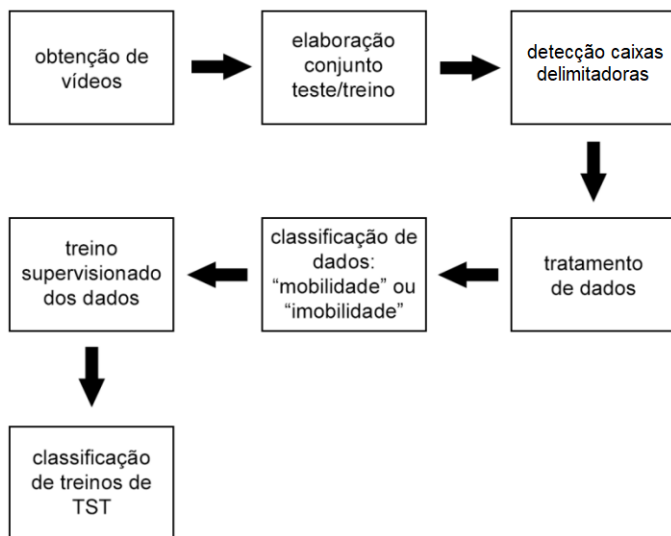
imóvel.(CRYAN; MOMBÉREAU; VASSOUT, 2005)

Ainda, Can e colaboradores em 2012, acrescentam que oscilações pendulares e movimentos com as patas dianteiras sem movimento das traseiras não constituem mobilidade.(CAN et al., 2012) Esse teste assim como o teste de nado forçado é o melhor para avaliação da eficácia antidepressiva de drogas (MINEUR; BELZUNG; CRUSIO, 2006).

3 DESENVOLVIMENTO

Este trabalho foi desenvolvido seguindo fluxograma demonstrado na Figura 6.

Figura 6 – Fluxograma do projeto.



Fonte: Autor.

O primeiro passo foi a obtenção de vídeos dos camundongos durante o processo dos testes de suspensão pela cauda, para esse projeto, foram utilizados apenas camundongos brancos de linhagem Swiss para treinar o computador para reconhecer as patas do animal. Após os parâmetros treinados do conjunto teste/treino, o sistema faz o reconhecimento das patas e informa a posição das mesmas. Com as restrições estabelecidas na detecção de patas, selecionando somente patas com valores superiores a 90%, há presença de dados faltantes, e então o conjunto de resultados é interpolado e então submetido ao treino de classificação supervisionado. Este teste supervisionado, possui sua classificação provinda de um profissional avaliador, que classifica o conjunto de posições das patas em mobilidade ou imobilidade. Após o treino de

classificação, é gerado uma nova tabela com as classificações quadro a quadro, porém com ruído. Por último um filtro foi elaborado, e adicionado ao final do processo de classificação de movimento do teste de suspensão pela cauda.

3.1 AQUISIÇÃO DOS DADOS

A aquisição das informações utilizadas neste trabalho foi realizada através de uma câmera filmadora profissional. A escolha da câmera levou em consideração a capacidade de algumas configurações da câmera, como *ISO*, tempo do obturador e abertura, para obter melhores desempenhos em todas as etapas de desenvolvimento. No que diz respeito aos camundongos e teste de suspensão pela cauda, o trabalho desenvolvido apenas capturou imagens de testes realizados no laboratório LAIF, na UFSC Campus Araranguá, não se envolvendo na manipulação dos animais e tampouco adicionado etapas/testes nos trabalhos já em curso no laboratório.

Durante os testes foram utilizados 30 camundongos Swiss machos, com idade média de 3 meses, provenientes do Biotério Central da UFSC. Alojados em gaiolas ventiladas com ciclo claro/escuro de 12 horas, controle de umidade (40% a 70%), temperatura ($22 \pm 2C$), e livre acesso a água e ração. Todo e qualquer procedimento realizado no presente estudo foi aprovado no Comitê de Ética no Uso de Animais/UFSC PP00956 - Prof. Rafael Cypriano Dutra (proponente).

3.1.1 Câmera

A câmera utilizada para a execução dos experimentos foi a câmera *Canon EOS Rebel T6*, que possui 18.0 *Megapixels*, e processador de imagem para maiores detalhes em ambientes com pouca luz. Possui valor máximo de 1/4000 para o obturador. A abertura varia entre f/3.5-5.6, e faixa de *ISO* de 100-6400.

As configurações utilizadas para as filmagens estão representadas na tabela 1, os valores de *ISO* e abertura foram máximos devido a necessidade de luz restringida pela velocidade do obturador, que necessitou ser baixo devido a alta agitação do animal nos experimentos.

Tabela 1 – Configurações *Canon EOS Rebel T6* utilizadas nos experimentos.

Configuração	Valores Utilizados
Vel. Obturador	1/400
Abertura	f/5.6
<i>ISO</i>	6.400

Fonte: Autor.

3.1.2 Gravações

As gravações dos testes de suspensão pela cauda foram executadas em ambientes silenciosos e com baixa luminosidade, pois esses testes são de carácter comportamental, e todos os vídeos foram gerados devido à pesquisas em candidatos a fármacos já em andamento.

Os ambientes de testes se assemelham com o da figura 7, onde h representa a altura do enquadramento, que pode ser de valor variado desde que capture o animal inteiro, pois variações nos valores são tratados com normalização dos dados, assunto coberto futuramente. A distância d utilizada foi de 750mm, respeitando a distância focal e o foco sob o animal.


As gravações ocorreram de acordo com o segmento normal do teste, respeitando os 6 minutos estipulados pela normativa do teste, e a uma taxa de 30 quadros por segundo, gerando 10.800 quadros cada vídeo.

3.1.3 *Labelling*: Etiquetando Objetos

O teste de suspensão pela cauda é uma teste comportamental que classifica os movimentos do animal em estado de mobilidade ou imobilidade, e estes estados são regidos pelos movimentos das patas traseiras, tornando o objetivo inicial para resolução do problema a identificação das mesmas. Para essa identificação optou-se por utilizar o *framework* em código aberto *TensorFlow*. Escolheu-se o modelo *Faster R-CNN* com *Inception ResNet-V2* para os treinos de identificação do objeto, as patas.

Para efetuar o treino nesta rede, é necessário selecionar imagens que contenham os objetos desejados. Essa seleção foi feita utilizando o

Figura 7 – Representação da aquisição de vídeo em teste de suspensão pela cauda.



Fonte: Autor.


programa *LabelImg*, que permitiu clicar e arrastar as áreas dos objetos desejados, bem como adicionar à classes correspondentes a cada objeto selecionado.

Este programa gerou um arquivo *XML* e então o mesmo foi convertido para *CSV*, se tornando pronto para ser utilizado pela rede. Conforme a tabela 2, o arquivo *CSV* continha em cada linha um *bounding box*, informando sua localização, além do nome, largura e altura de cada quadro.

3.1.4 Treinamento da Rede e Detecção

O treinamento da rede *Faster R-CNN* com *Inception ResNet-V2* foi alimentado com as imagens e suas classificações em um total de 1.000 quadros, com aproximadamente 2.000 objetos classificados. O conjunto teste e treinamento foi dividido em 70/30, ou seja, 70% dos objetos classificados foram para treinamentos e 30% para testes.

Figura 8 – Software LabelImg.



Fonte: Software LabelImg.

Tabela 2 – Arquivo *CSV* gerado após classificação de objetos.


filename	width	height	class	xmin	ymin	xmax	ymax
jpeg_paws38.jpeg	100	100	paw	8	35	62	100
jpeg_paws23.jpeg	100	100	paw	12	40	73	99
jpeg_paws9.jpeg	100	100	paw	14	1	70	85
jpeg_paws1.jpeg	100	100	paw	14	7	78	95
jpeg_paws27.jpeg	100	100	paw	15	33	83	73
jpeg_paws35.jpeg	100	100	paw	15	36	68	100
jpeg_paws6.jpeg	100	100	paw	17	8	77	100
jpeg_paws34.jpeg	100	100	paw	26	37	80	99
jpeg_paws17.jpeg	100	100	paw	27	5	84	79
jpeg_paws28.jpeg	100	100	paw	23	21	78	74
jpeg_paws46.jpeg	100	100	paw	2	27	49	83

Fonte: Autor.

O treinamentos atingiu 1.500 épocas. Este treino foi utilizado para classificar objetos em um vídeo, e apresentou falhas como a presença de 3 supostas patas, como mostrado na figura 9, tornando mais

complexo o discernimento entre quais seriam as patas traseiras, principalmente em eventuais estados de alta mobilidade. Outro problema encontrado foi a presença de falsas detecções, que poderiam induzir o algoritmo a interpretar essas como uma das patas, conforme figura 9.

Figura 9 – Detecção de 3 supostas patas.



Fonte: Autor.

Figura 10 – Detecção de pata errada.



Fonte: Autor.

A presença das patas erradas seriam consideradas *outliers*, e as falhas na detecção chamadas de dados faltantes (*em inglês, missing data*); ambos podem ser contornados com técnicas de tratamento de

dados, mas para a execução deste trabalho, preferiu-se evitar os *outliers* e trabalhar mais com os dados faltantes. Então para isso foi aprimorado o algoritmo para aceitar apenas detecção com confiança de mais de 90% e, dentre todos os objetos detectados acima de 90%, somente os dois com os maiores confiabilidade foram selecionados.

A partir dessas modificações, outro teste com 9123 quadros foi submetido, e então gerado dados para início do estudo, e o mesmo apontou uma detecção de 87.7% das possíveis 18246 patas, considerando patas esquerdas e direitas. A tabela 3 foi montada com os dados, apresentando o total de 16002 identificações de ambas as patas.

Tabela 3 – Relação de detecção de patas.

	Patas Esquerda	Patas Direita	Total	Total(%)
Total	9123	9123	18246	100%
Identificado	7305	8697	16002	87,7%
Faltantes	1818	426	2244	12,3%

Fonte: Autor.

3.1.5 Pré-processamento dos dados


Devido ao conhecimento dos movimentos estereotipados em animais como os camundongos, torna-se relevante a análise comparativa entre os movimentos das patas traseiras do animal, uma para com a outra, afim de descobrir se existem indicativos para afirmar que a ausência de informação de uma pata pode ser suprida pela presença de informações da outra pata. Esta análise torna-se necessária pelo fato do sistema de reconhecimento dos padrões das patas estarem definidos para apresentar somente objetos com grau de confiabilidade maior que 90%, deixando de fora todo e qualquer outro objeto inferior a este valor.

As coordenadas geradas pela rede neural apresentam caráter contínuo, pela própria natureza dos dados, devido o movimento natural de um animal, apresentando valores contínuos e apenas variação em suas direções. Através de uma amostra de 500 quadros, foi possível analisar uma semelhança de padrão entre os valores da coordenada x de ambas as patas. O movimento foi periódico e variou na maioria dos casos apenas na potência dos movimentos, mas mantendo o mesmo tempo de pico para ambos.

De acordo com a Figura 11, um gráfico mostrando as variações de

movimentos, existe uma tendência entre os dois gráficos, com picos em quadros próximos. Entretanto, devido às limitações do reconhecimento das patas, há dados faltantes. Estes dados faltantes são problemas para a análise dos valores, porém como analisado anteriormente, o camundongo apresenta uma simetria em seus movimentos, entre as duas patas, e assim reduzindo a participação no erro.

Figura 11 – Comparação das variações.



Fonte: Autor.

Outra análise feita foi a presença de dados faltantes em situações que a variação entre a crista e o vale da onda são maiores e então definidos como movimento, ou seja, esses dados estão presente durante o estado de agitação do animal e não em momentos mais importantes, como o começo ou o fim de um movimento, embora esse estado possa também ser considerado um movimento.

O custo de uma análise que apenas armazena informações de

objetos com um grau maior que 90% de confiabilidade, é a presença de dados faltantes no *dataset*, para todo e qualquer valor inferior a este valor. Para este método utilizado neste trabalho, torna-se necessário o uso de ferramentas para melhor lidar com os dados, e obter classificação do estados de agitação ou quietude do animal com a melhor precisão possível.

O objetivo de tratar os dados faltantes, assim como evitar a aquisição de dados errados, é a necessidade de gerar um dataset que possa ser o mais consistente, ou seja, mais próximo da realidade possível, para as análises dos dados e as relações criadas pelas técnicas de máquinas de aprendizado possam ter melhor desempenho. E considerando os movimentos estereotipados já mencionados, foram realizados testes para análise de correlação entre os movimentos da pata direita com a pata esquerda do animal com o propósito de analisar se ambas as patas possuem correlação em seus movimentos.

A análise de correlação entre o movimento das patas traseiras dos camundongos foi feita através da técnica *Pearson*, que gera um coeficiente que neste caso representa uma medida da qualidade da relação direta entre os dois sinais gerados pelo movimento de cada pata. Ou seja, este coeficiente de correlação mostra o quão forte estão relacionados os movimentos dos membros inferiores e se este valor pode ser considerado um fator relevante para a análise em caso de dados faltantes.

A correlação r entre -1 e $+1$ representa o quão forte estão relacionados os sinais, sendo o valor $r < 0$ correspondente a uma relação correlativamente negativa, ou seja, quando um sinal sobe, o outro tende a descer. Para valores em que $r > 0$, há uma correlação positiva, significando uma relação direta de crescimento entres ambos os sinais. Quanto maior o valor em módulo de r , mais forte é essa correlação, e mais intrínseca é a relação de ambos. E para $r = 0$, a correlação dos sinais não apresenta uma correção linear, porém passível de outra correlação.

Para gerar o coeficiente de correlação de *Pearson*, foi utilizado um *dataset* correspondente a com 9125 quadros, porém devido a presença de valores faltantes na aquisição das posições, foram removidas todas as linhas em que há presença de valores faltantes na tabela 5. A partir do *dataset* tratado, utilizando as coordenadas X e Y de cada uma das patas traseiras, duas novas colunas foram adicionadas, correspondentes ao movimentos absoluto de cada pata de um quadro para com o próximo.

A variação gerada na tabela 4 é correspondente ao módulo do

Tabela 4 – Variação de posição das patas esquerda e direita, sem presença de valores faltantes.

leftX	leftY	rightX	rightY	$\Delta 1$	$\Delta 2$
3,5473442077	1,0145026446	0,2784729004	2,4482828378	3,6895618363	2,4640689946
1,2214851379	1,8124222754	3,037261963	0,7457345724	2,1856121446	3,1274718679
0,086479187	0,1794344186	4,8662948609	0,2033704518	0,1991867475	4,8705425995
0,2880477905	0,1299369336	0,5141830444	0,1357734204	0,3159986334	0,5318069432
1,5390014649	0,1101583241	1,1242675781	0,6308180094	1,5429388728	1,2891504754
1,5433692932	0,0345414877	1,5021514893	0,1607823372	1,5437557739	1,5107316296
0,818862915	0,7440769672	0,7814788819	0,3947299719	1,1064298472	0,8755118466
0,801486969	0,2512907981	1,5462875367	0,5762243271	0,8399573958	1,6501635135
0,8834075928	0,8198225498	2,2285842896	0,9694629907	1,205204542	2,4303181739
2,0920181275	0,2814441919	1,7280960082	1,416168809	2,1108649125	2,2342448185
0,680141449	1,1264687776	3,9658737184	0,2460926771	1,3158739672	3,9735017247
0,4283905031	0,4533416032	0,9469509125	1,3179302215	0,6237283322	1,6228543063
4,2566490172	1,4794850349	1,4961719513	0,5154186486	4,506432827	1,5824622874
0,7258796692	1,6912293434	3,1671237946	0,8171832561	1,8404233171	3,2708502877

Fonte: Autor.

vetor deslocamento, desprezando a direção e o sentido do mesmo, considerando apenas o valor absoluto do deslocamento. Pois o objetivo desta análise foi averiguar se há movimentos em ambas as patas, para então saber se há uma caracterização de movimentos estereotipados entre as patas.

Após gerar os deltas deslocamentos para ambas as patas, os dados foram normalizados para haver uma melhor análise dos dados, com os mesmos padronizados, e possuam uma mesma escala. Para a padronização neste processo, os dados foram normalizados para uma extensão de 0 a 1. Foi usado a 2 para a normalização dos dados. Onde X é o valor a ser normalizado, $X.min$ o valor mínimo para a coluna X , e $X.max$ o valor máximo encontrado em X , na fórmula 3 é obtido o valor normalizado, onde $max = 1$, e $min = 0$, que são correspondentes ao valor máximo e mínimo da extensão escolhida para a normalização.

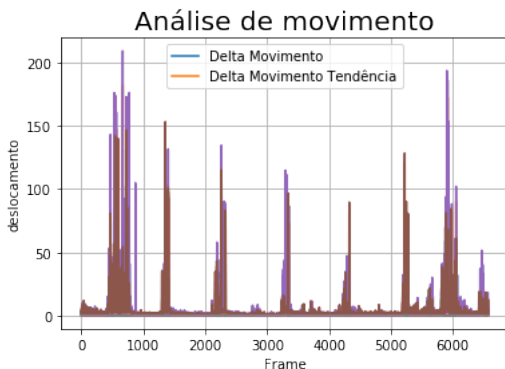
$$X_{(std)} = (X - X.min)/(X.max - X.min) \quad (3.1)$$

$$X_{(scaled)} = X_{std} * (max - min) + min \quad (3.2)$$

Com os dados normalizados, foi então aplicado a fórmula 3.1, correspondente a fórmula para o cálculos do coeficiente de correlação de *Pearson*. Para esse caso foi encontrado um valor de $r = 0.4133$, demonstrando uma fraca correlação entre as patas. Todavia, a *dataset*

foi produzido por um vídeo com 30 quadros por segundo, o que abre oportunidade para uma análise com médias móveis, devido ao interesse de saber a tendência do movimento do animal. Para isso foi usado média móvel, com a janela de tamanho 10, que apresenta sobreposição do sinal gerado, como na figura 12, que mostra o gráfico da tendência respeitando o tempo dos dados originais.

Figura 12 – Gráfico com a tendência gerada.



Fonte: Autor.

Com a utilização do novo sinal obtido através do cálculo de média móvel, o valor de correlação de *Pearson* chegou a $r = 0.7490$, mesmo com o gráfico apresentando variações bruscas após a remoção das linhas que haviam zero.

O valor de $r = 0.7490$ não revela uma precisão suficiente para admitir que existe de fato uma estereotipação dos movimentos das patas traseiras do camundongo, porém indicam uma relação que pode ser abordada de forma diferente quando submetida a uma técnica de classificação de dados.

Para guiar o classificador, foi gerada duas novas colunas na tabela, ambas com valores binários, sendo o valor 1 para a presença de dados, e o valor de 0 para os dados faltantes, conforme na tabela 5.

Para o treinamento com redes supervisionadas é necessário que um profissional faça a classificação dos dados, apesar de uma tarefa difícil, o conjunto de dados de treino foi completamente classificado através de um programa desenvolvido especialmente para essa tarefa, atendendo todos os requisitos do pesquisador. O programa é um re-

Tabela 5 – Variações de movimentos e informação de dados faltantes.

$\Delta 1$	$\Delta 2$	missing1	missing2
3,6895618363	2,4640689946	1	1
2,1856121446	3,1274718679	1	1
0,1991867475	4,8705425995	1	1
0,3159986334	0,5318069432	1	1
1,5429388728	1,2891504754	1	1
1,5437557739	1,5107316296	1	1
1,1064298472	0,8755118466	1	1
0,8399573958	1,6501635135	1	1
1,205204542	2,4303181739	1	1
2,1108649125	2,2342448185	1	1
1,3158739672	3,9735017247	1	1
0,6237283322	1,6228543063	1	1
4,506432827	1,5824622874	1	1
1,8404233171	3,2708502877	1	1

Fonte: Autor.

produtor de vídeo simplificado, que gera uma saída para cada quadro, com a classificação binária.

O profissional classificou 5 porções de vídeos durante este projeto, e estes resultados foram anexados à tabela, de tal forma que cada linha da tabela possui um delta deslocamento para cada pata, e também a classificação feita pelo pesquisador, conforme a tabela 6.

Tabela 6 – Classificação realizada por especialista.

$\Delta 1$	$\Delta 2$	missing1	missing2	classification
3,6895618363	2,4640689946	1	1	0
2,1856121446	3,1274718679	1	1	0
0,1991867475	4,8705425995	1	1	0
0,3159986334	0,5318069432	1	1	0
1,5429388728	1,2891504754	1	1	0
1,5437557739	1,5107316296	1	1	0
1,1064298472	0,8755118466	1	1	0
0,8399573958	1,6501635135	1	1	0
1,205204542	2,4303181739	1	1	0
2,1108649125	2,2342448185	1	1	0
1,3158739672	3,9735017247	1	1	0
0,6237283322	1,6228543063	1	1	0
4,506432827	1,5824622874	1	1	0
1,8404233171	3,2708502877	1	1	0

Fonte: Autor.

4 RESULTADOS

4.1 SVM - SUPPORT VECTOR MACHINES

Para a classificação dos dados foram utilizadas técnicas supervisionadas, pois todo o conjunto de dados possui classificação. Para o emprego das técnicas de classificação, foi utilizado a *API keras*, que funciona sob o *framework TensorFlow*.

A primeira técnica testada foi a Máquina de Vetores de Suporte, que tendem a funcionar bem em conjuntos supervisionados com duas classes, devido ao seu método de funcionamento. A variável C presente no método reflete o tamanho da margem do vetor de suporte, foi utilizado o valor de $C = 1$, que permite uma margem grande de distância do vetor de suporte, e também $C = 10$, com uma margem menor do vetor de suporte.

Para este método foi utilizado o *kernel* função de base radial, do inglês *Radius Base Function*, e o conjunto de dados com e sem colunas informando dados faltante.

Tabela 7 – Comparação de resultados do *SVM* com variações de parâmetros e conjunto de dados.

Técnicas	Acurácia
SVM - With Missing Data Columns - rbf, $C = 10$	0.919452
SVM - No Missing Data Columns - rbf, $C = 10$	0.906849
SVM - With Missing Data Columns - rbf, $C = 1$	0.922192
SVM - No Missing Data Columns - rbf, $C = 1$	0.913425

Fonte: Autor.

4.2 KNN - K-NEAREST NEIGHBOR

Para *k-Nearest Neighbor* foi definido utilizar três e cinco para o valor de K . O resultado está apresentado na seguinte tabela, e também disponível com e sem a informação dos dados faltantes.

Tabela 8 – Comparação de resultados do *KNN* com variações de parâmetros e conjunto de dados.

Técnicas	Acurácia
KNN CLASSIFICATION K = 5 / NO MISSING DATA	0.909041
KNN CLASSIFICATION K = 3 / NO MISSING DATA	0.904110
KNN CLASSIFICATION K = 5 / + MISSING DATA	0.910137
KNN CLASSIFICATION K = 3 / + MISSING DATA	0.905753

Fonte: Autor.

4.3 RANDOM FOREST

Random Forest possui uma ótima estratégia, no qual avalia quais atributos do conjunto de dados realmente é relevante, e cria também vários subconjuntos, e por meio de votação elege qual a melhor resolução para a classificação dos dados propostos. Isso também beneficia este modelo proposto, pois a classificação utiliza no teste da rede, pode haver variação pois é um conjunto que possui uma classificação de um humano, então esses subconjuntos vão tratar esses pequenos erros como *outliers*.

Tabela 9 – Comparação de resultados do *Random Forest* com variações de parâmetros e conjunto de dados.

Técnica	Acurácia
RANDOM FOREST - NO MISSING DATA	0.985050
RANDOM FOREST + MISSING DATA	0.985764

Fonte: Autor.

4.4 FILTRO

Dentre os resultados apresentados pelas 3 técnicas, *Random Forest* mostrou melhor resultado para classificação do conjunto de dados. Porém a classificação foi tratada para cada ponto, não levando em consideração o conjunto, ou seja, a classificação anterior não interfere na classificação seguinte. Esta falta de vínculo mostrou-se um problema

para movimentos classificados como de 'mobilidade' com a velocidade variada, ou seja, dentre um movimento de mobilidade, há baixos deslocamentos do animal, mas ainda considerado mobilidade, classificados pelo pesquisador de referência. Além disso, o movimento pendular do animal, ao trocar de sentido, apresenta deslocamento zero, devido a alta taxa de frames extraídos do vídeo.

Apesar de um desempenho 98% do Random Forest no conjunto de treinamento, uma análise em um novo vídeo resultou em um desempenho abaixo do esperado, resultado para um teste apresentou 81,17% de acurácia.

A forma eficiente de analisar este problema é utilizar de meios estatísticos para a entender o que está acontecendo. Utilizando a matriz confusão, é possível analisar onde houve classificação certa, errada e também saber onde houve erros de classificação 0 para 1, e vice-versa. A matriz confusão utilizada neste trabalho foi de carácter binário, pois faz apenas classificação entre mobilidade ou imobilidade. Esta matriz apresenta duas linhas e duas colunas, a primeira coluna implica em resultado positivo perante a classificação do pesquisador, e a segunda coluna a classificação negativa do pesquisador. A primeira linha remete ao que o algoritmo classificou por positivo, e a segunda linha remete ao que o algoritmo classificou por negativo. Para esta análise, trata-se positivo como imobilidade.

A matriz então cruza as informações e informa:

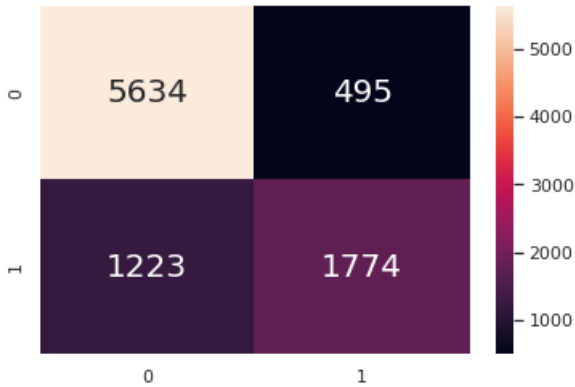
- Verdadeiro positivo: classificações positivas, e também classificadas por positiva pelo algoritmo
- Falso positivo: classificações negativas, porém classificadas como positiva pelo algoritmo
- Falso negativo: classificações positivas, porém classificados como negativo pelo algoritmo
- Verdadeiro negativo: classificações negativas, e também classificadas por negativa pelo algoritmo

A matriz confusão resultante é como a figura 13:

Os valores apresentados pela matrix confusão mostram:

- Verdadeiro positivo igual á 5634
- Falso positivo igual á 495
- Falso negativo igual á 1223

Figura 13 – Matrix confusão do dataset com 81.17% de acurácia.



Fonte: Autor.

- Verdadeiro negativo igual á 1774

Estes valores são chave para a detecção do problema, o valor do falso positivo está 2,47 vezes maior que o falso negativo, ou seja, o algoritmo acusa não-movimento enquanto há um movimento, mais vezes que o oposto, então há uma dica de problema.

Com estes dados também foi possível obter a sensibilidade, que é a capacidade do software classificar movimentos positivamente quando eles realmente forem positivos perante a pesquisadora. A especificidade, que é a capacidade de detectar corretamente os negativos, de acordo também com a pesquisadora. Os valores foram de acordo com a tabela 10.

Tabela 10 – Desempenho do sistema para o caso sem aplicação de filtro.

Tipo	Valor
Especificidade	0,9192
Sensibilidade	0,5919
Acurácia	0,8117
Precisão	0.7818

Fonte: Autor.

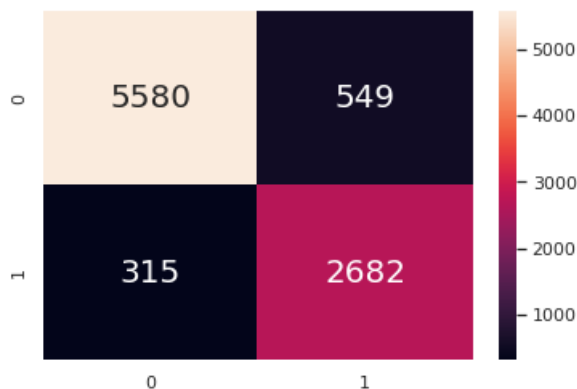
Ao analisar o vídeo, é possível perceber que o algoritmo aponta como não movimento as trocas de sentido de movimento, como é sabido, essa troca de direção passar por velocidade zero antes de trocar de sentido. Os frames próximos a essa troca também são afetados, assim como os movimentos com aceleração variada, que apesar de estarem em movimento segundo a pesquisadora, o algoritmo interpreta baixas velocidades dentro de um movimento como baixo como imobilidade.

Um filtro foi aplicado para remover estas classificações, e assim poder analisar uma sequência de frames, e não só ponto a ponto. Para isso, o filtro elaborado assemelha-se com o cálculo de tendência, com uma janela fixa em 30, referente a 1 segundo de vídeo, considerando que não haja mais de uma variação em menos que 1 segundo, devido limitações humanas de percepção e tempo de reação.

Com a aplicação de um filtro com janela de 30 quadros, o resultado obtido foi uma classificação de 90,53% para com a pesquisadora.

Com a aplicação do filtro de janela igual a 30, o matriz confusão apresentou uma variação positiva perante a tentativa inicial de tratar esses movimentos que eram considerado imóveis dentro de um conjunto maior de mobilidade. A figura 14 traz estas informações.

Figura 14 – Matrix confusão do dataset com 90.53% de acurácia.



Fonte: Autor.

Os valores da tabela 11 foram obtidos através da matriz confusão da figura 14.

Tabela 11 – Desempenho do sistema para o caso com aplicação de filtro.

Tipo	Valor
Especificidade	0,9104
Sensibilidade	0,8948
Acurácia	0,9053
Precisão	0,8300

Fonte: Autor.

5 CONCLUSÃO

O conjunto de dados foi tratado e trabalhado baseado nas afirmações da literatura, considerando os aspectos animais, e técnicas indicadas para o problema proposto. O conjunto de dados foi extraído de movimentos naturais dos camundongos, em testes já em andamento.

O estudo animal permitiu conhecer e investigar os movimentos estereotipados, que resultou na elaboração de um conjunto de atributos reduzido para a alimentação dos treinos e a classificação dos movimentos dos animais sob testes.

A classificação de movimentos em camundongos é regida pela análise de um especialista em observação comportamental de animais, entretanto a análise humana é passível de falhas, fadiga e erros de precisão temporal. Embora amplamente usado, é difícil estabelecer uma regra de ouro para a análise, então delimitou-se a um analisador gerar suas análises perante uma gama de vídeo.

Este conjunto reduzido de atributos justificou as técnicas obterem classificações com resultados superiores a 90% de precisão, mesmo com variações nos treinos provindos dos especialistas. Principalmente para a rede *Random Forest*, que trata melhor de problemas envolvidos a conjuntos supervisionados que ainda possuam inconsistências, como a classificação errônea de alguns quadros, devido à variação da percepção humana na hora do treino da rede.

Porém conforme explicado no capítulo de resultados, a análise teve uma variação, devido a interpretação da máquina, e devido ao treino com *Random Forest* remover os *outliers* e considerar todo e qualquer pequeno movimento sem considerar a classificação anterior. A forma de contornar este problema foi a elaboração de um filtro, utilizando uma janela de 30 quadros para por *quorum* estimar qual o movimento da presente fração de segundo.

Este filtro não foi ampliado devido a necessidade de um teste com a observadora e pesquisadora, para saber qual o seu tempo de resposta, e então escolher um filtro de acordo com a forma com que ela classificou o conjunto treinamento.

Para projetos futuros, há a necessidade de ampliar o dataset para aceitar também camundongos pretos, a classificação dos movimentos permaneceria a mesma caso haja similariedade fisiológica entre os animais.

O objeto deste projeto foi atingir um grau de classificação igual ao da pesquisadora, e futuramente com maior amostra de classifica-

ções de diferentes pesquisadores, existe a possibilidade de desenvolver algoritmo para encontrar padrões entre todos e então estabelecer sua própria classificação.

REFERÊNCIAS

- ABDULLAH, A. A.; YAAKOB, A.; IBRAHIM, Z. Prediction of spinal abnormalities using machine learning techniques. In: IEEE. *2018 International Conference on Computational Approach in Smart Systems Design and Applications (ICASSDA)*. [S.l.], 2018. p. 1–6.
- ANDREATINI, R. A importância dos modelos animais em psiquiatria. *Revista Brasileira de Psiquiatria*, SciELO Brasil, v. 24, n. 4, p. 164–164, 2002.
- BABU, K. R.; SUNITHA, K. A new approach to enhance images of mobile phones with in-built digital cameras using mean and variance. In: IEEE. *Advances in Computer Engineering (ACE), 2010 International Conference on*. [S.l.], 2010. p. 232–234.
- BHASKAR, H.; KHAN, F. et al. High-iso image de-noising using burst filtering. In: IEEE. *Circuits and Systems (MWSCAS), 2016 IEEE 59th International Midwest Symposium on*. [S.l.], 2016. p. 1–4.
- BOUSQUET, O.; LUXBURG, U. von; RÄTSCH, G. *Advanced Lectures on Machine Learning: ML Summer Schools 2003, Canberra, Australia, February 2-14, 2003, Tübingen, Germany, August 4-16, 2003, Revised Lectures*. [S.l.]: Springer, 2011.
- BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, n. 1, p. 5–32, 2001.
- BUDIHARTO, W. et al. Fast object detection for quadcopter drone using deep learning. In: IEEE. *2018 3rd International Conference on Computer and Communication Systems (ICCCS)*. [S.l.], 2018. p. 192–195.
- BÜLBÜL, H. I.; ÖZKAN, Ã. et al. Comparison of classification techniques used in machine learning as applied on vocational guidance data. In: IEEE. *2011 10th International Conference on Machine Learning and Applications Workshops*. [S.l.], 2011. p. 298–301.
- CAN, A. et al. The tail suspension test. *Journal of visualized experiments: JoVE*, MyJoVE Corporation, n. 59, 2012.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, n. 3, p. 273–297, 1995.

CRYAN, J. F.; MOMBÉREAU, C.; VASSOUT, A. The tail suspension test as a model for assessing antidepressant activity: review of pharmacological and genetic studies in mice. *Neuroscience & Biobehavioral Reviews*, Elsevier, v. 29, n. 4-5, p. 571–625, 2005.

DABÓCZI, T. Analysis of the distortion of marker-based optical position measurement as a function of exposure time. *IEEE Transactions on Instrumentation and Measurement*, IEEE, v. 65, n. 9, p. 2023–2034, 2016.

ELIZABETH. *Understanding Depth of Field – A Beginner’s Guide*. 2016. <<https://photographylife.com/what-is-depth-of-field>>.

GAVAL, N. R. et al. Mobilenets for flower classification using tensorflow. In: IEEE. *Big Data, IoT and Data Science, 2017 International Conference on*. [S.l.], 2017. p. 154–158.

GIRSHICK, R. Fast r-cnn. In: *Proceedings of the IEEE international conference on computer vision*. [S.l.: s.n.], 2015. p. 1440–1448.

GRAHAM, C. et al. Factors influencing thresholds for monocular movement parallax. *Journal of Experimental Psychology*, American Psychological Association, v. 38, n. 3, p. 205, 1948.

GUIMARÃES, M. V.; FREIRE, J. E. da C.; MENEZES, L. M. B. de. Utilização de animais em pesquisas: breve revisão da legislação no brasil. *Revista Bioética*, v. 24, n. 2, 2016.

HALL, M. A. Feature selection for discrete and numeric class machine learning. Computer Science, University of Waikato, 1999.

HÄNSCH, R.; HELLWICH, O. Semi-supervised learning for classification of polarimetric sar-data. In: IEEE. *Geoscience and Remote Sensing Symposium, 2009 IEEE International, IGARSS 2009*. [S.l.], 2009. v. 3, p. III–987.

HASAN, S. et al. Comparative analysis of classification approaches for heart disease prediction. In: IEEE. *2018 International Conference on Computer, Communication, Chemical, Material and Electronic Engineering (IC4ME2)*. [S.l.], 2018. p. 1–4.

HOWARD, A. G. et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*, 2017.

- HUNG, Y.; LIANG, C. Image-shearing camera for direct measurement of surface strains. *Applied Optics*, Optical Society of America, v. 18, n. 7, p. 1046–1051, 1979.
- IM, J.; LEE, S.; PAIK, J. Improved elastic registration for removing ghost artifacts in high dynamic imaging. *IEEE Transactions on Consumer Electronics*, IEEE, v. 57, n. 2, 2011.
- JIANG, Z.; DENG, Y. Improving knn based text classifications. In: IEEE. *Future Computer and Communication (ICFCC), 2010 2nd International Conference on*. [S.l.], 2010. v. 2, p. V2–317.
- KUBAT, M.; HOLTE, R. C.; MATWIN, S. Machine learning for the detection of oil spills in satellite radar images. *Machine learning*, Springer, v. 30, n. 2-3, p. 195–215, 1998.
- LANGLEY, R. G. et al. Confocal scanning laser microscopy of benign and malignant melanocytic skin lesions in vivo. *Journal of the American Academy of Dermatology*, Elsevier, v. 45, n. 3, p. 365–376, 2001.
- LI, H.; LIAO, X.; CARIN, L. Active learning for semi-supervised multi-task learning. In: IEEE. *Acoustics, Speech and Signal Processing, 2009. ICASSP 2009. IEEE International Conference on*. [S.l.], 2009. p. 1637–1640.
- LIN, T.-Y. et al. Feature pyramid networks for object detection. In: *CVPR*. [S.l.: s.n.], 2017. v. 1, n. 2, p. 4.
- LIN, T.-Y. et al. Focal loss for dense object detection. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, 2018.
- LIU, W. et al. Ssd: Single shot multibox detector. In: SPRINGER. *European conference on computer vision*. [S.l.], 2016. p. 21–37.
- MAN, W.; JI, Y.; ZHANG, Z. Image classification based on improved random forest algorithm. In: IEEE. *2018 IEEE 3rd International Conference on Cloud Computing and Big Data Analysis (ICCCBDA)*. [S.l.], 2018. p. 346–350.
- MIAO, X.; SIM, T. Ambient image recovery and rendering from flash photographs. In: IEEE. *Image Processing, 2005. ICIP 2005. IEEE International Conference on*. [S.l.], 2005. v. 2, p. II–1038.

MINEUR, Y. S.; BELZUNG, C.; CRUSIO, W. E. Effects of unpredictable chronic mild stress on anxiety and depression-like behavior in mice. *Behavioural brain research*, Elsevier, v. 175, n. 1, p. 43–50, 2006.

ORGANIZATION, W. H. et al. Relatório mundial da saúde-saúde mental: nova concepção, nova esperança. *Lisboa: Direcção-Geral da Saúde*, 2002.

ORGANIZATION, W. H. et al. Depression and other common mental disorders: global health estimates. World Health Organization, 2017.

SCHLEICHER, D. C.; ZAGAR, B. G. High dynamic range imaging by varying exposure time, gain and aperture of a video camera. In: IEEE. *Instrumentation and Measurement Technology Conference (I2MTC), 2010 IEEE*. [S.l.], 2010. p. 486–491.

SHYAM, D.; KOT, A.; ATHALYE, C. Abandoned object detection using pixel-based finite state machine and single shot multibox detector. In: IEEE. *2018 IEEE International Conference on Multimedia and Expo (ICME)*. [S.l.], 2018. p. 1–6.

STERU, L. et al. The tail suspension test: a new method for screening antidepressants in mice. *Psychopharmacology*, Springer, v. 85, n. 3, p. 367–370, 1985.

SU, B.; LU, S.; TAN, C. L. Blurred image region detection and classification. In: ACM. *Proceedings of the 19th ACM international conference on Multimedia*. [S.l.], 2011. p. 1397–1400.

SUN, C. et al. Revisiting unreasonable effectiveness of data in deep learning era. In: IEEE. *Computer Vision (ICCV), 2017 IEEE International Conference on*. [S.l.], 2017. p. 843–852.

SZEGEDY, C. et al. Inception-v4, inception-resnet and the impact of residual connections on learning. In: *AAAI*. [S.l.: s.n.], 2017. v. 4, p. 12.

SZWARCWALD, C. L. et al. Inequalities in healthy life expectancy by brazilian geographic regions: findings from the national health survey, 2013. *International journal for equity in health*, BioMed Central, v. 15, n. 1, p. 141, 2016.

TEICHMANN, M. et al. Multinet: Real-time joint semantic reasoning for autonomous driving. In: IEEE. *2018 IEEE Intelligent Vehicles Symposium (IV)*. [S.l.], 2018. p. 1013–1020.

- TELLEEN, J. et al. Synthetic shutter speed imaging. In: WILEY ONLINE LIBRARY. *Computer Graphics Forum*. [S.l.], 2007. v. 26, n. 3, p. 591–598.
- TENG, C. T.; HUMES, E. d. C.; DEMETRIO, F. N. Depressão e comorbidades clínicas. *Revista de Psiquiatria Clínica*, SciELO Brasil, v. 32, n. 3, p. 149–159, 2005.
- WANG, X.-z.; LU, S.-x. Improved fuzzy multicategory support vector machines classifier. In: IEEE. *Machine Learning and Cybernetics, 2006 International Conference on*. [S.l.], 2006. p. 3585–3589.
- WU, J.; LU, M.-Y.; WANG, C.-L. Enhancing svm active learning for image retrieval using semi-supervised bias-ensemble. In: IEEE. *Pattern Recognition (ICPR), 2010 20th International Conference on*. [S.l.], 2010. p. 3175–3178.
- ZHANG, X. et al. Polynet: A pursuit of structural diversity in very deep networks. In: IEEE. *Computer Vision and Pattern Recognition (CVPR), 2017 IEEE Conference on*. [S.l.], 2017. p. 3900–3908.
- ZHU, X.; GHAHRAMANI, Z.; LAFFERTY, J. D. Semi-supervised learning using gaussian fields and harmonic functions. In: *Proceedings of the 20th International conference on Machine learning (ICML-03)*. [S.l.: s.n.], 2003. p. 912–919.