

SISTEMA DE CLASSIFICAÇÃO DE IMAGENS PARA CATARATA EM CÃES

IMAGE CLASSIFICATION SYSTEM FOR CANINE CATARACTS

774

Gustavo Neves de Eyros¹, Mateus Ribeiro², Rian Yuri Rodrigues Ohara³, Luiz Lopes Junior⁴, Frederico Barbosa Muniz⁵, Thissiany Beatriz Almeida⁶

1, 2, 3 e 4- Graduando do Curso Superior de Desenvolvimento de Software, FATEC - Registro; 5 e 6 - Docente do Curso Superior de Desenvolvimento de Software, FATEC – Registro

Contato: frederico.muniz@fatec.sp.gov.br

RESUMO

O pré-diagnóstico da catarata em cães desempenha um papel crucial na preservação da saúde ocular desses animais. Identificar rapidamente a presença da catarata não apenas permite um tratamento adequado, minimizando o comprometimento da visão, mas também reduz significativamente o sofrimento dos cães. Além disso, um pré diagnóstico eficiente da catarata possibilita intervenções precoces e tratamentos apropriados, contribuindo para a conservação da saúde ocular e aprimorando a qualidade de vida dos cães afetados. O projeto proposto visa desenvolver um aplicativo que ofereça uma solução acessível e rápida para esse desafio, utilizando uma rede neural para o pré-diagnóstico eficiente da catarata em cães. Os resultados obtidos indicam que o aplicativo é eficaz e acessível, proporcionando um pré-diagnóstico confiável da doença em cães. Esse avanço representa uma contribuição significativa para o tratamento adequado e a promoção da saúde ocular canina, atendendo de maneira abrangente às necessidades das clínicas veterinárias.

Palavras-Chave: Pré-diagnóstico; Saúde ocular; Catarata..

ABSTRACT

Pre-diagnosis of cataracts in dogs plays a crucial role in preserving the ocular

health of these animals. Quickly identifying the presence of cataracts not only allows for proper treatment, minimizing vision impairment, but also significantly reduces the suffering of dogs. Additionally, efficient pre-diagnosis of cataracts enables early interventions and appropriate treatments, contributing to the conservation of ocular health and enhancing the quality of life for affected dogs. The proposed project aims to develop an application that offers an accessible and rapid solution to this challenge, utilizing a neural network for efficient pre-diagnosis of cataracts in dogs. The results obtained indicate that the application is effective and accessible, providing a reliable pre-diagnosis of the disease in dogs. This advancement represents a significant contribution to proper treatment and the promotion of canine ocular health, comprehensively addressing the needs of veterinary clinics.

Keywords: Pre-diagnosis; Ocular health; Cataracts.

INTRODUÇÃO

A Organização das Nações Unidas (ONU) desde o fim de 2015, juntamente com parceiros no Brasil e no mundo, trabalha para atingir os Objetivos de Desenvolvimento Sustentável (ODS), que foram definidos na Agenda 2030, um plano de ação global, com metas destinadas à sustentabilidade no mundo. Os objetivos e metas são integrados e possuem três dimensões do desenvolvimento sustentável, sendo elas: social, ambiental e econômica. Todas essas dimensões podem ser implementadas tanto pelo governo quanto pela sociedade civil, setor privado, e por cada cidadão (ONU, 2022). Os Objetivos de Desenvolvimento Sustentável relacionados a este projeto são as metas que se referem a fomentar a inovação, assegurar uma vida saudável e promover o bem-estar para todos, em todas as idades. A inovação desempenha um papel fundamental na consecução dessas metas, impulsionando o desenvolvimento de soluções criativas e sustentáveis para desafios globais, incluindo questões de saúde.

No entanto, é importante reconhecer que a inovação também pode ser

aplicada no campo da saúde ocular. O olho desempenha uma função crucial entre os órgãos sensoriais, pois desempenha um papel vital na visão e é essencial para a sobrevivência dos animais. Os animais, assim como os seres humanos, dependem do sentido da visão para obter alimento e escapar de possíveis ameaças, mas também estão suscetíveis a doenças oculares, como conjuntivite, membrana pupilar persistente, glaucoma e a catarata, que é o objeto de estudo deste trabalho.

A catarata em cães é uma condição na qual ocorre a perda da transparência normal do cristalino, uma estrutura intraocular que atua como uma lente. Quando a catarata está em estágio avançado, é possível observar uma área opaca e esbranquiçada no olho do cão (Lillmans, 2018) como exibido na figura 1. Essa condição é a principal causa de cegueira tratável em cães, e a única forma de tratamento eficaz é a remoção cirúrgica (Albuquerque et al., 2020). Existem várias causas para o desenvolvimento da catarata em cães, incluindo fatores metabólicos, senilidade, inflamações, toxinas, nutrição inadequada, uso de medicamentos, traumas e predisposição genética de raça (Zilá, 2021). Normalmente, a formação da catarata é lenta, começando com pequenas manchas esbranquiçadas até progredir e se tornar uma mancha do tamanho do olho, resultando em cegueira no cão. Felizmente, hoje em dia, a cirurgia é uma opção viável para eliminar as cataratas e melhorar a qualidade de vida dos cães afetados (Lillmans, 2018).

Figura 1 – Catarata

777

Fonte: Mendes (2016)

O pré-diagnóstico tradicional da catarata em cães é baseado em sinais clínicos, como visão embaçada, perda de contraste e halos em torno das luzes (Lillmans, 2018). No entanto, esses sintomas podem variar de um cão para outro e são subjetivos. A interpretação desses sinais depende da experiência do veterinário, o que pode levar a diagnósticos imprecisos ou atrasados. Além disso, a catarata em cães geralmente se desenvolve lentamente. Nos estágios iniciais, as mudanças no cristalino podem ser sutis e difíceis de detectar. O pré-diagnóstico pode falhar em identificar cataratas incipientes, especialmente quando os sintomas ainda não são evidentes (Zilá, 2021).

Em casos mais avançados, quando a opacidade do cristalino se torna densa, a ultrassonografia ocular é uma ferramenta importante para permitir a visualização das estruturas internas do olho, auxiliando o veterinário a avaliar a gravidade da catarata e o estado da retina (Dietrich, 2013).

Nesse sentido, a aplicação de tecnologia de inteligência artificial (IA), especificamente Redes Neurais Convolucionais (RNCs), pode ser uma solução promissora para a detecção precoce da catarata em cães. As RNCs são uma técnica avançada de aprendizado profundo comumente usada para tarefas de classificação de imagens. As RNCs têm se mostrado altamente eficazes na captura e aprendizado de padrões e características complexas presentes em imagens (Alves, 2018).

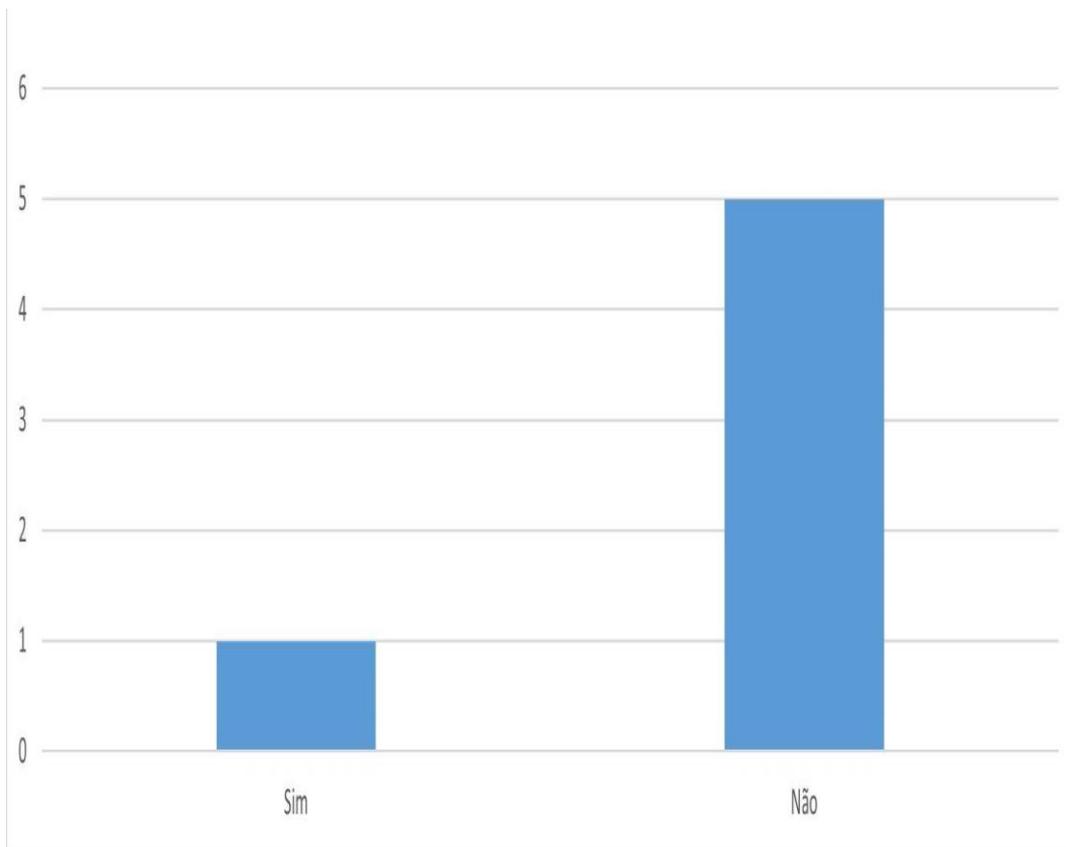
Neste projeto, o objetivo é apresentar um sistema que utilize IA, por meio de RNCs, para a detecção rápida e eficiente da catarata em cães. Essa abordagem tem o potencial de contribuir para um tratamento precoce e eficaz da anomalia, minimizando o sofrimento dos animais e reduzindo os custos para os proprietários. Além disso, a implementação desse sistema pode auxiliar na identificação mais ágil da catarata em cães resgatados, especialmente aqueles provenientes de áreas de risco que necessitam de tratamento.

Neste estudo, foi adotada uma amostragem por conveniência ao conduzir uma pesquisa de campo em seis clínicas veterinárias, selecionadas com base em critérios práticos, como proximidade geográfica e disponibilidade das clínicas. Foi desenvolvido um questionário composto por 12 questões, incluindo perguntas sobre doenças oculares em animais, visando avaliar a viabilidade do projeto e obter informações contextuais. Para garantir a representatividade do público-alvo, que são veterinários, foram selecionados exclusivamente profissionais veterinários para participar da pesquisa. A coleta de dados ocorreu por meio de visitas presenciais às clínicas veterinárias, onde os questionários foram distribuídos e preenchidos pelos participantes.

Os dados obtidos nesta pesquisa indicam que 83% das clínicas veterinárias não dispõem de aparelhos de ultrassonografia ocular, conforme mostrado na Figura 2. Essa limitação dificulta o diagnóstico de catarata em estágios avançados. Diante desse cenário, a rede neural desenvolvida neste projeto pode servir como uma ferramenta complementar eficaz, oferecendo diagnósticos precisos mesmo na ausência de equipamentos avançados.

779

Figura 2 – Gráfico de disponibilidade de Ultrassonografia Ocular – Pergunta: Possui Ultrassonografia ocular na clínica?



Fonte: elaborado pelo autor

PROCEDIMENTOS METODOLÓGICOS

O projeto em questão consiste no desenvolvimento de um sistema móvel para capturar imagens dos olhos de cães, enviando-as para uma rede neural para diagnóstico de catarata. Usuários podem acompanhar a saúde dos animais através de um histórico na plataforma.

O sistema é construído com React Native, uma estrutura de aplicativo móvel popular, baseada na linguagem JavaScript, que permite criar aplicativos móveis renderizados nativamente para iOS e Android (Cunha, 2023). A conexão com o banco de dados é feita usando FastAPI, uma ferramenta eficiente desenvolvida em Python (Lima, 2022). Para desempenho otimizado, é utilizado o Spring Boot em Java, que oferece uma arquitetura modular (Lima, 2021). As imagens são armazenadas na nuvem via Cloudinary, permitindo otimização e entrega eficiente (Astorga, 2023). O sistema é hospedado na plataforma Render, facilitando a construção, implantação e escalabilidade dos aplicativos (Hall, 2020).

Para armazenamento das informações, este projeto utiliza um banco de dados relacional (SQL), um termo utilizado para descrever bancos de dados que seguem o modelo relacional. Diferentemente dos bancos de dados NoSQL (Not Only SQL), os bancos de dados relacionais utilizam a linguagem SQL como linguagem principal para consultas. Esses sistemas são projetados para organizar dados de forma estruturada, utilizando tabelas e relações entre elas (Almeida, 2023). Neste projeto, utilizou-se o H2. O H2 é um sistema de gerenciamento de banco de dados relacional leve e eficiente, projetado para oferecer alto desempenho e facilidade de integração. Sua natureza incorpora as vantagens dos bancos de dados relacionais, proporcionando uma solução robusta para armazenamento e recuperação de dados (Junior, 2023).

No desenvolvimento da IA, o algoritmo de aprendizado de máquina

utilizado neste projeto é uma RNC, composta por três tipos principais de camadas: convolucionais, pooling e densas. Para esse projeto, utilizou-se a arquitetura VGG16, composta por 16 camadas, sendo 13 convolucionais e 3 densas.

As camadas convolucionais aplicam um número especificado de filtros de convolução à imagem. Para cada sub-região, a camada realiza um conjunto de operações matemáticas para produzir um único valor no mapa de recursos de saída (Bertoni; Feder, 2018).

As camadas de pooling reduzem a resolução dos dados extraídos pelas camadas convolucionais, com o objetivo de diminuir a dimensionalidade dos mapas de características, reduzindo a largura e a altura. Nas arquiteturas de convolução, é comum utilizar as funções de Max-pooling e AveragePooling, que determinam, respectivamente, o valor máximo e médio do agrupamento em uma vizinhança (Souza et al., 2020).

As camadas densas (totalmente conectadas) realizam a classificação com base nas características extraídas pelas camadas convolucionais e reduzidas pelas camadas de agrupamento. Em uma camada densa, todos os nós estão conectados a todos os nós da camada anterior (Bertoni; Feder, 2018).

O conjunto de dados utilizado consistiu em 56 imagens, sendo 28 saudáveis provisionados por uma base pública (eyes, 2023) e 28 não saudáveis provisionados da mesma maneira (Detection, 2023), igualmente divididas entre as duas categorias. Para melhorar o desempenho do modelo, foram aplicadas técnicas de aumento de dados, como rotação e zoom aleatórios. O aumento de dados cria variações artificiais das imagens de treinamento, o que ajuda o modelo a aprender melhor e a generalizar para novas imagens.

O modelo foi treinado por 25 ciclos, durante os quais ajustou automaticamente seus parâmetros para melhorar a precisão, com cada ciclo representando uma passagem completa pelo conjunto de dados de treinamento.

O treinamento e a validação do modelo foram realizados utilizando a placa de vídeo Radeon RX 5500 XT. Esta GPU é equipada com 8 GB de memória GDDR6 e possui um clock de núcleo de 1607 MHz, sendo ideal para o processamento intensivo de dados, como é o caso de redes neurais convolucionais.

Para construção do modelo, utilizou-se a função de softmax por sua capacidade de transformar os resultados da rede neural em probabilidades interpretáveis. Essa escolha se deve a vários fatores que contribuem para a precisão e a eficiência do sistema. A função softmax é aplicada na última camada da rede neural, convertendo os logits (valores de saída) em uma distribuição de probabilidades. Isso significa que cada valor de saída é transformado em uma probabilidade, facilitando a interpretação dos resultados. A fórmula matemática da softmax é:

Figura 3 – Função Softmax

$$s(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}}$$

Fonte: elaborado pelo autor

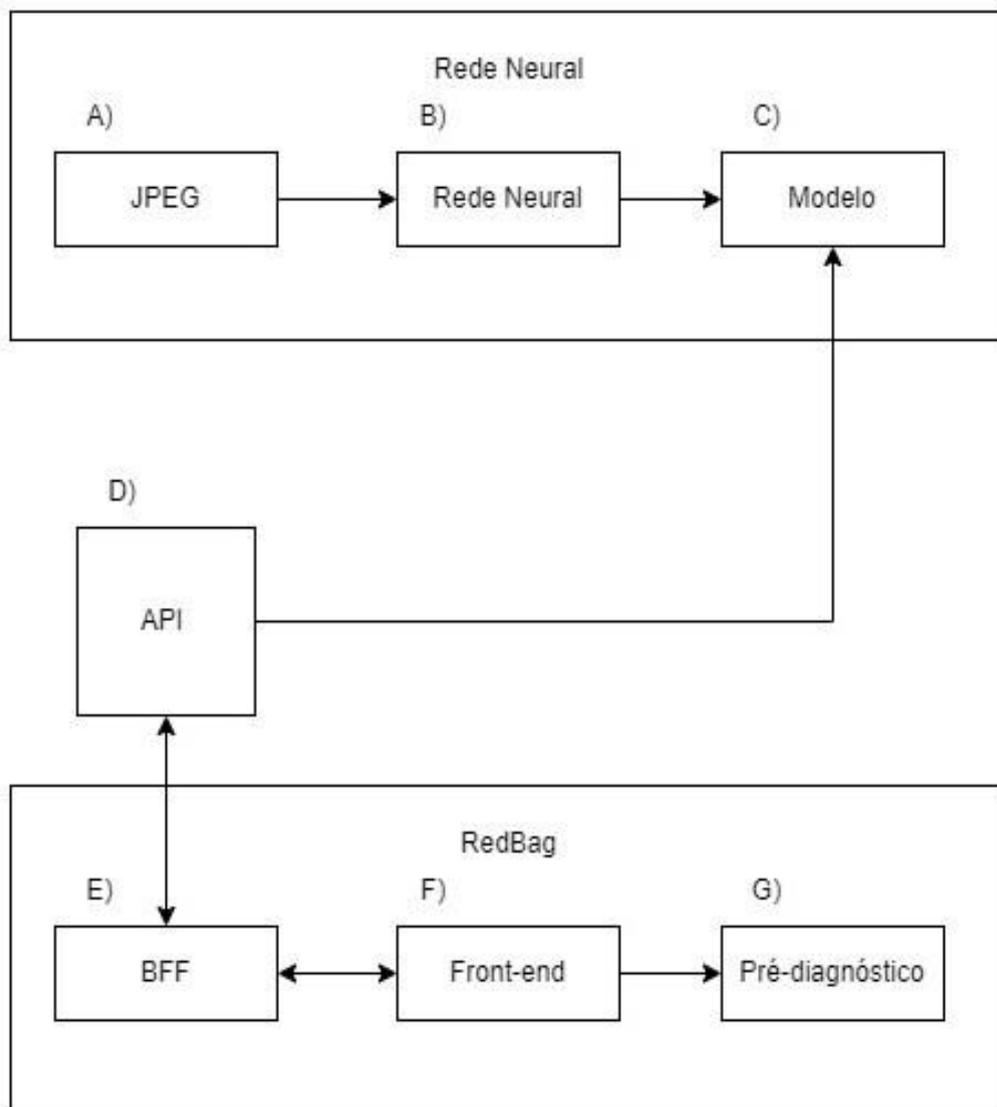
Onde z_i representa o valor de entrada para a i -ésima classe, e n é o número total de classes. Esse processo envolve a exponenciação dos valores de entrada e a normalização pela soma de todos os valores exponenciados, garantindo que a soma das probabilidades seja igual a 1. 5 Na prática, isso

permite que o modelo atribua uma probabilidade a cada classe (saudável ou não saudável), tornando o pré-diagnóstico mais confiável e fácil de interpretar tanto pelo sistema quanto pelo usuário final.

A arquitetura da aplicação, ilustrada na Figura 4, é fundamental para a implementação deste processo, onde:

- a) Representa a base de imagens em formato JPEG, contendo 56 fotos de cães saudáveis e não saudáveis. O formato JPEG foi escolhido por requerer menos memória e poder de processamento em comparação com outros, como o PNG;
- b) as imagens são processadas por uma rede neural convolucional baseada na arquitetura VGG16, composta por 16 camadas, sendo 13 convolucionais e 3 densas; c) a rede neural gera um modelo estruturado, contendo toda a lógica necessária para o pré-diagnóstico;
- c) API desenvolvida em Python utiliza o modelo gerado para receber novas imagens e calcular a taxa de acurácia dos resultados;
- d) API complementar desenvolvida em Java utilizada para conectar-se ao banco de dados e armazenar o histórico dos pré-diagnósticos realizados;
- e) a interface mobile serve para facilitar a visualização do histórico e dos resultados obtidos pelo usuário final;
- f) o retorno do pré-diagnóstico é apresentado visualmente ao usuário através desta interface mobile;

Figura 4 – Arquitetura do processo de funcionamento do sistema



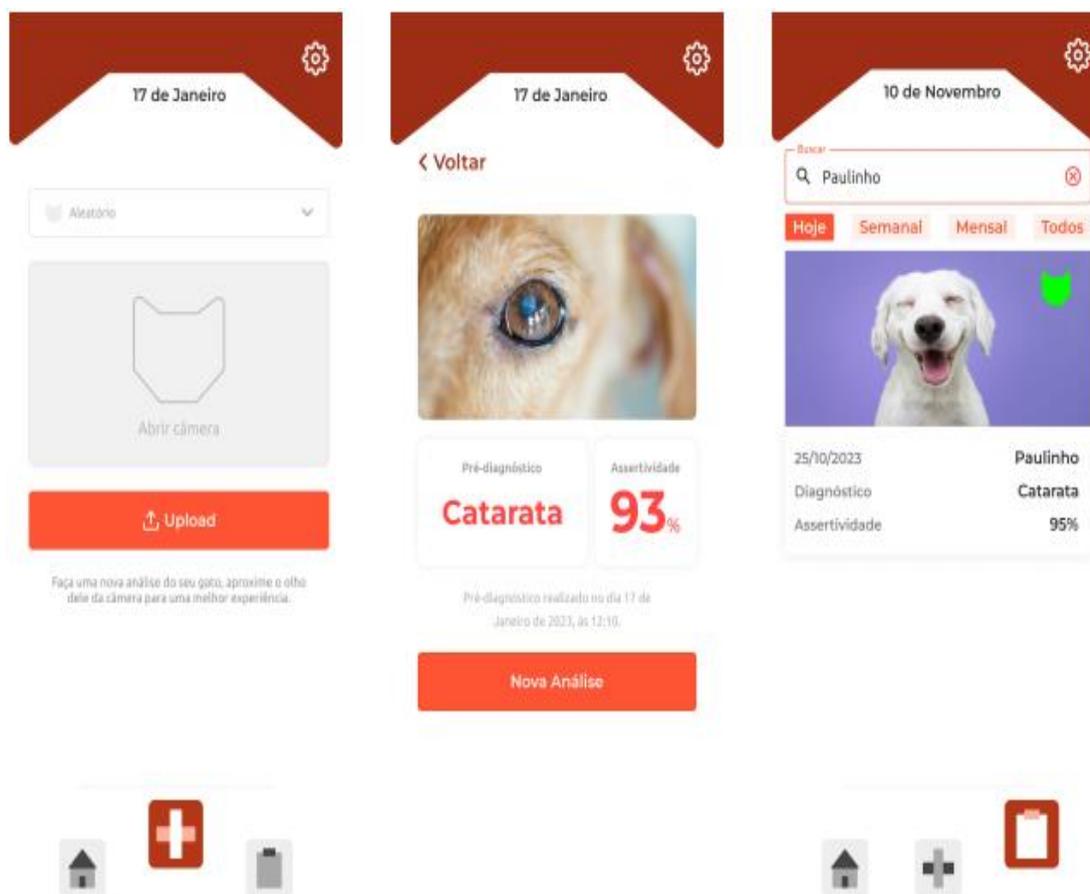
Fonte: elaborado pelo autor

RESULTADOS E DISCUSSÃO

Os resultados obtidos do projeto compreendem: a aplicação Mobile e a utilização das Redes Neurais Convolucionais no contexto do projeto.

Após acessar e se cadastrar no aplicativo, o usuário pode submeter uma imagem do animal usando a câmera do dispositivo para realizar o pré-diagnóstico (Figura 5a). Esse envio permite que a análise seja armazenada no histórico do aplicativo, facilitando consultas futuras. Essa funcionalidade é crucial para a integração do sistema e garante um acompanhamento completo do pré-diagnóstico. Após o envio da imagem na tela de análise (Figura 5a), o usuário recebe um retorno indicando se o animal está saudável ou não, juntamente com a precisão fornecida pela Rede Neural em relação a essa classificação (Figura 5b). Por fim, o usuário tem acesso ao histórico dos animais nos quais realizou o pré-diagnóstico (Figura 5c), com a possibilidade de obter informações específicas sobre cada animal, incluindo a data de envio da imagem, o nome e o estado de saúde, entre outros detalhes relevantes. Essa funcionalidade permite ao usuário acompanhar o registro completo das análises realizadas e facilita o monitoramento da evolução dos animais ao longo do tempo.

Figura 5 – Principais telas do aplicativo



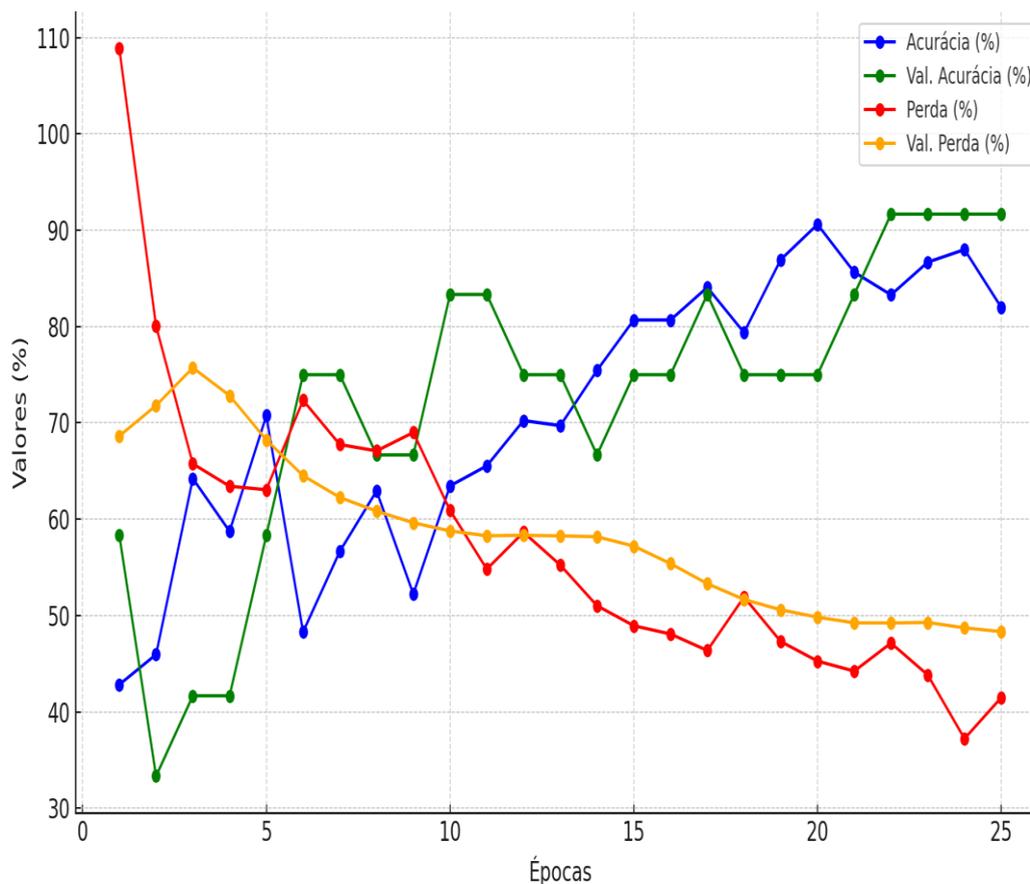
786

Fonte: elaborado pelo autor

Durante o treinamento, observou-se uma evolução notável nas métricas de desempenho. Inicialmente, a acurácia de treinamento começou em 42,83% e aumentou significativamente para 70,75% nas primeiras cinco épocas, com a perda de treinamento reduzindo de 108,85% para 63,06%. A acurácia de validação apresentou uma tendência de estabilização em 58,33% e a perda de validação diminuiu de 68,64% para 68,23%. À medida que o treinamento avançou, a acurácia de treinamento estabilizou entre 81,99% e 90,60%, e a perda de treinamento caiu para 41,48% até a época 25. A acurácia de validação atingiu um pico de 91,67% e a perda de validação estabilizou em 48,33%. Esses resultados indicam que o modelo não só melhorou seu ajuste aos dados

de treinamento, mas também apresentou uma capacidade eficaz de generalização para novos dados, sugerindo que o treinamento foi bem-sucedido e o modelo atingiu uma performance otimizada como exibido na figura 6.

Figura 6 – Principais telas do aplicativo



Fonte: elaborado pelo autor

Adicionalmente, a IA foi submetida a dois tipos de testes. Primeiramente, em relação a uma imagem saudável, observou-se que, quando treinada com metade da base de dados, classificou a imagem como saudável, apresentando uma probabilidade de 80,24%. Em contraste, ao ser treinada com a base total, a IA manteve a mesma previsão, mas com uma probabilidade significativamente

superior de 94,57%.

Em um segundo teste, a IA foi aplicada a uma imagem de um cão com catarata, caracterizando um estado não saudável. Neste cenário, a IA treinada com metade da base previu corretamente a classe como não saudável, com uma probabilidade de 85,97%. Por sua vez, quando treinada com a base total, a IA novamente fez uma previsão correta da classe não saudável, porém com uma probabilidade ainda maior de 93,84%.

Esses resultados corroboram a eficácia do modelo em diferentes contextos, demonstrando sua capacidade de classificação precisa tanto para imagens saudáveis quanto para aquelas que apresentam catarata. No entanto, é importante ressaltar que a obtenção de uma base de dados mais extensa é necessária para conduzir testes adicionais e aprimorar ainda mais a eficácia do modelo.

No entanto, a implementação desse sistema em clínicas veterinárias envolve desafios relacionados à integração da tecnologia com os processos existentes. A adoção de um sistema baseado em nuvem que utiliza IA requer não apenas a adaptação dos profissionais aos novos fluxos de trabalho, mas também uma mudança na cultura organizacional para incorporar o uso de novas ferramentas tecnológicas no dia a dia das clínicas. A familiarização com o sistema e o entendimento de seus benefícios são essenciais para garantir uma adoção eficaz.

Em termos de viabilidade econômica, é importante considerar os custos de implementação e manutenção do sistema. Embora a tecnologia envolva um investimento inicial, como a aquisição de infraestrutura de nuvem e a integração com o aplicativo, os benefícios a longo prazo podem superar os custos, especialmente considerando a eficiência no pré-diagnóstico precoce da catarata. Para clínicas menores, incentivos ou subsídios poderiam ser explorados para tornar a tecnologia mais acessível.

Uma possibilidade futura para melhorar a eficácia do modelo seria a criação de uma rede colaborativa, onde as clínicas veterinárias pudessem compartilhar imagens anonimizadas com outras clínicas participantes. Isso permitiria a ampliação contínua da base de dados, resultando em um modelo mais robusto e preciso. Como incentivo, clínicas que contribuíssem com imagens poderiam receber descontos ou outros benefícios no uso do sistema, criando um ecossistema de colaboração que beneficiaria tanto os desenvolvedores quanto os usuários da tecnologia. Além disso, clínicas que adotarem esse sistema podem se beneficiar de um diferencial competitivo, oferecendo diagnósticos rápidos e precisos, o que pode atrair novos clientes.

789

CONSIDERAÇÕES FINAIS

Com o objetivo de contribuir para as Metas de Desenvolvimento Sustentável estabelecidas, o presente projeto está alinhado com a terceira meta, relacionada à saúde e ao bem-estar. Essa correlação é evidente, uma vez que o sistema proposto permite um pré-diagnóstico eficiente e precoce da condição de catarata, prevenindo a progressão da doença para estágios mais avançados que poderiam resultar em cegueira total. Além disso, o projeto também se alinha com a nona meta, incentivando a pesquisa científica por meio de inovação e tecnologia.

Os principais usuários do sistema, direcionado para clínicas veterinárias, são os profissionais de saúde animal, permitindo um pré-diagnóstico rápido antes de uma consulta veterinária mais aprofundada. Contudo, ressaltamos a importância da confirmação desse pré-diagnóstico por parte de um veterinário, tornando-o um passo necessário. Em relação à viabilidade do projeto, é necessário conduzir testes mais aprofundados antes de sua implementação, uma vez que ainda não dispomos de uma base de imagens sólida para o

treinamento da Rede Neural. Além disso, estudos mais detalhados sobre o mercado de oftalmologia veterinária são essenciais para avaliar as viabilidades operacional e financeira.

Uma limitação significativa deste estudo reside no tamanho reduzido da amostra de dados utilizada. Com apenas 56 imagens (28 de animais saudáveis e 28 diagnosticados com catarata), a amostra disponível compromete a capacidade do modelo em generalizar os resultados para populações maiores e mais diversas, afetando, assim, a robustez estatística e a confiabilidade das previsões. Tal restrição pode introduzir vieses, limitando a precisão do pré-diagnóstico proposto. Para superar essa limitação, futuras iterações do projeto devem focar na ampliação do conjunto de dados, seja por meio de parcerias estratégicas com clínicas veterinárias, possibilitando a coleta de um volume mais representativo de imagens, seja pela adoção de técnicas avançadas de aumento de dados, como variações artificiais nas imagens existentes (rotacionamento, escalonamento, entre outras), que podem melhorar o desempenho do modelo e atenuar o impacto da amostra reduzida.

Adicionalmente, seria relevante realizar testes em condições de campo, com imagens capturadas em ambientes diversos, para avaliar a estabilidade e a precisão do modelo fora do laboratório. Esses testes permitiriam validar a eficácia do sistema em situações do dia a dia, aumentando a confiança na aplicabilidade do pré-diagnóstico em cenários reais de clínicas veterinárias. Portanto, pesquisas futuras devem considerar a implementação de testes em ambientes clínicos e a coleta de dados em diferentes contextos, o que contribuirá para a evolução do modelo e sua adaptação às variáveis encontradas no mundo real.

Em relação ao futuro do projeto, há planos para expandir a aplicabilidade do sistema, incluindo não apenas cães, mas também outros animais. Isso proporcionará uma abordagem mais abrangente e inclusiva, refletindo a

diversidade de animais de estimação nas clínicas veterinárias.

Concluindo, embora haja a atual limitação de uma base de imagens extensa para o treinamento, o projeto mantém sua viabilidade potencial, especialmente se for possível adquirir a base de imagens necessária. A proposta visa oferecer um sistema de fácil acesso para as clínicas veterinárias, ampliando as opções de mercado e contribuindo para avanços significativos na detecção precoce de condições oftalmológicas em animais.

791

REFERÊNCIAS BIBLIOGRÁFICAS

ALBUQUERQUE, L. et al. **Introdução à robótica educacional com Arduíno – hands on! iniciante.** [S. l.: s. n.], 2020. USP.

ALMEIDA, M. **Banco de dados relacionais: conhecendo conceitos, terminologias e ferramentas.** [S. l.: s. n.], jul. 2023. Disponível em: <https://www.alura.com.br/artigos/banco-dados-relacionais-conceitos-terminologias-ferramentas>. Acesso em: 10 de novembro 2023.

ALVES, G. **Entendendo Redes Convolucionais (CNNs).** [S. l.: s. n.], out. 2018. Disponível em: <https://medium.com/neuronio-br/entendendo-redes-convolucionais-cnns-d10359f21184>. Acesso em: 21 de maio 2023.

ASTORGA, M. Cloudinary: **A API de imagem e vídeo mais poderosa.** [S. l.: s. n.], abr. 2023. Disponível em: <https://vivevirtual.es/pt/inteligencia-artificial/cloudinary-la-api-de-imagen-y-video-mas-potentes>. Acesso em: 11 de novembro, 2023.

BERNI, A. **Uso de inteligência artificial para apoio na identificação de catarata,** 2021. Disponível em: <https://lume.ufrgs.br/handle/10183/235411>.

CUNHA, A. React Native: o que é e tudo sobre o Framework. [S. l.: s. n.], set. 2023. Disponível em: <https://www.alura.com.br/artigos/react-native>. Acesso em: 1 de maio, 2024.

DETECTION, Cat Breed. **Eye Disease Detection Dataset.** [S. l.]: Roboflow, set. 2023. <https://universe.roboflow.com/cat-breed-detection/eye-disease-detection->

eftgo.

DIETRICH, U. M. Ophthalmic Examination and Diagnostics. Part 3: Diagnostic Ultrasonography. 4. ed. [S. l.]: **Blackwell Publishing**, 2013. v. 1, cap. 10, p. 669–683.

EYES, Dog. **Healthy Dataset**. [S. l.]: **Roboflow**, jan. 2023. <https://universe.roboflow.com/dog-eyes/healthy-ul8lw>. visited on 2024-05-28.

FREITAS, D. et al. **Diagnóstico automático de Ceratoconjuntivite Infecciosa Bovina por meio de Imagens Termográficas e Redes Neurais Convolucionais**, 2019.

HALL, Susan. **Render: Cloud Deployment with Less Engineering**. [S. l.: s. n.], 2020. Disponível em: <https://brasil.un.org/pt-br/sdgs>. Acesso em: 26 de maio 2024.

JUNIOR, G. **Banco de dados H2 com Spring Boot**. [S. l.: s. n.], fev. 2023. Disponível em: <https://www.gasparbarancelli.com/post/banco-de-dados-h2-com-spring-boot>. Acesso em: 10 de novembro, 2023.

LILLMANS, G. **Catarata em cachorros: tratamento e cirurgia**. [S. l.: s. n.], ago. 2018. Disponível em: <https://www.peritoanimal.com.br/catarata-em-cachorros-tratamento-e-cirurgia-21743.html>. Acesso em: 27 de abril, 2024.

LIMA, C. **O que é FastAPI?** [S. l.: s. n.], abr. 2022. Disponível em: <https://www.treinaweb.com.br/blog/o-que-e-fastapi>. Acesso em: 10 de novembro 2023.

MENDES, R. **Catarata**: Saiba como identificar esse problema no seu Pet. [S. l.: s. n.], set. 2016. Disponível em: <http://www.jardimfranca.vet.br/catarata>. Acesso em: 27 de abril, 2024.

ONU. **Sobre o nosso trabalho para alcançar os Objetivos de Desenvolvimento Sustentável no Brasil**. [S. l.: s. n.], 2022. Disponível em: <https://brasil.un.org/pt-br/sdgs>. Acesso em: 11 de maio 2023.

SOUZA, V. et al. **Análise Comparativa de Redes Neurais Convolucionais no Reconhecimento de Cenas**, 2020. Disponível em: <https://periodicos.univali.br/index.php/acotb/article/view/16801>.

ZILÁ, M. **Catarata em cães: causas, raças propensas e tratamento**. [S. l.: s. n.], jun. 2021. Disponível em: <https://www.adoropets.com.br/catarata-em-caes>.

Acesso em: 27 de abril, 2024.

Os autores declaram não haver qualquer potencial conflito de interesses referente a este artigo.