



Aprimorando a Qualidade Diagnóstica:

Explorando a detecção de artefatos metálicos em imagens de Tomografia Computadorizada Craniana através de Inteligência Artificial.

Objetivo

- O objetivo do presente projeto é **desenvolver e implementar** um modelo baseado em Inteligência Artificial (IA) que classifica imagens médicas de Tomografia Computadorizada (TC) com e sem Artefatos Metálicos;

Relevância

- Ao automatizar esse processo de identificação utilizando *Deep Learning* (DL), não apenas aprimoramos a interpretação de imagens de TC, mas também garantimos maior confiabilidade de outros sistemas de suporte ao diagnóstico, resultando em diagnósticos mais confiáveis e tratamentos mais eficazes.

Dados

- Os dados da instituição X contam com cerca de 16.875 séries, divididas em 8.556 séries que possuem a presença de artefatos metálicos e 8.319 que não possuem;
- Para validação foram utilizados dados disponíveis publicamente, como os dados da plataforma **Kaggle** e o conjunto de dados públicos **CQ-500**



Etapas do Projeto



Coletar e adquirir os dados para o projeto;



Realizar uma análise exploratória e um estudo dos dados presentes.



Estudo da literatura sobre arquiteturas utilizadas em imagens de TC;



Implementar os modelos em Python;



Adaptar os modelos para diferentes entradas e dados;



Validar e ajustar os modelos conforme os resultados;



Tecnologias



PyTorch



MONAI⁺
Generative Models

Principais Desafios

1

Como criar um conjunto de dados balanceado entre suas características.

2

Desenvolver um modelo eficaz rápido, leve e capaz de atender em diferentes sistemas.

3

Encontrar dados com artefatos metálicos em bases públicas para validação.

Kaggle: O kaggle é uma plataforma para ciência de dados. Dentro dela, é possível acessar conjuntos de dados públicos dos mais diversos tipos.

CQ-500: O CQ-500 é um conjunto público de dados de Tomografia Computadorizada. Os dados são disponibilizados para projetos de pesquisa e Machine Learning.

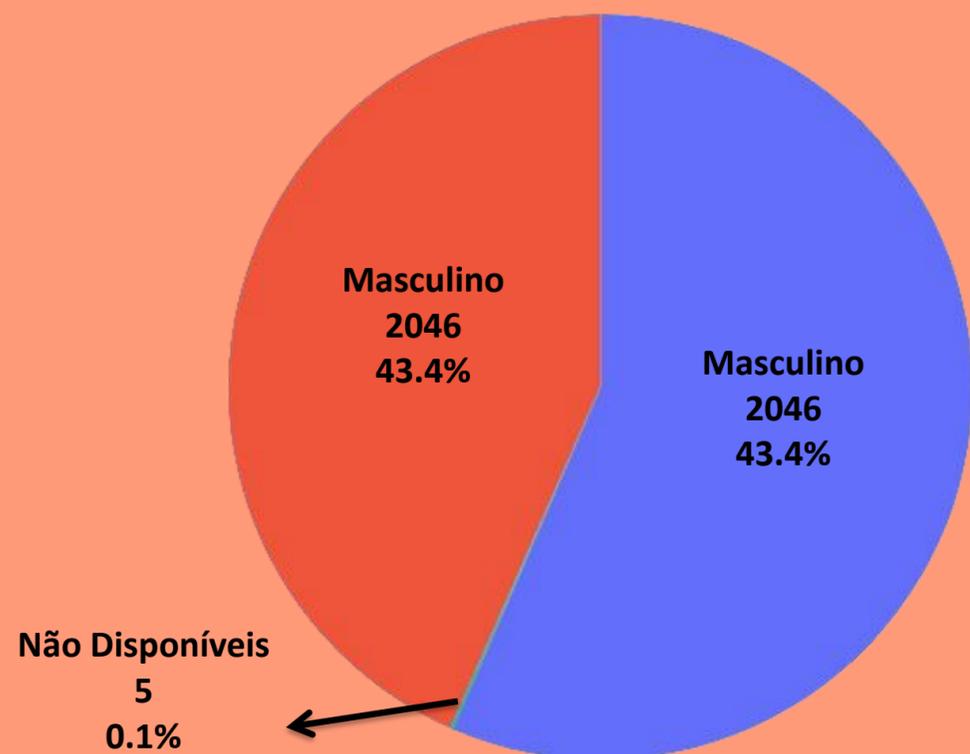
Análise Exploratória dos Dados

Após o levantamento dos dados disponíveis, foi realizado uma análise exploratória para melhor compreensão e criação de um conjunto de dados balanceado para as classes com e sem artefatos metálicos.

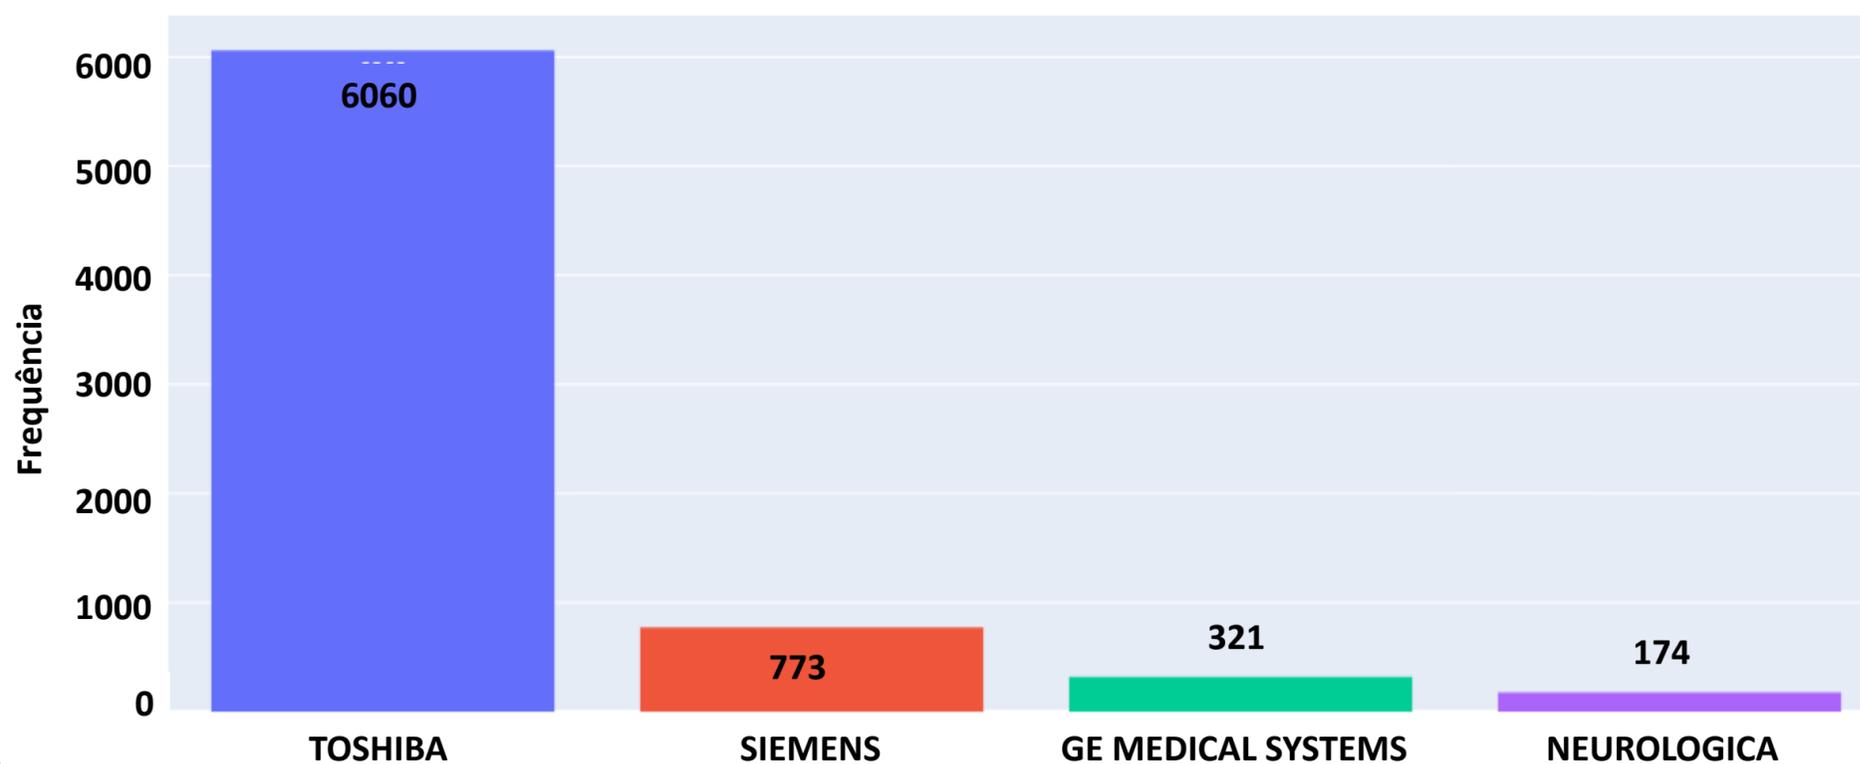
- Exames de indivíduos de ampla faixa etária, variando de 18 a 85 anos, com uma média de 48 anos e um desvio padrão anos de aproximadamente 18 anos de idade;
- O número de exames entre indivíduos masculinos e femininos é bem distribuído.
- A TOSHIBA foi a marca mais frequentemente utilizada nas aquisições dos exames.



Proporção de sexo entre os exames selecionados:



Máquinas utilizadas para aquisição dos exames



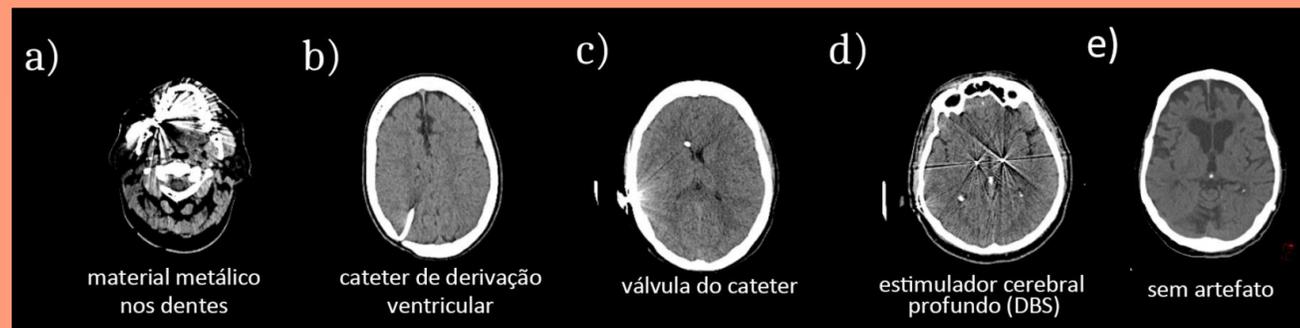
Resultados

Esse projeto demonstra a efetividade da IA na detecção de artefatos metálicos em TCs de cabeça. **Três arquiteturas de IA** foram testadas em um conjunto de dados selecionados, com resultados promissores. A tabela abaixo demonstra os resultados do modelo:

Modelo	Precisão	Recall	F1 Score	Size
EfficientNet	0.89	0.90	0.93	23mb
ResNET	0.84	0.87	0.89	170mb
3D CNN	0.87	0.80	0.90	54mb



Dentre os modelos testados, destacamos o modelo baseado na **EfficientNet** como o mais promissor, exibindo um bom equilíbrio entre as métricas de desempenho, tamanho e complexidade computacional.



Figuras A – D) Exemplos de casos nos quais há a presença de artefatos metálicos. **E)** Exemplo de caso no qual não há artefato metálico.

Explicação

Precisão: Avalia o quão preciso o modelo é ao realizar previsões positivas. Ou seja, a proporção de previsões corretas em relação ao total de previsões.

Exemplo: Se o modelo diz que um paciente tem uma determinada doença, qual é a probabilidade de o paciente realmente ter a doença?

Recall: Avalia a capacidade do modelo de encontrar corretamente todos os casos positivos.

Exemplo: Se há pacientes com artefatos, o modelo consegue encontra-los?

F1 Score: Uma média (score) equilibrada entre precisão e recall.

Exemplo: Queremos um equilíbrio entre identificar corretamente os casos positivos e evitar falsos positivos.

Próximos Passos

1

Aprimorar os modelos e testar com novos conjuntos de dados, ajustando parâmetros e arquiteturas.

2

Implementar um modelo capaz de destacar a localização dos artefatos encontrados, como os modelos do tipo **Attention**.

3

Comparar a precisão dos modelos do tipo **Attention** com os implementados anteriormente, validando sua eficácia.





Discussão dos Resultados

Os resultados obtidos demonstram a capacidade da IA em detectar com alta precisão a presença de artefatos metálicos em TCs de cabeça. As diferentes arquiteturas testadas apresentaram resultados promissores, evidenciando a robustez da metodologia proposta.

Ao considerar as diferentes arquiteturas, é possível discernir nuances de desempenho e eficácia, permitindo uma avaliação mais aprofundada das abordagens utilizadas. A generalização desses resultados para diferentes conjuntos de dados e cenários clínicos é um ponto relevante, indicando a aplicabilidade prática da abordagem.

A automação de processos, como a detecção de artefatos, resulta na automatização do envio de imagens com a qualidade necessária para os demais modelos envolvidos no suporte ao diagnóstico. Isso configura uma cadeia de eventos positivos que aprimoram significativamente o fluxo de trabalho de diagnósticos.

Em última análise, os resultados deste estudo não apenas ressaltam a eficácia da IA na detecção de artefatos metálicos em TCs de cabeça, mas também abrem portas para aplicações práticas que podem transformar positivamente o cenário clínico, proporcionando diagnósticos mais precisos e eficientes.

Conclusão

Os resultados preliminares do projeto demonstram o grande potencial da IA para aprimorar a precisão dos diagnósticos por imagem.

A detecção automática de artefatos metálicos é apenas um exemplo das diversas aplicações que essa tecnologia pode ter na área médica.

As próximas etapas de pesquisa e validação são essenciais para garantir a implementação eficaz da IA na prática clínica, abrindo caminho para um futuro mais preciso e eficiente na medicina, radiologia e áreas correlatas.

