

Sistema de Classificação de Imagens para Catarata em Cães

Image Classification System for Canine Cataracts

Frederico Barbosa Muniz	{ frederico.muniz@fatec.sp.gov.br }
Gustavo Neves de Eyros	{ gustavo.eyros@fatec.sp.gov.br }
Luiz Lopes Junior	{ luiz.lopes19@fatec.sp.gov.br }
Mateus Ribeiro	{ mateus.ribeiro13@fatec.sp.gov.br }
Rian Yuri Rodrigues Ohara	{ rian.ohara@fatec.sp.gov.br }
Thissiany Beatriz Almeida	{ thissiany.almeida@fatec.sp.gov.br }

RESUMO

O pré-diagnóstico da catarata em cães desempenha um papel fundamental na preservação da saúde ocular desses animais, permitindo intervenções precoces que minimizam o comprometimento visual e o sofrimento dos cães afetados. O presente projeto desenvolveu um aplicativo acessível e eficiente, que utiliza uma rede neural para realizar o pré-diagnóstico da catarata em tempo real. Durante o treinamento do modelo, observou-se uma evolução significativa na acurácia, alcançando 87,50% com a base completa após 25 épocas, evidenciando uma capacidade de generalização consistente. Adicionalmente, testes realizados com imagens de cães saudáveis e acometidos por catarata confirmaram a eficácia do modelo: ao ser treinado com a base completa, a IA diagnosticou corretamente uma imagem saudável com uma probabilidade de 94,57% e uma imagem de um cão com catarata com 93,84%. Conclui-se, portanto, que a solução desenvolvida oferece diagnósticos rápidos e confiáveis, representando uma contribuição relevante para as clínicas veterinárias, além de promover a saúde ocular canina de maneira eficaz.

PALAVRAS-CHAVE: Pré-diagnóstico; Saúde ocular; Catarata.

ABSTRACT

The pre-diagnosis of cataracts in dogs plays a fundamental role in preserving their ocular health, allowing for early interventions that minimize visual impairment and alleviate the suffering of affected dogs. This project developed an accessible and efficient application that uses a neural network to perform real-time pre-diagnosis of cataracts. During the model's training, a significant improvement in accuracy was observed, reaching 87.50% with the complete dataset after 25 epochs, demonstrating consistent generalization capability. Additionally, tests conducted with images of healthy and cataract-affected dogs confirmed the model's effectiveness: when trained with the full dataset, the AI correctly diagnosed a healthy image with a probability of 94.57% and an image of a dog with cataracts with 93.84%. It is concluded, therefore, that the developed solution provides fast and reliable diagnoses, representing a significant contribution to veterinary clinics and effectively promoting canine ocular health.

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



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).

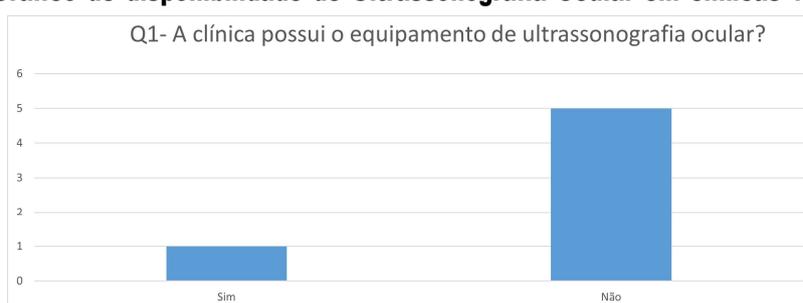
Nesse sentido, a aplicação de tecnologia de inteligência artificial (IA), especificamente Redes Neurais Convolucionais (RNCs), pode ser uma solução promissora para a detecção precoce da catarata em cães. As RNCs são uma técnica avançada de aprendizado profundo comumente usada para tarefas de classificação 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.

Figura 2 - Gráfico de disponibilidade de Ultrassonografia Ocular em clínicas veterinárias



Fonte: Autoria Própria (2024)

OBJETIVO

O objetivo geral é desenvolver um sistema de reconhecimento por Inteligência Artificial capaz de identificar a presença de catarata em cães de forma rápida e eficiente, contribuindo para a detecção precoce da anomalia, o que pode auxiliar na minimização do sofrimento dos animais e na conservação da saúde ocular.

ESTADO DA ARTE

A aplicação da IA no diagnóstico de doenças oculares em animais é uma área de crescente relevância, especialmente considerando a importância da visão para a sobrevivência dos animais. Este trabalho se concentra no diagnóstico de catarata, destacando projetos relevantes. Por exemplo, (Berni, 2021) desenvolveu um sistema integrado ao Teleoftalmo que analisa imagens oculares remotamente com uma acurácia de até 88,5%. Em (Scarpitta *et al.*, 2021), utiliza algoritmos como *Random Forest* para identificar Retinopatia Diabética e glaucoma com acurácia superior a 92%. Com relação aos animais bovinos, (Freitas *et al.*, 2019) criou um sistema que diagnostica Ceratoconjuntivite Infecciosa Bovina com 87% de acurácia usando imagens termográficas. O projeto atual utiliza Redes Neurais Convolucionais (RNCs) para análise de imagens oculares, enviando os resultados diretamente ao usuário via um aplicativo independente. Embora haja avanços significativos no uso da IA para doenças humanas, sua aplicação em animais é limitada, destacando o potencial de crescimento nesta área.

O projeto apresentado por Freitas possui semelhanças com o projeto em questão no que se refere à busca por um diagnóstico precoce, visando um tratamento mais eficiente. No entanto, ele se diferencia em relação ao tipo de imagem utilizada, pois o projeto de Freitas requer o uso de imagens termográficas para a identificação da doença, enquanto o presente projeto se baseia em imagens oculares convencionais.

No projeto de Berni, também há similaridades, já que ambos envolvem a captura de imagens do globo ocular e o envio dessas imagens para uma base de dados previamente treinada para a identificação de doenças. Contudo, a principal diferença está no destino dos resultados, uma vez que no aplicativo proposto os resultados são enviados diretamente ao usuário do sistema.

O projeto de Scarpitta também apresenta pontos em comum, como a identificação de doenças oculares e o uso da linguagem de programação Python. Porém, ele se distingue por suas integrações com o serviço público de saúde, enquanto o sistema proposto é um aplicativo inicialmente independente. É importante salientar que o projeto de Berni e Scarpitta utiliza RNCs, as quais são também adotadas no projeto atual, devido ao seu valor como um avanço significativo no campo da IA.

Por meio dessas análises, podemos observar que existem diversos projetos que fazem uso da classificação de imagens para o pré-diagnóstico de doenças utilizando IA já foram desenvolvidos, porém é notável que as pesquisas são mais voltadas a doenças humanas.

METODOLOGIA

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 em uma instância AWS EC2, um serviço de computação escalável da Amazon que permite o gerenciamento de servidores virtuais, oferecendo flexibilidade e controle total sobre os recursos de infraestrutura. Além disso, testes unitários foram realizados com JUnit, uma ferramenta amplamente utilizada para testar unidades de código em Java, cobrindo mais da metade do código, o que garante

a confiabilidade e a manutenção do sistema a longo prazo.

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 *Average-Pooling*, 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: Autoria Própria (2024)

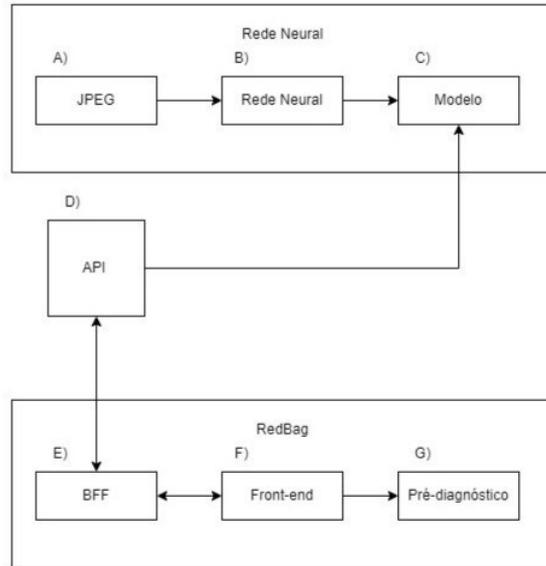
Onde z_i representa o valor de entrada para a i -ésima classe, e n é o número total de classes. Esse processo envolve a exponenciação dos valores de entrada e a normalização pela soma de todos os valores exponenciados, garantindo que a soma das probabilidades seja igual a 1.

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;
- d) API desenvolvida em Python utiliza o modelo gerado para receber novas imagens e calcular a taxa de acurácia dos resultados;
- e) API complementar desenvolvida em Java utilizada para conectar-se ao banco de dados e armazenar o histórico dos pré-diagnósticos realizados;
- f) a interface *mobile* serve para facilitar a visualização do histórico e dos resultados obtidos pelo usuário final;
- g) o retorno do pré-diagnóstico é apresentado visualmente ao usuário através desta interface *mobile*;

Figura 4 – Arquitetura do processo de funcionamento do sistema



Fonte: Autoria Própria (2024)

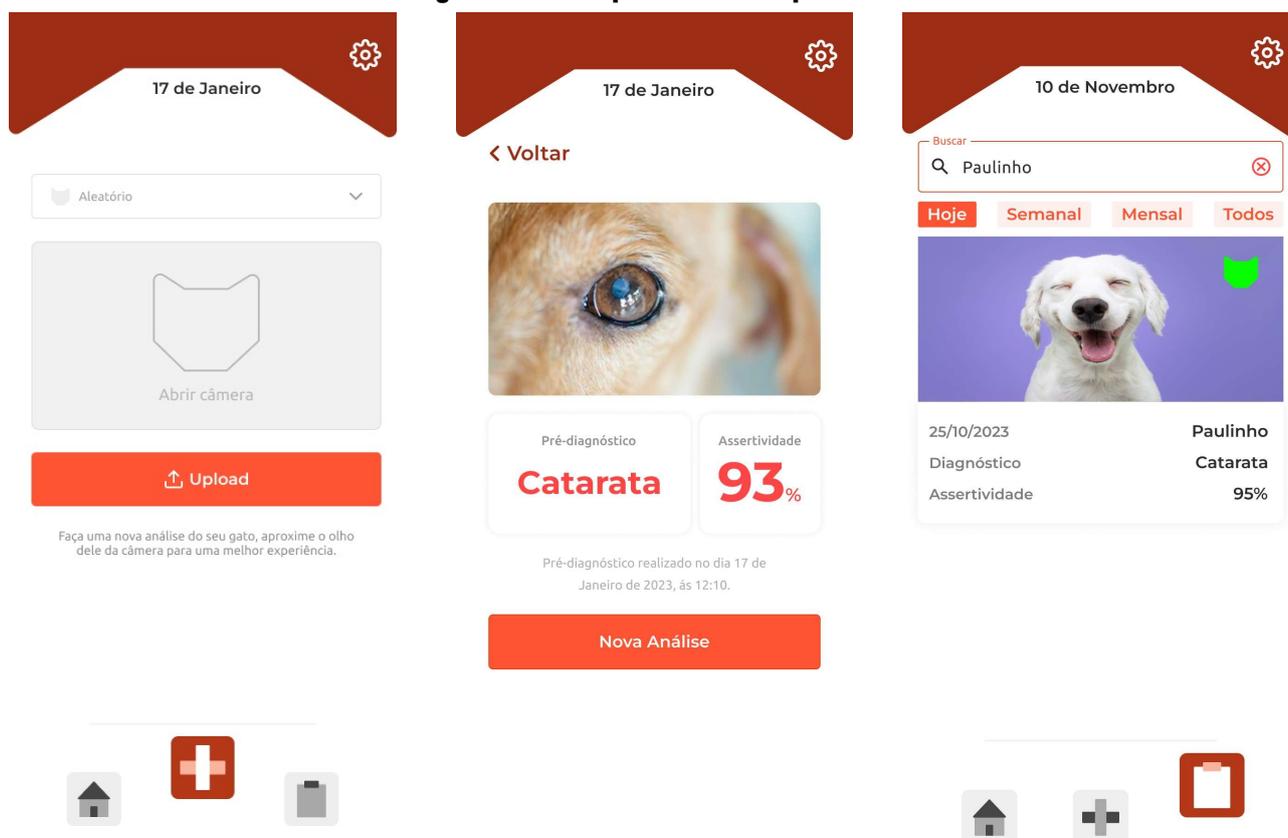
RESULTADOS E DISCUSSÕES

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



Fonte: Autoria Própria (2024)

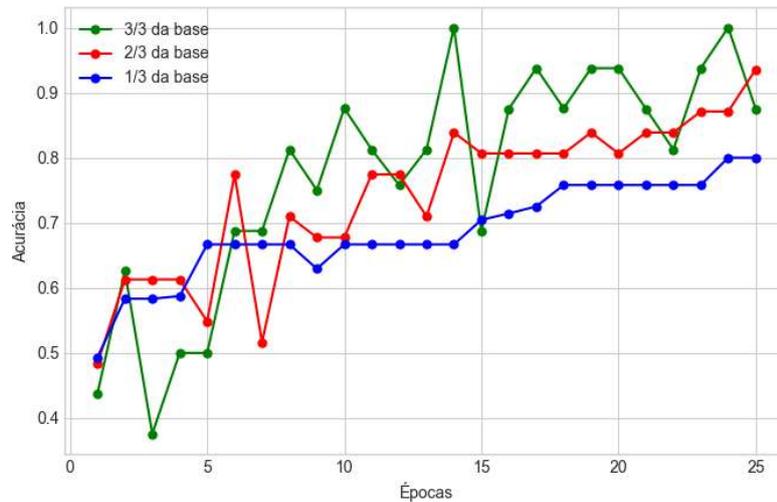
Durante o treinamento, observou-se uma evolução clara na acurácia de cada uma das bases ao longo das 25 épocas analisadas. A base composta por 1/3 dos dados (representada pela linha azul no gráfico) apresentou uma acurácia inicial de 49,33%, com uma evolução gradual e estável, alcançando uma acurácia de 80,00% ao final das 25 épocas. Esse comportamento demonstra uma melhoria progressiva na capacidade do modelo de se ajustar aos dados de treinamento dessa fração.

A base composta por 2/3 dos dados (linha vermelha) iniciou o treinamento com uma acurácia ligeiramente inferior de 48,39%, mas mostrou um salto expressivo após a quinta época, chegando a 77,42%. A acurácia dessa base também apresentou uma trajetória consistente de aumento, atingindo 93,55% ao final do período de treinamento, evidenciando uma boa capacidade do modelo de extrair padrões mesmo com uma quantidade maior de dados.

Por fim, a base completa (3/3 dos dados, representada pela linha verde) começou com uma acurácia de 43,75%, mais baixa do que as demais, e seguiu uma trajetória ascendente, particularmente após a quinta época, onde a acurácia subiu para 68,75%. A base completa, por ser maior e conter mais variabilidade, permitiu um ajuste mais refinado do modelo, o que se refletiu em uma acurácia final de 87,50%.

Esses resultados, apresentados na figura 6, mostram que o modelo se beneficiou do aumento de dados e das iterações. Todas as frações da base exibiram uma evolução consistente, com a base completa alcançando uma performance robusta, indicando que o modelo generalizou bem e convergiu para uma solução otimizada ao final do treinamento.

Figura 6 – Evolução das métricas por época



Fonte: Autoria Própria (2024)

Adicionalmente, a IA foi submetida a dois testes realizados por um usuário da região, que utilizou imagens de seus próprios cães, um saudável e outro com catarata. No primeiro teste, com a imagem do cão saudável, a IA treinada com metade da base de dados classificou corretamente a imagem como saudável, com uma probabilidade de 80,24%. Quando treinada com a base completa, a previsão permaneceu correta, mas com uma probabilidade significativamente maior de 94,57%.

No segundo teste, utilizando a imagem do cão com catarata, a IA também classificou corretamente a condição como não saudável. Com metade da base de dados, a probabilidade de acerto foi de 85,97%, enquanto com a base total, a previsão correta foi acompanhada de uma probabilidade aumentada, atingindo 93,84%.

Esses testes de usuários reforçam a eficácia do modelo em identificar corretamente tanto imagens saudáveis quanto de cães com catarata, destacando sua precisão em diferentes contextos. No entanto, a ampliação da base de dados é essencial para realizar mais testes e continuar aprimorando o desempenho do modelo.

CONCLUSÃO

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, a realização de testes adicionais com usuários seria útil para expandir a base de dados e melhorar a acurácia do modelo. Estudos mais detalhados sobre o mercado de oftalmologia veterinária também são imprescindíveis para avaliar as viabilidades operacional e financeira.

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.

REFERÊNCIAS

ALBUQUERQUE, L. *et al.* **Introdução à robótica educacional com Arduino – 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>.

BERTONI, A.; FEDER, G. Rede Neural convolucional aplicada à visão computacional para detecção de incêndio, 2018. Disponível em: <<http://repositorio.utfpr.edu.br/jspui/handle/1/8436>>.

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>. visited on 2024-05-28. Disponível em: <<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. Disponível em: <<https://universe.roboflow.com/dog-eyes/healthy-ul8lw>>.

FREITAS, D. *et al.* Diagnóstico automático de Ceratoconjuntivite Infecciosa Bovina por meio de Imagens Termográficas e Redes Neurais Convolucionais, 2019. Disponível em: <<http://www.alice.cnptia.embrapa.br/alice/handle/doc/1128432>>.

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.

LIMA, C. **O que é o Spring Boot?** [S. l.: s. n.], mar. 2021. Disponível em: <https://www.treinaweb.com.br/blog/o-que-e-o-spring-boot>. 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.

SCARPITTA, A. *et al.* Uso de técnicas de inteligência artificial para análise de retinografias e reconhecimento de processos patológicos, 2021. Disponível em: <<https://dspace.mackenzie.br/handle/10899/31040>>.

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.