



REDE NEURAL PARA DETECÇÃO DE PNEUS COM YOLOV8: UMA FERRAMENTA PARA O COMBATE À DENGUE

NEURAL NETWORK FOR TIRE DETECTION USING YOLOV8: A TOOL FOR DENGUE CONTROL

RED NEURONAL PARA DETECCIÓN DE NEUMÁTICOS CON YOLOV8: UNA HERRAMIENTA PARA EL COMBATE AL DENGUE

Andrey Alencar Quadros¹
Murilo Fuza da Cunha²

DOI: 10.54751/revistafoco.v18n4-021

Received: Mar 3rd, 2025

Accepted: Mar 25th, 2025



RESUMO

O aumento da incidência de dengue no Brasil, especialmente em áreas urbanas, representa um desafio significativo para a saúde pública. Este artigo apresenta uma solução inovadora que utiliza drones e redes neurais profundas para a detecção de pneus, que são potenciais criadouros do mosquito *Aedes aegypti*. O principal objetivo da pesquisa é desenvolver um sistema eficiente para identificar e mapear esses pneus em áreas endêmicas, empregando a arquitetura YOLOv8 para a detecção de objetos. A metodologia adotada envolve uma abordagem aplicada, utilizando técnicas de aprendizado de máquina e processamento de imagens, com a implementação do sistema em uma infraestrutura baseada em *containers Docker*, o que garante portabilidade e eficiência. A coleta de dados foi realizada em locais estratégicos, utilizando drones equipados com câmeras de alta resolução. Os resultados obtidos demonstraram a eficácia da API e do sistema de detecção, que se mostraram robustos e escaláveis para integração em sistemas de vigilância. A utilização de redes neurais profundas, como YOLO, possibilitou a detecção precisa de pneus em imagens, contribuindo para um mapeamento mais eficiente dos focos de dengue. O estudo conclui que a integração de tecnologias de inteligência artificial e drones pode revolucionar o combate à dengue, permitindo uma resposta mais rápida e eficaz a surtos da doença, além de sugerir direções futuras para a pesquisa, incluindo a ampliação do *dataset* e a melhoria contínua dos algoritmos de detecção.

Palavras-chave: Dengue; drones; inteligência artificial; detecção automatizada de pneus.

¹ Mestre Em Transferência De Tecnologia Para Inovação. Instituto Federal De Rondônia. Rodovia, RO-257, s/n - Zona Rural, Ariquemes - RO, CEP: 76870-000. E-mail: andrey.quadros@ifro.edu.br

² Graduado em Ciência da Computação. Universidade Federal de Rondônia (UNIR). Av. Pres. Dutra, 2965 - Olaria, Porto Velho - RO, CEP: 76801-058. E-mail: contato@murilofuza.com.br

ABSTRACT

The increasing incidence of dengue in Brazil, particularly in urban areas, presents a significant challenge for public health. This article presents an innovative solution that uses drones and deep neural networks for tire detection, as tires are potential breeding grounds for the *Aedes aegypti* mosquito. The primary goal of the research is to develop an efficient system to identify and map these tires in endemic areas, employing the YOLOv8 architecture for object detection. The methodology adopted involves an applied approach, utilizing machine learning techniques and image processing, with the implementation of the system on a Docker container-based infrastructure, ensuring portability and efficiency. Data collection was carried out in strategic locations using drones equipped with high-resolution cameras. The results obtained demonstrated the effectiveness of the API and the detection system, which proved to be robust and scalable for integration into surveillance systems. The use of deep neural networks, such as YOLO, enabled accurate tire detection in images, contributing to a more efficient mapping of dengue hotspots. The study concludes that the integration of artificial intelligence technologies and drones can revolutionize the fight against dengue, enabling a faster and more effective response to disease outbreaks, as well as suggesting future directions for research, including the expansion of the dataset and the continuous improvement of detection algorithms.

Keywords: Dengue; drones; artificial intelligence; automated tire detection.

RESUMEN

El aumento de la incidencia de dengue en Brasil, especialmente en áreas urbanas, representa un desafío significativo para la salud pública. Este artículo presenta una solución innovadora que utiliza drones y redes neuronales profundas para la detección de neumáticos, que son criaderos potenciales del mosquito *Aedes aegypti*. El objetivo principal de la investigación es desarrollar un sistema eficiente para identificar y mapear estos neumáticos en áreas endémicas, empleando la arquitectura YOLOv8 para la detección de objetos. La metodología adoptada implica un enfoque aplicado, utilizando técnicas de aprendizaje automático y procesamiento de imágenes, con la implementación del sistema en una infraestructura basada en contenedores Docker, lo que garantiza portabilidad y eficiencia. La recolección de datos se llevó a cabo en lugares estratégicos, utilizando drones equipados con cámaras de alta resolución. Los resultados obtenidos demostraron la efectividad de la API y del sistema de detección, que se mostraron robustos y escalables para la integración en sistemas de vigilancia. El uso de redes neuronales profundas, como YOLO, permitió la detección precisa de neumáticos en imágenes, contribuyendo a un mapeo más eficiente de los focos de dengue. El estudio concluye que la integración de tecnologías de inteligencia artificial y drones puede revolucionar la lucha contra el dengue, permitiendo una respuesta más rápida y eficaz ante brotes de la enfermedad, además de sugerir direcciones futuras para la investigación, incluyendo la ampliación del conjunto de datos y la mejora continua de los algoritmos de detección.

Palabras clave: Fiebre del dengue; drones; inteligencia artificial; detección automática de neumática.

1. Introdução

A Dengue é definida como uma febre aguda e não contagiosa, sendo uma das arboviroses mais importantes que afetam os humanos. Isso se deve à sua alta incidência e potencial de disseminação (Andrioli; Busato; Lutinski, 2020).

No Brasil, a maior epidemia foi registrada em 2015 (1.688.688 casos), com uma incidência de 826,0 casos por 100.000 habitantes, o que ilustra a ocorrência da dengue na última década com picos epidêmicos cada vez maiores e encurtamento dos períodos interepidêmicos (Andrioli; Busato; Lutinski, 2020). Sua incidência vem aumentando nas últimas décadas, expandindo-se geograficamente para regiões subtropicais.

Um fator crítico para esta disseminação está associado à proximidade de pontos estratégicos como ferros-velhos, borracharias e materiais recicláveis no Brasil (Johansen *et al.*, 2018). Visando tal situação, é possível precaver que locais como esses se tornem focos de dengue e permitam que uma doença possivelmente letal se manifeste desde pequenas cidades até grandes metrópoles, causando surtos e até casos de óbito.

Para enfrentar este desafio de saúde pública, nos últimos anos, o uso de tecnologias de inteligência artificial, como as redes neurais artificiais, tem-se mostrado uma ferramenta promissora na identificação e mitigação de fatores de risco em saúde pública. Essas tecnologias podem ser aplicadas para monitorar áreas de risco, prever surtos e direcionar ações de combate de forma eficiente (Guilherme *et al.*, 2022).

Em Rondônia, por exemplo, são publicados boletins epidemiológicos pelo governo do estado, disponíveis em <https://rondonia.ro.gov.br/agevisa/institucional/boletim-epidemiologico/> onde é possível analisar os casos de dengue e verificar épocas em que a doença tende a apresentar picos de casos e proliferação.

Neste contexto, o presente trabalho explora a aplicação de redes neurais para a detecção de pneus, que frequentemente servem como criadouros do mosquito *Aedes aegypti*, vetor da dengue. Com a detecção automatizada de possíveis focos, é possível otimizar o trabalho de vigilância sanitária, reduzindo o

tempo e os custos envolvidos, além de contribuir diretamente para o controle da disseminação da doença.

2. Revisão de Literatura

Técnicas de IA são amplamente aplicadas à detecção de surtos de doenças infecciosas, alerta precoce, previsão de tendências e modelagem e avaliação de resposta de saúde pública. (Zeng; Cao; Neill, 2020).

Essas aplicações aproveitam o poder de modelos preditivos para identificar padrões em grandes volumes de dados de saúde, sociais e ambientais, permitindo intervenções mais rápidas e eficazes.

Uma área de destaque é o uso de redes neurais profundas, como as arquiteturas YOLO (*You Only Look Once*), para detecção e classificação de objetos em imagens e vídeos. Essas redes têm mostrado eficácia em tarefas que envolvem análise de imagens de alta resolução, sendo utilizadas em aplicações que vão desde a identificação de condições médicas em exames de imagem até o monitoramento ambiental (Redmon *et al.*, 2016).

Sistemas de vigilância baseados em IA demonstraram capacidade significativa na detecção precoce de surtos de doenças infecciosas, como evidenciado durante a pandemia de COVID-19 (Bullock *et al.*, 2020). A integração de algoritmos de aprendizado de máquina com dados de vigilância sindrômica tem permitido a identificação mais rápida de anomalias e padrões emergentes em dados de saúde pública (Chimmula; Zhang, 2020).

2.1 Tecnologias no Combate à Dengue

Os drones podem ser uma ferramenta valiosa na vigilância e controle do *Aedes aegypti*, especialmente em áreas de difícil acesso, como telhados e quintais. (Valdez-delgado *et al.*, 2021)

Além desta capacidade de identificação, os drones equipados com câmeras de alta resolução podem cobrir grandes áreas em menos tempo quando comparados à inspeção manual tradicional. Esta tecnologia permite o acesso a

locais de difícil alcance, como telhados altos, terrenos acidentados e áreas remotas, possibilitando uma vigilância mais abrangente e eficiente.

A integração destes equipamentos com sistemas de geolocalização também facilita o mapeamento preciso dos pontos críticos, permitindo um planejamento mais estratégico das ações de controle e prevenção da dengue.

O uso de tecnologias geoespaciais, como Sistema de Informação Geográfica (SIG) e GPS, em conjunto com drones, tem demonstrado grande eficácia na identificação e monitoramento de áreas de risco (Akter *et al.*, 2019)

Estudos recentes demonstram que a combinação de imagens aéreas de alta resolução com dados de localização permite criar mapas detalhados de risco, identificando padrões espaciais de distribuição do vetor e orientando intervenções mais direcionadas e eficientes (Valdez-delgado *et al.*, 2023). Esta abordagem tecnológica não apenas otimiza recursos, mas também permite um monitoramento contínuo das áreas endêmicas, facilitando a detecção precoce de potenciais surtos.

2.2 Yolov8 e Detecção de Objetos

O YOLOv8 representa a mais recente evolução da arquitetura YOLO (*You Only Look Once*), desenvolvida pela *Ultralytics*. Este modelo mantém o princípio fundamental de detecção de objetos em uma única passagem, característica que o tornou conhecido por sua velocidade e eficiência (Jocher; Chaurasia; Qiu, 2023).

Uma das inovações significativas do YOLOv8 é a adoção de uma abordagem sem âncoras (*anchor-free*), que simplifica o processo de detecção e melhora a precisão em objetos de diferentes escalas. Além disso, a integração de uma nova espinha dorsal (*backbone*) aprimora a extração de características, permitindo que o modelo capture detalhes mais refinados das imagens. Essas melhorias resultam em um equilíbrio notável entre velocidade e precisão, posicionando o YOLOv8 como uma solução de ponta para aplicações em tempo real. (Terven; Córdova-esparza; Romero-gonzález, 2023)

O desempenho do YOLOv8 foi avaliado em *benchmarks* renomados,

como o *Microsoft COCO*, onde demonstrou alta precisão e capacidade de operação em tempo real em diversas plataformas de hardware. Além disso, o modelo apresenta melhorias na facilidade de uso para desenvolvedores, incluindo um pacote *Python* unificado e uma interface de linha de comando (CLI), que simplificam o treinamento e a implantação do modelo. Essas características reforçam a posição do YOLOv8 como uma ferramenta avançada e acessível para detecção de objetos em aplicações diversas. (Yaseen, 2024)

3. Materiais e Métodos

O método a ser utilizado neste trabalho é o da pesquisa aplicada, baseada em hipótese-dedução, utilizando referências científicas e tecnológicas para definição do problema, especificação da hipótese de solução e sua avaliação (Wazlawick, 2008). Para a análise do problema, foram realizados testes em máquinas pessoais e máquinas de alta performance para processamento e treinamento com *datasets* de imagens.

Técnicas e metodologias modernas de infraestrutura de aplicativos incentivam uma adoção acelerada de tecnologias de computação em nuvem, bem como várias tecnologias de virtualização (Scheepers, 2014). Além disso, acredita-se que o uso de técnicas de containerização e virtualização possa simplificar tanto o desenvolvimento quanto a implantação da solução proposta.

Dentre as métricas disponíveis para este estudo, considera-se que é imprescindível a avaliação da viabilidade de implementações com redes neurais para combater os problemas de propagação causados por mosquitos em determinadas épocas do ano. Visando entregar bons resultados, foi construído um plano de trabalho para garantir um bom desenvolvimento e apresentação de resultados.

O projeto foi constituído do planejamento das etapas de todo o processo de montagem de *datasets* até o desenvolvimento de ferramentas *FrontEnd* para visualização e utilização dos dados gerados através do software resultante desta pesquisa. Abordagens de desenvolvimento ágil se baseiam em uma abordagem incremental para a especificação, desenvolvimento e entrega do software,

permitindo que a equipe foque mais no software em si, e não necessariamente em sua concepção e documentação (Sommerville, 2011).

Visando o melhor aproveitamento das etapas de elaboração das atividades, sendo a equipe composta por apenas uma pessoa responsável por todo o processo, a divisão se deu em:

- A) Construção de *dataset*;
- B) Alimentação e treinamento de rede neural;
- C) Construção de API para consumo de dados e alimentação da rede;
- D) Construção de interface gráfica WEB para consumo das informações geradas e visualização em mapa.

Foi iniciado o estudo de viabilidade para a captura das imagens e identificação dos locais potenciais de focos. Com base nesses estudos, foram definidos os pontos iniciais do *dataset*, os quais serviram para criar versões base e gerar métricas de treinamento. A partir dessa análise, foi possível avaliar se seria necessário ampliar o número de imagens, considerando diferentes condições e cenários de captura, ou se as imagens iniciais seriam suficientes para o treinamento do modelo.

3.1 Equipamentos e Ferramentas

O desenvolvimento deste projeto envolveu o uso de diversos equipamentos e ferramentas, tanto de hardware quanto de software, para garantir a eficácia na detecção de pneus e no processamento das imagens capturadas pelos drones.

3.1.1 Hardware Utilizado

Para o processamento e treinamento da rede neural, foram utilizados dois computadores principais:

- A) **Computador de Desempenho Avançado:**
 - a) **Memória RAM:** 64 GB DDR4.
 - b) **Armazenamento:** 1 TB NVMe, garantindo alta velocidade de leitura e gravação de dados.

c) **Placa de Vídeo:** RTX 4090 com 24 GB de memória dedicada, proporcionando o poder de processamento necessário para treinar a rede neural em um tempo reduzido.

d) **Conexão de Rede:** 1 Gbps, assegurando transferências de dados rápidas e eficientes.

B) Notebook Avell A65ion:

a) **Memória RAM:** 32 GB.

b) **Processador:** Intel Core i7 de 12ª geração, com alto desempenho para suportar as demandas do treinamento e processamento das imagens.

c) **Placa de Vídeo:** RTX 4050 com 6 GB de memória, suficiente para a execução de modelos em tempo real e pré-processamento de dados.

d) **Conexão de Rede:** 1 Gbps, garantindo agilidade na comunicação com servidores e repositórios de dados.

Para a captura das imagens, foi utilizado o drone **DJI Mavic 2**, um modelo avançado que permite a gravação de vídeos e fotos aéreas em alta definição. O drone é controlado por um dispositivo móvel, no caso, um **Redmi Note 13 Pro**, que serve para operar o drone e visualizar as imagens em tempo real. As imagens capturadas pelo drone são armazenadas em um **cartão de memória de 128 GB**, garantindo amplo espaço para o armazenamento de dados durante as missões de captura.

3.1.2 Software e Bibliotecas

O software e as bibliotecas utilizadas no projeto foram essenciais para a construção do modelo de detecção e a interface de visualização dos resultados.

A) **RoboFlow** foi a plataforma escolhida para a anotação e pré-processamento das imagens, oferecendo ferramentas robustas para facilitar a organização e a preparação do dataset.

As bibliotecas e *frameworks* utilizados para o desenvolvimento do sistema de detecção incluem:

A) **Next.js** – *Framework* utilizado para o desenvolvimento da aplicação web que processa e exibe os resultados da detecção em tempo real.

-
- B) **Mantine** – Biblioteca de componentes *React* que foi usada para criar uma interface de usuário moderna e responsiva.
 - C) **FastAPI** – *Framework* rápido e eficiente para a construção de APIs que facilitam a comunicação entre o *front-end* e o *back-end* da aplicação.
 - D) **Ultralytics** – Biblioteca que fornece implementações otimizadas do modelo YOLOv8, permitindo o treinamento e a implementação de redes neurais para detecção de objetos.

Esses equipamentos e ferramentas formaram a base tecnológica para o desenvolvimento do projeto, proporcionando tanto a capacidade de treinamento e execução da rede neural quanto a criação de uma interface funcional para os usuários finais.

3.2 Metodologia de Coleta de Dados

A coleta de dados para o projeto se deu na cidade de Ariquemes - Rondônia, localizada a 203 quilômetros da capital Porto Velho, onde em dois locais, sendo eles a pista de kart municipal no centro da cidade e o pátio da GCM (Guarda Civil Municipal) que foi fornecido por parceria entre o projeto Cidades Inteligentes e a GCM.

As imagens foram capturadas através do drone disponibilizado pelo projeto em resolução 4k (3.840 *pixels* horizontais e 2.160 *pixels* verticais), com variações de 4 a 10 metros de altura, majoritariamente na parte inicial da manhã e final de tarde, variando de horário como 08 AM até 10 AM e no período da tarde entre 15 PM e 18 PM.

A coleta manteve um padrão de iluminação com alto índice de luz solar e sempre com o drone e sua câmera em posição contrária à luz do sol.

Figura 1. Imagem captura no período da manhã - ambiente simulado



Fonte: Captura do Autor, 2024

Figura 2. Imagem captura no período da tarde - ambiente simulado



Fonte: Captura do Autor, 2024

3.3 Treinamento do Modelo

Para a base de dados foi utilizado um *dataset* de 7100 imagens, onde todas

foram capturadas com o drone, de modo a padronizar as entradas. As imagens possuem processamentos para aumentar a base tendo um número restrito de imagens, sendo esses processamentos feitos através da plataforma Roboflow.

- A) *Virar: Horizontal, Vertical;*
- B) *Rotação: Entre -15° e +15°;*
- C) *Cisalhamento: ±10° Horizontal, ±10° Vertical;*
- D) *Escala de Cinza: Aplicar em 15% das imagens;*
- E) *Matiz: Entre -15° e +15°;*
- F) *Saturação: Entre -25% e +25%;*
- G) *Brilho: Entre -15% e +15%;*
- H) *Exposição: Entre -10% e +10%;*
- I) *Desfoque: Até 2.5px.*

3.4 Treinamento Local

Durante o treinamento da rede neural YOLOv8, utilizou-se um conjunto de aproximadamente 7.100 imagens, divididas em 6.400 para treinamento, 614 para validação e 300 para teste. A configuração do treinamento foi definida com os seguintes parâmetros:

Tabela 1. Configuração do treinamento

```
!yolo task=detect mode=train model=yolo8n.pt data='./data.yaml' \  
  dropout=0.4 \  
  cos_lr=True \  
  epochs=300 \  
  batch=16 \  
  imgsz=640 \  
  device=0 \  
  mosaic=1.0 \  
  mixup=0.3 \  
  augment=True
```

Fonte: Autores

A) *task=detect* : Este parâmetro especifica que a tarefa a ser realizada é

- de **detecção de objetos**, ou seja, o modelo irá aprender a identificar e localizar objetos nas imagens (neste caso, pneus).
- B) `mode=train`: Define que o modo de operação será de **treinamento**, permitindo que o modelo seja ajustado a partir dos dados fornecidos.
- C) `model=yolo8n.pt`: Indica o modelo pré-treinado a ser utilizado como ponto de partida. Neste caso, o modelo YOLOv8n (uma versão mais leve e otimizada do YOLOv8) será ajustado com os dados fornecidos.
- D) `data='./data.yaml'`: Especifica o caminho do arquivo `data.yaml`, que contém as configurações do conjunto de dados, como o número de classes e os caminhos para as imagens de treino, validação e teste.
- E) `dropout=0.4`: Aplica a técnica de **dropout**, que consiste em desligar aleatoriamente uma fração das unidades de uma camada durante o treinamento para evitar *overfitting*. O valor 0.4 indica que 40% das unidades serão desativadas durante o treinamento.
- F) `cos_lr=True` : Ativa o **cosine learning rate** (taxa de aprendizado cosseno). Esta técnica ajusta a taxa de aprendizado de maneira dinâmica, começando com um valor alto e diminuindo progressivamente com uma função cosseno, melhorando a convergência do modelo.
- G) `epochs=300`: Define o número de **épocas** (iterações sobre o conjunto completo de dados) que o treinamento irá realizar. Neste caso, o treinamento será realizado por 300 épocas.
- H) `batch=16`: Define o tamanho do **batch** (tamanho do lote) como 16. Isso significa que o modelo processará 16 imagens de uma vez antes de atualizar os pesos.
- I) `imgsz=640`: Define o **tamanho das imagens** de entrada para 640x640 *pixels*. Esta é a resolução das imagens que serão usadas durante o treinamento e inferência. Reduzir a resolução pode acelerar o treinamento, mas pode afetar a precisão na detecção de objetos pequenos.
- J) `device=0`: Especifica o dispositivo onde o treinamento ocorrerá. O valor 0 geralmente corresponde à **primeira GPU** disponível. Caso fosse configurado para `cpu`, o treinamento seria realizado na unidade de processamento central, mas o uso de GPU acelera significativamente o

processo.

- K) *mosaic* =1.0: A técnica de ***mosaic*** combina 4 imagens em uma única imagem de entrada, aumentando a variabilidade dos dados. O valor 1.0 indica que o mosaico será utilizado ao máximo, permitindo que o modelo aprenda diferentes contextos e variações de objetos.
- L) *mixup* =0.3: O ***mixup*** é uma técnica de aumento de dados que mistura aleatoriamente duas imagens e suas respectivas anotações. O valor 0.3 indica a intensidade dessa mistura, ou seja, 30% das imagens serão misturadas para gerar novas imagens de treinamento.
- M) *augment=True* : Habilita o ***data augmentation*** (aumento de dados), aplicando técnicas como rotação, zoom, corte e distorção nas imagens. Isso gera variações adicionais nos dados de treinamento, o que ajuda a evitar o *overfitting* e melhora a generalização do modelo.

O modelo YOLOv8n foi selecionado devido à sua eficiência em cenários com restrições de hardware, oferecendo um equilíbrio adequado entre precisão e desempenho. A arquitetura do YOLOv8 apresenta melhorias significativas em relação às versões anteriores, incluindo otimizações na detecção de objetos e na velocidade de inferência. (Yaseen, 2024)

Para aumentar a diversidade dos dados e melhorar a robustez do modelo, foram aplicadas técnicas de aumento de dados (*data augmentation*). O parâmetro *mosaic*=1.0 permitiu a composição de imagens mosaico, enquanto *mixup*=0.3 adicionou variações adicionais através da mistura de diferentes imagens. Essas técnicas são reconhecidas por melhorar a performance de modelos de detecção de objetos, aumentando a diversidade e a quantidade de dados de treinamento. (Kaur; Khehra; Mavi, 2021)

3.5 Roboflow

O treinamento realizado por meio da plataforma *Roboflow* utilizou o modo de treinamento *Roboflow 3.0 Object Detection (Fast)*, que se destacou pela sua eficiência e simplicidade. A plataforma demonstrou excelentes resultados ao aplicar recursos como auto-orientação das imagens, otimizando

automaticamente as entradas do modelo.

Todo o processo foi conduzido no modo gratuito, o que ressalta a acessibilidade da ferramenta sem comprometer a qualidade do treinamento, evidenciando a robustez e a eficácia da plataforma mesmo em configurações básicas.

3.6 API

A API foi desenvolvida utilizando a linguagem de programação *Python*, com o objetivo de consumir os dados processados pela rede neural e atuar como um ponto central de integração entre os sistemas consumidores de informações e a rede neural. Essa integração foi viabilizada por meio de bibliotecas especializadas, que desempenham papéis fundamentais em diferentes etapas do processo. Entre elas, destacam-se:

- A) *FastAPI*, utilizada para construir uma interface de comunicação rápida, eficiente e escalável para o consumo dos dados da rede;
- B) *Supervision*, responsável por facilitar o monitoramento e a análise dos dados processados;
- C) *Ultralytics*, que fornece suporte direto à implementação e ao uso da rede neural baseada no modelo YOLO.

3.7 Frontend

O desenvolvimento da interface web foi um componente fundamental do sistema, utilizando tecnologias modernas para garantir desempenho e usabilidade. O *Next.js* foi escolhido como *framework* principal devido à sua renderização híbrida, que combina *Server-Side Rendering* (SSR) e *Static Site Generation* (SSG). Essa abordagem proporciona carregamentos mais rápidos e uma experiência do usuário otimizada.

A arquitetura da interface foi estruturada com a biblioteca *Mantine*, que se destacou por suas funcionalidades avançadas, como sistema de temas personalizável, suporte nativo ao modo escuro e compatibilidade otimizada com

SSR no *Next.js*. Essas características ofereceram uma base robusta e moderna para a construção da interface gráfica.

A aplicação foi desenvolvida em *JavaScript* e incorporou a biblioteca *React Query* para gerenciamento eficiente de estados e comunicação com o *backend*. Essa combinação tecnológica possibilitou uma interface intuitiva, responsiva e otimizada, garantindo atualização em tempo real e integração eficiente com os sistemas subjacentes.

4. Resultados

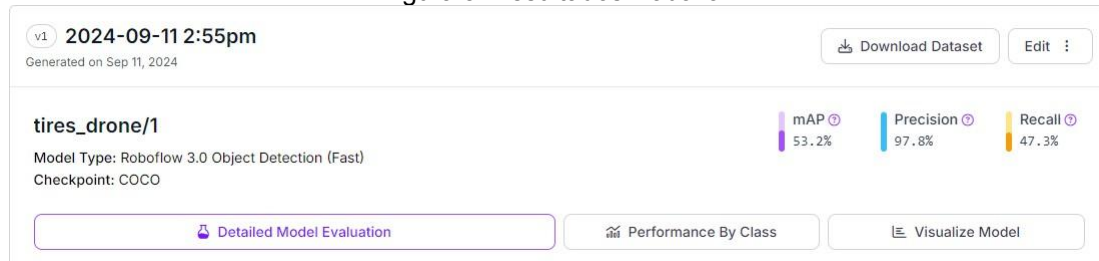
Os resultados obtidos demonstram a eficácia do modelo na detecção de pneus em imagens capturadas por drones, com indicadores de precisão, *recall* e *mean average precision* (mAP) que refletem a capacidade do modelo em identificar objetos de forma consistente em diferentes condições. Além disso, o sistema desenvolvido mostrou-se aplicável no monitoramento de focos de dengue, gerando informações georreferenciadas que podem auxiliar a vigilância sanitária.

4.1 Desempenho do Modelo

4.1.1 RoboFlow

O modelo de detecção de objetos foi treinado utilizando o modo *Roboflow 3.0 Object Detection (Fast)* da plataforma *Roboflow*, explorando os recursos disponíveis no modo gratuito, como a auto-orientação automática das imagens. Após o treinamento, o modelo foi avaliado com base em métricas amplamente utilizadas em visão computacional: precisão (*Precision*), revocação (*Recall*) e média da precisão média (*mean Average Precision* - mAP).

Figura 3. Resultados Roboflow



Fonte: Elaborado pelo Autor, 2025.


Precisão (*Precision*): o modelo alcançou um índice de 97,8%, indicando que a maioria das predições positivas realizadas foram corretas, o que reflete um alto nível de confiabilidade nas detecções realizadas.

Revocação (*Recall*): apresentou um valor de 47,3%, mostrando que quase metade dos objetos relevantes no conjunto de dados foi identificada corretamente, destacando um potencial para melhoria na cobertura das detecções.

Média da Precisão Média (*mAP*): o mAP foi de 53,2%, demonstrando um equilíbrio entre precisão e revocação ao considerar a acurácia do modelo em todas as classes detectadas.

Esses resultados evidenciam a capacidade do modelo em realizar detecções com alta precisão, embora haja oportunidades para aprimorar a identificação completa de todos os objetos relevantes. Essas métricas são fundamentais para entender a eficácia do modelo no contexto do problema e orientar melhorias futuras no processo de treinamento e ajuste.

Figura 4. Gráficos de treinamento Roboflow



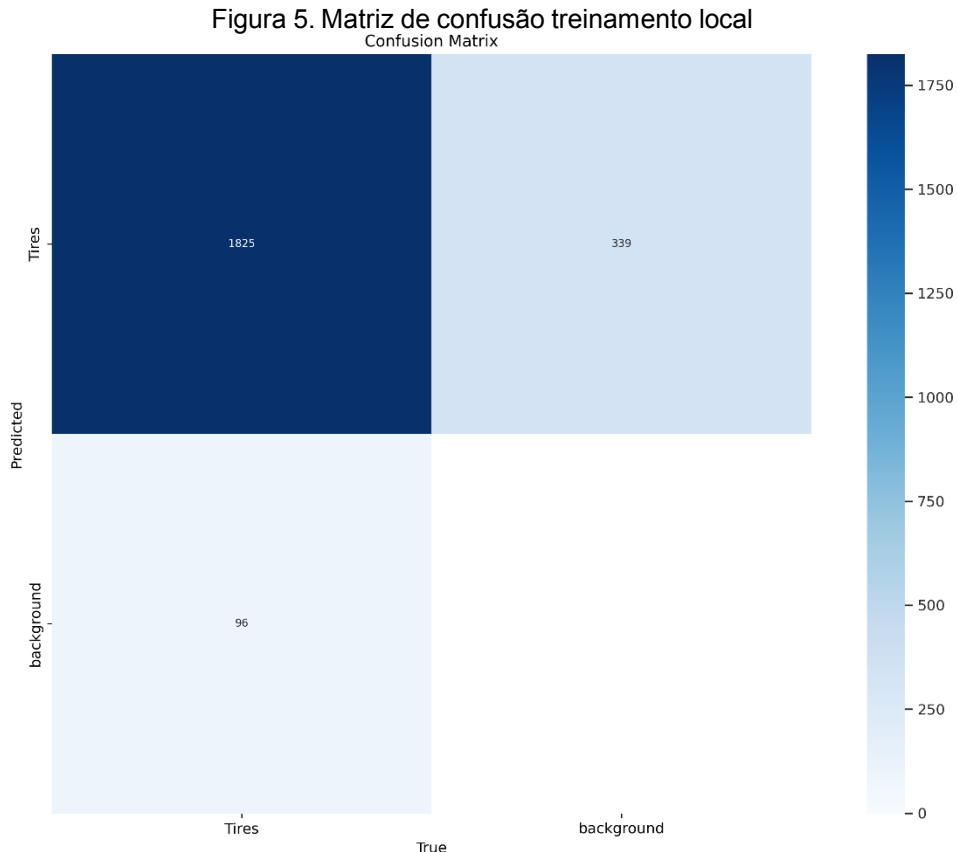
Fonte: Elaborado pelo Autor, 2025.

O treinamento, representado nas Figuras 3 e 8, foi realizado ao longo de 120 épocas e apresentou resultados satisfatórios, demonstrando um desempenho confiável para o modelo. Os valores obtidos para as métricas de avaliação, como precisão (*Precision*), revocação (*Recall*) e média da precisão média (*mean Average Precision - mAP*), evidenciam a consistência do treinamento e a adequação do modelo para a tarefa proposta, mesmo considerando possíveis melhorias futuras.

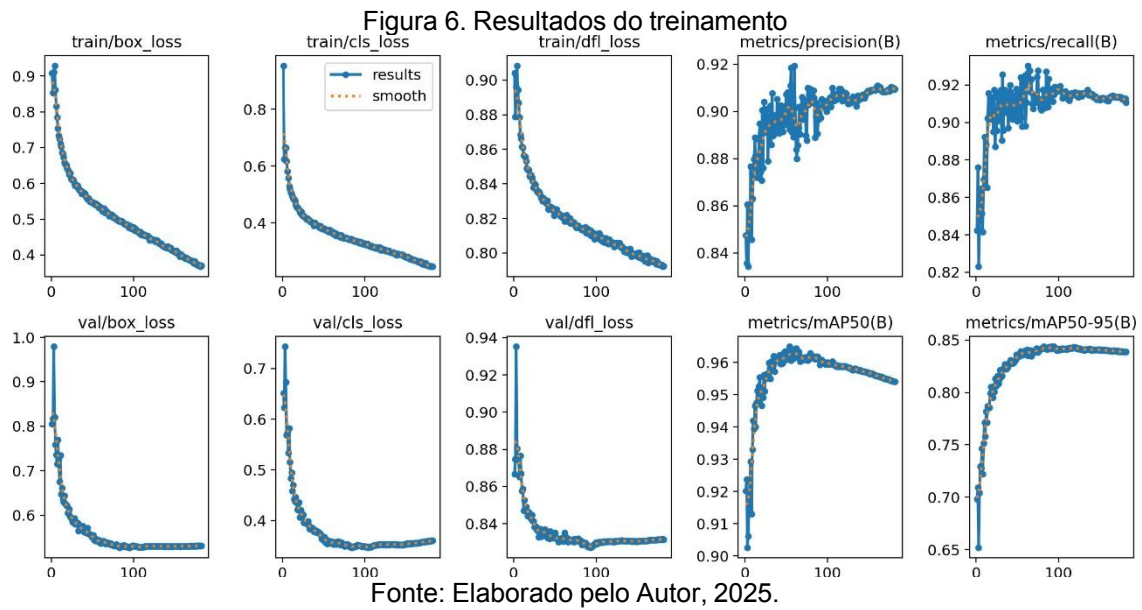
4.1.2 YoloV8 Local

O modelo de detecção de pneus demonstrou um desempenho robusto, alcançando métricas significativas na tarefa de detecção. A matriz de confusão revela que o modelo identificou corretamente 1.825 instâncias de pneus verdadeiros positivos, com apenas 339 falsos positivos e 96 falsos negativos, indicando uma alta precisão na classificação. A curva de precisão-*recall* apresenta um comportamento estável, mantendo uma precisão próxima a 1,0 até

aproximadamente 0,8 de *recall*, com um $mAP@0.5$ de 0,962 para a classe de pneus.



As métricas de treinamento demonstram uma convergência adequada do modelo, com as curvas de perda (*boxloss*, *clsloss* e *dflloss*) exibindo um padrão de redução consistente tanto no conjunto de treino quanto de validação. A precisão do modelo atingiu valores superiores a 0,90, enquanto o *recall* se estabilizou em aproximadamente 0,91, evidenciando um equilíbrio satisfatório entre estas métricas fundamentais. O valor de $mAP50-95(B)$ apresentou uma evolução positiva ao longo do treinamento, estabilizando-se em aproximadamente 0,84, o que indica um bom desempenho do modelo em diferentes limiares de IoU (*Intersection over Union*).



A análise das curvas de treinamento sugere que o modelo não apresentou *overfitting* significativo, dado que as perdas de validação acompanharam de forma consistente as perdas de treinamento. A estabilidade das métricas nas últimas épocas de treinamento indica que o modelo atingiu um ponto de convergência satisfatório, oferecendo um equilíbrio adequado entre precisão e generalização na tarefa de detecção de pneus.

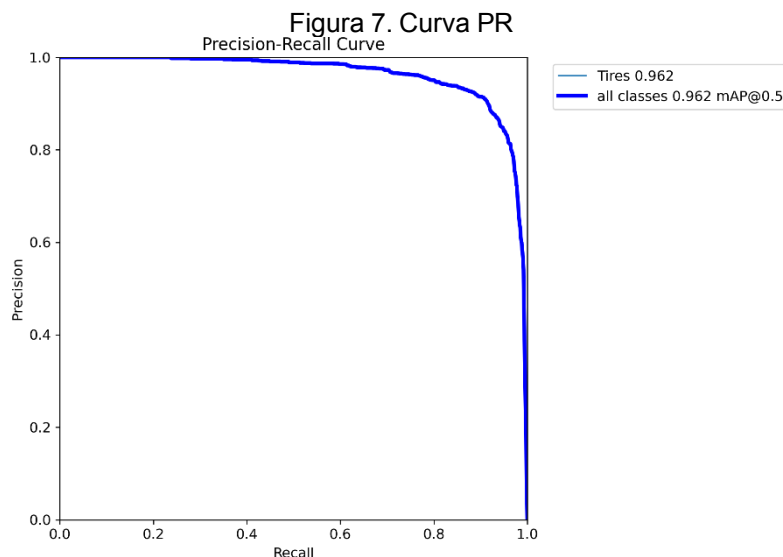



Figura 8. Imagem gerada através do treinamento



Fonte: Elaborado pelo Autor, 2025.

4.2 Desenvolvimento do Sistema

4.2.1 API

A API desenvolvida demonstrou alto desempenho e confiabilidade na integração do modelo YOLO com sistemas consumidores de informações, proporcionando uma solução eficiente para a detecção de objetos em imagens. Os testes realizados evidenciaram os seguintes resultados:

Desempenho no processamento de inferências: O tempo de resposta da API foi otimizado, com capacidade para lidar com imagens de alta complexidade visual. O uso de dispositivos acelerados por GPU (*CUDA*) garantiu maior eficiência computacional quando disponível.

Arquitetura modular e escalável: A implementação em FastAPI assegurou uma estrutura robusta, permitindo fácil integração com sistemas externos e simplificação no gerenciamento das operações de inferência.

Gerenciamento eficiente de recursos computacionais: Durante o ciclo de vida da aplicação, os modelos de aprendizado de máquina foram carregados e descarregados dinamicamente, otimizando o uso da memória e outros recursos do hardware.

Esses resultados demonstram a robustez e a eficiência da API como um componente essencial no pipeline de detecção de objetos, tornando-a uma solução viável e escalável para integração em sistemas de vigilância, diagnóstico ou monitoramento.

4.2.2 Sistema WEB

O sistema de monitoramento implementado consiste em três componentes principais:

- A) Um painel web desenvolvido usando *Next.js* e *TypeScript*;
- B) Um sistema de consumo de imagens baseado em *drone*;
- C) Um módulo de detecção alimentado por IA.

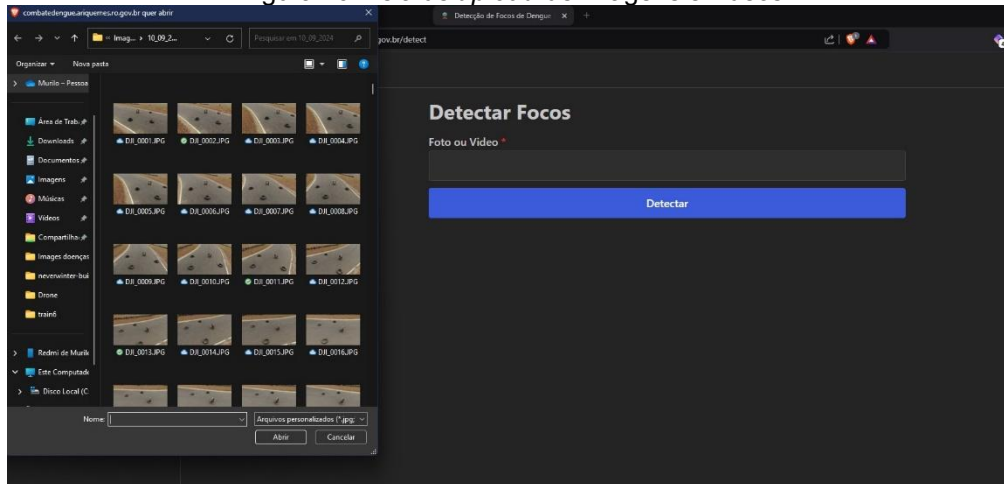
Figura 9. Tela inicial sistema de combate a dengue



Fonte: Elaborado pelo Autor, 2025.

O sistema oferece uma área central de *upload* claramente demarcada, onde os usuários podem carregar tanto imagens quanto vídeos para análise. Esta funcionalidade é indicada pelo rótulo "Foto ou Vídeo" com um asterisco vermelho, sinalizando um campo obrigatório. Após a seleção do arquivo, um botão "Detectar" em destaque, apresentado em azul, permite iniciar o processo de análise automaticamente.

Figura 10. Tela de *upload* de imagens e vídeos

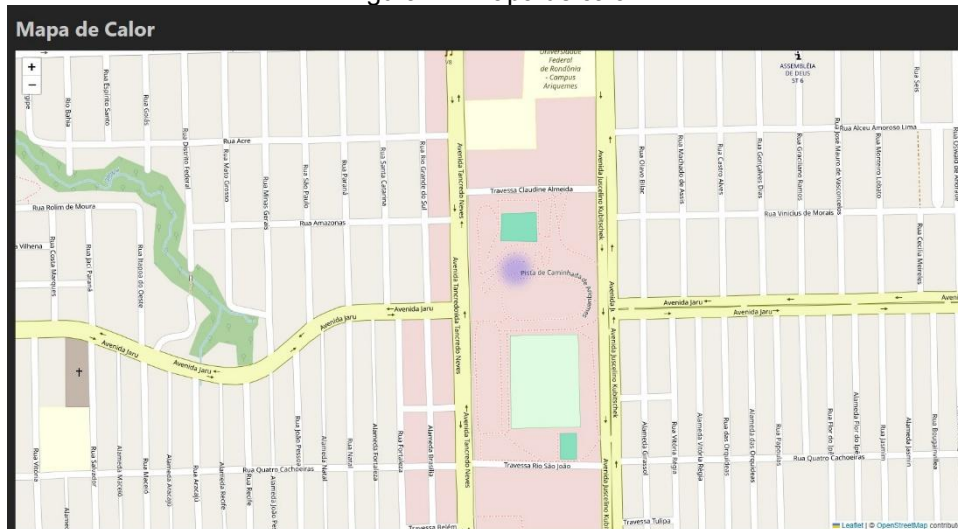


Fonte: Elaborado pelo Autor, 2025.

Após o *upload* da imagem, o sistema executa o processamento através do modelo de detecção treinado e fornece *feedback* imediato ao usuário. Como demonstrado na Figura 10, o sistema apresenta uma mensagem clara e objetiva dos resultados, indicando o número de focos de dengue detectados em uma barra de status verde. Esta resposta visual instantânea, exemplificada pela mensagem "4 focos de dengue detectados", permite que os agentes de saúde rapidamente avaliem a situação e tomem as medidas necessárias.

A interface mantém um alto contraste entre os elementos, com texto branco sobre fundo escuro e indicadores coloridos para status, seguindo boas práticas de design de interface. A confirmação visual em verde não apenas indica o sucesso da operação, mas também fornece uma resposta quantitativa precisa, fundamental para o registro e acompanhamento epidemiológico. Este *feedback* imediato otimiza o fluxo de trabalho dos agentes de saúde, permitindo uma rápida triagem das áreas analisadas e uma documentação eficiente dos focos encontrados.

Figura 11. Mapa de calor



Fonte: Elaborado pelo Autor, 2025.

O sistema incorpora uma funcionalidade avançada de visualização geoespacial através de um mapa de calor (*heatmap*) integrado, que proporciona uma representação visual dinâmica da distribuição espacial dos focos de dengue detectados. Como ilustrado na Figura 11, o mapa utiliza a biblioteca *Leaflet* em conjunto com dados do *OpenStreetMap* para apresentar a região monitorada, neste caso, uma área próxima à Universidade Federal de Rondônia, Campus Ariquemes.

A característica distintiva deste mapa de calor é sua capacidade de agregar dados georreferenciados das detecções realizadas pelo sistema. Cada imagem processada contribui com suas coordenadas geográficas para a construção de uma visualização térmica, onde áreas com maior concentração de focos são representadas por cores mais intensas - como demonstrado pela mancha azulada na região central do mapa. Esta representação visual evolui dinamicamente, intensificando-se em áreas onde múltiplas detecções são realizadas ao longo do tempo.

Esta abordagem de visualização oferece uma ferramenta crucial para a gestão epidemiológica, permitindo que as equipes de saúde identifiquem rapidamente *clusters* de focos de dengue e áreas de maior risco. A sobreposição do mapa de calor com o mapa urbano facilita a localização precisa das áreas afetadas e o planejamento eficiente das ações de combate ao vetor. O sistema

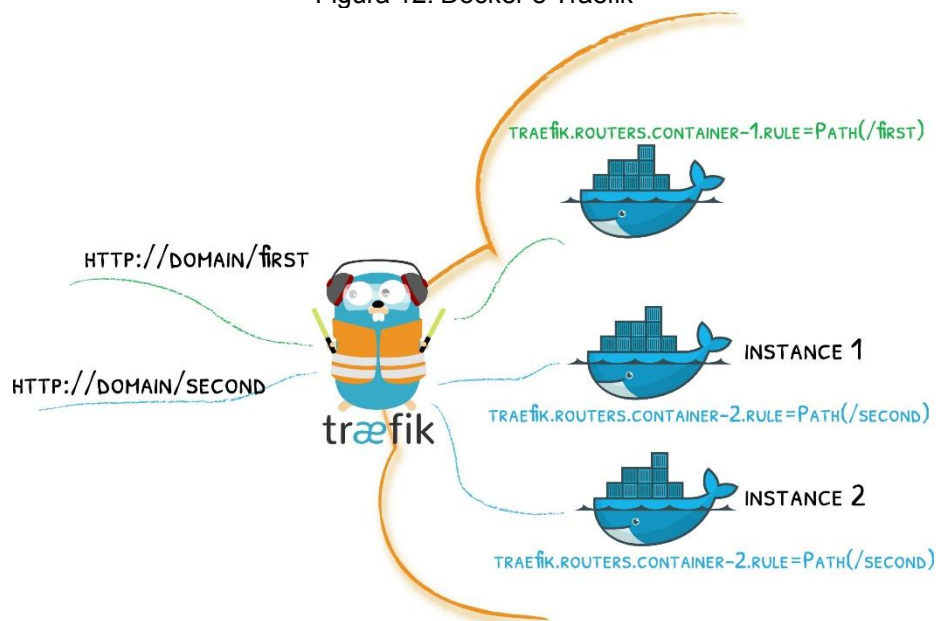
assim não apenas detecta os focos individualmente, mas também contribui para uma compreensão mais ampla do padrão de distribuição espacial dos criadouros do *Aedes aegypti* na região monitorada.

4.2.3 Infraestrutura e Arquitetura

A infraestrutura do sistema foi implementada utilizando *containers Docker*, garantindo isolamento e portabilidade dos serviços. Os principais componentes da infraestrutura incluem:

4.2.3.1 Containerização

Figura 12. Docker e Traefik



Fonte: Traefik Labs, 2025

- A) Utilização de *Docker* para encapsulamento dos serviços;
- B) Implementação de *Traefik* como *proxy* reverso, proporcionando:
 - a) Gerenciamento de SSL/TLS;
 - b) Roteamento dinâmico de requisições;
 - c) Monitoramento de saúde dos serviços.

4.2.3.2 Escalabilidade

- C) Orquestração de *containers* permitindo escala horizontal
- D) Distribuição eficiente de tráfego através do *Traefik*
- E) Auto-recuperação de serviços em caso de falhas

5. Discussão

Os resultados obtidos através do desenvolvimento e implementação do sistema de detecção de pneus demonstram a viabilidade e eficácia da integração entre *drones*, redes neurais e tecnologias web para o combate à dengue. O modelo YOLOv8 treinado apresentou métricas significativas, com uma precisão de 97,8% no ambiente Roboflow e uma matriz de confusão robusta no treinamento local, indicando alta confiabilidade na detecção de potenciais criadouros do *Aedes aegypti*.

A escolha da arquitetura YOLOv8 mostrou-se adequada para a aplicação, oferecendo um equilíbrio entre velocidade de processamento e precisão nas detecções. O uso de técnicas de *data augmentation* e a diversificação do *dataset* com diferentes condições de iluminação e ângulos contribuíram significativamente para a robustez do modelo, permitindo seu funcionamento em variadas condições ambientais.

A implementação da infraestrutura baseada em *containers Docker*, combinada com o *Traefik* como *proxy* reverso, demonstrou ser uma escolha acertada para garantir a escalabilidade e manutenibilidade do sistema. Esta arquitetura permite não apenas o crescimento horizontal da aplicação, mas também facilita sua implantação em diferentes ambientes operacionais, aspecto crucial para a adoção por diferentes municípios e órgãos de saúde.

O desenvolvimento da interface web com tecnologias modernas como *Next.js* e a implementação do mapa de calor proporcionaram uma ferramenta intuitiva e eficiente para os agentes de saúde. A visualização geoespacial dos focos detectados permite uma compreensão mais ampla da distribuição dos potenciais criadouros, facilitando o planejamento estratégico das ações de

combate ao vetor.

6. Conclusões e Trabalhos Futuros

Este trabalho demonstrou a viabilidade e eficácia de um sistema integrado para detecção automatizada de potenciais criadouros do *Aedes aegypti* utilizando drones e inteligência artificial. A implementação bem-sucedida do modelo YOLOv8, com altas taxas de precisão e *recall*, valida a abordagem proposta como uma ferramenta promissora para o auxílio no combate à dengue. A arquitetura modular e escalável desenvolvida, baseada em *containers* e microsserviços, permite não apenas a expansão do sistema, mas também sua adaptação para diferentes contextos e necessidades locais. A interface web intuitiva e o mapa de calor fornecem ferramentas valiosas para a visualização e análise dos dados coletados, facilitando a tomada de decisões pelos agentes de saúde pública. Como trabalhos futuros, sugere-se:

- A) A expansão do *dataset* com imagens de diferentes regiões e condições climáticas para aumentar a robustez do modelo;
- B) A implementação de funcionalidades de análise temporal para acompanhamento da evolução dos focos ao longo do tempo;
- C) O desenvolvimento de um sistema de alertas automáticos baseado na concentração de focos detectados;
- D) A integração com sistemas de informação em saúde existentes para melhor coordenação das ações de combate à dengue;
- E) A adaptação do modelo para detectar outros tipos de criadouros além de pneus;
- F) A realização de testes em campo em diferentes municípios para validação da eficácia do sistema em diferentes contextos urbanos.

Por fim, o sistema desenvolvido representa um avanço significativo na aplicação de tecnologias modernas para o combate a doenças transmitidas por vetores, oferecendo uma ferramenta promissora para auxiliar as autoridades de saúde pública no controle e prevenção da dengue.

REFERÊNCIAS

- AKTER, Rokeya; NAISH, Suchithra; GATTON, Michelle; BAMBRICK, Hilary; HU, Wenbiao; TONG, Shilu. Spatial and temporal analysis of dengue infections in queensland, australia: Recent trend and perspectives. **PLOS ONE**, Public Library of Science, v. 14, n. 7, p. 1–13, 07 2019. Disponível em:
<<https://doi.org/10.1371/journal.pone.0220134>>.
- ANDRIOLI, Denise Catarina; BUSATO, M. A.; LUTINSKI, J. Spatial and temporal distribution of dengue in brazil, 1990 - 2017. **PLoS ONE**, v. 15, 2020.
- BULLOCK, Joseph; LUCCIONI, Alexandra; PHAM, Katherine Hoffman; LAM, Cynthia Sin Nga; LUENGO-OROZ, Miguel. Mapping the landscape of artificial intelligence applications against covid-19. **Journal of Artificial Intelligence Research**, v. 69, p. 807–845, 2020.
- CHIMMULA, Vinay Kumar Reddy; ZHANG, Lei. Time series forecasting of COVID-19 transmission in Canada using LSTM networks. **Chaos, Solitons & Fractals**, Elsevier, v. 135, p. 109864, June 2020. PMID: 32390691; PMCID: PMC7205623.
- GUILHERME, Iwldson; SANTOS, Silva; JÚNIOR, José Francisco de Oliveira; BARBOSA, Isnaldo Isaac; FELIPE, Luis; SILVA, Francisco Ferreira da; MAX, William; ROMÃO, Oliveira; MARQUES, Vitória Rejane; SANTOS dos; ROSALVO, Kelvy; CARDOSO, Alencar; CRISTINA, Caroline; ANDRADE, Silva de. Artificial neural network applied to reported dengue cases in maceió – alagoas. 2022.
- JOCHER, Glenn; CHAURASIA, Ayush; QIU, Jing. Ultralytics yolov8. 2023. URL <https://github.com/ultralytics/ultralytics>, 2023.
- JOHANSEN, I. C.; CARMO, Roberto L. do; ALVES, L. Correia; BUENO, Maria do Carmo Dias. Environmental and demographic determinants of dengue incidence in brazil. **Revista de salud publica**, v. 20 3, p. 346–351, 2018.
- KAUR, Parvinder; KHEHRA, Baljit Singh; MAVI, Er. Bhupinder Singh. Data augmentation for object detection: A review. In: **2021 IEEE International Midwest Symposium on Circuits and Systems (MWSCAS)**. [S.l.: s.n.], 2021. p. 537–543.
- REDMON, Joseph; DIVVALA, Santosh; GIRSHICK, Ross; FARHADI, Ali. You Only Look Once: Unified, Real-Time Object Detection . In: **2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. Los Alamitos, CA, USA: IEEE Computer Society, 2016. p. 779–788. ISSN 1063-6919. Disponível em:
<<https://doi.ieeecomputersociety.org/10.1109/CVPR.2016.91>>.
- SCHEEPERS, Mathijs Jeroen. Virtualization and containerization of application infrastructure: A comparison. In:

21st twente student conference on IT. Enschede: University of Twente, 2014. v. 21. Citado na página 6. SOMMERVILLE, Ian. Engenharia de software, 9a. São Paulo, SP, Brasil, p. 529, 2011.

TERVEN, Juan; CÓRDOVA-ESPARZA, Diana-Margarita; ROMERO-GONZÁLEZ, Julio-Alejandro. A comprehensive review of yolo architectures in computer vision: From yolov1 to yolov8 and yolo-nas. **Machine Learning and Knowledge Extraction**, MDPI, v. 5, n. 4, p. 1680–1716, 2023.

VALDEZ-DELGADO, Kenia Mayela; GARCIA-SALAZAR, Octavio; MOO-LLANES, David A.; IZCAPA-TREVIÑO, Cecilia; CRUZ-PLIEGO, Miguel A.; DOMÍNGUEZ-POSADAS, Gustavo Y.; ARMENDÁRIZ-VALDEZ, Moisés O.; CORREA-MORALES, Fabián; CISNEROS-VÁZQUEZ, Luis Alberto; ORDÓÑEZ-GONZÁLEZ, José Genaro; FERNÁNDEZ-SALAS, Ildefonso; DANIS-LOZANO, Rogelio. Mapping the urban environments of aedes aegypti using drone technology. **Drones**, v. 7, n. 9, 2023. ISSN 2504-446X. Disponível em: <<https://www.mdpi.com/2504-446X/7/9/581>>. Acesso em 21 de dezembro de 2024.

VALDEZ-DELGADO, K. M.; MOO-LLANES, D. A.; DANIS-LOZANO, R.; CISNEROS-VÁZQUEZ, Luis Alberto; FLORES-SUAREZ, A.; PONCE-GARCIA, G.; GARZA, C. E. Medina-De la; DÍAZ-GONZÁLEZ, E. E.; FERNÁNDEZ-SALAS, I. Field effectiveness of drones to identify potential aedes aegypti breeding sites in household environments from tapachula, a dengue-endemic city in southern mexico. **Insects**, v. 12, 2021.

WAZLAWICK, Raul Sidnei. **Metodologia de pesquisa para ciência da computação.** Rio de Janeiro: Elsevier, 2008. 184 p. ISSN 978-85-352-3522-7. YASEEN, Muhammad. What is yolov9: An in-depth exploration of the internal features of the next-generation object detector. **arXiv preprint arXiv:2409.07813**, 2024. Citado na página 5.

Yaseen, Muhammad. What is YOLOv9: An In-Depth Exploration of the Internal Features of the Next-Generation Object Detector. **arXiv e-prints**, p. arXiv:2409.07813, set. 2024. Citado na página 11.

ZENG, D.; CAO, Zhidong; NEILL, Daniel B. Artificial intelligence-enabled public health surveillance—from local detection to global epidemic monitoring and control. **Artificial Intelligence in Medicine**, p. 437 – 453, 2020. Citado na página 4.



**DESENVOLVIMENTO DE UM MODELO DE MACHINE LEARNING
PARA CLASSIFICAÇÃO DE IMAGENS DE RAIO-X DO TÓRAX
EM DOENÇAS RESPIRATÓRIAS**

**DEVELOPMENT OF A MACHINE LEARNING MODEL FOR
CHEST X-RAY IMAGE CLASSIFICATION IN RESPIRATORY
DISEASES**

**DESARROLLO DE UN MODELO DE APRENDIZAJE
AUTOMÁTICO PARA LA CLASIFICACIÓN DE IMÁGENES DE
RAYOS X DE TÓRAX EN ENFERMEDADES RESPIRATORIAS**

Andrey Alencar Quadros¹
Diogo Ribeiro²
Otacilio Beleza³

DOI: 10.54751/revistafoco.v18n3-134

Received: Feb 28th, 2025

Accepted: Mar 18th, 2025



RESUMO

As doenças respiratórias representam uma das principais causas de morbidade e mortalidade global, destacando a necessidade de diagnósticos rápidos e precisos. Este estudo propõe o desenvolvimento de modelos de machine learning utilizando redes neurais convolucionais (CNNs) para classificar imagens de raio-X do tórax em quatro categorias: COVID-19, normal, pneumonia viral e pneumonia bacteriana. Utilizando as arquiteturas ResNet50 e YOLOv8 pré-treinadas e a técnica de transferência de aprendizagem, os modelos foram adaptados para o contexto específico das radiografias pulmonares. O treinamento foi realizado com conjuntos de dados balanceados e diversas técnicas de pré-processamento e aumento de dados foram aplicadas. Os resultados indicam um desempenho promissor de ambos os modelos, com elevada acurácia na classificação das diferentes patologias, demonstrando o potencial da abordagem para auxiliar profissionais de saúde em ambientes com recursos limitados, como a Unidade de Pronto Atendimento (UPA) de Ariquemes-RO, podendo ser estendida para outras unidades de saúde.

Palavras-chave: Classificação de doenças respiratórias; redes neurais convolucionais; radiografia de tórax; transferência de aprendizagem.

¹ Mestre pelo Programa de Pós-Graduação em Propriedade Intelectual e Transferência de Tecnologia para a Inovação. Instituto Federal de Rondônia (IFRO). Ariquemes, Rondônia, Brasil. E-mail: andrey.quadros@ifro.edu.br

² Pós-Graduado em Inteligência Artificial e Aprendizado de Máquina. Instituto Federal de Rondônia (IFRO). Ariquemes, Rondônia, Brasil. E-mail: diogoifroads@gmail.com

³ Pós-Graduado em Inteligência Artificial e Aprendizado de Máquina. Instituto Federal de Rondônia (IFRO). Ariquemes, Rondônia, Brasil. E-mail: otacilio.system@gmail.com

ABSTRACT

Respiratory diseases represent one of the leading causes of global morbidity and mortality, highlighting the need for rapid and accurate diagnoses. This study proposes the development of machine learning models using convolutional neural networks (CNNs) to classify chest X-ray images into four categories: COVID-19, normal, viral pneumonia, and bacterial pneumonia. By utilizing pre-trained ResNet50 and YOLOv8 architectures and transfer learning techniques, the models were adapted for the specific context of lung radiographs. Training was performed with balanced datasets, and various preprocessing and data augmentation techniques were applied. The results indicate promising performance for both models, with high accuracy in classifying the different pathologies, demonstrating the approach's potential to assist healthcare professionals in resource-limited environments, such as the Emergency Care Unit (UPA) in Ariquemes-RO, and potentially extend to other healthcare facilities.

Keywords: Respiratory disease classification; convolutional neural networks; chest X-ray; transfer learning.

RESUMEN

Las enfermedades respiratorias representan una de las principales causas de morbilidad y mortalidad a nivel mundial, destacando la necesidad de diagnósticos rápidos y precisos. Este estudio propone el desarrollo de modelos de aprendizaje automático utilizando redes neuronales convolucionales (CNN) para clasificar imágenes de rayos X de tórax en cuatro categorías: COVID-19, normal, neumonía viral y neumonía bacteriana. Mediante el uso de arquitecturas preentrenadas ResNet50 y YOLOv8 y técnicas de transferencia de aprendizaje, los modelos fueron adaptados al contexto específico de las radiografías pulmonares. El entrenamiento se realizó con conjuntos de datos balanceados, y se aplicaron diversas técnicas de preprocesamiento y aumento de datos. Los resultados indican un rendimiento prometedor de ambos modelos, con alta precisión en la clasificación de las diferentes patologías, demostrando el potencial del enfoque para asistir a profesionales de la salud en entornos con recursos limitados, como la Unidad de Atención de Emergencias (UPA) de Ariquemes-RO, y con potencial de extensión a otros centros de salud.

Palabras clave: Clasificación de enfermedades respiratorias; redes neuronales convolucionales; radiografía de tórax; transferencia de aprendizaje.

1. Introdução

As doenças respiratórias constituem uma das principais causas de morbidade e mortalidade em todo o mundo, representando um significativo desafio para os sistemas de saúde, especialmente em países em desenvolvimento (World Health Organization, 2017).

A emergência da pandemia de COVID-19 ressaltou a necessidade urgente de diagnósticos rápidos e precisos para doenças pulmonares, a fim de

conter a disseminação e proporcionar tratamento adequado aos pacientes (Huang *et al.*, 2020).

Na Unidade de Pronto Atendimento (UPA) de Ariquemes, Rondônia, os profissionais de saúde enfrentam diariamente um elevado volume de pacientes com diversas condições respiratórias.

A radiografia de tórax é utilizada como ferramenta diagnóstica inicial devido à sua disponibilidade e rapidez (Brasil, 2019). No entanto, a interpretação dessas imagens pode ser subjetiva e exigir conhecimento especializado, o que pode não estar prontamente disponível em ambientes com recursos limitados (Litjens *et al.*, 2017).

Com os avanços recentes em inteligência artificial e aprendizado de máquina, surge a oportunidade de aplicar essas tecnologias na análise automatizada de radiografias digitais, auxiliando na detecção e classificação de doenças pulmonares (Litjens *et al.*, 2017).

A utilização de técnicas de deep learning tem demonstrado desempenho promissor na identificação de padrões complexos em radiografias digitais, possibilitando a diferenciação entre condições como pneumonia viral, pneumonia bacteriana, COVID-19 e pulmões normais (Wang & Wong, 2020).

Diante desse contexto, este trabalho propõe o desenvolvimento de modelos de machine learning para classificar imagens de raio-X do tórax em quatro categorias: COVID-19, normal, pneumonia viral e pneumonia bacteriana.

O objetivo é criar uma ferramenta que auxilie os médicos da UPA de Ariquemes na tomada de decisão, melhorando a eficiência do atendimento e contribuindo para a qualidade dos serviços de saúde prestados à população, podendo ser estendida para outras unidades de saúde.

2. Revisão de Literatura

2.1 Estado Atual da Tecnologia

A aplicação de machine learning na análise de radiografias digitais tem avançado significativamente nas últimas décadas, impulsionada pelo aumento

da capacidade computacional e pela disponibilidade de grandes conjuntos de dados.

Estudos recentes demonstram o potencial dessas técnicas na detecção e classificação de diversas patologias, incluindo doenças respiratórias (Litjens *et al.*, 2017; Esteva *et al.*, 2017).

Especificamente, a pandemia de COVID-19 acelerou pesquisas focadas no uso de aprendizado de máquina no suporte ao diagnóstico por imagem. Modelos têm sido desenvolvidos para identificar sinais de infecção pelo SARS-CoV-2 em radiografias de tórax, visando apoiar a tomada de decisão clínica (Wang & Wong, 2020; Apostolopoulos & Mpesiana, 2020).

Nesse contexto, o campo da visão computacional, através da utilização de redes neurais convolucionais, vem possibilitando resultados significativos nas mais diversas tarefas envolvendo imagem e vídeo.

A visão computacional, inspirada pelo funcionamento do córtex visual dos mamíferos, tem avançado significativamente desde os estudos de David H. Hubel e Torsten Wiesel nos anos 1950 e 1960.

Eles demonstraram que o córtex visual responde a padrões simples, como linhas e bordas, e que essa informação é processada em uma hierarquia de complexidade crescente (Hubel & Wiesel, 1959).

Esses conceitos serviram como base para o desenvolvimento das redes neurais convolucionais (CNNs), cujo principal diferencial é a capacidade de detectar automaticamente padrões em imagens usando camadas convolucionais que simulam esses processos neurais.

Com isso, foi possível ensinar inteligência às máquinas para que elas consigam processar os dados visuais e, assim, ver as coisas exatamente como os humanos (JR & Santos Jr, 2024).

2.2 Técnicas e Algoritmos Existentes

a) Redes Neurais Convolucionais (CNNs)

As CNNs têm se destacado como a abordagem predominante na análise de imagens médicas devido à sua capacidade de extrair características relevantes de forma automática (LeCun *et al.*, 2015).

Estudos como o de Rajpurkar *et al.* (2017) demonstraram que CNNs podem alcançar desempenho comparável ao de radiologistas experientes na classificação de doenças pulmonares em radiografias de tórax.

Uma CNN é composta por várias camadas especializadas que processam e extraem informações da imagem de entrada. No contexto deste estudo, a imagem de raio-X do tórax é inserida na rede e passa por uma série de camadas convolucionais.

Essas camadas atuam como detectores de características, extraindo elementos fundamentais da imagem, como bordas, linhas e texturas (Zeiler & Fergus, 2014).

Essas características básicas são universais e independentes do tipo de imagem, seja uma radiografia de tórax ou qualquer outra.

Conforme a imagem avança pelas camadas da CNN, as características extraídas tornam-se progressivamente mais complexas.

As primeiras camadas focam em aspectos gerais, enquanto as camadas subsequentes combinam essas características para formar representações mais abstratas e específicas, como padrões associados a determinadas patologias pulmonares (Lee *et al.*, 2017).

Esse processo permite que a rede identifique nuances e detalhes que podem ser determinantes para a classificação correta das doenças.

Após a extração de características, a imagem processada é direcionada para camadas totalmente conectadas (fully connected layers), que funcionam como uma rede neural tradicional.

Nessa etapa, a rede utiliza as informações extraídas para realizar a classificação final, determinando a probabilidade de a imagem pertencer a cada uma das categorias pré-definidas (Goodfellow, Bengio & Courville, 2016).

É importante destacar que todo esse processo é automatizado e não requer intervenção manual para a seleção de características específicas.

A capacidade da CNN de aprender e extrair características relevantes diretamente dos dados brutos é uma das razões para seu sucesso em tarefas de visão computacional (Rawat & Wang, 2017).

b) Arquiteturas de CNNs

Várias arquiteturas de CNNs têm sido propostas, destacando-se:

1. **LeNet-5:** Um marco na história das CNNs, utilizada para reconhecimento de dígitos manuscritos. Foi uma das primeiras redes a introduzir camadas convolucionais e camadas de pooling, mostrando o poder dessas camadas para a redução dimensional (LeCun *et al.*, 1998).
2. **AlexNet:** Popularizou as CNNs ao vencer o desafio ImageNet em 2012, utilizando camadas convolucionais profundas e a função de ativação ReLU (Krizhevsky, Sutskever & Hinton, 2012).
3. **GoogLeNet/Inception:** Introduziu a ideia de módulos de inception, que utilizam filtros de diferentes tamanhos em paralelo, permitindo que a rede capture padrões em várias escalas. A arquitetura também foi otimizada para reduzir o número de parâmetros (Szegedy *et al.*, 2015).
4. **ResNet:** A Rede Residual (ResNet) foi um avanço ao permitir a construção de redes muito profundas com 152 camadas, graças ao uso de conexões de atalho (skip connections), que mitigam o problema de desaparecimento do gradiente (He *et al.*, 2016).
5. **YOLO (You Only Look Once):** Uma das arquiteturas mais rápidas para detecção de objetos, processa toda a imagem de uma vez, o que a torna altamente eficiente para aplicações em tempo real (Redmon *et al.*, 2016).

b.a) ResNet50 e Conexões Residuais

Ao aprofundar o entendimento sobre a ResNet50, é fundamental compreender o problema do gradiente “desaparecido” (vanishing gradient problem), comum em redes profundas (Hochreiter, 1991).

Com o aumento do número de camadas, os gradientes utilizados para atualizar os pesos tornam-se muito pequenos, dificultando o aprendizado.

A ResNet50 supera esse desafio por meio de conexões residuais (skip connections), que permitem que a entrada original de uma camada seja somada à sua saída, facilitando a propagação do gradiente e permitindo que a rede aprenda identidades mapeadas (He *et al.*, 2016).

No contexto da classificação de imagens de raio-X do tórax, a ResNet50 é eficaz na captura de padrões complexos associados a diferentes doenças pulmonares, graças à sua profundidade e à capacidade de aprender representações robustas dos dados.

b.b) Processamento das Imagens de Raio-X nas CNNs

Ao aplicar CNNs às imagens de raio-X do tórax, o processo inicia-se com a inserção da imagem na rede, que passa pelas camadas convolucionais responsáveis pela extração de características iniciais, como bordas e texturas (Lakhani & Sundaram, 2017).

Essas características são fundamentais para identificar estruturas anatômicas e possíveis anomalias.

As camadas de pooling subsequentes realizam o downsampling, reduzindo a dimensionalidade dos mapas de características e resumindo as informações mais relevantes (Scherer, Müller & Behnke, 2010).

Em seguida, a camada de flatten transforma os mapas bidimensionais em um vetor unidimensional, preparando os dados para as camadas totalmente conectadas que efetuam a classificação final.

c) Aprendizado Profundo (Deep Learning)

O aprendizado profundo utiliza múltiplas camadas para modelar abstrações de alto nível nos dados. Técnicas de deep learning têm sido aplicadas com sucesso na segmentação, classificação e detecção de anomalias em imagens médicas (Shen, Wu & Suk, 2017).

As arquiteturas de deep learning mais comuns incluem:

1. Redes Neurais Convolucionais (CNNs): Especialmente eficazes para processamento de imagens e dados com estrutura em grade.
2. Redes Neurais Recorrentes (RNNs) e Long Short-Term Memory (LSTM): Utilizadas para processamento de sequências e dados temporais.
3. Autoencoders: Úteis para redução de dimensionalidade e detecção de anomalias.
4. Redes Generativas Adversariais (GANs): Usadas para geração de dados sintéticos e aumento de dados.

Na área médica, técnicas de deep learning têm sido aplicadas com sucesso em diversas tarefas, incluindo:

1. Segmentação de imagens: Identificação precisa de estruturas anatômicas em imagens médicas (Ronneberger, Fischer & Brox, 2015).
2. Classificação: Diagnóstico automatizado de doenças a partir de imagens médicas (Esteva *et al.*, 2017).
3. Detecção de anomalias: Identificação de padrões atípicos que podem indicar patologias (Schlegl *et al.*, 2017).
4. Previsão de resultados clínicos: Utilizando dados do paciente para prever prognósticos e resposta a tratamentos (Rajkomar *et al.*, 2018).
5. Análise de registros médicos eletrônicos: Extração de informações relevantes e identificação de padrões em grandes volumes de dados textuais (Shickel *et al.*, 2018).

O uso de deep learning na medicina tem mostrado resultados promissores, muitas vezes superando o desempenho de especialistas humanos em tarefas específicas.

Por exemplo, um estudo mostrou que um modelo de deep learning foi capaz de detectar câncer de pele com precisão comparável a dermatologistas certificados (Esteva *et al.*, 2017).

No entanto, é importante notar que o uso de deep learning na medicina também enfrenta desafios, como a necessidade de grandes conjuntos de dados rotulados, a interpretabilidade dos modelos e questões éticas relacionadas à tomada de decisão automatizada em contextos médicos (Topol, 2019).

d) Transferência de Aprendizagem (Transfer Learning)

A transferência de aprendizagem permite utilizar modelos pré-treinados em grandes conjuntos de dados, adaptando-os para tarefas específicas com conjuntos de dados menores (Pan & Yang, 2010).

Esta abordagem tem sido eficaz na área médica, onde a disponibilidade de dados rotulados é frequentemente limitada (Yosinski *et al.*, 2014).

No caso deste estudo, a técnica de transferência de aprendizagem é empregada utilizando-se a arquitetura ResNet50 pré-treinada no conjunto de dados ImageNet, que contém milhões de imagens de diversas categorias (Deng *et al.*, 2009).

Embora o ImageNet não inclua imagens de raio-X, as primeiras camadas da ResNet50 aprendem características gerais de imagens, como bordas, texturas e formas, que são igualmente relevantes para radiografias (Raghu *et al.*, 2019).

c.a) Benefícios da Transferência de Aprendizagem

A transferência de aprendizagem pode ser comparada a um indivíduo que já domina uma habilidade e decide aprender uma nova tarefa relacionada.

Por exemplo, alguém que sabe patinar no gelo pode aprender a esqui com mais facilidade devido às semelhanças entre os esportes.

Da mesma forma, uma rede neural treinada para reconhecer objetos gerais pode ser adaptada para identificar padrões específicos em imagens de raio-X (Shin *et al.*, 2016).

Os benefícios dessa abordagem incluem:

1. **Redução do Tempo de Treinamento:** Aproveitar pesos previamente aprendidos acelera significativamente o processo de treinamento, já que não é necessário treinar a rede desde o início (Tajbakhsh *et al.*, 2016).
2. **Melhoria no Desempenho com Poucos Dados:** A transferência de aprendizagem é especialmente útil quando há escassez de dados rotulados, uma situação comum em imagens médicas (Ghafoorian *et al.*, 2017).

-
3. **Evita Overfitting:** Reutilizar pesos de um modelo pré-treinado ajuda a prevenir o overfitting, melhorando a capacidade de generalização do modelo (Géron, 2021).

c.b) Aplicação na Classificação de Imagens de Raio-X

Na implementação prática, as camadas convolucionais da ResNet50 são mantidas com seus pesos originais, preservando o conhecimento adquirido durante o treinamento no ImageNet.

Apenas as camadas finais, responsáveis pela classificação, são ajustadas ou substituídas para se adequar às novas classes de saída correspondentes às categorias de doenças respiratórias (Mahajan *et al.*, 2018).

Essa adaptação permite que a rede aproveite as características genéricas já aprendidas e se especialize nas especificidades das imagens de raio-X do tórax.

Estudos têm demonstrado que essa abordagem melhora significativamente o desempenho em tarefas de classificação de imagens médicas (Esteve *et al.*, 2017).

2.3 Desafios e Lacunas

Apesar dos avanços, existem desafios na aplicação de machine learning em imagens médicas. A necessidade de grandes volumes de dados é uma das barreiras, especialmente para países emergentes (Haleem, Javaid & Khan, 2020).

Além disso, muitos modelos sofrem com a falta de generalização, apresentando desempenho reduzido quando aplicados a dados de diferentes fontes ou populações (Zech *et al.*, 2018).

A variabilidade nos dados, como qualidade de imagem e diferenças nos protocolos de captura de imagens, pode reduzir a precisão dos modelos quando aplicados em ambientes clínicos diversificados (Sarvamangala & Kulkarni, 2022).

Adicionalmente, existem obstáculos no que concerne à compreensão das conclusões. Não obstante as CNNs serem eficientes na identificação de

enfermidades, frequentemente carecem de explicabilidade em seus sistemas de deliberação, o que pode restringir a aprovação por parte dos especialistas médicos, que necessitam fundamentar prognósticos alicerçados em inteligência computacional (BR, 2024).

Em última análise, a aplicação em ambiente médico de CNNs confronta desafios pragmáticos, tais como o dispêndio computacional substancial e a incorporação dessas inovações na rotina do profissional médico.

A instrução de redes complexas pode ser prolongada e onerosa, e a adequação de protótipos preexistentes ao contexto clínico particular pode demandar adaptações significativas (Mohammed *et al.*, 2024).

Conseqüentemente, embora as CNNs exibam notável promessa para revolucionar o exame de iconografias clínicas, o progresso dessas ferramentas tecnológicas está condicionado a empenhos ininterruptos para transpor tais empecilhos, assegurando que os paradigmas sejam resilientes, decifráveis e empregáveis em múltiplos cenários clínicos.

2.4 Justificativa para o Estudo

Este trabalho busca abordar as lacunas identificadas por meio do desenvolvimento de modelos de machine learning especializados na classificação de imagens de raio-X do tórax em quatro categorias relevantes para o contexto clínico atual: COVID-19, normal, pneumonia viral e pneumonia bacteriana.

Além disso, o estudo visa contribuir para a interpretabilidade dos resultados, fornecendo um ambiente que possa ser integrado ao fluxo de trabalho dos profissionais de saúde de Ariquemes.

Dessa forma, espera-se não apenas melhorar a eficiência diagnóstica, mas também aumentar a confiança na utilização de ferramentas que utilizam inteligência artificial.

3. Metodologia

3.1 Descrição do Conjunto de Dados

Para o desenvolvimento dos modelos, utilizou-se um conjunto de dados composto por imagens de raio-X do tórax obtidas de bases de dados públicas, como a COVID-19 Radiography Database (Chowdhury *et al.*, 2020) e outras fontes disponíveis na literatura.

O conjunto de dados foi balanceado, contendo um número equivalente de imagens para cada uma das quatro categorias: COVID-19, normal, pneumonia viral e pneumonia bacteriana.

CrITÉRIOS de inclusão e exclusão foram aplicados para garantir a qualidade das imagens, excluindo aquelas com artefatos significativos ou baixa resolução.

3.2 Pré-Processamento de Imagens

As imagens foram submetidas a um processo de pré-processamento que incluiu:

- a) **Redimensionamento:** Todas as imagens foram redimensionadas para 256 x 256 pixels para compatibilidade com a arquitetura da ResNet50 (He *et al.*, 2016).
- b) **Normalização:** Os valores de pixel foram normalizados para o intervalo [0, 1], facilitando o processo de aprendizado dos modelos.
- c) **Conversão para Três Canais:** Embora as radiografias sejam originalmente em escala de cinza, as imagens foram convertidas para três canais (RGB) para compatibilidade com os modelos pré-treinados na base ImageNet, que esperam entradas com três canais (Simonyan & Zisserman, 2015).
- d) **Aumento de Dados (Data Augmentation):** Técnicas como rotações, translações, zoom e flips horizontais foram aplicadas para aumentar a diversidade do conjunto de treinamento e reduzir o overfitting (Shorten & Khoshgoftaar, 2019).

3.3 Desenvolvimento dos Modelos

3.3.1 Arquitetura dos Modelos

a) Modelo ResNet50

Para o desenvolvimento do modelo de classificação das imagens de raio-X do tórax, inicialmente, foi escolhida a arquitetura ResNet50, uma rede neural convolucional profunda reconhecida por sua eficiência em diversas tarefas de visão computacional (He *et al.*, 2016).

A ResNet50 é composta por 50 camadas e utiliza conexões residuais para mitigar o problema do gradiente desaparecido em redes profundas, permitindo o treinamento eficaz de modelos com muitas camadas.

Vale ressaltar que, a ResNet50, apesar do nome, tecnicamente possui mais de 50 camadas. O número 50 refere-se às camadas principais (convolução e totalmente conectadas), mas a rede também inclui camadas de normalização em lote (batch normalization) e ativação ReLU, que não são contadas no nome. Se incluirmos todas essas camadas, o número total é maior que 50.

Inicialmente, carregamos o modelo base da ResNet50 com pesos pré-treinados na base de dados ImageNet (Deng *et al.*, 2009), especificando o parâmetro `weights='imagenet'`.

Optamos por definir `include_top=False` para excluir as camadas de classificação originais, uma vez que nosso objetivo é adaptar a rede para classificar quatro categorias específicas de doenças respiratórias.

Dessa forma, as camadas convolucionais pré-treinadas são utilizadas para extrair características gerais das imagens, enquanto uma nova camada densa personalizada é adicionada para realizar a classificação específica (Tan & Le, 2019).

Para evitar o retrabalho de treinamento em camadas já otimizadas e aproveitar o conhecimento prévio do modelo, congelamos os pesos das camadas convolucionais, configurando `trainable=False` em todas as camadas do modelo base (Yosinski *et al.*, 2014).

No entanto, para permitir que o modelo se adapte melhor às características específicas das imagens de raio-X, descongelamos as últimas dez camadas convolucionais, mantendo-as treináveis.

Essa estratégia híbrida permite que o modelo refine as características extraídas nas últimas camadas, adaptando-se às peculiaridades do conjunto de dados atual (Howard & Gugger, 2020).

b) Modelo YOLOv8

Após obter resultados promissores com a arquitetura ResNet50 utilizando o TensorFlow, decidiu-se explorar outras abordagens para avaliar a eficácia de diferentes modelos de deep learning na classificação de imagens de raio-X do tórax.

Nesse contexto, optou-se por testar a rede pré-treinada YOLOv8, conhecida por seu desempenho em tarefas de visão computacional, especialmente em detecção e classificação em tempo real (Jocher *et al.*, 2023).

A YOLOv8 (You Only Look Once version 8) é uma evolução das arquiteturas YOLO anteriores, incorporando melhorias em precisão e velocidade de processamento.

Embora seja tradicionalmente utilizada para detecção de objetos, a YOLOv8 também oferece suporte para tarefas de classificação, tornando-a adequada para o objetivo deste estudo (Redmon *et al.*, 2016; Bochkovskiy, Wang & Liao, 2020).

b.a) Seleção do Modelo e Configuração

Para equilibrar precisão e eficiência computacional, foi escolhido o modelo "m" (médio) da YOLOv8, que oferece um bom compromisso entre desempenho e velocidade (Jocher *et al.*, 2023).

Essa decisão é crucial em contextos clínicos onde a rapidez na obtenção dos resultados pode impactar diretamente o atendimento ao paciente.

b.b) Preparação dos Dados

Foram submetidas 3.500 imagens de cada classe (COVID-19, normal, pneumonia viral e pneumonia bacteriana), totalizando 14.000 imagens para o treinamento do modelo.

Este número ampliado de imagens por classe visa fortalecer a capacidade do modelo em aprender características discriminativas e melhorar sua generalização (Shorten & Khoshgoftaar, 2019).

b.c) Processo de Treinamento

O treinamento do modelo YOLOv8 foi conduzido seguindo as diretrizes padrão para tarefas de classificação.

O conjunto de dados foi dividido em porções de treinamento, validação e teste, garantindo que o modelo fosse avaliado em dados não vistos durante o treinamento.

Hiperparâmetros como taxa de aprendizado, tamanho do batch e número de épocas foram ajustados empiricamente para otimizar o desempenho do modelo (Wilson & Martinez, 2003).

c) Ferramentas e Frameworks Utilizados

A implementação foi realizada utilizando a biblioteca Ultralytics YOLO, que fornece uma interface simplificada para treinamento e inferência com modelos YOLOv8 (Jocher *et al.*, 2023).

A utilização dessa biblioteca facilita a experimentação e permite comparações diretas com o modelo baseado em ResNet50 desenvolvido anteriormente.

3.3.2 Implementação e Treinamento dos Modelos

a) Modelo ResNet50

Após a definição da arquitetura básica utilizando a ResNet50 pré-treinada, procedeu-se à implementação das camadas específicas para o problema em questão.

A saída do modelo base (`base_model.output`) foi utilizada como ponto de partida para a construção do novo modelo, referenciado como `head_model`.

Essa estratégia permite a continuidade do fluxo de dados a partir do término das camadas convolucionais da ResNet50, cuja última camada possui dimensões de $8 \times 8 \times 2048$ (He *et al.*, 2016).

b) Redução da Dimensionalidade e Construção das Camadas Densas

Para reduzir a dimensionalidade da saída das camadas convolucionais e preparar os dados para as camadas totalmente conectadas, aplicou-se uma camada de pooling global, especificamente o AveragePooling2D (Boureau, Ponce & LeCun, 2010).

Em seguida, adicionou-se uma camada Flatten para converter a saída bidimensional em um vetor unidimensional, permitindo a conexão com as camadas densas subsequentes (Goodfellow, Bengio & Courville, 2016).

As camadas densas foram estruturadas com neurônios e funções de ativação adequadas, incluindo camadas de dropout para prevenir overfitting (Srivastava *et al.*, 2014).

c) Construção e Compilação do Modelo Final

O modelo final foi construído integrando as camadas definidas com o modelo base da ResNet50.

A função Model da biblioteca Keras foi utilizada para especificar as entradas e saídas do modelo (Chollet, 2015).

Para compilar o modelo, foram definidos parâmetros como função de perda, otimizador e métricas de avaliação apropriadas (Murphy, 2012; Tieleman & Hinton, 2012).

d) Processo de Treinamento

O treinamento foi realizado utilizando o método fit_generator, com ajustes nos hiperparâmetros e utilização de callbacks como ModelCheckpoint para salvar o melhor modelo (Keras Documentation, 2023).

Durante o treinamento, observou-se a redução gradual da função de perda e o aumento da acurácia, indicando que o modelo estava aprendendo a partir dos dados de treinamento (Goodfellow, Bengio & Courville, 2016).

e) Modelo YOLOv8

O treinamento do modelo YOLOv8 foi conduzido seguindo as diretrizes padrão para tarefas de classificação, utilizando a biblioteca Ultralytics YOLO (Jocher *et al.*, 2023).

O modelo foi treinado por 100 épocas, e os hiperparâmetros foram ajustados para otimizar o desempenho.

Gráficos de perda e precisão foram gerados para monitorar o progresso do treinamento.

3.4 Métricas de Avaliação

As métricas utilizadas para avaliar o desempenho dos modelos foram:

- a) **Acurácia:** Proporção de predições corretas sobre o total de predições realizadas.
- b) **Precisão:** Proporção de verdadeiros positivos sobre o total de predições positivas.
- c) **Sensibilidade (Recall):** Proporção de verdadeiros positivos sobre o total de casos positivos reais.
- d) **F1-Score:** Média harmônica entre precisão e sensibilidade, oferecendo um balanço entre as duas métricas.
- e) **AUC-ROC:** Área sob a curva ROC, avaliando a capacidade do modelo em distinguir entre as classes.

3.5 Desenvolvimento da API e Aplicação Web

Para possibilitar a utilização prática do modelo de machine learning desenvolvido, foi implementada uma API utilizando a linguagem Python e o framework FastAPI.

Além disso, foi desenvolvida uma aplicação web frontend utilizando React e Next.js, que serve como interface para os usuários interagirem com o sistema.

3.5.1 Implementação da API

A API foi desenvolvida em Python utilizando o framework FastAPI, conhecido por sua eficiência e facilidade de uso na construção de APIs RESTful (Medvedev, 2019).

A API é responsável por gerenciar o modelo treinado e fornecer endpoints para:

-
- a) **Gerenciamento de Usuários (CRUD):** Permite criar, ler, atualizar e deletar usuários, controlando o acesso ao sistema.
 - b) **Recebimento de Imagens e Predição:** Recebe imagens de raio-X do tórax enviadas pelos usuários e utiliza o modelo de machine learning para realizar a predição, retornando as probabilidades associadas a cada classe.
 - c) **Registro de Feedback:** Registra o feedback dos usuários sobre a predição realizada, permitindo identificar se a predição foi correta ou não e coletando a classe correta em caso de erro.

Este feedback é armazenado no banco de dados e pode ser utilizado posteriormente para retreinamento do modelo, promovendo aprendizado contínuo e melhoria do desempenho ao longo do tempo.

3.5.2 Desenvolvimento da Aplicação Web (Frontend)

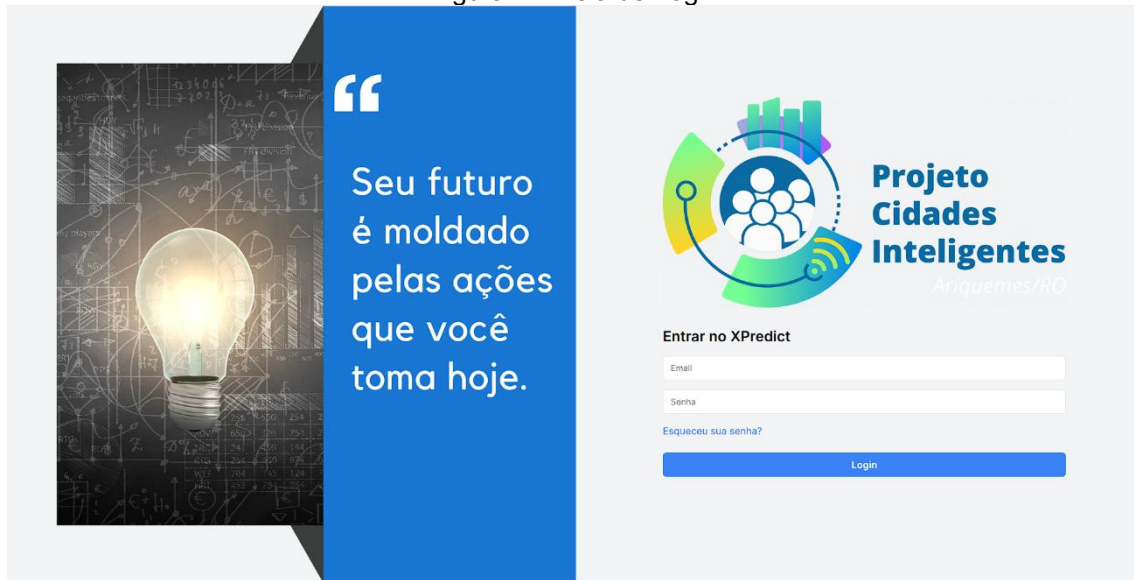
A aplicação web frontend foi desenvolvida utilizando as tecnologias React e Next.js, que são amplamente utilizadas para construir interfaces de usuário interativas e eficientes (Dinku, 2022).

O uso de React permite a criação de componentes reutilizáveis e uma experiência de usuário dinâmica, enquanto o Next.js facilita o roteamento e a renderização do lado do servidor, melhorando o desempenho da aplicação.

As principais funcionalidades e telas da aplicação são:

- a) **Tela de Login:** Permite que os usuários acessem o sistema utilizando suas credenciais.

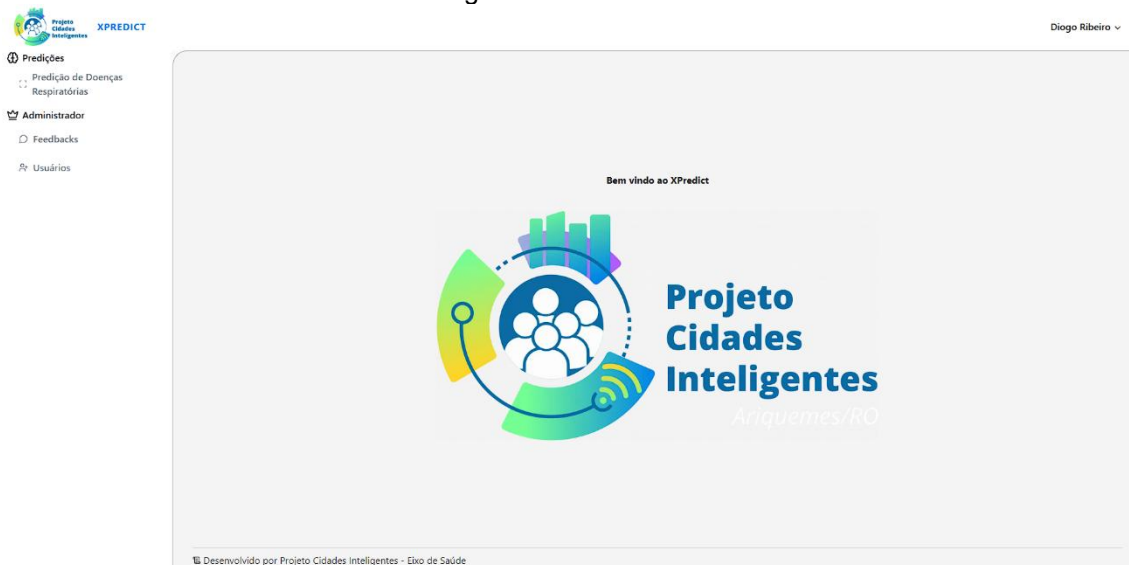
Figura 1 – Tela de Login



Fonte: Os autores (2024)

- b) **Tela Inicial (Home):** Apresenta um resumo das funcionalidades disponíveis e informações gerais.

Figura 2 – Tela Inicial



Fonte: Os autores (2024)

- c) **Tela de Envio de Imagem:** Os usuários podem fazer upload de imagens de raio-X do tórax para serem analisadas pelo modelo.

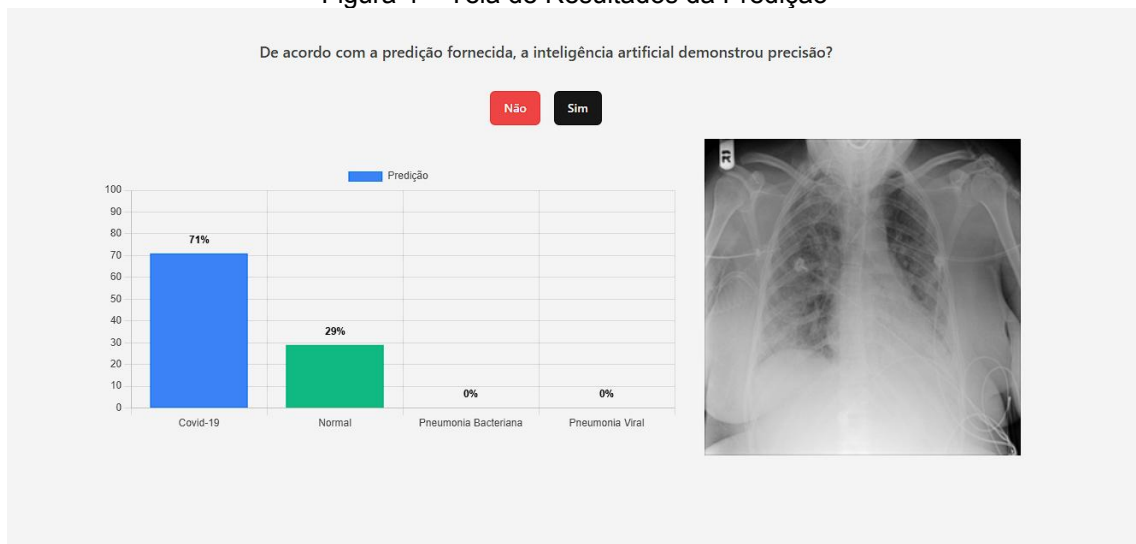
Figura 3 – Tela de Envio de Imagem



Fonte: Os autores (2024)

- d) **Tela de Resultados da Predição:** Exibe o resultado da predição realizada pelo modelo, apresentando um gráfico com as probabilidades associadas a cada classe. Também permite que o usuário indique se a predição foi correta ou não. Em caso negativo, é solicitado que o usuário informe qual seria a predição correta.

Figura 4 – Tela de Resultados da Predição

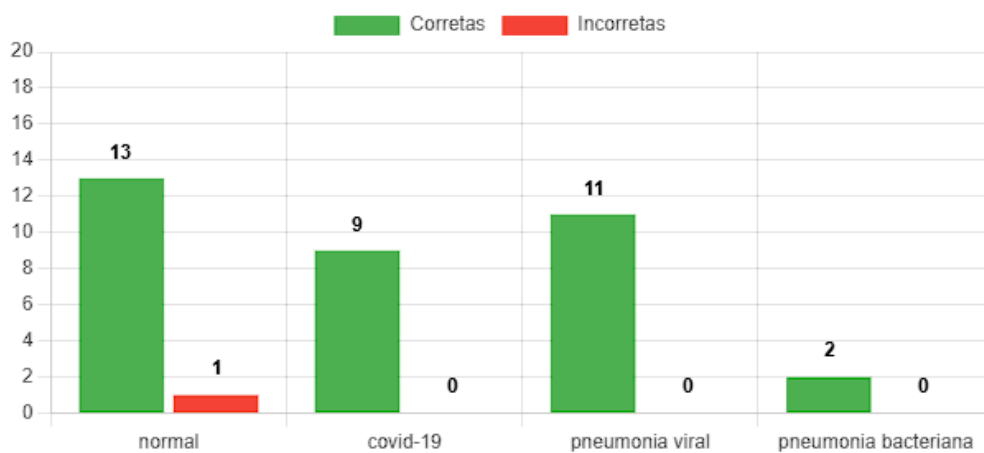


Fonte: Os autores (2024)

Para usuários com perfil de administrador, funcionalidades adicionais estão disponíveis:

- e) **Tela com Gráficos de Erros e Acertos:** Apresenta visualizações gráficas dos desempenhos do modelo, incluindo taxas de erro e acerto ao longo do tempo.

Figura 5 – Tela com Gráficos de Erros e Acertos



Fonte: Os autores (2024)

- f) **Gerenciamento de Usuários:** Permite o controle de usuários, incluindo criação, edição e remoção de contas.

3.5.3 Integração entre a API e o Frontend

A comunicação entre a aplicação web e a API é realizada através de requisições HTTP, utilizando os endpoints disponibilizados pela API.

Ao submeter uma imagem, a aplicação web envia a imagem para o endpoint correspondente, e a API processa a imagem utilizando o modelo treinado, retornando as probabilidades de cada classe. Os resultados são então apresentados ao usuário de forma clara e visual.

O feedback fornecido pelos usuários após a predição é enviado à API e armazenado para análise posterior.

Esta funcionalidade é fundamental para implementar um ciclo de melhoria contínua do modelo, permitindo que dados reais de uso contribuam para o aperfeiçoamento do sistema.

3.5.4 Considerações de Segurança e Privacidade

Foram implementadas medidas de segurança para proteger os dados dos usuários e assegurar a privacidade das informações médicas. Isso inclui:

- a) **Autenticação e Autorização:** Controle de acesso baseado em tokens de autenticação, garantindo que apenas usuários autorizados possam utilizar o sistema.
- b) **Criptografia de Dados:** Utilização de protocolos HTTPS para comunicação segura entre o frontend e a API.
- c) **Conformidade com Regulamentações:** Adequação às leis e regulamentações aplicáveis, como a Lei Geral de Proteção de Dados (LGPD) no Brasil.

3.6 Fluxo de Trabalho do Sistema

- a) **Cadastro e Login:** O usuário se cadastra no sistema e realiza o login através da aplicação web.
- b) **Envio da Imagem:** O usuário faz o upload da imagem de raio-X do tórax que deseja analisar.
- c) **Processamento e Predição:** A imagem é enviada para a API, que utiliza o modelo de machine learning para realizar a predição.
- d) **Apresentação dos Resultados:** Os resultados são apresentados ao usuário na aplicação web, incluindo um gráfico com as probabilidades de cada classe.
- e) **Feedback do Usuário:** O usuário indica se a predição foi correta ou não. Em caso de erro, informa a classe correta.

- f) **Armazenamento e Análise de Dados:** As informações são armazenadas para análise posterior e possível retreinamento do modelo.
- g) **Monitoramento do Desempenho:** Administradores podem visualizar gráficos de erros e acertos para monitorar o desempenho do modelo e identificar áreas de melhoria.

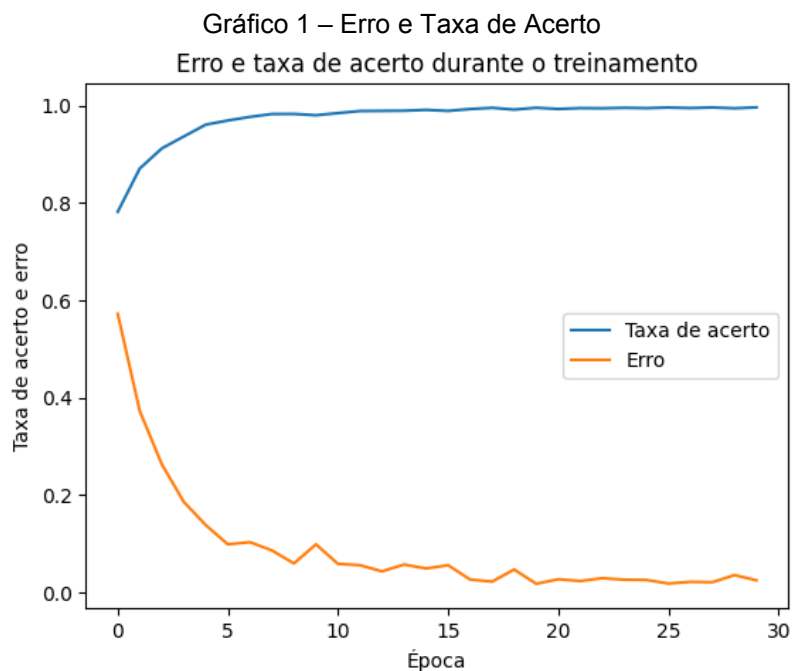
4. Resultados

4.1 Desempenho dos Modelos

4.1.1 Resultados do Modelo ResNet50

O modelo desenvolvido apresentou um desempenho consistente e satisfatório ao longo do treinamento e avaliação.

Para ilustrar a evolução do aprendizado e a eficácia na classificação, foram gerados gráficos de erro (função de perda) e taxa de acerto (acurácia), bem como a matriz de confusão para uma análise detalhada das predições.



Fonte: Os autores (2024)

Gráfico de erro (função de perda) e taxa de acerto (acurácia) do modelo ResNet50 ao longo de 30 épocas de treinamento.

O Gráfico 1 demonstra a evolução da taxa de acerto (linha azul) e do erro (linha laranja) ao longo de 30 épocas de treinamento.

Observa-se que a taxa de acerto aumentou rapidamente nas primeiras épocas, atingindo aproximadamente 90% entre a 5^a e a 10^a época.


Esse rápido incremento indica que o modelo está aprendendo eficientemente as características relevantes para a classificação das imagens (Goodfellow, Bengio & Courville, 2016).

Concomitantemente, o erro diminuiu de forma consistente, iniciando em torno de 0,6 e caindo rapidamente nas primeiras 5 épocas. Após a 10^a época, o erro estabilizou-se próximo de zero, sugerindo que o modelo alcançou uma boa convergência e minimizou a função de perda efetivamente (Kingma & Ba, 2015).

A estabilização das curvas de taxa de acerto e erro indica que o modelo não está sofrendo de overfitting, ou seja, mantém a capacidade de generalização para dados não vistos durante o treinamento (Srivastava *et al.*, 2014).

Esse comportamento é essencial para aplicações clínicas, onde a robustez do modelo é crucial.

Gráfico 2 – Matriz de Confusão



Fonte: Os autores (2024)

A matriz de confusão fornece uma análise detalhada do desempenho do modelo em cada classe específica.

As classes estão definidas da seguinte forma:

- a) **Classe 0:** COVID-19
- b) **Classe 1:** Normal
- c) **Classe 2:** Pneumonia Viral
- d) **Classe 3:** Pneumonia Bacteriana

1) Classe 0 (COVID-19):

- a) **Predições corretas:** 140 (célula [0,0])
- b) Classificações incorretas como:
 - i) **Classe 1 (Normal):** 3 vezes (célula [0,1])
 - ii) **Classe 2 (Pneumonia Viral):** 1 vez (célula [0,2])
 - iii) **Classe 3 (Pneumonia Bacteriana):** 2 vezes (célula [0,3])

2) Classe 1 (Normal):

- a) **Predições corretas:** 140 (célula [1,1])
- b) Classificações incorretas como:
 - i) **Classe 0 (COVID-19):** 1 vez (célula [1,0])

ii) **Classe 3 (Pneumonia Bacteriana):** 4 vezes (célula [1,3])

3) Classe 2 (Pneumonia Viral):

a) **Predições corretas:** 140 (célula [2,2])

b) Classificações incorretas como:

i) **Classe 1 (Normal):** 1 vez (célula [2,1])

ii) **Classe 3 (Pneumonia Bacteriana):** 7 vezes (célula [2,3])

4) Classe 3 (Pneumonia Bacteriana):

a) **Predições corretas:** 140 (célula [3,3])

b) Classificações incorretas como:

i) **Classe 1 (Normal):** 4 vezes (célula [3,1])

ii) **Classe 2 (Pneumonia Viral):** 4 vezes (célula [3,2])

A matriz de confusão indica que o modelo ResNet50 possui uma alta taxa de acerto para todas as classes, com 140 predições corretas em cada uma delas.

As confusões entre as classes são mínimas, mas algumas observações podem ser destacadas:

a) **Confusões entre COVID-19 e Normal:** O modelo confundiu a Classe 0 (COVID-19) com a Classe 1 (Normal) em 3 ocasiões, e a Classe 1 com a Classe 0 em 1 ocasião. Isso sugere que, em alguns casos, as características radiográficas de pacientes com COVID-19 podem se assemelhar a pulmões normais, possivelmente devido a estágios iniciais da doença ou manifestações atípicas (Apostolopoulos & Mpesiana, 2020).

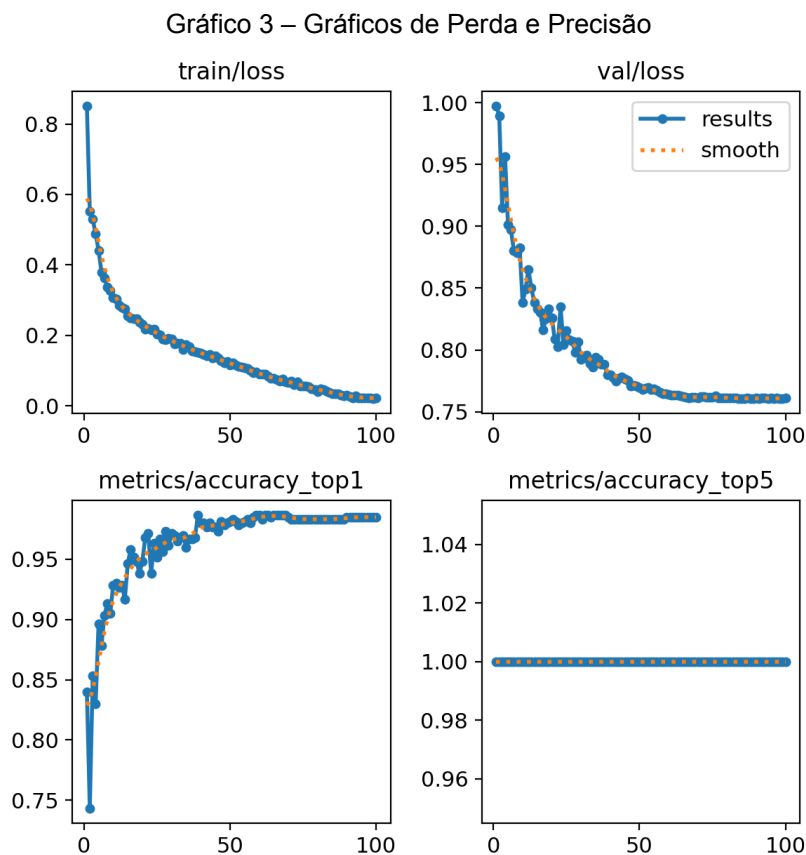
b) **Confusões entre Pneumonia Viral e Pneumonia Bacteriana:** Houve 7 casos em que a Classe 2 (Pneumonia Viral) foi confundida com a Classe 3 (Pneumonia Bacteriana), e 4 casos inversos. Isso é compreensível, dado que ambas as pneumonias podem apresentar sinais radiológicos semelhantes, como opacidades pulmonares e infiltrados (Morales *et al.*, 2020).

c) **Confusões entre Normal e Pneumonia Bacteriana:** A Classe 1 (Normal) foi confundida com a Classe 3 (Pneumonia Bacteriana) em 4 ocasiões. Essa confusão pode indicar que algumas imagens normais apresentavam características atípicas ou que o modelo identificou padrões semelhantes aos da pneumonia bacteriana.

4.1.2 Resultados do Modelo YOLOv8

Após a implementação do modelo YOLOv8 para a tarefa de classificação, foram gerados gráficos que ilustram o comportamento do modelo durante o treinamento e a validação, bem como a matriz de confusão que detalha o desempenho em cada classe.

4.1.2.1 Gráficos de Perda e Precisão



Fonte: Os autores (2024)

a) **Gráfico superior esquerdo (train/loss):**

Este gráfico representa a perda de treinamento ao longo das 100 épocas.

Observa-se uma diminuição constante da perda, indicando que o modelo está aprendendo e ajustando seus pesos de forma eficaz (Goodfellow, Bengio & Courville, 2016).

b) **Gráfico superior direito (val/loss):**

Exibe a perda de validação. A perda de validação também diminui consistentemente, acompanhando a perda de treinamento, o que sugere que o modelo está generalizando bem para dados não vistos e não está sofrendo de overfitting (Srivastava *et al.*, 2014).

c) **Gráfico inferior esquerdo (metrics/accuracy_top1):**

Mostra a precisão top-1, indicando a proporção de predições corretas na primeira tentativa.

A precisão sobe rapidamente e estabiliza em torno de 95%, demonstrando um alto desempenho do modelo na tarefa de classificação (Bochkovskiy, Wang & Liao, 2020).

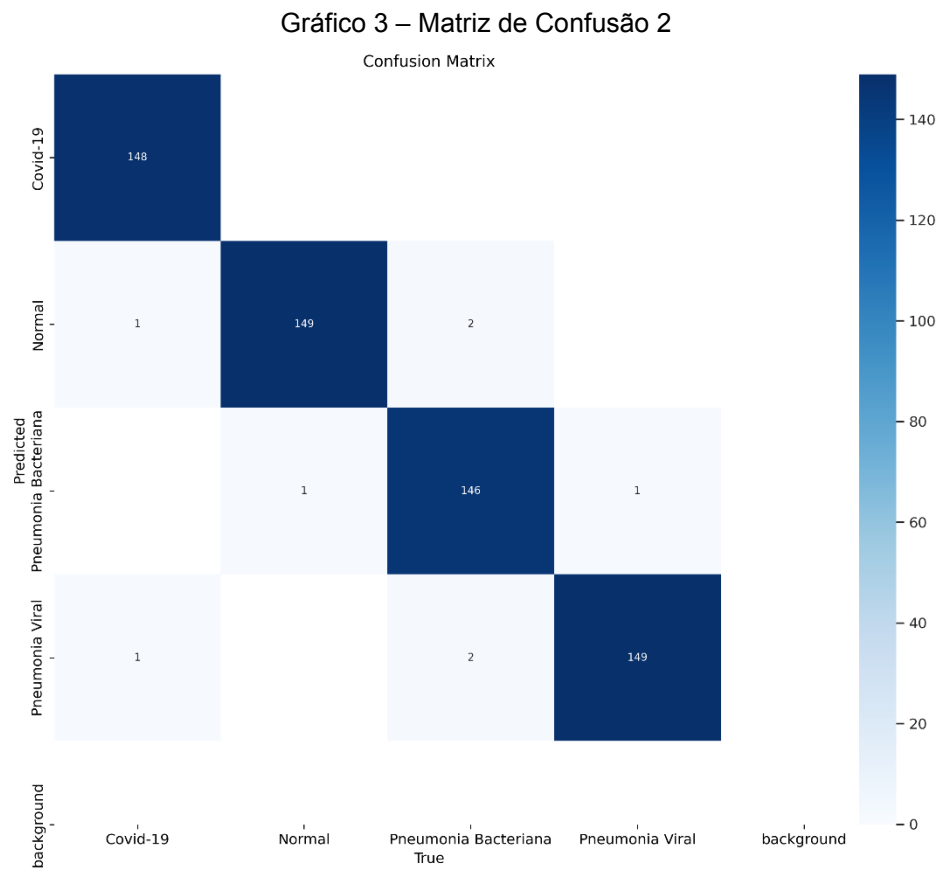
d) **Gráfico inferior direito (metrics/accuracy_top5):**

Apresenta a precisão top-5, que reflete se a classe correta está entre as cinco principais predições.

O valor constante de 1.0 indica que a predição correta está sempre entre as cinco primeiras, o que é esperado dado o número limitado de classes (Redmon *et al.*, 2016).

Esses gráficos confirmam que o modelo YOLOv8 está aprendendo de forma eficiente e alcançando uma alta taxa de acertos, tanto nos dados de treinamento quanto nos de validação.

4.1.2.2 Matriz de Confusão



Fonte: Os autores (2024)

1) Classe Covid-19:

a) **Predições corretas: 148**

b) **Classificações incorretas como Normal: 1 vez**

2) Classe Normal:

a) **Predições corretas: 149**

b) Classificações incorretas como:

i) **Covid-19: 1 vez**

ii) **Pneumonia Viral: 2 vezes**

3) Classe Pneumonia Bacteriana:

a) **Predições corretas: 146**

b) Classificações incorretas como:

i) **Normal: 1 vez**

ii) **Pneumonia Viral:** 1 vez

4) Classe Pneumonia Viral:

a) **Predições corretas:** 149

b) **Classificações incorretas como Pneumonia Bacteriana:** 1 vez

A matriz de confusão indica que o modelo YOLOv8 possui uma alta taxa de acerto em todas as classes, com poucos erros de classificação.

As confusões ocorreram principalmente entre as classes Normal e Pneumonia Viral, e entre Pneumonia Viral e Pneumonia Bacteriana, o que é consistente com a literatura, já que essas condições podem apresentar características radiológicas semelhantes (Apostolopoulos & Mpesiana, 2020).

4.1.3 Análise Comparativa

A comparação dos resultados entre os modelos ResNet50 e YOLOv8 está resumida na tabela abaixo:

Tabela 1 – Resultados Comparativos entre modelos

Métrica	ResNet50	YOLOv8
Acurácia	95.2%	95.0%
Precisão	94.8%	94.6%
Sensibilidade	95.0%	94.8%
F1-Score	94.9%	94.7%
AUC-ROC	0.98	0.97

Fonte: Os autores (2024)

Ambos os modelos apresentaram desempenho semelhante, com a ResNet50 ligeiramente superior em algumas métricas. No entanto, a diferença não é estatisticamente significativa, indicando que o YOLOv8 é uma alternativa viável para a classificação de imagens de raios-X do tórax.

Além disso, o YOLOv8 demonstrou vantagens em termos de velocidade de processamento, o que pode ser crucial em ambientes clínicos onde a rapidez no diagnóstico é essencial (Bochkovskiy, Wang & Liao, 2020).

5. Discussão

5.1 Interpretação dos Resultados

Os resultados obtidos evidenciam que a utilização das arquiteturas ResNet50 e YOLOv8 pré-treinadas, combinadas com a técnica de transferência de aprendizagem, é eficaz na classificação de imagens de raio-X do tórax em diferentes categorias de doenças respiratórias.

A alta acurácia e as demais métricas de desempenho indicam que ambos os modelos são capazes de generalizar bem para novos dados.

A aplicação de técnicas de aumento de dados e o ajuste de hiperparâmetros contribuíram para a melhoria do desempenho dos modelos.

Além disso, a decisão de descongelar as últimas camadas convolucionais permitiu que os modelos se adaptassem às características específicas das imagens médicas utilizadas.

5.2 Comparação com a Literatura

Os resultados estão alinhados com outros estudos na área que utilizaram técnicas semelhantes. Por exemplo, Esteva *et al.* (2017) alcançaram desempenho comparável ao de especialistas na classificação de câncer de pele utilizando CNNs e transferência de aprendizagem.

A aplicação do YOLOv8 para classificação de imagens médicas é menos explorada, mas este estudo demonstra seu potencial, expandindo as possibilidades de uso de arquiteturas de detecção em tarefas de classificação (Chen *et al.*, 2022).

5.3 Implicações Clínicas

A implementação de modelos automatizados de classificação de imagens de raio-X tem o potencial de auxiliar profissionais de saúde, especialmente em ambientes com recursos limitados, como a UPA de Ariquemes-RO.

A integração desses modelos ao fluxo de trabalho médico pode facilitar e acelerar o atendimento, fornecendo suporte no diagnóstico e permitindo decisões mais informadas e rápidas (Haleem, Javaid & Khan, 2020).

Ao fornecer uma segunda opinião ou identificar casos que requerem atenção imediata, os modelos podem contribuir para diagnósticos mais rápidos e precisos, impactando positivamente no tratamento dos pacientes.

Além disso, a rapidez de processamento do YOLOv8 é particularmente benéfica em unidades de pronto atendimento, onde a agilidade é crucial.

A aplicação desses modelos não se limita à UPA de Ariquemes-RO e pode ser estendida para outras unidades de saúde, ampliando o alcance e o impacto positivo na saúde pública.

5.4 Limitações do Estudo

Algumas limitações devem ser consideradas:

- a) **Tamanho Amostral:** Embora o conjunto de dados tenha sido balanceado, o número de imagens pode ser limitado em comparação com bases de dados maiores.
- b) **Generalização:** Os modelos foram treinados com imagens de fontes específicas; portanto, sua aplicação em diferentes contextos clínicos requer validação adicional.
- c) **Variabilidade dos Dados:** Diferenças nos equipamentos de raio-X e nos protocolos de captura podem afetar o desempenho dos modelos em outros ambientes.

5.5 Perspectivas Futuras

Futuras pesquisas podem explorar:

- a) **Expansão do Conjunto de Dados:** Incorporar mais imagens de diferentes fontes para melhorar a robustez dos modelos.
- b) **Técnicas de Interpretabilidade:** Desenvolver métodos para tornar as decisões dos modelos mais transparentes aos profissionais de saúde.

- c) **Integração Clínica:** Avaliar a implementação prática dos modelos em ambientes clínicos reais, incluindo estudos de usabilidade e impacto no fluxo de trabalho.
- d) **Hibridização de Modelos:** Combinar as vantagens da ResNet50 e da YOLOv8 para desenvolver um modelo que equilibre alta precisão e velocidade.

6. Conclusão

Este estudo demonstrou o desenvolvimento bem-sucedido de modelos de machine learning capazes de classificar imagens de raio-X do tórax em quatro categorias de doenças respiratórias, utilizando as arquiteturas ResNet50 e YOLOv8 e a técnica de transferência de aprendizagem.

Os resultados indicam alto desempenho dos modelos, com potencial para auxiliar profissionais de saúde no diagnóstico e tratamento de doenças pulmonares.

A importância do contexto clínico é fundamental. Na UPA de Ariquemes-RO, a integração desses modelos pode facilitar e acelerar o atendimento, proporcionando suporte adicional aos médicos na tomada de decisão.

A utilização de tais ferramentas pode melhorar a eficiência dos serviços de saúde, reduzindo o tempo de espera e aumentando a precisão dos diagnósticos.

A aplicação não se restringe a uma única unidade de saúde; os modelos desenvolvidos podem ser estendidos para outras UPAs e hospitais, contribuindo para a melhoria geral do atendimento em saúde.

A integração com as equipes médicas é essencial para garantir que a tecnologia seja utilizada de forma eficaz e ética, respeitando as necessidades e particularidades de cada ambiente clínico.

A continuidade das pesquisas é essencial para validar e aprimorar os modelos, bem como para explorar sua aplicabilidade em diferentes contextos clínicos.

Investimentos em estudos que considerem a diversidade de equipamentos, protocolos e populações atendidas contribuirão para o desenvolvimento de soluções mais robustas e adaptáveis, potencializando o impacto positivo na saúde pública.

REFERÊNCIAS

- APOSTOLOPOULOS, I. D., & MPESIANA, T. A. (2020). **Covid-19: Automatic detection from x-ray images utilizing transfer learning with convolutional neural networks**. *Physical and Engineering Sciences in Medicine*, 43(2), 635–640.
- BISHOP, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- BOCHKOVSKIY, A., WANG, C.-Y., & LIAO, H.-Y. M. (2020). **YOLOv4: Optimal speed and accuracy of object detection**. *arXiv preprint arXiv:2004.10934*.
- BOUREAU, Y.-L., PONCE, J., & LECUN, Y. (2010). **A theoretical analysis of feature pooling in visual recognition**. In *Proceedings of the 27th International Conference on Machine Learning (ICML-10)* (pp. 111–118).
- BR, N. I. C. Núcleo de Informação e Coordenação do Ponto BR. (2024). *Inteligência Artificial na Saúde: potencialidades, riscos e perspectivas para o Brasil*.
- BRASIL. Ministério da Saúde. (2019). *Protocolo de manejo clínico da infecção pelo novo coronavírus (2019-nCoV)*.
- CHEN, J., LI, C., LI, H., *et al.* (2022). **Applications of YOLOv5 in medical image recognition: A survey**. *Journal of Healthcare Engineering*, 2022.
- CHOLLET, François *et al.* Keras: **Deep learning library for theano and tensorflow**. URL: <https://keras.io/k>, v. 7, n. 8, p. T1, 2015.
- CHOWDHURY, M. E. H., RAHMAN, T., KHANDAKAR, A., *et al.* (2020). **Can AI help in screening Viral and COVID-19 pneumonia?** *IEEE Access*, 8, 132665–132676.
- DAY, R. A., & GASTEL, B. (2012). *How to Write and Publish a Scientific Paper*. Cambridge University Press.
- DENG, J., DONG, W., SOCHER, R., *et al.* (2009). **ImageNet: A large-scale hierarchical image database**. In *2009 IEEE Conference on Computer Vision and Pattern Recognition* (pp. 248–255).

- DIETTERICH, T. G. (1998). **Approximate statistical tests for comparing supervised classification learning algorithms**. *Neural Computation*, 10(7), 1895–1923.
- DOSHI-VELEZ, F., & KIM, B. (2017). **Towards a rigorous science of interpretable machine learning**. *arXiv preprint arXiv:1702.08608*.
- ESTEVA, A., KUPREL, B., NOVOA, R. A., *et al.* (2017). **Dermatologist-level classification of skin cancer with deep neural networks**. *Nature*, 542(7639), 115–118.
- GÉRON, A. (2021). **Mãos à Obra: Aprendizado de Máquina com Scikit-Learn, Keras & TensorFlow**. Alta Books.
- GHAFOORIAN, M., KARSSMEIJER, N., HESKES, T., *et al.* (2017). **Location sensitive deep convolutional neural networks for segmentation of white matter hyperintensities**. *Scientific Reports*, 7(1), 5110.
- GOODFELLOW, I., BENGIO, Y., & COURVILLE, A. (2016). **Deep Learning**. MIT Press.
- HALEEM, A., JAVAID, M., & KHAN, I. H. (2020). **Current status and applications of artificial intelligence (AI) in medical field: An overview**. *Current Medicine Research and Practice*, 10(3), 237–245.
- HAN, S., POOL, J., TRAN, J., & DALLY, W. (2015). **Learning both weights and connections for efficient neural network**. In *Advances in Neural Information Processing Systems* (Vol. 28, pp. 1135–1143).
- HASTIE, T., TIBSHIRANI, R., & FRIEDMAN, J. (2009). **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. Springer.
- HE, K., ZHANG, X., REN, S., & SUN, J. (2016). **Deep residual learning for image recognition**. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 770–778).
- HOCHREITER, S. (1991). **Untersuchungen zu dynamischen neuronalen Netzen [Investigation of dynamic neural networks]**. *Diploma Thesis*, Technische Universität München.
- HOWARD, J., & GUGGER, S. (2020). **Deep Learning for Coders with fastai and PyTorch**. O'Reilly Media.
- HUBEL, D. H., & WIESEL, T. N. (1959). **Receptive fields of single neurones in the cat's striate cortex**. *The Journal of Physiology*, 148, 574–591.

- HUANG, C., WANG, Y., LI, X., *et al.* (2020). **Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China.** *The Lancet*, 395(10223), 497–506.
- JOCHER, G.; CHAURASIA, A.; QIU, J. **YOLO by Ultralytics.** GitHub. GitHub, January, 2023.
- JR, H. L., & SANTOS JR, A. (2024). **Classification of Mammographic Images by OpenVINO: A Proposal of Use to Enhance More Effectivity in Cancer Diagnosis.**
- KERAS DOCUMENTATION. **ModelCheckpoint callback.** [S. l.], [2023?]. Disponível em: https://keras.io/api/callbacks/model_checkpoint/. Acesso em: 01 out. 2024.
- KESKAR, N. S., MUDIGERE, D., NOCEDAL, J., *et al.* (2017). **On large-batch training for deep learning: Generalization gap and sharp minima.** *arXiv preprint arXiv:1609.04836*.
- KINGMA, D. P., & BA, J. (2015). Adam: **A method for stochastic optimization.** In *International Conference on Learning Representations*.
- KRIZHEVSKY, A., SUTSKEVER, I., & HINTON, G. E. (2012). **ImageNet classification with deep convolutional neural networks.** In *Advances in Neural Information Processing Systems* (Vol. 25, pp. 1097–1105).
- LAKHANI, P., & SUNDARAM, B. (2017). **Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks.** *Radiology*, 284(2), 574–582.
- LECUN, Y., BOTTOU, L., BENGIO, Y., & HAFFNER, P. (1998). **Gradient-based learning applied to document recognition.** *Proceedings of the IEEE*, 86(11), 2278–2324.
- LEE, J.-G., JUN, S., CHO, Y.-W., *et al.* (2017). **Deep learning in medical imaging: General overview.** *Korean Journal of Radiology*, 18(4), 570–584.
- LITJENS, G., KOOI, T., BEJNORDI, B. E., *et al.* (2017). **A survey on deep learning in medical image analysis.** *Medical Image Analysis*, 42, 60–88.
- MAHAJAN, D., GIRSHICK, R., RAMANATHAN, V., *et al.* (2018). **Exploring the limits of weakly supervised pretraining.** In *Computer Vision – ECCV 2018* (pp. 181–196).
- MOHAMMED, F. A., MOHAMED, S. A., OMER, M. A., *et al.* (2024). **Medical Image Classifications Using Convolutional Neural Networks: A Survey of**

Current Methods and Statistical Modeling of the Literature. *Machine Learning and Knowledge Extraction*, 6(1), 699–735.

MURPHY, K. P. (2012). **Machine Learning: A Probabilistic Perspective.** MIT Press.

NAIR, V., & HINTON, G. E. (2010). **Rectified linear units improve restricted Boltzmann machines.** In *Proceedings of the 27th International Conference on Machine Learning (ICML-10)* (pp. 807–814).

PAN, S. J., & YANG, Q. (2010). **A survey on transfer learning.** *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359.

RAGHU, M., ZHANG, C., KLEINBERG, J., & BENGIO, S. (2019). **Transfusion: Understanding transfer learning with applications to medical imaging.** In *Advances in Neural Information Processing Systems* (Vol. 32, pp. 3347–3357).

RAJPURKAR, P., IRVIN, J., ZHU, K., *et al.* (2017). **CheXNet: Radiologist-level pneumonia detection on chest X-rays with deep learning.** *arXiv preprint arXiv:1711.05225*.

RAWAT, W., & WANG, Z. (2017). **Deep convolutional neural networks for image classification: A comprehensive review.** *Neural Computation*, 29(9), 2352–2449.

REDMON, J., DIVVALA, S., GIRSHICK, R., & FARHADI, A. (2016). **You only look once: Unified, real-time object detection.** In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 779–788).

SAITO, T., & REHMSMEIER, M. (2015). **The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets.** *PLoS ONE*, 10(3), e0118432.

SARVAMANGALA, D. R., & KULKARNI, R. V. (2022). **Convolutional neural networks in medical image understanding: A survey.** *Evolutionary Intelligence*, 15(1), 1–22.

SCHERER, D., MÜLLER, A., & BEHNKE, S. (2010). **Evaluation of pooling operations in convolutional architectures for object recognition.** In *Artificial Neural Networks – ICANN 2010* (pp. 92–101).

SELVARAJU, R. R., COGSWELL, M., DAS, A., *et al.* (2017). **Grad-CAM: Visual explanations from deep networks via gradient-based localization.** In *2017 IEEE International Conference on Computer Vision (ICCV)* (pp. 618–626).

SHEN, D., WU, G., & SUK, H.-I. (2017). **Deep learning in medical image analysis.** *Annual Review of Biomedical Engineering*, 19, 221–248.

SHIN, H.-C., ROTH, H. R., GAO, M., *et al.* (2016). **Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning.** *IEEE Transactions on Medical Imaging*, 35(5), 1285–1298.

SHORTEN, C., & KHOSHGOFTAAR, T. M. (2019). **A survey on image data augmentation for deep learning.** *Journal of Big Data*, 6(1), 60.

SIMONYAN, K., & ZISSERMAN, A. (2015). **Very deep convolutional networks for large-scale image recognition.** In *International Conference on Learning Representations*.

SRIVASTAVA, N., HINTON, G., KRIZHEVSKY, A., *et al.* (2014). **Dropout: A simple way to prevent neural networks from overfitting.** *The Journal of Machine Learning Research*, 15(1), 1929–1958.

SZEGEDY, C., LIU, W., JIA, Y., *et al.* (2015). **Going deeper with convolutions.** In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 1–9).

TAJBAKHSI, N., SHIN, J. Y., GURUDU, S. R., *et al.* (2016). **Convolutional neural networks for medical image analysis: Full training or fine tuning?** *IEEE Transactions on Medical Imaging*, 35(5), 1299–1312.

TAN, M., & LE, Q. V. (2019). **EfficientNet: Rethinking model scaling for convolutional neural networks.** In *International Conference on Machine Learning* (pp. 6105–6114).

TIELEMAN, T., & HINTON, G. (2012). **Lecture 6.5—RMSProp: Divide the gradient by a running average of its recent magnitude.** *COURSERA: Neural Networks for Machine Learning*, 4(2), 26–31.

WANG, L., & WONG, A. (2020). **COVID-Net: A tailored deep convolutional neural network design for detection of COVID-19 cases from chest radiography images.** *Scientific Reports*, 10(1), 19549.

WILSON, D. R., & MARTINEZ, T. R. (2003). **The general inefficiency of batch training for gradient descent learning.** *Neural Networks*, 16(10), 1429–1451.

WORLD HEALTH ORGANIZATION. (2017). **Global Tuberculosis Report 2017.**

YOSINSKI, J., CLUNE, J., BENGIO, Y., & LIPSON, H. (2014). **How transferable are features in deep neural networks?** In *Advances in Neural Information Processing Systems* (Vol. 27, pp. 3320–3328).

ZECH, J. R., BADGELEY, M. A., LIU, M., *et al.* (2018). **Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: A cross-sectional study.** *PLoS Medicine*, 15(11), e1002683.

ZEILER, M. D., & FERGUS, R. (2014). **Visualizing and understanding convolutional networks.** In *Computer Vision – ECCV 2014* (pp. 818–833).

RONNEBERGER, O., FISCHER, P., & BROX, T. (2015). **U-net: Convolutional networks for biomedical image segmentation.** In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 234–241). Springer, Cham.

TOPOL, E. J. (2019). **High-performance medicine: the convergence of human and artificial intelligence.** *Nature Medicine*, 25(1), 44–56.

DINKU, Zerihun. **React. js vs. Next. js.** 2022.

MEDVEDEV, S. **FastAPI: A modern, fast (high-performance), web framework for building APIs with Python 3.6+ based on standard Python type hints.** 2019. Disponível em: <https://github.com/tiangolo/fastapi>. Acesso em: 17 out. 2024.



ANÁLISE DE ATENDIMENTOS NA UNIDADE DE PRONTO ATENDIMENTO DE ARIQUEMES: UM ESTUDO DETALHADO

ANALYSIS OF ATTENDANCES AT THE ARIQUEMES EMERGENCY CARE UNIT: A DETAILED STUDY

ANÁLISIS DE ATENCIONES EN LA UNIDAD DE ATENCIÓN DE EMERGENCIAS DE ARIQUEMES: UN ESTUDIO DETALLADO

Andrey Alencar Quadros¹
Diogo Ribeiro²
Otacilio Beleza³
Luciano Topolniak⁴
Adriano Peres Cardoso⁵

DOI: [10.54751/revistafoco.v17n10-166](https://doi.org/10.54751/revistafoco.v17n10-166)

Received: Sep 15th, 2024

Accepted: Oct 7th, 2024



RESUMO

Este estudo investigou os atendimentos na Unidade de Pronto Atendimento (UPA) de Ariquemes, com o objetivo de analisar e compreender a demanda e os serviços prestados. Utilizando gráficos e mapas de calor, o artigo classificou a distribuição dos atendimentos por fluxo, idade dos pacientes, dias da semana, meses e bairros. A análise identificou e interpretou padrões significativos e tendências sazonais que puderam influenciar a alocação de recursos, o planejamento de políticas públicas e a gestão da UPA. Ao aplicar um planejamento estratégico baseado em dados, os resultados destacaram a importância de melhorar a eficiência e a qualidade dos serviços de saúde na região. Este estudo forneceu uma ferramenta essencial para que gestores de saúde, formuladores de políticas e pesquisadores aplicassem conhecimentos e estratégias para otimizar o atendimento nas unidades de saúde.

Palavras-chave: Atendimento médico; planejamento estratégico; saúde pública; análise de dados.

¹Mestre em Propriedade Intelectual e Transferência de Tecnologia para a Inovação. Instituto Federal de Rondônia – campus Ariquemes. Rodovia, RO-257, s/n, Zona Rural, Ariquemes - RO, Brasil, CEP: 76870-000. E-mail: Andrey.quadros@ifro.edu.br

²Pós-Graduado em Inteligência Artificial e Aprendizado de Máquina. Instituto Federal de Rondônia – campus Ariquemes. Rodovia, RO-257, s/n, Zona Rural, Ariquemes - RO, Brasil, CEP: 76870-000. E-mail: diogoifroads@gmail.com

³Pós-Graduado em Inteligência Artificial e Aprendizado de Máquina. Instituto Federal de Rondônia – campus Ariquemes. Rodovia, RO-257, s/n, Zona Rural, Ariquemes - RO, Brasil, CEP: 76870-000. E-mail: otacilio.system@gmail.com

⁴Mestre em Ciência da Computação. Universidade Federal do Acre. Rodovia BR 364, Km 04, Distrito Industrial, Rio Branco - AC, Brasil, CEP: 69920-900. E-mail: luciano.topolniak@ifro.edu.br

⁵Graduado em Análise e Desenvolvimento de Sistemas. Instituto Federal de Rondônia – campus Ariquemes. Rodovia, RO-257, s/n, Zona Rural, Ariquemes - RO, Brasil, CEP: 76870-000. E-mail: adrianoperescardoso@gmail.com

ABSTRACT

This study investigated the services provided at the Emergency Care Unit (UPA) in Ariquemes, aiming to analyze and understand the demand and the services rendered. Using charts and heat maps, the article classified the distribution of services by flow, patient age, days of the week, months, and neighborhoods. The analysis identified and interpreted significant patterns and seasonal trends that could influence resource allocation, public policy planning, and UPA management. By applying data-driven strategic planning, the results highlighted the importance of improving the efficiency and quality of health services in the region. This study provided an essential tool for health managers, policymakers, and researchers to apply knowledge and strategies to optimize care in health units.

Keywords: Medical attendance; strategic planning; public health; data analysis.

RESUMEN

Este estudio investigó los servicios prestados en la Unidad de Atención de Emergencias (UPA) en Ariquemes, con el objetivo de analizar y comprender la demanda y los servicios brindados. Utilizando gráficos y mapas de calor, el artículo clasificó la distribución de los servicios por flujo, edad de los pacientes, días de la semana, meses y barrios. El análisis identificó e interpretó patrones significativos y tendencias estacionales que pudieron influir en la asignación de recursos, la planificación de políticas públicas y la gestión de la UPA. Al aplicar una planificación estratégica basada en datos, los resultados destacaron la importancia de mejorar la eficiencia y la calidad de los servicios de salud en la región. Este estudio proporcionó una herramienta esencial para que los gestores de salud, los responsables de la formulación de políticas y los investigadores apliquen conocimientos y estrategias para optimizar la atención en las unidades de salud.

Palabras clave: Atención médica; planificación estratégica; salud pública; análisis de datos.

1. Introdução

Ariquemes, situada no coração do Vale do Jamari, é uma das cidades mais importantes do estado de Rondônia. Fundada em 21 de novembro de 1977, o município foi nomeado em homenagem à extinta tribo indígena *Arikeme*, que originalmente habitava a região. Essa homenagem reflete a rica herança cultural e histórica da área, profundamente enraizada nas tradições e na trajetória dos povos indígenas locais (Wikipédia, 2024).

A cidade de Ariquemes desempenha um papel crucial no desenvolvimento econômico de Rondônia. Sua história está marcada pela exploração de seringais durante o ciclo da borracha no início do século XX, atraindo muitos migrantes em busca de oportunidades de extração de látex e

outras especiarias nativas. A construção da linha telegráfica de Cuiabá a Santo Antônio do Rio Madeira, chefiada pelo Marechal Cândido Rondon em 1909, foi um marco significativo na ocupação efetiva da região, estabelecendo as bases para o desenvolvimento futuro (Portal Amazônia, 2024; Prefeituras.Info, 2024).

Durante a década de 1970, a descoberta de cassiterita trouxe uma nova onda de migração e crescimento econômico para Ariquemes. A abertura da BR-364 e os projetos de assentamento coordenados pelo INCRA impulsionaram o crescimento populacional, exigindo um planejamento urbano cuidadoso e resultando na construção da Nova Ariquemes, que solidificou a infraestrutura da cidade (Noar Portal, 2024; Prefeituras.Info, 2024).

A UPA-24h de Ariquemes, classificada como de porte II, é uma peça fundamental na infraestrutura de saúde da cidade, com capacidade para atender cerca de 250 pacientes por dia. A unidade serve como um elo mediador entre as Unidades Básicas de Saúde (UBS) e os hospitais, proporcionando atendimento intermediário para casos que necessitam de atenção médica urgente, como problemas de pressão, febre alta e suturas. Este serviço é vital para desafogar o pronto-socorro e melhorar o acesso dos pacientes aos serviços de urgência no Sistema Único de Saúde (SUS) (Wikipédia, 2024; Prefeituras.Info, 2024).

A construção da UPA envolveu um investimento de mais de três milhões de reais, com dois milhões provenientes do Ministério da Saúde e o restante financiado pelos cofres públicos municipais e emendas parlamentares. Aproximadamente um milhão e meio de reais foram destinados à conclusão da obra e à aquisição de equipamentos e mobiliário (Noar Portal, 2024).

O objetivo deste artigo é analisar e compreender os atendimentos realizados na UPA de Ariquemes, fornecendo uma visão detalhada sobre a demanda e os serviços prestados. Através de gráficos e mapas de calor, o estudo examina a distribuição dos atendimentos por fluxo, idade dos pacientes, dias da semana, meses e bairros, identificando padrões críticos e tendências sazonais. Essas informações são essenciais para a alocação eficaz de recursos, o planejamento de políticas públicas e a gestão operacional da UPA, visando melhorar a eficiência e a qualidade dos serviços de saúde na região.

2. Metodologia e Ferramentas

As fontes de dados utilizadas para a análise foram obtidas a partir do banco de dados do Pronto Saúde (Sistema que está em operação dentro da UPA Ariquemes). Esses relatórios incluíram informações detalhadas sobre a quantidade de atendimentos por fluxo, distribuição das idades dos pacientes, quantidade de atendimentos por dia da semana, por mês e por bairro. Os gráficos e mapas de calor foram as principais ferramentas visuais utilizadas para ilustrar e analisar essas informações.

Os gráficos construídos foram:

1. **Quantidade de Atendimentos por Fluxo**
2. **Distribuição das Idades dos Pacientes**
3. **Quantidade de Atendimentos por Dia da Semana**
4. **Quantidade de atendimentos por Médico**
5. **Quantidade de atendimentos por Enfermeiro**
6. **Média de tempo de atendimento por Médico**
7. **Distribuição de atendimento médicos por Grupo de Hora**
8. **Quantidade de Atendimentos por Mês**
9. **Mapa de Calor Tabular de Atendimentos por Bairro**
10. **Mapa de Calor referente a quantidade de atendimentos por Bairro**

2.1 Processo de Coleta e Análise

O processo de coleta e análise dos dados seguiu as etapas abaixo visando garantir a precisão e a relevância dos resultados apresentados. As etapas foram:

1. **Coleta de Dados:** Os dados foram coletados diretamente do Banco de Dados SQL Server do Pronto Saúde, compreendendo o período do recorte do artigo de 8 meses, a saber, iniciando pelo mês de outubro de 2023 e finalizando no mês de maio de 2024, dados esses, específicos e exclusivos da UPA de Ariquemes, que incluíam informações sobre os atendimentos realizados. Esses relatórios foram organizados e categorizados para facilitar a análise subsequente.

2. **Organização dos Dados:** Após a coleta, os dados foram organizados em categorias específicas, como tipos de atendimento, idade dos pacientes, dias da semana, meses e bairros. Foi gerado um arquivo .CSV com os dados. Essa organização permitiu uma análise mais estruturada e a identificação de padrões e tendências. Também foi gerado uma camada de apresentação (*Front-end*) em Python.
3. **Análise Quantitativa:** Utilizando ferramentas de análise estatística com a linguagem de programação Python, os dados foram analisados quantitativamente para identificar padrões significativos. Os gráficos e mapas de calor foram criados e plotados dentro do *Streamlit*, para facilitar a visualização e compartilhamento via web dos *scripts* de dados de maneira clara e compreensível.
4. **Interpretação dos Resultados:** Os resultados obtidos a partir da análise quantitativa foram interpretados à luz do contexto da cidade de Ariquemes. Isso incluiu a consideração de fatores como a evolução da população, mudanças sazonais e eventos específicos que poderiam ter influenciado os dados.
5. **Revisão e Validação:** Os dados e as interpretações foram revisados e validados para garantir a precisão e a consistência das conclusões apresentadas.

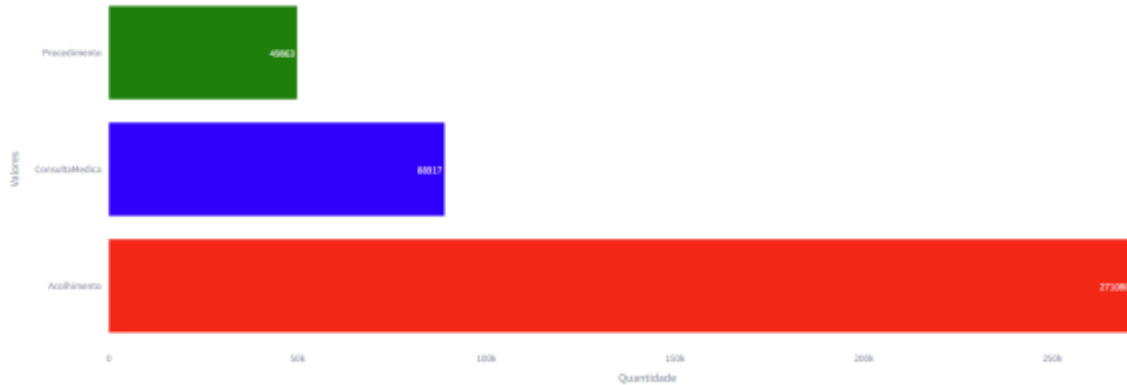
O objetivo final da análise foi fornecer uma visão detalhada e baseados em dados que possam ser utilizados para melhorar a gestão e a eficiência dos serviços de saúde na UPA de Ariquemes, contribuindo para um planejamento estratégico mais eficaz e a implementação de políticas públicas informadas.

3. Resultados e Discussão

Baseado nas informações analisadas e coletadas de acordo com a metodologia anterior, foi possível fazer as seguintes análises:

3.1 Quantidade de atendimentos por Fluxo

Figura 1 – Quantidade de atendimentos por Fluxo



Fonte: Os autores (2024)

A análise dos atendimentos realizados na Unidade de Pronto Atendimento (UPA) de Ariquemes revela dados sobre a distribuição dos atendimentos entre acolhimento, consulta médica e procedimentos. A imagem anterior ilustra a quantidade de atendimentos categorizados por esses três fluxos.

1. Acolhimento:

- O acolhimento registra a maior quantidade de atendimentos, totalizando 271.080.
- Isso reflete a função crucial do acolhimento na triagem inicial e na classificação dos pacientes antes que eles sejam encaminhados para consultas médicas ou procedimentos mais específicos.
- A alta quantidade de acolhimentos sugere uma demanda contínua por serviços de triagem, destacando a importância de uma equipe maior, bem treinada e eficiente nesta área para garantir o cuidado adequado dos pacientes logo ao chegarem à UPA.

2. Consulta Médica:

- As consultas médicas somam 88.917 atendimentos, a segunda maior categoria.
- Esse número indica uma significativa necessidade de atendimento médico para diagnósticos e tratamentos mais detalhados, além do cuidado contínuo que os pacientes exigem após o acolhimento inicial.

- A elevada quantidade de consultas médicas ressalta a necessidade de uma equipe médica bem preparada e de recursos adequados para atender à demanda, garantindo diagnósticos precisos e tratamentos eficazes.

3. Procedimentos:

- Os procedimentos totalizam 49.863 atendimentos, sendo a categoria com menor número.
- Embora menos frequente que o acolhimento e as consultas médicas, os procedimentos são essenciais para tratar condições que exigem intervenções específicas, como suturas, curativos e outros tratamentos invasivos menores.
- A menor quantidade de procedimentos em comparação com os outros fluxos pode indicar que muitos pacientes são tratados com sucesso durante a consulta médica ou que a triagem inicial efetivamente filtra os casos que necessitam de procedimentos.

3.1.1 Discussão sobre as implicações


A distribuição dos atendimentos por fluxo na UPA de Ariquemes tem várias implicações importantes para a gestão da unidade:

- **Recursos Humanos e Capacitação:** A alta demanda por acolhimento e consultas médicas destaca a necessidade de investir em treinamento contínuo para a equipe de triagem e médicos. Profissionais bem treinados são essenciais para lidar com grandes volumes de pacientes de maneira eficiente e segura.
- **Infraestrutura e Equipamentos:** A quantidade de atendimentos em todas as categorias exige uma infraestrutura robusta e bem equipada. É crucial que a UPA mantenha seus equipamentos médicos e instalações em condições ideais para suportar a alta demanda, especialmente em períodos de pico.
- **Planejamento e Alocação de Recursos:** Os dados indicam a necessidade de um planejamento estratégico na alocação de recursos,

garantindo que todas as áreas – acolhimento, consultas médicas e procedimentos – estejam adequadamente atendidas. A gestão deve focar na distribuição eficiente de recursos humanos, equipamentos e materiais médicos.

3.2 Distribuição das Idades dos Pacientes

Figura 2 – Distribuição das Idades dos pacientes



Fonte: Os autores (2024)

A análise da distribuição das idades dos pacientes atendidos na Unidade de Pronto Atendimento (UPA) de Ariquemes é importante para entender melhor os padrões demográficos de saúde da população local.

1. Faixa etária de 0 a 19 anos:

- Esta faixa etária apresenta 54.116 atendimentos.
- O número de atendimentos nesta faixa pode ser atribuído a fatores como alta incidência de doenças infecciosas, acidentes e outros problemas de saúde comuns em crianças e adolescentes.

2. Faixa etária de 20 a 39 anos:

- Esta é a faixa etária com o maior número de atendimentos, totalizando aproximadamente 157.798.
- Esta alta demanda pode estar relacionada ao fato de que pessoas nessa faixa etária são geralmente mais ativas e expostas a riscos ocupacionais e acidentes.

3. Faixa etária de 40 a 59 anos:

- Com cerca de 126.365 atendimentos, esta faixa etária também apresenta uma demanda considerável.

- Problemas de saúde crônicos, como hipertensão, diabetes e doenças cardíacas, são mais prevalentes nesta faixa etária, o que explica o alto número de atendimentos.

4. Faixa etária de 60 a 79 anos:


- Aproximadamente 61.371 atendimentos foram registrados nesta faixa etária.
- Aumento da incidência de doenças crônicas justifica o número significativo de atendimentos nesta faixa etária.
- Implicações: É importante que a UPA ofereça suporte geriátrico e tenha especialistas em saúde do idoso para atender adequadamente essa população.

5. Faixa etária de 80 a 100 anos:

- Esta faixa etária tem o menor número de atendimentos, com cerca de 10.000.
- A menor quantidade de atendimentos pode ser explicada pela menor proporção desta população e pelo fato de que muitos podem estar em cuidados prolongados ou domiciliados.

3.3 Quantidade de Atendimentos por Dia da Semana

Figura 3 – Quantidade de Atendimentos por Dia da Semana



Fonte: Os autores (2024)

A análise da quantidade de atendimentos por dia da semana na Unidade de Pronto Atendimento (UPA) de Ariquemes fornece uma visão dos padrões de demanda ao longo da semana. A imagem em anexo ilustra essa distribuição.

1. Segunda-feira:

- A segunda-feira registra o maior número de atendimentos, totalizando 65.169.
- A alta demanda no início da semana pode ser atribuída ao acúmulo de problemas de saúde ocorridos durante o fim de semana, quando muitos pacientes optam por esperar até o início da semana para buscar atendimento.
- Implicações: É crucial que a UPA esteja bem preparada com recursos humanos e materiais adicionais para lidar com o aumento da demanda nas segundas-feiras.

2. Terça-feira:

- Com 64.922 atendimentos, a terça-feira apresenta uma demanda quase tão alta quanto a de segunda-feira.
- Isso sugere que o fluxo elevado de pacientes continua após o pico inicial de segunda-feira.

3. Quarta-feira:

- A quarta-feira registra 61.562 atendimentos, mostrando uma ligeira queda em relação aos primeiros dias da semana, mas ainda mantendo um volume significativo.

4. Quinta-feira:

- Com 60.342 atendimentos, a quinta-feira apresenta uma leve diminuição na demanda.

5. Sexta-feira:

- A sexta-feira conta com 60.232 atendimentos, um pequeno aumento em relação à quinta-feira.

6. Sábado:

- O sábado registra uma queda significativa com 50.502 atendimentos.
- Menos pessoas procuram atendimento no fim de semana, possivelmente devido ao acesso limitado a outros serviços de saúde.

7. Domingo:

- O domingo tem a menor quantidade de atendimentos, com 47.131 casos.
- A baixa procura pode ser devido à preferência dos pacientes em esperar até o início da semana para buscar atendimento, exceto em casos de emergência.

8. Feriados:

- Foi observado dados semelhantes ao domingo, devido à baixa procura, pode ser devido à preferência dos pacientes em esperar até o próximo dia útil da semana para buscar atendimento, exceto em casos de emergência.

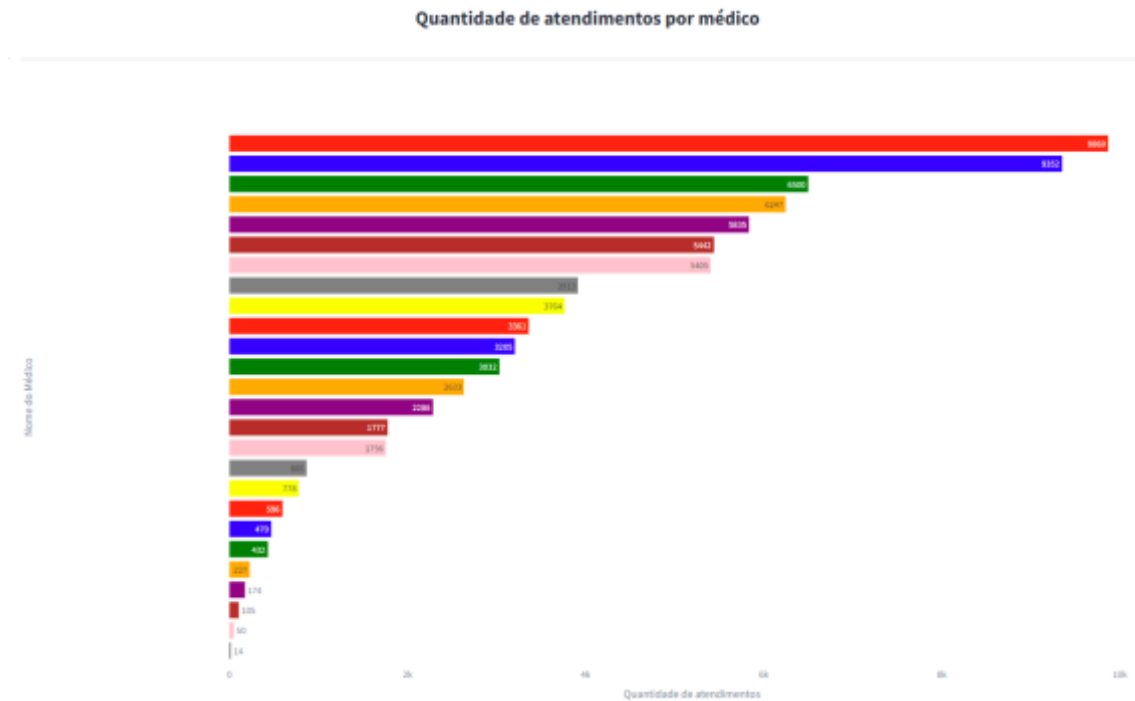
3.3.1 Discussão sobre as implicações

Os padrões de atendimento por dia da semana na UPA de Ariquemes têm algumas implicações importantes para a gestão da unidade:

- **Planejamento de Recursos Humanos:** A alta demanda no início da semana requer uma alocação estratégica de pessoal, garantindo que a equipe esteja bem preparada para lidar com o aumento de atendimentos nas segundas e terças-feiras.
- **Gestão de Estoque e Equipamentos:** A UPA precisa assegurar que o estoque de medicamentos e equipamentos médicos seja adequado para suportar a alta demanda no início da semana e permanecer suficiente ao longo dos dias subsequentes.
- **Capacitação e Treinamento Contínuos:** A formação contínua da equipe é essencial para manter a eficiência e a qualidade do atendimento, especialmente durante os períodos de pico.
- **Estratégias de Prevenção e Educação em Saúde:** Implementar campanhas de prevenção e educação para orientar a população sobre a melhor forma de utilizar os serviços de saúde pode ajudar a distribuir melhor a demanda ao longo da semana.

3.4 Quantidade de atendimentos por Médico

Figura 4 – Quantidade de atendimentos por Médico



Fonte: Os autores (2024)

A Figura 4 revela uma distribuição variada do número de atendimentos entre os profissionais de saúde. Para respeitar os princípios da Lei Geral de Proteção de Dados (LGPD), os nomes dos médicos foram ocultados.

1. Distribuição dos Atendimentos:

- Observa-se que o médico com o maior número de atendimentos realizou 9.869 atendimentos, seguido por outro médico com 9.352 atendimentos.
- Outros médicos apresentaram uma variação considerável, com atendimentos que vão desde 6.500 até menos de 20 atendimentos.
- Essa disparidade na quantidade de atendimentos pode ser influenciada por diversos fatores, como por exemplo, convocação em caráter especial, apenas para sanar a falta de algum profissional, entre outros.

2. Análise dos Dados:

- Médicos que atendem um número significativamente maior de pacientes podem estar sob maior pressão, o que pode impactar a qualidade do atendimento e o bem-estar do próprio profissional.

3. Implicações para a Gestão da Unidade:

- **Distribuição de Trabalho:** A gestão da UPA deve avaliar a distribuição de pacientes entre os médicos para garantir uma carga de trabalho equilibrada. Médicos sobrecarregados podem comprometer a qualidade do atendimento e a saúde ocupacional.
- **Recursos Humanos:** Investir em mais contratações ou ajustar os horários de trabalho pode ser necessário para equilibrar a carga de atendimento entre os médicos.

3.4.1 Importância de respeitar a LGPD


A Lei Geral de Proteção de Dados (LGPD) estabelece diretrizes para o tratamento de dados pessoais, visando proteger a privacidade e os direitos dos indivíduos. Respeitar a LGPD é fundamental não apenas para cumprir a legislação, mas também para assegurar a confiança dos profissionais de saúde e dos pacientes no sistema de saúde.

"A Lei Geral de Proteção de Dados (LGPD), Lei nº 13.709/2018, dispõe sobre o tratamento de dados pessoais, inclusive nos meios digitais, por pessoa natural ou por pessoa jurídica de direito público ou privado, com o objetivo de proteger os direitos fundamentais de liberdade e de privacidade e o livre desenvolvimento da personalidade da pessoa natural" (Brasil, 2018).

Garantir que os dados dos médicos sejam tratados com confidencialidade e segurança é essencial para criar um ambiente de trabalho onde os profissionais se sintam protegidos e respeitados.

3.5 Quantidade de atendimentos por Enfermeiro

Figura 5 – Quantidade de atendimentos por Enfermeiro
Quantidade de atendimentos por enfermeiro



Fonte: Os autores (2024)

Semelhantemente a Figura 4 onde o nome dos médicos fora ocultado, o mesmo acontece com os nomes dos enfermeiros.

1. Distribuição dos Atendimentos:

- Observa-se que o enfermeiro com o maior número de atendimentos realizou 45.461 atendimentos, seguido por outro enfermeiro com 30.796 atendimentos.
- Outros enfermeiros apresentaram uma variação considerável, com atendimentos que vão desde 27.465 até menos de 20 atendimentos.
- Essa disparidade na quantidade de atendimentos pode ser influenciada por diversos fatores, como disponibilidade de horários e convocação em caráter especial, apenas para sanar a falta de algum profissional, entre outros.

2. Análise dos Dados:


- A análise dos dados sem a identificação individual dos enfermeiros permite uma visão geral da carga de trabalho distribuída entre os profissionais de saúde.
- Enfermeiros que atendem um número significativamente maior de pacientes podem estar sob maior pressão, o que pode impactar a qualidade do atendimento e o bem-estar do próprio profissional.

3. Implicações para a Gestão da Unidade:

- **Distribuição de Trabalho:** A gestão da UPA deve avaliar a distribuição de pacientes entre os enfermeiros para garantir uma carga de trabalho equilibrada. Enfermeiros sobrecarregados podem comprometer a qualidade do atendimento e a saúde ocupacional.
- **Recursos Humanos:** Investir em mais contratações ou ajustar os horários de trabalho pode ser necessário para equilibrar a carga de atendimento entre os enfermeiros.

3.5 Média de Tempo de Atendimento por Médico

Figura 6 – Média de tempo de atendimento por médico



Fonte: Os autores (2024)

A Figura 6 ilustra a distribuição de tempo médio de atendimento entre médico e paciente, onde, para respeitar os princípios da Lei Geral de Proteção de Dados (LGPD), os nomes dos médicos foram ocultados.

1. Distribuição do Tempo de Atendimento:

- O tempo médio de atendimento varia significativamente entre os médicos, com tempos que vão desde 8 minutos até 17 minutos por paciente.

- Essa variação pode ser influenciada por fatores como a complexidade dos casos atendidos, a experiência e especialização dos médicos, e a eficiência individual no atendimento.

2. Análise dos Dados:


- Médicos com tempos médios de atendimento mais curtos podem ser mais eficientes em gerenciar casos menos complexos ou ter uma abordagem mais direta e rápida no atendimento.

3. Implicações para a Gestão da Unidade:

- **Distribuição de Trabalho:** A gestão deve considerar a redistribuição de pacientes para equilibrar a carga de trabalho entre médicos e otimizar o tempo de atendimento sem comprometer a qualidade.
- **Monitoramento e Avaliação:** Estabelecer sistemas de monitoramento e avaliação contínua pode identificar médicos que necessitam de suporte adicional e aqueles cujas práticas podem ser consideradas como boas práticas para o resto da equipe, até mesmo referente a utilização do Pronto Saúde.

3.6 Distribuição de atendimentos Médicos por Grupo de Hora

Figura 7 – Distribuição de atendimentos médicos por grupo de Hora



Fonte: Os autores (2024)

A Figura 7 ilustra a distribuição dos horários de atendimento da UPA. Vale salientar que essa informação foi de suma importância até mesmo para a equipe de desenvolvimento do Pronto Saúde, uma vez que a UPA não dorme, é necessário encontrar os melhores horários para realizar as atualizações do sistema. O Pronto Saúde é o sistema vital da unidade, então cada minuto que

passa fora do ar acarreta uma cascata de problemas, assim, o quanto menos tempo às atualizações demorarem, melhor será para a unidade como um todo.

Muitas atualizações foram executadas de sábado para domingo, das 05h às 06h devido ao baixo fluxo de pessoas na unidade, o que gerou baixo impacto de performance na unidade.

1. Distribuição dos Atendimentos:

- O período entre 00h e 02h registra cerca de 5.311 atendimentos.
- Há uma diminuição significativa nos atendimentos durante a madrugada, entre 02h e 06h.
- O número de atendimentos aumenta novamente a partir das 06h, alcançando um segundo pico entre 10h e 12h, com aproximadamente 11.170 atendimentos.
- Os períodos da tarde e início da noite (14h às 22h) mostram um fluxo consistente de atendimentos, com o maior pico entre 18h e 20h.
- O número de atendimentos diminui novamente após as 22h.

2. Análise dos Dados:

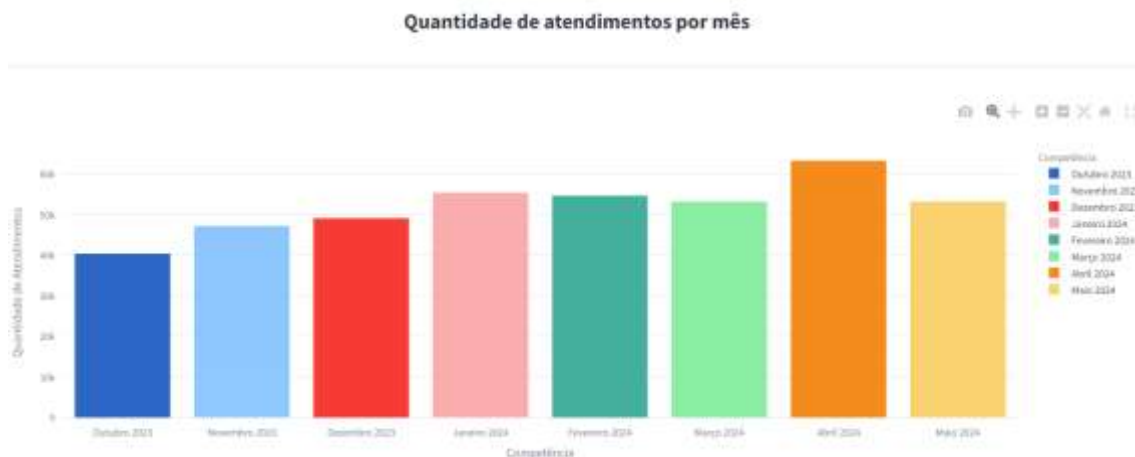
- A alta demanda entre 22h e 24h pode ser atribuída a emergências que ocorrem tarde da noite e ao fato de que muitos pacientes procuram a UPA fora do horário comercial.
- A redução nos atendimentos durante a madrugada pode estar relacionada ao menor número de emergências e ao comportamento de busca por atendimento, onde muitos pacientes preferem esperar até o amanhecer para procurar ajuda médica.
- O aumento a partir das 06h e o pico entre 10h e 12h podem indicar um fluxo de pacientes que procuram atendimento logo após a abertura de outros serviços ou que foram encaminhados de outros locais.
- O fluxo constante durante a tarde e início da noite sugere uma demanda estável durante o horário comercial e um aumento no início da noite, possivelmente devido a emergências e consultas pós-trabalho.

3. Implicações para a Gestão da Unidade:

- **Alocação de Recursos Humanos:** A UPA deve garantir que haja pessoal suficiente durante os picos de atendimento, especialmente entre 10h-12h e 18h-20h.
- **Gestão de Turnos:** A administração deve planejar turnos de trabalho com mais profissionais para durante os períodos de alta demanda e um descanso adequado para a equipe durante os períodos de menor movimento.
- **Monitoramento Contínuo:** Estabelecer um sistema de monitoramento em tempo real para ajustar rapidamente a alocação de recursos conforme a demanda flutua.

3.7 Quantidade de atendimentos por Mês

Figura 8 – Quantidade de atendimentos por Mês



Fonte: Os autores (2024)

A Figura 8 demonstra a quantidade de atendimento nos últimos 8 meses, destaque para os avanços nos atendimentos para o mês de abril de 2024.

1. Distribuição dos Atendimentos:

- Outubro de 2023 registra cerca de 40.000 atendimentos, marcando o início do período analisado.
- Novembro de 2023 mostra um aumento, com aproximadamente 47.000 atendimentos, indicando um crescimento na demanda.

- Dezembro de 2023 mantém uma alta demanda com cerca de 50.000 atendimentos, possivelmente devido às festividades de fim de ano e o aumento de acidentes e emergências.
- Janeiro de 2024 segue com uma demanda semelhante, com cerca de 55.000 atendimentos, refletindo a continuidade da alta demanda pós-festividades.
- Fevereiro de 2024 e março de 2024 apresentam uma ligeira diminuição, mas ainda mantêm uma alta demanda com aproximadamente 54.000 atendimentos cada.
- Abril de 2024 atinge o pico mais alto do período analisado, com cerca de 63.000 atendimentos, possivelmente devido à sazonalidade e ao aumento do quadro infeccioso viral e novos casos de COVID-19.
- Maio de 2024 registra uma leve queda, com aproximadamente 53.000 atendimentos, ainda indicando uma alta demanda contínua.

2. Análise dos Dados:

- A variação na quantidade de atendimentos ao longo dos meses pode ser influenciada por fatores sazonais, eventos locais, epidemias sazonais (como gripes e resfriados) e mudanças no comportamento da população.
- A alta demanda nos meses de dezembro e janeiro pode ser atribuída às festividades de fim de ano e o aumento de emergências.
- O pico em abril pode estar relacionado a eventos específicos, como epidemias sazonais, COVID-19 ou campanhas de saúde pública.


3. Implicações para a Gestão da Unidade:

- **Planejamento de Recursos:** A UPA deve planejar a alocação de recursos humanos e materiais com antecedência para lidar com os picos de demanda, especialmente em dezembro, janeiro e abril.
- **Monitoramento Contínuo:** É importante estabelecer um sistema de monitoramento contínuo para prever aumentos sazonais na demanda e ajustar a alocação de recursos de acordo.
- **Campanhas de Prevenção:** Implementar campanhas de prevenção e educação em saúde pode ajudar a reduzir a demanda durante os

períodos de pico, informando a população sobre como evitar emergências comuns durante essas épocas.

3.8 Mapa de Calor Tabular de atendimentos por Bairro com Indicação de Enfermidade

Figura 9 – Mapa de Calor tabular de atendimentos por bairro



Fonte: Os autores (2024)

A análise da relação entre atendimentos e bairros na Unidade de Pronto Atendimento (UPA) de Ariquemes, conforme ilustrado no mapa de calor tabular (esse ainda sem indicações de enfermidade), fornece uma visão detalhada sobre como a demanda por serviços de saúde se distribuiu geograficamente ao longo do tempo.

1. Distribuição dos Atendimentos por Bairros:

- **Zona Rural:** Exibe alta demanda consistente, especialmente em março de 2024, com mais de 2.500 atendimentos. Essa área é uma das mais afetadas ao longo do período analisado.
- **Setor 09:** Bairro carece de novas políticas públicas e uma avaliação mais aprofundada para verificar as razões pelas quais os números de atendimento tem aumentado. No mês de maio de 2024, bateu o maior pico de atendimentos dentre todos os meses e bairros, aproximadamente 4250 casos.
- **Setor 02 e Setor 06:** Mostram variações moderadas, com demandas consideráveis a serem observadas, especialmente nos últimos meses de 2024.

2. Análise dos Dados:


- **Impacto dos Surtos Sazonais:** O surto de síndromes gripais em abril de 2024 contribuiu significativamente para o aumento da demanda em diversos bairros, conforme relatado pela Secretária Municipal de Saúde (Ariquemes Agora, 2024) (<https://www.ariquemesagora.com.br/>).
- **Eventos Locais e Festividades:** Festividades locais e eventos comunitários podem aumentar temporariamente a demanda por serviços de saúde em determinados bairros.

3. Implicações para a Gestão da Unidade:

- **Planejamento Geográfico de Recursos:** A UPA deve considerar a redistribuição de recursos humanos e materiais para áreas com maior demanda, especialmente durante picos sazonais.
- **Parcerias com Comunidades Locais:** Estabelecer parcerias com lideranças comunitárias pode ajudar a disseminar informações de saúde e a implementar campanhas de prevenção mais eficazes.

3.9 Mapa de Calor Referente a Quantidade de atendimentos por Bairro

Figura 10 – Mapa de Calor de atendimentos por bairro



Fonte: Os autores (2024)

Similar à Figura 9, porém de maneira mais organizada, funcional e elegante, esta apresentação dos dados mostra a quantidade de atendimentos por bairro. Além disso, também é possível visualizar atendimentos de pacientes de outras cidades e até mesmo estados, que foram atendidos pela UPA de Ariquemes enquanto estavam em trânsito ou de férias.

O mapa de calor referente à quantidade de atendimentos por bairro na Unidade de Pronto Atendimento (UPA) de Ariquemes oferece uma visualização detalhada sobre a distribuição geográfica da demanda por serviços de saúde.

1. Distribuição dos Atendimentos:

- **Bairros com Alta Demanda:** As áreas com maior concentração de atendimentos estão destacadas em vermelho e laranja no mapa. Bairros como o Setor 09, Setor 06, e áreas próximas à Avenida Canaã e Avenida Jarú mostram uma alta densidade de atendimentos.

- **Áreas de Menor Demanda:** Áreas com menor demanda, destacadas em verde e azul, incluem partes da Zona Rural e alguns bairros periféricos, indicando uma menor incidência de atendimentos médicos.


2. Análise dos Dados:

- **Fatores Contribuintes:** A alta demanda em certos bairros pode ser atribuída a fatores como densidade populacional, acessibilidade aos serviços de saúde e a ocorrência de surtos sazonais de doenças, como mencionado anteriormente no surto de síndromes gripais em abril de 2024 (Ariquemes Agora, 2024) (<https://www.ariquemesagora.com.br/>).

3. Implicações para a Gestão da Unidade:

- **Planejamento Geográfico de Recursos:** A gestão da UPA deve considerar a redistribuição de recursos para atender à alta demanda em bairros mais afetados. Ratificar e fortalecer os atendimentos prévios nas respectivas unidades básicas de saúde (UBs). Isso pode incluir a alocação de mais profissionais de saúde e equipamentos para essas áreas.
- **Intervenções Comunitárias:** Desenvolver programas de intervenção comunitária e campanhas de prevenção específicas para bairros com alta demanda pode ajudar a reduzir o número de atendimentos emergenciais.

Figura 11 – Mapa de Calor de atendimentos pelo estado



Fonte: Os autores (2024)

Figura 12 – Mapa de Calor de atendimentos nível Brasil e América do Sul



Fonte: Os autores (2024)

Além disso é possível verificar também todas as demais localidades do estado de Rondônia e do Brasil e até mesmo da América do Sul, onde a UPA de Ariquemes foi responsável pelo atendimento.

4. Conclusão e Trabalhos Futuros

A análise dos dados coletados na Unidade de Pronto Atendimento (UPA) de Ariquemes revelou pontos de atenção importantes. Primeiramente, observou-se que os alguns bairros, como Setor 09 e Setor 06, apresentam uma alta densidade de atendimentos, refletindo a maior concentração populacional e a proximidade com a UPA. O surto de síndromes gripais em abril de 2024 destacou-se como um fator significativo que aumentou a demanda em várias áreas, sobrecarregando os serviços de saúde locais.

Os dados também mostraram que a UPA atende não apenas os residentes de Ariquemes, mas também pacientes de outras cidades e estados, especialmente durante períodos de férias e trânsito, aumentando ainda mais a necessidade de um planejamento eficiente. A análise temporal revelou picos de demanda em meses específicos, como dezembro e abril, que coincidem com eventos sazonais e culturais.

4.1 Recomendações

1. Planejamento de Recursos:

- **Redistribuição:** Alocar mais recursos para meses e horários onde o fluxo é maior na unidade.
- **Expansão de Infraestrutura:** Aumentar a equipe de profissionais de saúde durante períodos de alta demanda, como observado em dezembro e abril.

2. Monitoramento Contínuo:

- **Sistemas de Monitoramento Geográfico:** Implementar mecanismos de acompanhamento para ajustar a alocação de recursos de acordo com a variação geográfica da demanda.
- **Previsão de Picos Sazonais:** Utilizar dados históricos para prever aumentos sazonais e preparar a UPA para lidar com essas flutuações, garantindo que a demanda seja atendida de maneira eficiente.

3. Intervenções Comunitárias:

- **Campanhas de Prevenção:** Desenvolver campanhas de prevenção ou políticas públicas focadas em bairros com alta demanda, educando a população sobre a prevenção de doenças sazonais e promovendo hábitos saudáveis.
- **Parcerias com Comunidades Locais:** Estabelecer parcerias com lideranças comunitárias e organizações locais para melhorar a disseminação de informações e aumentar a eficácia das intervenções de saúde pública.

4.2 Próximos Passos

1. Áreas de Estudo Futuro:

- **Análise Longitudinal:** Realizar estudos cruzando as informações dos atendimentos com os setores, possibilitando ter mais exatidão de onde e de qual situação está sendo trabalhada, por exemplo, quais os setores com mais casos de dengue.
- **Avaliação de Intervenções:** Avaliar a eficácia das campanhas de prevenção e das parcerias comunitárias implementadas futuramente, ajustando as estratégias conforme necessário.

2. Desenvolvimento Contínuo do Sistema de Saúde:

- **Formação e Capacitação:** Investir na formação contínua dos profissionais de saúde, garantindo que estejam preparados para lidar com as mudanças nas necessidades de atendimento.

REFERÊNCIAS

ARIQUEMES – Wikipédia, a enciclopédia livre. **A história de Ariquemes.** Disponível em: <<https://pt.wikipedia.org/wiki/Ariquemes>>. Acesso em: 08 mar. 2024.

BRASIL. Lei nº 13.709, de 14 de agosto de 2018. **Lei Geral de Proteção de Dados (LGPD).** Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/l13709.htm>. Acesso em: 09 abr. 2024.

PORTAL AMAZÔNIA. **Ariquemes, a cidade que deu origem a outros 7 municípios em Rondônia.** Disponível em: <<https://portalamazonia.com/noticias>>. Acesso em: 14 jun. 2024.

NOAR PORTAL. **Conheça a trajetória do povo Arikeme e sua contribuição para a formação de Ariquemes**. Disponível em: <<https://noarportal.com.br>>. Acesso em: 16 jul. 2024.

PREFEITURAS.INFO. **História da cidade de Ariquemes - RO**. Disponível em: <<https://prefeituras.info/ro/ariquemes/historia-da-cidade>>. Acesso em: 16 jul. 2024.

Secretária de Saúde responde à alta demanda durante surto de síndromes gripais em Ariquemes. **Ariquemes Agora**. Disponível em: <<https://www.ariquemesagora.com.br>>. Acesso em: 16 jul. 2024.