

Rafael R.

**Aplicação de aprendizado de máquina no
diagnóstico de aves do gênero *Amazona***

Projeto de pesquisa

São Carlos, SP
Janeiro de 2021

SUMÁRIO

1. Introdução e revisão bibliográfica.....	2
1.1 <i>Objetivo</i>	6
1.2 <i>Motivação</i>	7
2. Material e métodos.....	8
2.1 <i>Forma de análise dos resultados</i>	12
3. Plano de trabalho	13
4. Considerações finais	15
Referências	15
Apêndice.....	19



RESUMO

O manejo e a realização de exames em aves é um procedimento delicado, principalmente quando a ave está com a saúde debilitada. Nesse sentido, uma aplicação de aprendizado de máquina que possa inferir a existência de alguma doença a partir de dados obtidos de forma não invasiva pode mitigar riscos e auxiliar a tomada de decisão. Existem algumas poucas aplicações desse tipo relatadas em literatura, principalmente utilizando áudio como dado de entrada. Entretanto, nenhuma delas atende o caso específico de aves do gênero *Amazona* (papagaios), bastante presentes na América Latina e com reconhecida capacidade de vocalização. Além disso, existem outros dados coletados no atendimento clínico que podem ser utilizados como dado de entrada. Propõe-se, então, realizar uma pesquisa exploratória de desenvolvimento e validação empírica da aplicação do aprendizado de máquina para auxílio no diagnóstico de papagaios. Deverá ser verificado, junto à comunidade de veterinários, qual é o diagnóstico prioritário para a abordagem por aprendizado de máquina e os principais dados disponíveis, a partir dos quais será possível elencar a classe de modelos mais apropriada à solução do problema. Entretanto, independente do tipo de modelo e dado de entrada, propõe-se seguir as macro-etapas comuns das aplicações de aprendizado de máquina (problema, dataset, modelo, treino, teste, deploy e validação), as quais podem ser executadas sob o paradigma de desenvolvimento ágil, pautado em uma evolução progressiva da compreensão do problema e sua solução, e incorporar boas práticas reportadas em literatura. Os resultados, que podem ser apresentados na forma de um laudo estatístico de saúde da ave, devem ser analisados conforme métricas, vieses, semântica e interpretabilidade para avaliar a capacidade preditiva do modelo de aprendizado. Uma vez concluído o desenvolvimento, poderá ser avaliada a hipótese da possibilidade de aplicação do aprendizado de máquina ao diagnóstico de aves do gênero *Amazona* e sua real contribuição à prática clínica considerando o estado da arte atual.

1. INTRODUÇÃO E REVISÃO BIBLIOGRÁFICA

Em entrevistas com veterinários especialistas em aves (HESS, 2011, 2010), foram mencionados benefícios que a tecnologia trouxe à prática clínica, evidenciando a utilidade de ferramentas computacionais nessa área. Em particular, foi notável a resposta do Dr. Folland à pergunta “Qual artigo de tecnologia que ainda está por ser desenvolvido para a medicina veterinária que você desejaria que existisse para lhe auxiliar no aprimoramento de seus atendimentos?”:

“Eu adoraria um dispositivo portátil daquele utilizado por Dr. McCoy em Star Trek que diagnostica e trata, tudo ao mesmo tempo, somente apontando-o para o paciente. [...]” (tradução minha, HESS, 2011).

Não foi relatado o motivo específico que levou Dr. Folland a desejar algo assim, entretanto é possível intuir que resulte de alguns desafios e riscos envolvidos no atendimento de aves (POWERS, 2006), por exemplo:

- pacientes em condições críticas de saúde ou dispneicas podem entrar em pânico e não sobreviver ao manejo;
- o manejo pode resultar em fobia de mãos;
- os benefícios de uma punção para retirada de sangue para exame devem ser confrontados com os riscos do procedimento, incluindo os riscos de sedação; e
- riscos de fratura óssea durante a imobilização para radiografia.

Atualmente, existem diversas aplicações de aprendizado de máquina (AM) para o reconhecimento de espécies de aves e algumas para diagnósticos. Banakar, Sadeghi e Shushtari (2016) relataram sucesso nos diagnósticos de doença de Newcastle, vírus da bronquite e influenza aviária em aves de granja a partir de sinais de áudio. Foi possível obter uma acurácia de até 83% usando um classificador do tipo Support vector machine (SVM) operando em features dos áudios no domínio do tempo. Sadeghi, Banakar et al. (2015) utilizaram features de áudio no domínio do tempo para realizar diagnóstico de infecção por *Clostridium perfringens*. Nesse caso, uma estrutura de Rede Neural de Reconhecimento de Padrões com uma camada escondida foi empregada para detectar os sinais e classificar galinhas em saudáveis e não-saudáveis. Liu et al.

(2018) usaram sinais de áudio para detectar alteração no bem estar provocado por stress térmico em perus. Um modelo SVM foi empregado para a classificação a partir de features mistas no domínio do tempo e da frequência, atingindo uma acurácia de 89%. Ainda no contexto de identificação de stress, Lee et al. (2015) empregaram um sistema de três classificadores binários tipo SVM para selecionar features significativas de áudio, detectar e classificar a ocorrência de stress provocado por medo ou variação térmica em galinhas chocadeiras. Sadeghi e Banakar (2017), em uma aplicação fora do contexto do diagnóstico, porém que se propõe a solucionar de maneira simples um desafio no atendimento de aves, classifica sinais de áudio de galinhas d'angola usando SVM baseado em Gaussian Radial Basis Function (GRBF) para realizar a sexagem desses animais. Já Okinda et al. (2019), usam mídia de vídeo para construir um classificador de frangos saudáveis e doentes. Aplicando Support Vector Machine (RBF-SVM), foi obtido uma acurácia de 0.98. Feiyang et al. (2016) analisa features de cinemática de translação advindos de dados de RFID em aves de granja. Beaufrère, Ammersbach e Tully Jr (2013) usam um módulo de AM presente em um software (*open source*) analisador de células em lâminas para realizar a classificação e contagem automática de uma amostra de células de aves da ordem *psittaciformes*, a qual congrega a ordem *Amazona*. Porém o modelo empregado não é explicitado no artigo. Uma busca livre na internet retornou uma iniciativa de aplicação voltada ao diagnóstico por áudio de aves de granja (ALONZO, 2020).

Existem alguns trabalhos específicos para diagnósticos de outras classes de animais vertebrados cuja análise é interessante para visualizar um panorama maior de aplicações possíveis e dados empregáveis. Freitas (2019) realiza o diagnóstico de Ceratoconjuntivite Infecciosa em bois a partir de imagens de câmera termográfica introduzidas em uma rede neural convolucional (RNC), obtendo acurácia de até 94%. Fraiwan e Abutarbush (2020) exploram árvores de decisão, perceptron multicamada, redes bayesianas e Naïve Bayes para prever a necessidade de cirurgia e a probabilidade de sobrevivência para equinos com abdome agudo (cólica), obtendo, nos melhores casos, acurácias de 76% e 85%, respectivamente. Bradley et al. (2019) buscam prever o risco de doença crônica dos rins em gatos para os horizontes de tempo de 2 anos, 1 ano e próximo do diagnóstico, a partir de anamnese clínica (texto) aplicada à uma rede neural recorrente.

Observa-se que as aplicações encontradas são recentes, ocorridas em espaço de tempo

inferior a cinco anos, e em quantidade ainda modesta. Não obstante, é possível inferir que uma plataforma de AM pode suportar a prática clínica da medicina veterinária de aves de maneira benéfica, do mesmo modo que Perle (2019) menciona isso no âmbito da patologia veterinária e as revisões de Cihan, Gökçe e Kalıpsız (2019), Awaysheh et al. (2019) e Lustgarten et al. (2020) constataram para outras áreas da veterinária. Ainda, convenientemente, na maioria dos casos, a coleta dos dados de entrada para utilização nos modelos foi realizado com procedimentos não invasivos, reduzindo os riscos de atendimento e, eventualmente, podendo ser realizados até por leigos. Nenhuma delas, porém, visa aplicação específica para aves do gênero *Amazona*, a qual corresponde às aves conhecidas como papagaios, bastante presentes na América latina e popularmente reconhecidas por sua capacidade de imitação quando inseridas em ambientes humanos¹.

As melhorias que o AM pode agregar ao atendimento de aves ainda não soluciona o desejo de Dr Folland em sua totalidade, porém consiste em um dos passos para torná-lo uma realidade.

No que concerne os *datasets*, existem alguns disponíveis que contém dados de *psittaciformes*, contudo não foi encontrado nenhum com classificação sobre o estado de saúde da ave ou que contemplasse situações de imitação. Xeno-canto (2005) é um repositório na forma de um website mantido pela fundação Xeno-canto, ou “*Stichting Xeno-canto voor natuurgeluiden*” no original holandês, para o compartilhamento livre de áudios de pássaros em vida selvagem de todo o mundo. Macaulay Library (1929) é um repositório na web de vídeos, áudios e fotos, administrado pelo Laboratório de Ornitologia da Universidade de Cornell e alimentado por contribuições da comunidade. Wikiaves (2008) é um repositório mantido no Brasil no formato *wiki* contendo áudio e fotos (com metadados) inseridos pela comunidade. Por fim, Belko, Dobratulin e Kuznetsov (2020) apresentam um dataset de penas de aves.

No levantamento bibliográfico, foram buscadas aplicações de AM ao diagnóstico de aves contendo tipos variados de dados de entrada. Foi observado uma variedade pequena de tipos de dados de entrada em publicações e datasets, sendo que o dado mais utilizado foi o de áudio, principalmente com pesquisas realizadas pelos autores Banakar e Sadeghi. Por outro lado, há

¹Aqui surge uma "provocação": será que essa proximidade da vocalização dos humanos também aproximaria para o uso de modelos/algoritmos mais eficiente em humanos?

tantos outros dados de coleta não invasiva apresentados por Powers (2006) e Lightfoot (2010) presentes em um atendimento de psitacídeos:

- peso;
- temperatura;
- observações/inspeção visual de:
 - penas;
 - fezes (aspecto e quantidade);
 - epitélio dos pés;
 - massa muscular;
 - força de preensão dos pés e bico;
 - alcance de movimento das articulações;
 - ambulação;
 - voo;
- amostras para culturas:
 - fezes;
 - material de regurgitação;
 - fluido nasal;
- alterações comportamentais relatadas pelos tutores:
 - quantidade de vocalização;
 - brincadeiras;
 - movimentação nos ambientes;
 - interação com objetos, pessoas e outros pássaros;
 - consumo de água e hábitos alimentares;
 - comportamentos de reprodução;
 - autocuidado das penas;
 - banho;
 - poleiros preferidos;
 - ciclo de sono;
- Romagnano (1999) lista uma série de perguntas feitas ao tutor numa consulta de medicina preventiva e aspectos de observação para anamnese.

- por fim, há ainda os dados cuja coleta é "invasiva", os quais são escolhidos caso a caso avaliando a relação risco-benefício:
 - resposta cardiovascular e respiratória ao manejo e exercícios;
 - radiografias;
 - hemograma;
 - ecocardiograma;
 - exames oftálmicos;

Nota-se a distância entre a pluralidade dos tipos de dados observados em consulta clínica e dos tipos utilizados nas pesquisas. Ainda, Lightfoot (2010) salienta que registrar os dados com uma certa frequência pode ser tão útil quanto exames laboratoriais.

1.1. OBJETIVO

Desse modo, é proposto um trabalho de pesquisa com objetivo de sustentar ou refutar a hipótese que é possível prover uma ferramenta baseada em aprendizado de máquina que apresente efetividade suficiente para auxiliar tutores e médicos veterinários no diagnóstico de aves do gênero *Amazona*, popularmente conhecidas como papagaios.

Nesse contexto, algumas questões preliminares permeiam esse objetivo:

- qual o desafio ou problema prioritário da comunidade de veterinários especialistas em papagaios para ser abordado com AM?
- qual tipo de dado existe em maior abundância e disponibilidade para papagaios? Quanto "fácil" será o acesso a esse dados para a compilação de um dataset? Será adequado (tamanho, balanceamento, classificações, qualidade, etc)?
- Um aprendizado baseado em dados de outros *psittaciformes* pode ser transferido para os papagaios? E vice-versa?
- Quais os requisitos de hardware que o problema prioritário, os dados disponíveis e o modelo de aprendizado irão impor?
- Quais métricas de previsão serão as mais relevantes para o problema?
- Os algoritmos atualmente existentes são suficientes para utilização com papagaios (apresentarão bom desempenho ou capacidade de previsão)? Caso negativo, porque? Como podem ser modificados?

- Como será a recepção e percepção da aplicação pela comunidade veterinária?

1.2. MOTIVAÇÃO

O AM é uma abordagem moderna para a análise de problemas, guardando oportunidades ainda pouco exploradas nesse contexto de auxílio ao diagnóstico, principalmente na medicina veterinária de aves. Para os médicos veterinários, as respostas fornecidas pelo modelo podem funcionar como uma segunda opinião, aumentando o poder de diagnóstico nos atendimentos ao mesmo tempo que pode reduzir o risco de coleta de material para diagnóstico em alguns casos. Adicionalmente, é uma abordagem geradora de ferramentas potencialmente portáteis (acessíveis pela internet) com capacidade de prover respostas quantitativas rápidas com relativa facilidade e precisão, ou seja, no caso de uso por tutores, esses não dependeriam da agenda do médico veterinário para obter uma primeira avaliação do paciente, de modo que essa primeira avaliação pode eventualmente reduzir o tempo de ação em casos mais urgentes.

Resolver o objetivo no âmbito de uma pesquisa acadêmica possibilita que o método científico agregue robustez e lisura ao desenvolvimento e validação da aplicação de AM ao diagnóstico, o que é importante para uma aplicação proposta para auxiliar na preservação de vidas da avifauna brasileira, seja em ambiente urbano, rural ou em seu habitat natural no caso de necessidade de intervenção provocado por catástrofes naturais. Além disso, devido ao número modesto de aplicações existentes, é provável que o trabalho contribua para a expansão da fronteira do conhecimento nessa frente interdisciplinar.

2. MATERIAL E MÉTODOS

A pesquisa bibliográfica descrita na introdução foi realizada para identificar o panorama atual da aplicação de aprendizado de máquina no contexto da medicina veterinária, em particular no diagnóstico de aves. Consistiu na busca de artigos utilizando o portal Google Scholar e nas revistas das áreas de aves, ornitologia, aprendizado de máquina e inteligência artificial com classificação maiores ou iguais que Qualis B1 segundo plataforma Sucupira-CAPES. Plataformas tradicionais como Scopus e Web of Science não foram utilizadas por serem restritas ao uso institucional. Alguns artigos foram encontrados pelo rastreamento da citação ou recomendações de artigos similares das plataformas dos editores e indexadores.

Inicialmente, a estratégia de busca consistiu no levantamento e classificação de palavras-chave relevantes ao contexto do objetivo:

tipo: review, survey, challenges, best practices, nenhum;

técnica: machine learning, artificial intelligence, data science;

especificador: veterinary, (blue-fronted) parrot, amazona, psittacids, psittacidae, psittaciformes, psittacines, avian, birds, poultry;

língua: português, inglês, espanhol.

As palavras-chave foram então agrupadas para formar *strings* de busca:

Title, Abstract: (review OR survey OR challenges OR "best practices") AND ("artificial intelligence" OR "machine learning" OR "Data science") AND (veterinary)

Title, Abstract: ("artificial intelligence" OR "machine learning" OR "Data science") AND (avian OR bird OR poultry)

Any field: ("artificial intelligence" OR "machine learning" OR "Data science") AND (parrot OR amazona OR psittacids OR psittacines OR psittacidae OR psittaciformes)

Entretanto a sintaxe de busca do Google Scholar não foi capaz de resolver a busca de modo preciso usando esses termos. Com isso, a busca foi simplificada, usando algumas combinações de pares de palavras-chave, por exemplo ("artificial intelligence" psittaciformes) ou ("machine learning" parrot), e foram verificados os resultados mais relevantes apresentados

nas primeiras páginas de resultado.

A busca na base de patentes americanas foi realizada para patentes requeridas e consolidadas a partir da busca no campo do resumo que continham pares de palavras chave dos grupos seguintes: (machine learning, artificial intelligence) e (psittacidae, psittaciformes, avian, poultry, flock). Já no portal Kaggle, foram utilizados simplesmente as palavras parrot, bird e avian.

Para realizar a revisão referente aos modelos de aprendizado de máquina, convém aguardar a definição do diagnóstico prioritário e, em seguida, definir o tipo de aprendizado (supervisionado, não-supervisionado, por reforço) e do dado de entrada (áudio, imagem, texto, ou outros). Entretanto, é possível compor o método com um *pipeline* de referência e boas práticas que são independentes dessas definições.

As macro etapas (*pipeline*) da aplicação e validação de um modelo de AM são as seguintes (HAPKE; NELSON, 2020), com a ressalva de não terem andamento linear, ou seja, após uma iteração podem ocorrer ajustes em etapas anteriores:

Problema: Definição e compreensão do problema (diagnóstico) prioritário e dos dados disponíveis;

Dataset: Compilação, formatação e versionamento do dataset; validação e pré-processamento dos dados;

Modelo/Algoritmo: Seleção de um ou mais modelos adequados ao problema; seleção da arquitetura computacional (hardware e software) e relações de compromisso para viabilização operacional;

Treio e teste: Partição do dataset; treino dos modelos e manejo dos recursos computacionais; ajuste dos parâmetros dos modelos e análise dos resultados dos testes segundo métricas, vieses/semântica e interpretabilidade (CARVALHO; PEREIRA; CARDOSO, 2019); seleção do modelo mais apropriado;

Deploy: Host, API de comunicação (*backend*) e interface com usuário (*front-end*); UX e apresentação eficaz dos resultados; Protocolo de uso e educação do usuário;

Validação contínua: análise e síntese dos resultados do uso cotidiano segundo métricas,

vieses/semântica e interpretabilidade (CARVALHO; PEREIRA; CARDOSO, 2019); coleta da conclusão do usuário (diagnóstico final);

Realimentação: realimentação de novo dataset; automações; manutenção e melhorias do modelo e da infraestrutura.

Sob a hipótese de existir um dataset de relativo fácil acesso e boa qualidade, ressalta-se que o cerne da pesquisa de mestrado consiste nas etapas de modelo, treino e teste. No caso de doutorado, a pesquisa é estendida até a etapa da validação contínua empírica.

O desenvolvimento das macro etapas pode ser feito sob o paradigma dos valores do desenvolvimento ágil (BECK et al., 2001), provendo um produto mínimo viável melhor e mais completo a cada iteração de desenvolvimento, bem como uma compreensão progressiva do problema e sua solução (TURKAY et al., 2019; BOX; HUNTER; HUNTER, 2008). Salienta-se que esse tipo de desenvolvimento pode ser compatível com o desenvolvimento de pesquisa quando se respeita o método científico e, da mesma forma, aprimora-se a pesquisa a cada iteração da aplicação. Jackson, Yaqub e Li (2019) aparenta apontar alguns pontos de atenção do desenvolvimento ágil voltado a aplicações de AM em healthcare.

Além do método ágil, o desenvolvimento também pode ser galgado em práticas adequadas de engenharia de software (SERBAN et al., 2020) e boas práticas de AM (ZINKEVICH, 2018). Em particular para a aplicação de AM na saúde, há boas práticas específicas e maneiras adequadas de reportar o desenvolvimento da aplicação. Kakarmath et al. (2020) apresenta um editorial da revista *Digital medicine* associada à revista *Nature* do qual é possível destacar cuidados que os autores devem ter ao reportar aplicações de inteligência artificial na saúde e Rose (2018) comenta sobre aspectos que podem melhorar a utilidade de uma aplicação de aprendizado de máquina, particularmente para predições a partir de dados de prontuário eletrônico. Dentre os aspectos mencionados, destacam-se:

- a aplicação deve ter uma relação clara de diagnóstico ou prognóstico com um problema de saúde importante;
- relatar qual potencial benefício clínico da aplicação e quando possível, comparar com outras técnicas de diagnóstico e tratamento;
- datasets devem contemplar aspectos demográficos variados para permitirem generaliza-

ção adequada;

- descrever as labels do dataset, os motivos de sua seleção e sua relação com o padrão ouro clínico;
- justificar o tamanho do dataset;
- sugerir quais padrões podem emergir dos dados a partir do conhecimento atual da área de aplicação;
- reportar o desempenho do modelo em termos matemáticos e clínicos;
- comparar (estatisticamente) os resultados do modelo com resultados obtidos de análise puramente humana, preferencialmente decorrentes de práticas padrão ouro e de rotina;
- apresentar o contexto clínico e a integração da aplicação da ferramenta no *workflow* clínico;
- discutir as implicações de erros do modelo e apresentar análises dos possíveis erros que ocorreram durante testes;
- detalhar a transferência de aprendizado quando utilizada;
- relatar a percepção e confiança dos usuários para com o modelo/ferramenta;
- apesar de comumente ser otimizada a *area under the receiver operating characteristic curve* (AUC), o que a clínica pode necessitar é de alta sensibilidade ou *positive predictive value*;
- quando o modelo é aplicado à previsão de intervenção em pacientes de alto risco, pode ser essencial calcular métricas como a porcentagem de casos verdadeiros (positivos e negativos) no percentil identificado de alto risco;
- “um padrão de avaliação aceito que pode ser adotado em futuras aplicações de aprendizado de máquina é a validação cruzada K-fold (por exemplo, com $k=10$)” (tradução minha, ROSE, 2018);
- não conseguir que o modelo seja generalizável pode ser um indicativo de que populações diferentes necessitam modelos diferentes;
- modelos que anteriormente atingiram boa generalização podem ficar ultrapassados a medida que técnicas de diagnóstico e tratamento mudam;
- algoritmos que conseguem combinar a experiência clínica com parâmetros robustos são as mais promissoras;
- identificar os níveis mínimos das métricas que resultem num modelo com capacidade de

previsão maior que a humana; e

- por fim, as aplicações de AM na área da saúde ainda estão sendo descobertas e exploradas, de modo que resultados devem analisados sob uma ótica pragmática, no sentido que essas aplicações não terão necessariamente o mesmo valor para diferentes áreas clínicas.

2.1. FORMA DE ANÁLISE DOS RESULTADOS

Uma vez desenvolvida a aplicação (ou a cada produto mínimo viável dela), os resultados do treino devem ser analisados sob aspectos de métricas, vieses/semântica e interpretabilidade para avaliar o desempenho e a capacidade preditiva do modelo de aprendizado. Finalizada a análise, é possível propor ajustes ao modelo ou concluir, caso satisfatório. Assim como na Seção 2, convém aguardar a definição do tipo de problema abordado para especificar os parâmetros de avaliação adequados ao objetivo do diagnóstico, tipo de aprendizado e dado utilizados.

Espera-se que, ao final do processo de pesquisa e desenvolvimento, a partir de dados de entrada, como radiografia, áudio, informações de anamnese ou outros, seja possível gerar um laudo estatístico da condição de saúde do paciente similar ao conceito apresentado no Apêndice. As saídas do modelo podem ser comparadas com resultados de literatura e, num prazo mais longo, comparadas ao resultado final do diagnóstico obtido pelo médico veterinário para avaliar a capacidade preditiva do modelo e contribuição no contexto clínico.

3. PLANO DE TRABALHO

A partir da entrada no programa de pós-graduação, serão realizadas as atividades protocolares exigidas em seu regulamento: disciplinas obrigatórias e de escolha livre, exame de proficiência em língua estrangeira, exame de qualificação, publicações e defesa. Concomitante às atividades protocolares, seguirão as atividades referentes às macro etapas (pipeline) discriminadas na Seção 2, sendo que os principais entregáveis propostos são:

1. Plano de pesquisa;
2. Protótipo conceitual;
3. Artigo de revisão bibliográfica das aplicações atuais para aves;
4. Deploy de réplica de trabalho de literatura;
5. "Matrícula" do(a) coorientador(a) médico(a) veterinário(a);
6. Artigo reportando o consenso da priorização do diagnóstico para ser abordado com AM²;
7. Artigo de validação do trabalho replicado;
8. Dataset compilado (e publicado em artigo?);
9. Código do(s) modelo(s) para início do treino, teste e ajuste de parâmetros;
10. Revisão bibliográfica sobre os modelos e métricas mais apropriados ao diagnóstico desejado e o dataset disponível;
11. Conclusão das disciplinas;
12. Qualificação e teste de proficiência;
13. Artigo reportando a capacidade preditiva do modelo e comparando-a com outros casos de aplicação (*benchmark*);
14. Deploy do modelo para validação por veterinários;
15. Artigo reportando os resultados da validação; e
16. Defesa de tese.

Ao longo do andamento das atividades, deve-se atentar para os valores do desenvolvimento ágil, bem como para a adaptação do escopo, objetivo e atividades conforme a redução das incertezas promovida pelo incremento do conhecimento do problema ao longo da pesquisa.

²A definição do diagnóstico e tipo de dado de entrada prioritários deverá atender uma relação de compromisso estratégica entre interesse veterinário, dataset disponível ou factível e hardware disponível para operação.

São propostas sugestões de publicação de artigos para que as etapas da pesquisa sejam continuamente revisada por pares, incrementando a possibilidade de resultar em uma aplicação bem embasada e robusta cientificamente.

Para a integralização dos 42 créditos em disciplinas, é inicialmente proposto a participação em uma gama de disciplinas que abordem o conhecimento de maneira horizontal, ou seja, um pouco em cada segmento do projeto, como apresentado na Tabela 1.

Tabela 1 – Proposta de participação em disciplinas.

Disciplina	Cr.	Justificativa
Metodologia e Preparação pedagógica	6	Disciplinas obrigatórias
Clínica e patologia de aves selvagens (UNESP-Campus Jaboticabal)	4	Imersão no método veterinário
EST5534 Aprendizado de Máquina Estatístico (PIPGES-ICMC/UFSCar)	10	Fundamentos de estatística aplicados ao aprendizado de máquina
SCC5900 Projeto de Algoritmos	12	Fundamento de algoritmos e obrigatória para ME/DD
SCC5789 ou SCC5845 Bases de Dados	12	Fundamentos sobre o dataset
TOTAL		44

Fonte: Autoria própria.

4. CONSIDERAÇÕES FINAIS

Finalmente, para completar o projeto de pesquisa, há a justificativa para a necessidade de uma coorientação em medicina veterinária. A coorientação de um profissional veterinário especialista em aves será importante em diferentes etapas do trabalho de pesquisa, por exemplo:

Geral: identificação da necessidade e acesso ao comitê de ética;

Definição do problema a ser abordado: auxílio na elaboração de formulários e entrevistas para outros veterinários, seleção preliminar do problema e dados prioritários;

Dataset: possíveis fontes, possíveis implicações éticas, identificação de vieses e dados espúrios;

Modelo: identificação de similaridades que apresentem potencial para interoperabilidade dos modelos de aprendizado entre humanos e aves;

Teste: avaliação preliminar da capacidade preditiva, avaliação junto a outros veterinários, protocolo de utilização, interpretação da avaliação de outros veterinários; e

Deploy: auxílio na promoção do uso para validação.

REFERÊNCIAS

ALONZO, Austin. **How audio analytics can detect respiratory disease:** new analytical software can detect symptoms of laryngotracheitis, infectious bronchitis and potentially other diseases as well as welfare issues. Out. 2020. Disponível em: <<https://www.wattagnet.com/articles/41408-how-audio-analytics-can-detect-respiratory-disease>>. Acesso em: 11 jan. 2021.

AWAYSHEH, Abdullah et al. Review of Medical Decision Support and Machine-Learning Methods. **Veterinary Pathology**, v. 56, n. 4, p. 512–525, 2019. PMID: 30866728. DOI: 10.1177/0300985819829524.

BANAKAR, Ahmad; SADEGHI, Mohammad; SHUSHTARI, Abdolhamid. An intelligent device for diagnosing avian diseases: Newcastle, infectious bronchitis, avian influenza. **Computers and Electronics in Agriculture**, v. 127, p. 744–753, 2016. ISSN 0168-1699. DOI: 10.1016/j.compag.2016.08.006.

BEAUFRÈRE, Hugues; AMMERSBACH, Mélanie; TULLY JR, Thomas N. Complete Blood Cell Count in Psittaciformes by Using High-Throughput Image Cytometry: A Pilot Study. **Journal of Avian Medicine and Surgery**, Association of Avian Veterinarians, v. 27, n. 3, p. 211–217, 2013. DOI: 10.1647/1082-6742-27.3.211.

BECK, Kent et al. **Manifesto for agile software development**. 2001. Disponível em: <<https://agilemanifesto.org/>>. Acesso em: 9 jan. 2021.

BELKO, Alina; DOBRATULIN, Konstantin; KUZNETSOV, Andrey. Feathers dataset for Fine-Grained Visual Categorization, 2020. Disponível em: <<https://github.com/feathers-dataset/>>.

BOX, George E.P.; HUNTER, J. Stuart; HUNTER, William G. **Estadística para Investigadores**: Diseño, innovación y descubrimiento. Tradução: Xavier Tomàs Morer. 2. ed. Barcelona: Reverté, 2008. 639 p. Versão espanhola do original inglês. ISBN 978-84-291-5044-5.

BRADLEY, Richard et al. Predicting early risk of chronic kidney disease in cats using routine clinical laboratory tests and machine learning. **Journal of Veterinary Internal Medicine**, v. 33, n. 6, p. 2644–2656, 2019. DOI: 10.1111/jvim.15623.

CARVALHO, Diogo V.; PEREIRA, Eduardo M.; CARDOSO, Jaime S. Machine Learning Interpretability: A Survey on Methods and Metrics. **Electronics**, v. 8, n. 8, p. 832, 2019. ISSN 2079-9292. DOI: 10.3390/electronics8080832.

CIHAN, Pinar; GÖKÇE, Erhan; KALIPSIZ, Oya. A Review on Determination of Computer Aid Diagnosis and/or Risk Factors Using Data Mining Methods in Veterinary Field. **Atatürk Üniversitesi Veteriner Bilimleri Dergisi**, Atatürk University, v. 14, p. 209–220, 2019. ISSN 1306-6137.

FEIYANG, Zhang et al. Monitoring behavior of poultry based on RFID radio frequency network. **International Journal of Agricultural and Biological Engineering**, v. 9, n. 6, p. 139–147, 2016. DOI: 10.3965/j.ijabe.20160906.1568.

FRAIWAN, Mohammad A.; ABUTARBUSH, Sameeh M. Using Artificial Intelligence to Predict Survivability Likelihood and Need for Surgery in Horses Presented With Acute Abdomen (Colic). **Journal of Equine Veterinary Science**, v. 90, p. 102973, 2020. ISSN 0737-0806. DOI: 10.1016/j.jevs.2020.102973.

FREITAS, Dhyonatan Santos de. **Diagnóstico automático de Ceratoconjuntivite Infeciosa Bovina por meio de Imagens Termográficas e Redes Neurais Convolucionais**. 2019. Diss. (Mestrado) – Universidade Federal do Pampa – Campus Bajé.

GUEDES, Reinaldo; COMUNIDADE. **Wikiaves**. 2008. Disponível em: <<https://www.wikiaves.com.br/wiki/psittaciformes>>. Acesso em: 31 dez. 2020.

HAPKE, Hannes; NELSON, Catherine. **Building machine learning pipelines**. O'Reilly Media, Inc., 2020. ISBN 9781492053194.

HESS, Laurie. Technology and the 21st Century Exotic Animal Veterinarian: Positives and Negatives. **Journal of Avian Medicine and Surgery**, Association of Avian Veterinarians, v. 25, n. 4, p. 295–299, 2011. DOI: 10.1647/1082-6742-25.4.295.

_____. The Internet: Friend or Foe? **Journal of Avian Medicine and Surgery**, Association of Avian Veterinarians, v. 24, n. 3, p. 237–240, 2010. DOI: 10.1647/1082-6742-24.3.237.

JACKSON, Stuart; YAQUB, Maha; LI, Cheng-Xi. The Agile Deployment of Machine Learning Models in Healthcare. **Frontiers in Big Data**, v. 1, p. 7, 2019. ISSN 2624-909X. DOI: 10.3389/fdata.2018.00007.

KAKARMATH, Sujay et al. Best practices for authors of healthcare-related artificial intelligence manuscripts. **npj Digital Medicine**, v. 3, n. 1, p. 134, out. 2020. ISSN 2398-6352. DOI: 10.1038/s41746-020-00336-w.

LEE, Jonguk et al. Stress detection and classification of laying hens by sound analysis. eng. **Asian-Australasian journal of animal sciences**, Asian-Australasian Association of Animal Production Societies (AAAP), Korean Society of Animal Science e Technology (KSAST), v. 28, n. 4, p. 592–598, abr. 2015. ISSN 1011-2367. DOI: 10.5713/ajas.14.0654.

- LIGHTFOOT, Teresa L. Geriatric Psittacine Medicine. **Veterinary Clinics of North America: Exotic Animal Practice**, v. 13, n. 1, p. 27–49, 2010. Geriatrics. ISSN 1094-9194. DOI: 10.1016/j.cvex.2009.10.002.
- LIU, Longshen et al. Assessment of heat stress in turkeys using animal vocalization analysis. In: (ASABE Paper No. 1801743), p. 1. DOI: 10.13031/aim.201801743.
- LUSTGARTEN, Jonathan L et al. Veterinary informatics: forging the future between veterinary medicine, human medicine, and One Health initiatives—a joint paper by the Association for Veterinary Informatics (AVI) and the CTSA One Health Alliance (COHA). **JAMIA Open**, v. 3, n. 2, p. 306–317, abr. 2020. ISSN 2574-2531. DOI: 10.1093/jamiaopen/ooaa005.
- OKINDA, Cedric et al. A machine vision system for early detection and prediction of sick birds: A broiler chicken model. **Biosystems Engineering**, v. 188, p. 229–242, 2019. DOI: 10.1016/j.biosystemseng.2019.09.015.
- ORNITHOLOGY, The Cornell Lab of; COMMUNITY. **Macaulay Library**. The digital conversion program began early in 2000. 1929. Disponível em: <<https://www.macaulaylibrary.org/>>. Acesso em: 31 dez. 2020.
- PERLE, Krista M. D. La. Machine Learning and Veterinary Pathology: Be Not Afraid! **Veterinary Pathology**, v. 56, n. 4, p. 506–507, 2019. PMID: 31185880. DOI: 10.1177/0300985819848504.
- PLANQUÉ, Bob; VELLINGA, Willem-Pier; COMMUNITY. **Xeno-canto**: Psittaciformes order. 2005. Disponível em: <<https://www.xeno-canto.org/explore/taxonomy?o=PSITTACIFORMES>>. Acesso em: 31 dez. 2020.
- POWERS, Lauren V. Common Procedures in Psittacines. **Veterinary Clinics of North America: Exotic Animal Practice**, v. 9, n. 2, p. 287–302, 2006. Common Procedures. ISSN 1094-9194. DOI: 10.1016/j.cvex.2006.03.001.
- ROMAGNANO, April. Examination and Preventive Medicine Protocols in Psittacines. **Veterinary Clinics of North America: Exotic Animal Practice**, v. 2, n. 2, p. 333–355, 1999. Physical Examination and Preventive Medicine. ISSN 1094-9194. DOI: 10.1016/S1094-9194(17)30127-5.
- ROSE, Sherri. Machine Learning for Prediction in Electronic Health Data. **JAMA Network Open**, v. 1, n. 4, e181404–e181404, ago. 2018. ISSN 2574-3805. DOI: 10.1001/jamanetworkopen.2018.1404.
- SADEGHI, M; BANAKAR, A et al. An Intelligent Procedure for the Detection and Classification of Chickens Infected by Clostridium Perfringens Based on their Vocalization. en. **Brazilian Journal of Poultry Science**, scielo, v. 17, p. 537–544, dez. 2015. ISSN 1516-635X. DOI: 10.1590/1516-635X1704537-544.
- SADEGHI, M.; BANAKAR, A. Gender Determination of Fowls by Using Bio-acoustical Data Mining Methods and Support Vector Machine. **Journal of Agricultural Science and Technology**, v. 19, n. 5, p. 1041–1055, 2017.
- SERBAN, Alex et al. Adoption and Effects of Software Engineering Best Practices in Machine Learning. In: PROCEEDINGS of the 14th ACM / IEEE International Symposium on Empirical Software Engineering and Measurement (ESEM). Bari, Italy: Association for Computing Machinery, 2020. (ESEM '20). ISBN 9781450375801. DOI: 10.1145/3382494.3410681.
- TURKAY, Cagatay et al. **Progressive Data Science: Potential and Challenges**. 2019. arXiv: 1812.08032.

ZINKEVICH, Martin. **ML Universal Guides**. 2018. Disponível em: <<https://developers.google.com/machine-learning/guides/rules-of-ml>>. Acesso em: 6 jan. 2021.



PapagaiA

Laudo estatístico de saúde

baseado em inteligência artificial

Data: 10 de dezembro de 2020

Nome: Loro

Gênero: Papagaio

Espécie: *Amazona aestiva*

Sexo: Indefinido

Idade: 40 anos

Tutor: Rafael

Contato: rahcor@protonmail.com

Veterinário: Médico veterinário

CRMV: 12.345

Contato: papagaia@pm.me

Local: Clínica veterinária

Endereço: Rua do Brasil, 10
São Carlos - SP

DADOS FORNECIDOS

Foram fornecidos os seguintes dados de entrada:

- Áudio
- Sintomas

Informações do arquivo de áudio:

Arquivo: exemplo-dante-ccbyncsa.mp3

721587fd0bf1c6c7e6d6a7c024b33

SHA256: 728280aa9298528e6645439b0e481
788c4a

Tamanho: 12 segundos

Ruído: ausente

Sintomas relatados:

- Perda de penas
- Outros


RESULTADO

Após análise realizada no dia 10 de dezembro de 2020, o sistema de inteligência artificial indicou, para esse paciente, as hipóteses de ocorrência de:

- Condição A
- Condição B

Atenção! Esses diagnósticos não são definitivos, ou seja, servem apenas de referência e devem ser complementados com exames adequados prescritos por um médico veterinário especialista em animais silvestres.

As probabilidades relativas dos possíveis diagnósticos obtidas do modelo de inteligência artificial se encontram na figura a seguir dispostas em ordem decrescente:



BREVE DESCRIÇÃO DO MÉTODO

O modelo de inteligência artificial utilizado no PapagaiA é baseado em uma rede neural profunda de três camadas (fonte). Os dados de treinamento e teste provêm de um conjunto de 1.234 arquivos de áudio da espécie *Amazona Aestiva*, divididos em uma fração de 3/4 para treinamento. Esses arquivos são originados principalmente das bases *xeno-canto* e *wikiaves*. Os próprios arquivos fornecidos ao PapagaiA são reutilizados no treinamento após o médico veterinário indicar o diagnóstico final, obtido após exames complementares, de modo a garantir a melhoria contínua do modelo.