

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
CURSO DE GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Renan de Siqueira Cecchin

**INTEGRAÇÃO DE MODELOS DE INTELIGÊNCIA ARTIFICIAL PARA
ANÁLISE DE IMAGENS MÉDICAS USANDO STREAMLIT**

Santa Maria, RS
2023

Renan de Siqueira Cecchin

**INTEGRAÇÃO DE MODELOS DE INTELIGÊNCIA ARTIFICIAL PARA ANÁLISE DE
IMAGENS MÉDICAS USANDO STREAMLIT**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Ciência da Computação da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Bacharel em Ciência da Computação**.

Orientador: Prof. Daniel Welfer

Santa Maria, RS
2023

Renan de Siqueira Cecchin

**INTEGRAÇÃO DE MODELOS DE INTELIGÊNCIA ARTIFICIAL PARA ANÁLISE DE
IMAGENS MÉDICAS USANDO STREAMLIT**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Ciência da Computação da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Bacharel em Ciência da Computação**.

Aprovado em 18 de dezembro de 2023:

**Daniel Welfer, Dr. (UFSM)
(Presidente/Orientador)**

Joaquim Vinicius Carvalho Assunção, Dr. (UFSM)

Luis Alvaro de Lima Silva, Dr. (UFSM)

Santa Maria, RS
2023

DEDICATÓRIA

Ao meu pai e minha mãe, pelo apoio contínuo ao longo dos anos

AGRADECIMENTOS

Gostaria de agradecer a todos que estiveram ao meu lado no decorrer da minha jornada acadêmica e me auxiliaram de alguma forma. Dito isso, quero agradecer a...

Meu orientador, por me auxiliar neste trabalho;

Ao curso, por me proporcionar a expansão de conhecimentos;

À banca, pela leitura e avaliação deste trabalho;

À minha avó Maria, que partiu durante o desenvolvimento deste trabalho, muito obrigado por todas as memórias de amor e carinho, pela infância feliz que tive ao brincar em sua casa às tardes que estava em Santa Maria;

À minha tia Mauren, por, junto com a minha avó, tornar a minha infância a melhor que qualquer criança poderia sonhar e continuar o carinho e suporte enquanto eu crescia;

Minha mãe e meu pai, por tudo que fizeram pela a pessoa que me tornei e pelas repetidas palavras e ações de apoio que realizaram por mim;

À minha família, por compartilhar vários momentos e sempre estar presente em minha vida oferecendo apoio;

À Lua, pelos carinhos, momentos e palavras oferecidas na vida;

Ao Gleison e Christian, por me ajudarem a divulgar este trabalho para as pessoas da saúde;

À minha turma de 2020, por todos os momentos engraçados, tristes e felizes que passei na graduação, serem grandes amigos e as melhores pessoas que conheci, portanto, muito obrigado a: Álisson Braga, Alisson Schmidt, Ana Paula, Andriza, Augusto, Bento, Gabriel, Guilherme, Gustavo, Henrique, Juliano, Natã, Thiago;

Ao melhor gato do mundo, Presidente Bartolomeu Miau, grande gato pirata, que hoje coordena o inferno dos gatos;

À melhor cachorra do mundo, Flor, que me acompanha a 16 anos dormindo e roncando.

RESUMO

INTEGRAÇÃO DE MODELOS DE INTELIGÊNCIA ARTIFICIAL PARA ANÁLISE DE IMAGENS MÉDICAS USANDO STREAMLIT

AUTOR: Renan de Siqueira Cecchin

Orientador: Daniel Welfer

O avanço das tecnologias de inteligência artificial (IA) culminou no rápido desenvolvimento de modelos aplicados para resolver problemas da vida real. Uma das áreas mais beneficiadas por esse avanço foi a área da saúde (RAJPURKAR et al., 2022), devido aos diversos desafios enfrentados em ambientes médicos. Para os pacientes, é essencial obter um diagnóstico preciso e rápido. Porém, almejar os dois atributos simultaneamente é um grande desafio na área da saúde, especialmente em momentos de superlotação de hospitais. Regularmente, apenas uma das medidas é priorizada, podendo expor os pacientes a riscos. Uma solução que é bastante discutida na literatura é a integração de sistemas de IA com procedimentos médicos, a fim de agilizar, auxiliar e fornecer uma maior precisão aos hospitais. Dito isso, esse trabalho busca facilitar o equilíbrio das duas métricas ao criar um sistema destinado a auxiliar profissionais de saúde na sua tarefa de reconhecimento de lesões e doenças em imagens médicas. Esse sistema é composto por diversos modelos de visão computacional pré-treinados, capazes de analisar e alertar os profissionais sobre doenças ou lesões no paciente, disponíveis em uma aplicação no Streamlit, que facilita o acesso e o uso do programa por usuários. O sistema foi testado por pessoas da área da saúde e avaliado a partir de um questionário para medir sua efetividade. O formulário de avaliação não obteve muitas respostas, mas o retorno foi positivo.

Palavras-chave: Imagens médicas. Processamento de imagem. Detecção de lesões e doenças. Inteligência artificial. (...)

ABSTRACT

INTEGRATION OF ARTIFICIAL INTELLIGENCE MODELS FOR MEDICAL IMAGE ANALYSIS USING STREAMLIT

AUTHOR: Renan de Siqueira Cecchin

ADVISOR: Daniel Welfer

The advance of artificial intelligence (AI) technologies has culminated in the rapid development of applied models to solve real-life problems. One of the areas that has greatly benefited from this progress is healthcare (RAJPURKAR et al., 2022), due to the many challenges faced in medical environments. For patients, it is essential to obtain an accurate and rapid diagnosis. However, targeting both attributes simultaneously is a major challenge in healthcare, especially in times of hospital overcrowding. Regularly, only one of the measures is prioritized, which can expose patients to risks. One solution that is widely discussed in the literature is the integration of AI systems with medical procedures, in order to speed up, assist and provide greater precision to hospitals. That said, this work aims to ease the balance between the two metrics by creating a system designed to help healthcare professionals in their task of recognizing lesions and diseases in medical images. This system is made up of several pre-trained computer vision models, capable of analyzing and alerting professionals to diseases or injuries in the patient, available in a Streamlit application, which makes it easy for users to access and use the software. The system was tested by healthcare professionals and evaluated using a survey to measure its effectiveness. The feedback form didn't get many responses, but the results were positive.

Keywords: Medical images. Image processing. Lesion and disease detection. Artificial Intelligence. (...)

LISTA DE FIGURAS

Figura 1 – Caixas limitadoras para reconhecer esteatose	17
Figura 2 – Exemplo da segmentação de imagens	18
Figura 3 – CAM aplicado na região do tórax	20
Figura 4 – Fluxograma das atividades desenvolvidas	27
Figura 5 – Página resumindo decoradores do Streamlit	30
Figura 6 – Página de introdução da aplicação	32
Figura 7 – Página geral dos modelos na aplicação	33
Figura 8 – Página de introdução da aplicação	34

LISTA DE TABELAS

TABELA 1 – Tabela de trabalhos relacionados.....	22
--------------------------------------------------	----

LISTA DE QUADROS

Quadro 1 – Quadro com informações sobre os modelos selecionados.	28
-----------------------------------------------------------------------	----

LISTA DE SIGLAS

CNN	<i>Convolutional Neural Networks</i>
IA	Inteligência Artificial
ML	<i>Machine Learning</i>
RSNA	<i>Radiological Society of North America</i>
NIH	<i>National Institute of Health</i>
CAM	<i>Class Activation Map</i>
PLN	Processamento de Linguagem Natural
API	<i>Application Programming Interface</i>

SUMÁRIO

1	INTRODUÇÃO	12
2	REFERENCIAL TEÓRICO	13
2.1	INTELIGÊNCIA ARTIFICIAL	13
2.2	<i>MACHINE LEARNING</i>	13
2.3	REDES NEURAIS	14
2.4	APLICAÇÃO DE CNN NA ÁREA MÉDICA	15
2.5	TÉCNICAS DE PROCESSAMENTO DE IMAGENS	16
2.5.1	<i>Bounding Box</i>	16
2.5.2	Segmentação de imagem	17
2.5.3	CAM	18
2.6	STREAMLIT	19
3	TRABALHOS RELACIONADOS	21
4	METODOLOGIA	27
4.1	MODELOS	27
4.2	ARQUITETURA DA PLATAFORMA	30
4.3	FUNCIONAMENTO DA PLATAFORMA	31
4.4	EXPERIMENTO	33
5	RESULTADOS E DISCUSSÕES	35
6	CONCLUSÃO	36
	REFERÊNCIAS BIBLIOGRÁFICAS	37
	APÊNDICE A – QUESTIONÁRIO DE AVALIAÇÃO	39

1 INTRODUÇÃO

O rápido avanço da Inteligência Artificial (IA) ao longo dos anos corroborou em diversas aplicações capazes de resolver problemas de várias complexidades. Uma das áreas que mais se beneficiou é a área da saúde, recebendo várias contribuições de IA para auxílio de pacientes e profissionais de saúde, principalmente em análises médicas (RAJPURKAR et al., 2022). A divulgação de grandes modelos, como o IBM Watson, que auxilia hospitais dos Estados Unidos em análises médicas (GANTENBEIN, 2014), aumentou gradualmente a popularidade da IA e incentivou muitas pesquisas e testes para solucionar problemas. Por conta disso, existe um grande número de modelos pré-treinados disponíveis em plataformas como Kaggle, GitHub, Roboflow, entre outras.

Este trabalho busca aproveitar esses modelos descentralizados, disponíveis em diversas plataformas, e compor um aplicativo que integra diversos modelos que detectem lesões, doenças e outros problemas em imagens médicas, a fim de proporcionar um fácil acesso aos profissionais de saúde a esse tipo de tecnologia. O objetivo desse aplicativo é agir em colaboração a médicos, ao interpretar imagens médicas, para oferecer diagnósticos mais precisos e ágeis para os pacientes, resultando em tratamentos mais eficientes e melhores resultados clínicos. Ao utilizar esses modelos, podemos aproveitar o tempo gasto em programação e treinamento de novas redes e economizar recursos computacionais, ao mesmo passo que é possível aplicar os modelos pré-treinados para situações da vida real.

O aplicativo desenvolvido consiste em uma página *web* criada pelo *Streamlit*, que permite ao usuário escolher o modelo que pretende usar e inserir a imagem para predição da IA. Quanto à seleção e a integração de modelos no aplicativo, foi realizada uma análise, levando em consideração alguns atributos, a fim de medir a precisão da IA. Todos os modelos incorporados no aplicativo utilizam redes neurais convolucionais (CNN), devido à sua notável capacidade de identificar e compreender padrões complexos em imagens médicas, o que é fundamental para o sucesso da detecção de problemas de saúde.

2 REFERENCIAL TEÓRICO

Neste capítulo, estão apresentados os principais conceitos para a estruturação e compreensão do trabalho. Nele, são apresentados os aportes teóricos necessários para embasar e contextualizar o aplicativo. No decorrer do capítulo, são definidos conceitos essenciais do conhecimento apresentado neste trabalho, como IA, ML, redes neurais e técnicas de processamento de imagem.

2.1 INTELIGÊNCIA ARTIFICIAL

A IA é uma campo da ciência da computação que foca suas pesquisas na tarefa de criar máquinas que possam realizar operações cognitivas semelhantes aos humanos, como: aprendizado, raciocínio, resolução de problemas e reconhecimento de padrões. Dada a diversidade de dados que uma máquina pode processar, foram criadas diferentes técnicas e subáreas, cada uma adaptada para lidar com tipos específicos de dados.

Além da construção de inteligência geral, outro objetivo dos pesquisadores de IA é o conceito de *intelligence augmentation*, que se traduz para ampliação da inteligência. O objetivo da ampliação da inteligência é servir como apoio para o enriquecimento da inteligência e criatividade humana. Esse foco mostra a IA como uma ferramenta que visa ampliar a colaboração entre humanos e sistemas inteligentes (POOLE; MACKWORTH, 2017).

2.2 MACHINE LEARNING

ML é o campo da IA que estuda a ciência de criar sistemas que podem aprender a partir de dados e cumprir tarefas complexas, sem que sejam explicitamente programados para isso (GÉRON, 2022). Os algoritmos de ML podem se ajustar às tarefas e melhorar o seu desempenho com experiência obtida dos dados. Existem diversos tipos de modelos de ML, cada um contando com diferentes aplicações e domínios.

Por conta da vasta possibilidade de uso de ML, podemos dividi-lo em diferentes tipos, com essa separação sendo diretamente relacionada ao tipo de aprendizado do algoritmo. Sendo assim, os principais tipos são: aprendizado supervisionado, não supervisionado, por reforço, semi-supervisionado, fraco e ativo (GÉRON, 2022). Para este trabalho, é relevante compreender apenas sobre o aprendizado supervisionado e o fraco.

No aprendizado supervisionado, os algoritmos aprendem a partir de dados rotulados, ou seja, dados que possuem a resposta da predição. O objetivo desse tipo de apren-

dizado é encontrar uma função que mapeia os dados da entrada para a saída, enquanto minimiza o erro de predição. Esse tipo de aprendizado requer uma grande quantidade de dados rotulados, o que pode dificultar a implementação de um algoritmo de ML de aprendizado supervisionado. Além disso, a necessidade por grandes contingentes de dados traz à tona dois possíveis problemas: *overfitting*, quando o algoritmo se ajusta demais aos dados de treinamento e perde a capacidade de generalizar as características dos dados, e *underfitting*, quando o algoritmo não captura a complexidade dos dados. Para evitar esses problemas, a escolha ou a construção de um modelo adequado à complexidade dos dados é essencial, junto às normalizações, métricas e validações aplicadas nos conjuntos.

O aprendizado fraco pode ser visto como um tipo de aprendizado supervisionado, porém, os dados são rotulados de forma incompleta ou ruidosa para produzir modelos com precisão moderada. Quando os dados são escassos ou difíceis de obter, o aprendizado fraco pode se mostrar útil. Além disso, ele possui outra vantagem quando combinado com outras técnicas, como o *boosting*, que combina vários modelos fracos para formar um modelo forte e de precisão. Isso é feito ao treinar os modelos de forma sequencial, em que cada modelo tem como objetivo corrigir os erros cometidos pelos modelos anteriores.

2.3 REDES NEURAIS

As redes neurais são um tipo de algoritmo de ML de aprendizado supervisionado inspiradas no funcionamento do cérebro humano. Por conta disso, sua composição consiste em camadas de processamento interconectadas, chamadas de neurônios, que computam informações de forma paralela. Para cada conexão entre os neurônios, existe um peso associado, que permite as adaptações às mudanças geradas pelos padrões contidos nos dados de entrada. As execuções das redes neurais são compostas por 3 fases principais: treinamento, validação e *deploy*. As fases de treinamento e validação ocorrem em conjunto, nelas, as redes aprendem os padrões dos dados e ajustam seus pesos e validam o conhecimento obtido. A fase de *deploy* consiste no modelo treinado com os pesos ajustados pronto para ser usado em aplicações.

Uma das principais características do aprendizado das redes neurais é a generalização. Ao tentar compreender padrões nos dados de treinamento e confirmar nos dados de validação, as redes conseguem generalizar uma compreensão mais abrangente dos padrões, permitindo a aplicação do conhecimento para dados não vistos durante o treinamento e validação. Por conta dessa generalização e do paralelismo implementado entre as camadas, o que torna o aprendizado extremamente rápido, as redes neurais são utilizadas em uma variedade de campos (KUBAT, 1999).

Existem diversos tipos de arquiteturas de redes neurais, dentre elas, uma das que mais se destaca na área de processamento de imagens é as *Convolutional Neural*

Networks (CNN). As CNN são projetadas para receber dados de entrada com estrutura espacial, como imagens, e se destacam ao extrair características relevantes. Esse destaque acontece devido às camadas convolucionais, que aplicam filtros auxiliares para detectar padrões específicos como bordas, texturas e formas, e às camadas de *pooling*, que reduzem as dimensões dos recursos extraídos. Com esse conjunto de técnicas, as CNN têm como especialidade detectar as características mais discriminativas das imagens, tornando-as ideais para tarefas de classificação e reconhecimento de objetos em imagens. Assim, as CNN desempenham um papel fundamental no campo da visão computacional e contribuem ativamente para o avanço da IA em diversas áreas.

2.4 APLICAÇÃO DE CNN NA ÁREA MÉDICA

Pesquisas envolvendo reconhecimento de padrões das CNN avançaram significativamente ao longo dos anos, principalmente por conta de modelos famosos, como ImageNet (DENG et al., 2009) e YOLO (REDMON; FARHADI, 2018), e da maior acessibilidade à tecnologia com *frameworks* como Tensorflow e Torch. Essas pesquisas buscam resolver problemas em diversas áreas diferentes usando a generalização de imagens. Uma área que recebeu bastante atenção devido à quantidade de dados e problemas não resolvidos disponíveis foi a área da saúde. Inspirados na missão de colaborar com médicos para oferecer diagnósticos mais precisos e rápidos, diversos projetos de previsão, classificação e localização de lesões, doenças e outros sintomas foram criados com o tempo.

O desenvolvimento de aplicações de CNN para a área médica enfrenta diversos desafios. Dentre eles, está a dificuldade de obter grandes conjuntos de dados rotulados, por conta da sensibilidade que dados médicos possuem. Além disso, para treinar uma CNN, é necessário um uso extensivo de recursos computacionais. Por fim, mesmo com um modelo perfeitamente treinado e capaz de identificar categorias com uma precisão boa, é fundamental reconhecer que profissionais de saúde podem não consentir plenamente com o uso da ferramenta na prática clínica.

O consentimento de profissionais de saúde e pacientes é extremamente importante na implementação de IA na área da saúde. Isso ocorre devido a vários motivos, como: a necessidade de interpretabilidade nos resultados dos modelos, as preocupações éticas quanto à autonomia e a privacidade do paciente e a confiança nos métodos tradicionais. É necessária uma abordagem coletiva para que os médicos observem o desenvolvimento de perto e auxiliem na criação de uma solução mais ética e alinhada com as práticas clínicas já estabelecidas.

Certos projetos notáveis na aplicação de CNN para a área médica como o CheXNet (PRANAV et al., 2017) e o U-Net (ZUNAIR; Ben Hamza, 2021) obtiveram um reconhecimento significativo. O CheXNet, por exemplo, obteve sucesso ao identificar e localizar 14

diferentes doenças na região torácica, enquanto o U-Net demonstrou eficácia ao segmentar imagens biomédicas. Esses trabalhos destacam-se como referência de CNN aplicada à saúde, sendo reconhecidos pela amplitude das aplicações. Além disso, esses projetos capturam interesse de outros pesquisadores pela possibilidade de realizar a técnica de *Transfer Learning* nesses modelos. Com essa técnica, os pesquisadores podem aproveitar a especialização em determinadas categorias contidas em alguns modelos para criar os seus próprios, permitindo a expansão dessas categorias e ampliando o escopo de uso desses modelos.

2.5 TÉCNICAS DE PROCESSAMENTO DE IMAGENS

Usar imagens em IA revolucionou muitos aspectos da área da saúde. A capacidade de generalização de informações visuais é bastante útil para diversas aplicações na área. Quando se trata de implementar modelos de IA para interpretação de imagens, existem três problemas centrais: classificação de imagens, detecção de objetos e segmentação de imagens. A classificação de imagens envolve reconhecer o conteúdo geral da imagem e atribuir uma categoria a ela. Na detecção de objetos, a tarefa é identificar e delimitar a localização do objeto na imagem. Na segmentação, a IA divide a imagem em regiões, ou segmentos, com base em características específicas. Esses três desafios são fundamentais para medir a capacidade de IA de aprender e processar dados visuais em imagens.

Com o intuito de facilitar a leitura dos resultados por humanos, algumas técnicas de processamento de imagens são aplicadas nas saídas da CNN. Dessa forma, o padrão identificado fica mais visível e permite ao usuário compreender o raciocínio por trás das decisões da rede neural. Essas técnicas são essenciais na comunicação entre humano e máquina e na compreensão das CNN como uma ferramenta capaz de oferecer inteligência ampliada (POOLE; MACKWORTH, 2017) para os usuários. Neste trabalho, foram abordadas três técnicas de reconhecimento de imagens, sendo elas: *bounding box*, segmentação de imagens e *Class Activation Maps* (CAM).


2.5.1 *Bounding Box*

As *bounding boxes*, ou caixas limitadoras, são bastante usadas em detecções de objetos, em que o objetivo é classificar e localizar objetos na imagem. As caixas são compostas por quatro coordenadas na imagem, retornadas pela rede neural como caixa limitadora mínima para o objeto. Com essas coordenadas, é possível definir uma posição e uma aproximação do tamanho do objeto classificado.

Na área médica, existem diversos usos de caixas limitadoras em CNN, dada a sua

possibilidade de analisar a gravidade de uma condição médica ao localizar e medir a área e o tamanho de estruturas anômalas ou objetos de interesse, como tumores, nódulos, fraturas ósseas, vasos sanguíneos e órgãos. Um exemplo do uso de caixas limitadoras está indicado na Figura 1, na qual é utilizada uma caixa com um texto, indicando a confiança da rede neural em classificar a doença de fígado, esteatose.

Figura 1 – Caixas limitadoras para reconhecer esteatose



Fonte: Retirado da base de dados de Dada (2022).


2.5.2 Segmentação de imagem

A segmentação da imagem foca em dividir uma imagem em regiões ou segmentos de interesse onde o objetivo é detectado. Essa técnica se especializa em isolar objetos individuais na imagem retornando apenas a região do objeto de estudo. Essa técnica é amplamente usada na extração de dados específicos da imagem, retornando objetos individuais e áreas de destaque. Existem vários tipos de segmentação diferentes, cada um com características e aplicabilidades próprias. No contexto da pesquisa sobre segmentação de imagem, é importante adaptar e pesquisar técnicas para que se moldem melhor ao problema aplicado.

Na área da medicina, a segmentação de imagens tem um papel fundamental em exames baseados em imagens, como tomografia computadorizada, ressonâncias magnéticas, entre outros. Uma arquitetura de rede neural bastante famosa capaz de realizar uma

segmentação *pixel a pixel*, que atribui uma classe a cada *pixel* da imagem, é o U-Net (RONNEBERGER; FISCHER; BROX, 2015). Essa arquitetura é bastante conhecida na literatura de segmentação de imagens para imagens biomédicas, possuindo experimentos de segmentação de estruturas neuronais em imagens de microscopia eletrônica e segmentação de células em imagens de microscopia de contraste de fase e *Differential Interference Contrast*. Na Figura 2, é possível ver uma segmentação de células glioblastoma-astrocitoma U373 cultivados em um substrato de poliacrilamida. Na esquerda, está a imagem original, e, na direita, a máscara cor ciano destacando a célula.

Figura 2 – Exemplo da segmentação de imagens



Fonte: Retirado de Ronneberger, Fischer e Brox (2015).

2.5.3 CAM

A técnica de CAM, inicialmente proposta por Zhou et al. (2016), propõe uma nova maneira de se aproveitar da generalização da CNN para extrair as regiões da imagem para uma categoria em particular. Essa técnica usa de *global average pooling* (GAP), que consiste em reduzir as dimensões da última camada de convolução em uma CNN para apenas uma unidade por canal. Como resultado, o GAP retorna uma representação unidimensional das ativações da última cada de convolução. Para gerar o CAM a partir do GAP, é necessário projetar os pesos de uma camada *Softmax* no mapa de características gerado pelo GAP, aplicar uma função de ativação e redimensionar os resultados para o tamanho da imagem original. Dessa forma, a imagem resultante será um mapa de calor mais relevante da categoria retornada.

O CheXNet (PRANAV et al., 2017) é um modelo popular na área da saúde, que aplica CAM para auxiliar médicos radiologistas a identificar, localizar e realizar diagnósticos precoces em condições médicas na região do tórax. Esse modelo é capaz de reconhecer 14 doenças diferentes e retornar um mapa de calor com as regiões classificadas pela última camada de convolução. Um exemplo de como funciona sua detecção está na Figura 3. Na parte superior, temos a entrada da rede, uma imagem de raio-X da região frontal do

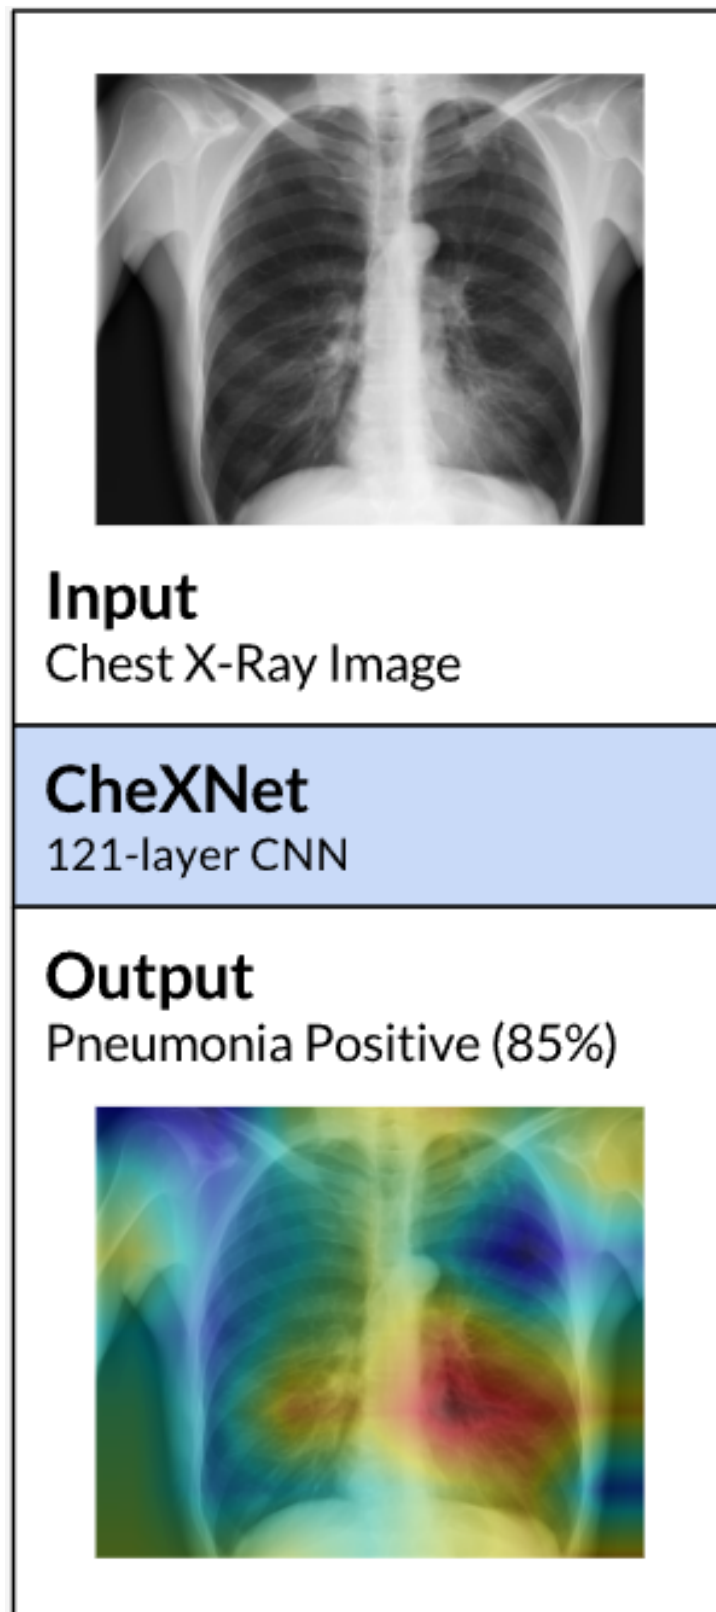
tórax do paciente, e como resultado a rede retorna positivo para pneumonia com 85% de confiança, e um mapa de calor da região onde essa classificação foi encontrada.

2.6 STREAMLIT

Streamlit é uma biblioteca de código aberto de Python, que facilita a criação de aplicativos *web*. A biblioteca permite aos programadores transformar rapidamente um programa em uma página *web* funcional, sem a necessidade de uma experiência extensiva em desenvolvimento *web*. Com isso, os desenvolvedores conseguem criar uma interface para usuários simplificada de uma maneira eficiente e dinâmica.

Por conta dessa facilidade de implementação disponibilizada pelo Streamlit, essa é uma biblioteca bastante popular em projetos de ML para fazer *deploy* e compartilhar seu modelo. Além disso, os desenvolvedores usam a plataforma Streamlit *Community Cloud* para disponibilizar seus projetos com outras pessoas. Dessa forma, o Streamlit está em uma crescente popularidade na comunidade de ML para aplicações e *deploys* de seus modelos.

Figura 3 – CAM aplicado na região do tórax



Fonte: Retirado do trabalho de Pranav et al. (2017).

3 TRABALHOS RELACIONADOS

O diagnóstico por imagem é um procedimento padrão em hospitais e envolve diferentes tipos de exames. Esses diagnósticos são feitos por parte do médico mediante uma análise visual. Embora os resultados geralmente sejam precisos, em situações que demandam agilidade e precisão, como as de superlotação de hospitais, a relação entre rapidez e precisão do diagnóstico por imagem é comprometida. Ocasionalmente, a vida de um paciente pode ser posta em risco, devido a um diagnóstico incorreto ou devido a um tempo de espera muito grande. Diante desse cenário, ferramentas de processamento de imagens podem auxiliar a manter o equilíbrio de um diagnóstico preciso e rápido usando técnicas de classificação, detecção e/ou segmentação de imagens.

Dito isso, existem diversos trabalhos na literatura que almejam auxiliar os médicos na tarefa de diagnóstico usando processamento de imagens e PLN. Portanto, o objetivo desta revisão de literatura é discutir os principais trabalhos nessa área de aplicação que são capazes de identificar patologias por imagens e que envolvem integrar e generalizar diversos modelos.

A IBM contribuiu para o avanço do ML no diagnóstico por imagem, por meio do seu sistema Watson (GANTENBEIN, 2014). No entanto, esse tipo de tecnologia não é acessível a todos, por conta da necessidade de infraestrutura, recursos e precisão do modelo, além dos desafios éticos e legais que precisam ser enfrentados para obter dados de pacientes. Dito isso, existem diversas pesquisas focadas em preencher essas lacunas e aplicar modelos de CNN na prática clínica como um auxílio a médicos.

A detecção de patologias em imagens de raio-x, principalmente as do tórax, é uma das aplicações mais promissoras de ML no diagnóstico por imagem. Alguns modelos baseados nessa técnica se destacaram e inspiraram outros trabalhos na área que complementam a pesquisa. Um desses modelos é o CheXNet (PRANAV et al., 2017), que usa o trabalho de Wang et al. (2017), que criou um *dataset* com 14 patologias reconhecidas.

Os *datasets* de radiografias de tórax são gerados de maneira mais eficiente por meio de anotadores automáticos que aplicam PLN aos relatórios radiológicos para detectar as patologias indicadas e ignorar qualquer erro. Essas pesquisas motivaram a criação de outros *datasets*, como os trabalhos de Shih et al. (2019), Bustos et al. (2020), Irvin et al. (2019) e Johnson et al. (2019) que ampliam o domínio das radiografias de tórax ao disponibilizar mais imagens e rótulos para os conjuntos de dados públicos.

Na questão de integração de diversas pesquisas, um trabalho muito importante é o do Cohen et al. (2020), que testou a compatibilidade vários modelos quando usados para prever imagens de outros *datasets*. Além disso, o autor comparou vários modelos pré-treinados em diferentes conjuntos de dados e analisou a sua acurácia em imagens com rotuladas de forma diferente. Toda essa pesquisa extensa em diversas bases de dados

famosas e modelos pré-treinados culmina na criação da biblioteca TorchXRayVision, que fornece uma padronização para modelos nessa tarefa, permitindo aos usuários expandir seus trabalhos ao avaliar os modelos nos mesmos *datasets* de outros modelos famosos. Essa ideia de fornecer ao usuário uma avaliação melhor e mais acessível, a fim de auxiliar no trabalho dos pesquisadores, é aplicada neste trabalho, ao facilitar o uso de modelos famosos na literatura por parte dos médicos.

Tabela 1 – Tabela de trabalhos relacionados.

Início da Tabela 1			
Referência	Objetivo	Método	Diferencial
Pranav et al. (2017)	Facilitar a detecção de pneumonia e outras doenças a partir de imagens de raio-x frontais da região torácica	Treinar o modelo CheXNet, baseado na arquitetura DenseNet (HUANG et al., 2017), usando o <i>dataset</i> ChestX-ray14 (WANG et al., 2017)	O modelo usa CAM para gerar mapas de calor que auxiliam na localização da doença
Shih et al. (2019)	Fornecer um <i>dataset</i> anotado para auxiliar no desenvolvimento de ferramentas de ML para detecção de pneumonia	Expandir as classificações de pneumonia e opacidade pulmonar do trabalho de Wang et al. (2017) usando <i>bounding boxes</i> e nivelando a doença como baixa, média e alta probabilidade	Base de dados focada em pneumonia e opacidade pulmonar com comprovação de radiologistas experientes de diferentes instituições
Wang et al. (2017)	Apresentar um <i>dataset</i> com as doenças mais comuns da região torácica e propor um modelo de classificação e localização usando aprendizado fraco	Extrair os relatórios radiológicos de radiografias frontais de tórax e empregar técnicas de PLN para identificar e extrair oito rótulos de doenças torácicas e associá-los às suas respectivas imagens	Um conjunto de dados amplo e diversificado usado para treinar um modelo de aprendizado fraco capaz de identificar e localizar as oito patologias

Continuação da Tabela 1			
Referência	Objetivo	Método	Diferencial
Bustos et al. (2020)	Apresentar um novo conjunto de dados de radiografias frontais de tórax com imagens de alta resolução e relatórios anotados com múltiplos rótulos, organizados como uma taxonomia hierárquica e mapeados para o sistema unificado de linguagem médica.	Identificar e extrair rótulos dos relatórios radiológicos usando um algoritmo de PLN	A quantidade de rótulos necessária para os dados de validação de base é feita manualmente por médicos treinados
Irvin et al. (2019)	Avançar na automação da interpretação de radiografias do tórax com o intuito de beneficiar a prática de radiologistas	Criar um rotulador que usa PLN para detectar e classificar incertezas nos relatórios de radiografias usando palavras-chave, expressões regulares e regras de contexto, além de fornecer um <i>dataset</i> anotado com radiografias de tórax amplo, com padrões de referência forte e provêm métricas de performance humana para comparação	Diferentes abordagens para classificar as incertezas, como positivo, negativo e ignorar, e comparar os efeitos na performance do modelo

Continuação da Tabela 1			
Referência	Objetivo	Método	Diferencial
Peng et al. (2018)	Apresentar um novo algoritmo para detectar achados negativos e incertos em relatórios chamado NegBio	Usar um analisador sintático para obter as dependências universais dos relatórios, em sequência, um conjunto de padrões baseados nas dependências que indicam gatilhos de negação ou incerteza e outro para identificar o escopo dessa negação. Após esses passos, é possível marcar as palavras ou frases que foram negadas ou incertas	A inovação está em usar padrões de dependências universais, em vez de usar regras baseadas em palavras-chave. Esses padrões são mais precisos porque levam a estrutura sintática do texto, consequentemente, esse algoritmo é capaz de lidar com casos lógicos complexos.
Johnson et al. (2019)	Adaptar o conjunto de dados público chamado MIMIC-CXR com imagens em formato DICOM para um novo conjunto constituído de imagens em formato JPG	Converter o formato das imagens usando uma ferramenta de conversão de imagem médica e usar algoritmos de PLN para identificar e extrair 14 rótulos dos relatórios radiológicos usando palavras-chave, expressões regulares e regras de contexto	O artigo propõe um novo <i>dataset</i> em um formato de imagem mais conveniente e padronizado, também são fornecidos as referências padrões de divisão de dados e os rótulos de imagem

Continuação da Tabela 1			
Referência	Objetivo	Método	Diferencial
Ye et al. (2020)	Apresentar um novo método para localizar e identificar lesões em radiografias de tórax usando apenas rótulos de imagem	Usar uma operação de agrupamento global chamada <i>Probabilistic CAM pooling</i> , que explora a capacidade de localização do CAM usando probabilidades. Dessa forma, o algoritmo é capaz de gerar mapas de probabilidade para cada rótulo auxiliando na interpretabilidade do modelo.	A localização do CAM de forma probabilística é uma nova operação de agrupamento global proposta pelos autores. Esse método é bastante preciso e consistente, além de localizar as lesões de uma maneira fracamente supervisionada.
Cohen et al. (2021)	Apresentar uma biblioteca de <i>software</i> de código aberto para trabalhar com modelos de ML e conjuntos de dados de radiografias de tórax públicos.	A biblioteca foi implementada em Python utilizando o <i>framework</i> de ML PyTorch. Vários modelos pré-treinados e outras ferramentas úteis foram disponibilizados na biblioteca. Além disso, são disponibilizados <i>datasets</i> de radiografias públicos	Facilita o desenvolvimento e a avaliação de modelos de ML para radiografias de tórax, permitindo o fácil uso dos modelos pré-treinados para analisar grandes conjuntos de dados, ou para reutilizar características para aprendizado.

Continuação da Tabela 1			
Referência	Objetivo	Método	Diferencial
Cohen et al. (2020)	Apresentar um estudo em grande escala para quantificar o sucesso das tarefas de predição diagnóstica em radiografias de tórax quando usadas em diferentes conjuntos de dados.	Usar um modelo pré-treinado em um conjunto de dados de imagens naturais e treinar em quatro conjuntos de dados de radiografias de tórax: ChestX-ray8 (WANG et al., 2017), CheXpert (IRVIN et al., 2019), PadChest (BUSTOS et al., 2020) e MIMIC (JOHNSON et al., 2019). Após isso, o modelo é avaliado em cada conjunto e em permutações dos conjuntos de dados, usando métricas como AUC, a F1-score e a acurácia	Um estudo em larga escala para avaliar a generalização entre domínios para a mesma tarefa, detectar patologias em imagens de radiografias. Além disso, o estudo revela uma variação no desempenho e na concordância entre os modelos.
Final da Tabela 1			

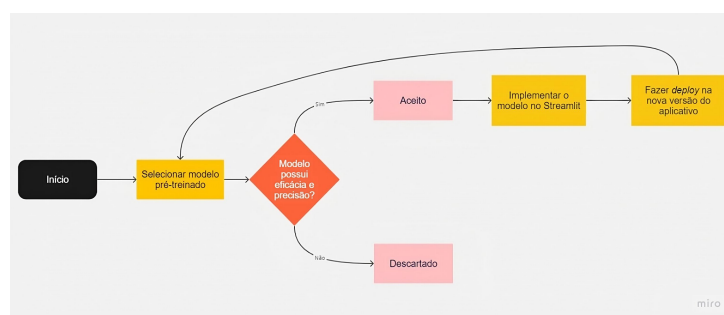
Fonte: Os autores.

4 METODOLOGIA

Este trabalho foi feito na linguagem de programação Python, usando como base do aplicativo a biblioteca Streamlit, que facilita a criação de uma página *web* para *deploy* dos modelos. Inicialmente, foi necessário escolher os modelos pré-treinados de plataformas, que permitem ao usuário compartilhar seu trabalho como *GitHub*, *Kaggle*, *RoboFlow*, entre outros. Esse processo foi ilustrado em um fluxograma na Figura 4. Todos os modelos são direcionados para o processamento de imagens médicas. Realizamos uma análise da quantidade de categorias que cada modelo abrangeu, levando em consideração a disponibilidade de imagens para cada uma dessas categorias, a fim de descartar modelos muito genéricos que falham em detectar os problemas.

A plataforma também permite ao usuário subir seus próprios modelos para fins de comparação de eficiência e precisão. Desse modo, pessoas sem conhecimento de programação podem avaliar e testar um modelo pré-treinado disponível online, e programadores podem avaliar seus próprios modelos em relação aos outros disponíveis de forma prática e fácil.

Figura 4 – Fluxograma das atividades desenvolvidas



Fonte: Os autores.

4.1 MODELOS

No Quadro 1, estão descritos todos os modelos com algumas informações básicas dos mesmos que proporcionam uma visão geral de cada um. Esta seção tem como objetivo fornecer uma análise mais aprofundada de cada modelo, apresentando uma breve descrição para contextualizar suas características e relevância para a pesquisa. Ao contextualizar os modelos é possível aprofundar-se nas peculiaridades de cada modelo, para compreender o papel de cada um na plataforma.

O modelo CheXNet escolhido para a plataforma é uma reimplementação do trabalho de mesmo nome de Pranav et al. (2017), criada com os mesmos dados do original

Quadro 1 – Quadro com informações sobre os modelos selecionados.

Referência	Modelo	Número de categorias	URL de acesso
Pranav et al. (2017)	CheXNet	14	github.com/arnoweng/CheXNet
Ghanem (2022)	<i>Brain Tumor Detection</i>	3	universe.roboflow.com/roboflow-100/brain-tumor-m2ppb
Dada (2022)	<i>Liver Disease Detection</i>	4	universe.roboflow.com/roboflow-100/liver-disease
Cohen et al. (2021) e Cohen et al. (2020)	DenseNet 224 geral	18	github.com/mlmed/torchxrayvision
Shih et al. (2019)	DenseNet 224 RSNA	2	github.com/mlmed/torchxrayvision
Wang et al. (2017)	NIH ChestX-ray14	18	github.com/mlmed/torchxrayvision
Bustos et al. (2020)	PadChest	18	github.com/mlmed/torchxrayvision
Irvin et al. (2019)	CheXpert	7	github.com/mlmed/torchxrayvision
Johnson et al. (2019) e Peng et al. (2018)	MIMIC NB	11	github.com/mlmed/torchxrayvision
Johnson et al. (2019) e Irvin et al. (2019)	MIMIC CH	11	github.com/mlmed/torchxrayvision
Cohen et al. (2021) e Cohen et al. (2020)	ResNet 512 geral	18	github.com/mlmed/torchxrayvision
Ye et al. (2020)	JF <i>Healthcare</i> DenseNet	5	github.com/mlmed/torchxrayvision
Cohen et al. (2021) e Cohen et al. (2020)	Anatomical Segmentation	18	github.com/mlmed/torchxrayvision

Fonte: Os autores.

(WANG et al., 2017). Esse modelo recebe como entrada uma imagem de raio-x frontal da região torácica e retorna um mapa de calor e a previsão com as probabilidades, como mostrado na Figura 3. O treinamento foi realizado no conjunto de dados ChestX-ray14 (WANG et al., 2017), que é composto por 112.120 imagens de raio-X frontal de 30.805 pacientes únicos. Essas imagens foram individualmente rotuladas com até 14 patologias torácicas diferentes.

O modelo *Brain Tumor Detection* é um trabalho de Ghanem (2022), criado com o *dataset* do RoboFlow 100, uma iniciativa de Intel para criar um novo *benchmark* para a generalização de modelos, e usa como base um modelo da YOLOv5. Esse modelo recebe uma imagem de ressonância magnética axial, detecta e localiza com caixas delimitadoras os tumores encontrados. O treinamento conta com 9900 imagens de ressonância magnética axial coloridas.

O modelo Liver Disease Detection é um trabalho de Dada (2022), também criado com o *dataset* do RoboFlow 100, e usa como base um modelo da YOLOv5. Esse modelo recebe como entrada imagens de microscopia do fígado e retorna caixas delimitadoras encontradas para 4 patologias diferentes. Ele foi treinado com 3976 imagens de microscopia do fígado.

O modelo DenseNet 224 geral foi disponibilizado pela biblioteca TorchXRyVision de Cohen et al. (2021) e Cohen et al. (2020) e foi treinado com todos os *datasets* disponíveis na mesma. Por conta disso, esse modelo possui valores bons para uso geral na sua área de atuação, consolidando-se como um dos modelos mais fidedignos da coleção. Esse modelo recebe imagens frontais de raio-x da região torácica e retorna a probabilidade associada à presença de cada uma das 18 doenças reconhecidas pelo modelo.

O modelo DenseNet RSNA foi treinado com um *dataset* de opacidade pulmonar e pneumonia Shih et al. (2019). Esse modelo apresenta as maiores taxas de precisão nas duas categorias que ele identifica, justamente por ser treinado em uma base de dados especializada para o caso. Ele recebe como entrada uma foto de raio-x frontal da região torácica e retorna as probabilidades da presença de cada uma das doenças.

O modelo NIH ChestX-ray14 foi treinado usando os trabalhos de Wang et al. (2017)

e Pranav et al. (2017), que utilizam imagens com rótulos fracos, podendo apresentar múltiplas etiquetas de doenças. Este modelo, ao receber uma imagem de raio-x da vista frontal do tórax, fornece a probabilidade associada a cada uma das 14 doenças que é capaz de identificar.

O modelo PadChest foi treinado usando o trabalho de Bustos et al. (2020). O *dataset* utilizado para treinar este modelo, conhecido como PadChest, contém imagens de alta resolução interpretadas e relatadas por radiologistas do *Hospital San Juan*, Espanha, de 2009 a 2017. Além disso, o dataset inclui anotações detalhadas para complementar as imagens da base de dados. Esse modelo recebe uma imagem de raio-x frontal da região torácica e retorna a probabilidade de cada uma das 14 doenças reconhecidas.

O modelo CheXpert foi treinado usando o trabalho de Irvin et al. (2019). Essa base de dados, retirada do *Stanford Hospital*, se destaca ao apresentar rótulos de incerteza nas imagens, uma característica importante na interpretação de imagens médicas. Esse modelo recebe uma imagem de raio-x frontal da região torácica e retorna a probabilidade de cada uma das 7 doenças reconhecidas.

O modelo MIMIC NB foi treinado usando o *dataset* de Johnson et al. (2019) e o rotulador NegBio (PENG et al., 2018). O rotulador NegBio é uma ferramenta de processamento de linguagem natural para detectar negação e incerteza em texto clínicos. Esse modelo recebe uma imagem de raio-x frontal da região torácica e retorna a probabilidade de cada uma das 11 doenças reconhecidas.

O modelo MIMIC CH foi treinado usando o *dataset* de Johnson et al. (2019) e o rotulador CheXpert (IRVIN et al., 2019). Diferente do outro rotulador citado anteriormente, o CheXNet é capaz de rotular relatórios para a presença de 14 doenças como positivo, negativo ou incerto. Esse modelo recebe uma imagem de raio-x frontal da região torácica e retorna a probabilidade de cada uma das 11 doenças reconhecidas.

O modelo ResNet 512 geral foi treinado usando todos *datasets* presentes no TorchXRyVision (COHEN et al., 2021; COHEN et al., 2020). Esse modelo recebe uma imagem de raio-x frontal da região torácica e retorna a probabilidade de cada uma das 17 doenças reconhecidas. O principal diferencial desse modelo é a resolução, esse é o único disponível na biblioteca especializado para lidar com imagens de tamanho 512x512 *pixels*.

O modelo JF Healthcare DenseNet foi treinado durante uma competição usando o *dataset* de Irvin et al. (2019). Esse modelo recebe uma imagem de raio-x frontal da região torácica e retorna a probabilidade de cada uma das 5 doenças reconhecidas.

O modelo ResNet 512 geral foi treinado usando todos *datasets* presentes no TorchXRyVision (COHEN et al., 2021; COHEN et al., 2020). Esse modelo recebe uma imagem de raio-x frontal da região torácica e retorna a probabilidade de cada uma das 17 doenças reconhecidas. O principal diferencial desse modelo é a resolução, esse é o único disponível na biblioteca especializado para lidar com imagens de tamanho 512x512 *pixels*.

O modelo Anatomical Segmentation foi treinado usando todos *datasets* presentes

no TorchXRayVision (COHEN et al., 2021; COHEN et al., 2020). Esse modelo recebe uma imagem de raio-x frontal da região torácica e retorna uma imagem para cada parte do corpo destacada.

4.2 ARQUITETURA DA PLATAFORMA

O processo de projeto e desenvolvimento da plataforma envolveu diversos desafios, que serão descritos nesta subseção. O objetivo é apresentar os aspectos técnicos da plataforma, explicando as metodologias e ferramentas utilizadas para construir o produto final.

Inicialmente, é necessário explicar como funciona o Streamlit e alguns aspectos que diferem ele de outras plataformas. O Streamlit pode ser executado usando um comando homônimo que recebe como argumento o nome do *script* em Python que contém o código da aplicação. Dito isso, quando executamos esse comando com o nosso arquivo principal, uma página na *web* local é aberta e atualizada em tempo real ao alterar o código. O Streamlit permite criar interfaces interativas, como botões, *sliders* ou *upload* de arquivos, que são diretamente associados à variáveis no código. Quando o usuário interage com essas interfaces, o Streamlit executa todo código novamente, alterando o valor da variável correspondente. A primeira vista, essa forma de execução parece ineficaz, principalmente quando o foco é carregar modelos pré-treinados, o que pode demorar e afetar constantemente o desempenho da ferramenta. Porém, o Streamlit resolve isso usando dois decoradores: o *st.cache_data*, para primitivas, *dataframes* e chamadas de API, e o *st.cache_resource*, para modelos de ML e conexões com bases de dados, como ilustrado na Figura 5. Esses decoradores armazenam o conteúdo na memória e, quando o código é reexecutado, eles são apenas carregados em vez de executados.

Figura 5 – Página resumindo decoradores do Streamlit



Fonte: Retirado da documentação do Streamlit

O Streamlit possui uma série de ferramentas e interfaces úteis para o usuário. Neste projeto, os comandos textuais da biblioteca, que envolvem escrever títulos, textos e avisos, foram usados com arquivos de *Markdown* e *strings* simples. O *Markdown* é uma linguagem

de marcação que facilita a formação de texto. Além disso, utilizamos interfaces de *upload* de arquivos, que permitem ao usuário enviar fotos para serem analisadas pelos modelos ou arquivos .h5 para carregar modelos pré-treinados externos.

Assim, o fluxo de execução parte de um arquivo CSV que contém o nome que aparece na barra lateral, a fonte e o nome do arquivo *Markdown* com a descrição do modelo escrita. Esse arquivo é carregado e anexado à interface seletora de modelos na barra lateral da página. Por padrão, o Streamlit seleciona automaticamente o primeiro item da lista, logo, a página de introdução. Ao alterar o modelo selecionado, a classe específica do modelo escolhido começa sua função de execução.

As classes dos modelos herdam de uma classe abstrata denominada *Streamlit-Page*, que define quatro métodos abstratos: *title*, *description*, *show_image* e *run*. Esses métodos são responsáveis por escrever o título, inserir a descrição, mostrar a interface das imagens e executar a página, respectivamente. O método *run* invoca os demais métodos e ajusta os argumentos conforme necessário. Nas classes dos modelos, pré-processamentos são realizados na imagem de acordo com especificidades de cada modelo e enviam a imagem para a predição. Cada modelo apresenta os resultados e a saída de forma distinta, dependendo do tipo de tarefa realizada, sendo elas: detecção, classificação ou segmentação.

A predição foi realizada utilizando os *frameworks* mais populares de ML como PyTorch, Tensorflow, SciPy e Scikit-Learn. Adicionalmente, empregamos o *framework* do TorchXRyVision (COHEN et al., 2021; COHEN et al., 2020), que oferece modelos pré-treinados para análise de imagens médicas. Para a integração de diferentes *frameworks*, recorreremos a bibliotecas como Pandas, NumPy, Pillow e OpenCV, que facilitam o processamento e a manipulação dos dados.

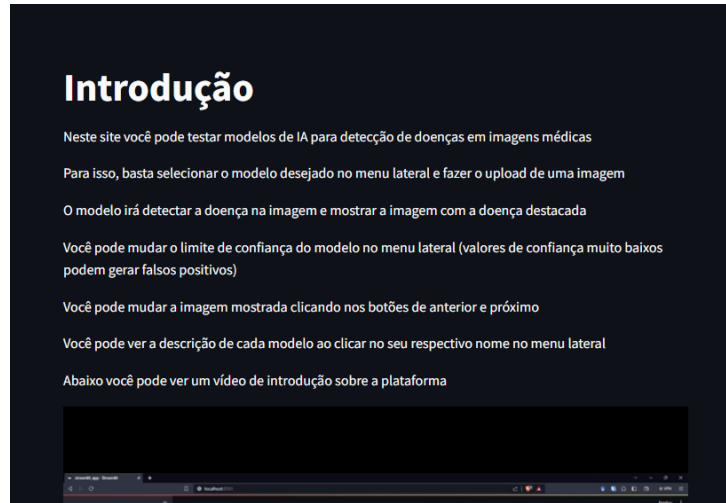
Por fim, este trabalho usa o serviço de *Community Cloud* disponibilizado pelo Streamlit, portanto, alguns pequenos ajustes precisam ser feitos para adaptar o código. O sistema de *cloud* funciona como um ambiente virtual de Python, que necessita de dois arquivos para executar o código: o *requirements.txt*, que especifica as bibliotecas Python necessárias, e o *packages.txt*, que indica os pacotes do sistema operacional necessários. Para integrar o serviço de *Community Cloud* com o GitHub, é preciso definir o argumento de execução do Streamlit, ou seja, o *script* principal da aplicação.

4.3 FUNCIONAMENTO DA PLATAFORMA

A ferramenta foi criada tendo em mente o usuário final, uma pessoa da medicina, o que norteou as decisões de desenvolvimento para uma interface agradável e intuitiva. Ao abrir a plataforma, é apresentada ao usuário uma página de introdução com algumas instruções de uso. Essa descrição é feita textualmente e complementada com um vídeo

mostrando o passo a passo do uso da ferramenta. No final da descrição, disponibilizamos um *link* que encaminha para um formulário de validação deste trabalho. Essa página está ilustrada na Figura 6.

Figura 6 – Página de introdução da aplicação



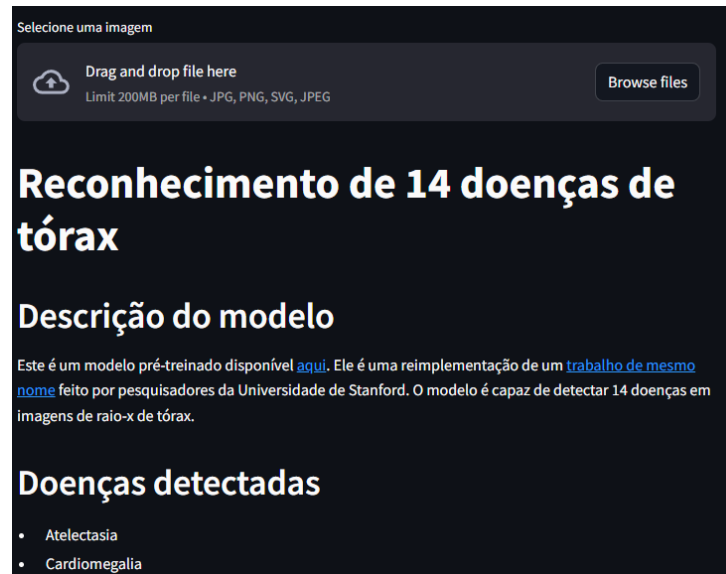
Fonte: Os autores.

À esquerda da página, há uma barra lateral com uma caixa de seleção e um *slider*, neles estão indicadas as funções de, respectivamente, seleção de modelo e ajuste de confiança. Nos modelos disponíveis, estão todos os modelos descritos no Quadro 1 com a adição de uma página de introdução, já mencionada anteriormente.

As páginas dos modelos possuem uma estrutura comum, no início da página se encontra a aplicação do modelo treinado. Além disso, o resto da página é composta por uma descrição, contendo uma breve história do modelo, as categorias que o mesmo detecta, definições da entrada e saída das imagens e exemplo de uma execução do modelo. Um exemplo de página geral do modelo está mostrado na Figura 7.

Em cada página específica do modelo, uma seção destinada à entrada de imagens foi desenvolvida. Ao submeter uma imagem, o resultado da predição é apresentado imediatamente abaixo. Este resultado consiste em duas colunas de imagens: a primeira exibindo a imagem original e a segunda contendo um seletor de imagens com todas as previsões geradas pelo modelo, acompanhadas da categoria predita e da probabilidade associada, variando de 0 a 100. A precisão dessa probabilidade é diretamente influenciada pelo limiar de confiança estabelecido pelo usuário. Caso a probabilidade seja inferior ao valor especificado, o resultado será descartado. Um exemplo dessa execução está demonstrado na Figura 8.

Figura 7 – Página geral dos modelos na aplicação



Fonte: Os autores.

4.4 EXPERIMENTO

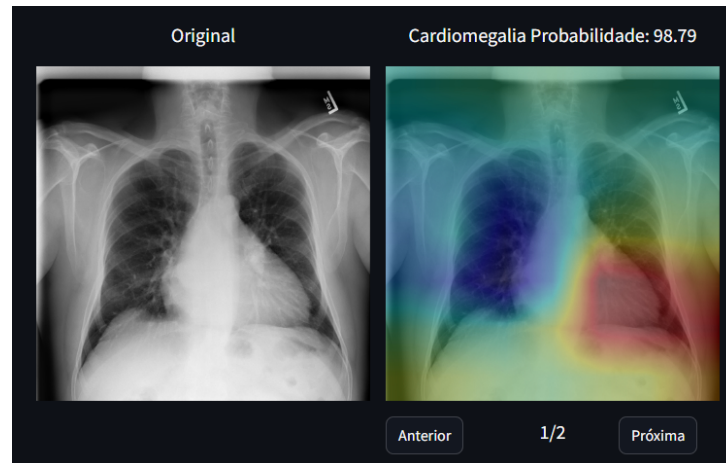
Para validar esse trabalho, ele foi disponibilizado para estudantes, residentes e profissionais de medicina por 2 semanas. No topo da plataforma, está um questionário (Apêndice A) destinado aos participantes para avaliar diversos fatores deste trabalho. No questionário, é solicitado para o usuário avaliar a ferramenta, interface, entre outros fatores importante para a experiência do usuário.

Buscamos contato com pessoas da medicina de várias formas: entramos em contato com um médico para divulgar o projeto pra residentes, colaboramos com um estudante para um acesso mais fácil aos estudantes de medicina de uma universidade e com outro estudante para divulgação em outras duas universidades. Além disso, também estivemos presente em uma aula da medicina para divulgar a ferramenta e solicitar testes aos estudantes.

Durante o período de testes, foi exibido um aviso na plataforma solicitando aos usuários para realizar a avaliação ao término do teste. Ademais, os usuários não precisavam testar todos os modelos disponíveis no sistema, mas apenas entender o objetivo da pesquisa e avaliar a plataforma como uma ferramenta para alcançá-lo. Com isso em mente, questionário foi bastante simplificado para incentivar os testadores a responder, ele era composto das seguintes seções:

- **Informações do usuário:** que possuía perguntas pessoais como nome, a posição na área da saúde (estudante, residente ou profissional) e quantos anos de experiência na área.
- **Avaliação geral da ferramenta:** que continha perguntas sobre as expectativas, ava-

Figura 8 – Página de introdução da aplicação



Fonte: Os autores.

liações da interface e da plataforma, além de fornecer um espaço para críticas, sugestões e comentários sobre a pesquisa no geral.

5 RESULTADOS E DISCUSSÕES

Apesar da divulgação da plataforma e de todas as mudanças para tornar o processo mais simples, o questionário não obteve muitas repostas. Ao todo, obtivemos 36 acessos à plataforma e apenas 2 respostas ao formulário. As respostas obtidas são de estudantes recentes de medicina e foram positivas, apenas algumas sugestões de melhoria na interface foram realizadas.

Entretanto, a plataforma ainda possui outros resultados desvinculados do questionário de avaliação. A flexibilidade arquitetura da plataforma construída permite a adição de novos modelos de diagnóstico por imagem no futuro, sem a necessidade de grandes alterações no código fonte. Isso torna a atualização e manutenção da plataforma mais eficiente e simples, bem como abre espaço para a integração de novas tecnologias e funcionalidades, tornando, assim, a plataforma um produto mais dinâmico e de fácil readaptação, podendo atender às demandas e expectativas dos usuários.

Além disso, a ferramenta possui um valor educacional para estudantes de medicina, que podem aprender a identificar e localizar patologias por meio de imagens médicas, comparando com as predições dos modelos. A ferramenta pode contribuir para a integração entre as tecnologias de IA e os médicos, reduzindo resistência e desconfiança em relação a esse tipo de ferramenta. Ainda, os usuários podem aprender mais sobre cada modelo disponível na plataforma, sendo capazes de compreender quais modelos são mais adequados em diferentes situações. Ademais, esse sistema pode despertar o interesse e a curiosidade dos estudantes pela área de IA aplicada à medicina, estimulando novas pesquisas, projetos e desafios no campo.

Por fim, permitimos ao usuário testar um modelo pré-treinado de sua escolha, por meio de um arquivo que contém a arquitetura e os pesos das camadas. Isso permite que o usuário utilize e avalie modelos treinados em outros contextos e compare os resultados com o desempenho dos modelos disponíveis na plataforma. Essa funcionalidade adiciona flexibilidade à plataforma, tornando-a uma ferramenta valiosa no desenvolvimento de modelos que classificam, segmentam ou delimitam imagens médicas.

6 CONCLUSÃO

Este trabalho criou uma plataforma capaz de construir uma ponte entre os médicos e os modelos de IA, a fim de facilitar o acesso a diagnósticos assistidos por inteligência artificial. Por meio dessa plataforma, os médicos podem experimentar modelos famosos na literatura, como o CheXNet (PRANAV et al., 2017), em dados de pacientes reais. Isso não apenas aprimora a eficiência do diagnóstico, mas também oferece aos médicos uma oportunidade de testarem o potencial e as limitações dos modelos de IA.

Além disso, a plataforma detém um valor educacional para os estudantes de medicina, tanto para diagnóstico de exames, quanto para compreender aplicações de IA na prática clínica. À medida que as pesquisas e os desenvolvimentos em IA se expandem, a probabilidade de que ela desempenhe um papel fundamental na medicina aumenta, tornando-se indispensável que os profissionais estejam habituados com o uso de tais tecnologias emergentes.

Por fim, o trabalho foi testado por alunos de medicina, e obtivemos um retorno positivo, mesmo que com poucas respostas. Ademais, a plataforma possui valores educacionais, ao servir como um guia para estudantes que estão iniciando na área de diagnóstico por imagem, e para pesquisa, ao permitir que qualquer um possa comparar modelos com trabalhos de referência da área sem necessitar do conhecimento de programação. Como trabalho futuro, existem alguns pontos que podem ser melhor desenvolvidos, dentre eles é importante citar:

- Uma testagem em maior escala.
- Mais modelos de outros tipos de diagnósticos na plataforma
- Uma ferramenta de comparação entre modelos, incluindo modelos que o usuário mesmo colocou na plataforma
- Adicionar suporte para outros tipos de arquivos de modelos pré-treinados externos

REFERÊNCIAS

BUSTOS, A. et al. Padchest: A large chest x-ray image dataset with multi-label annotated reports. **Medical Image Analysis**, Elsevier BV, v. 66, p. 101797, dez. 2020. ISSN 1361-8415. Disponível em: <<http://dx.doi.org/10.1016/j.media.2020.101797>>.

COHEN, J. P. et al. On the limits of cross-domain generalization in automated x-ray prediction. In: **Medical Imaging with Deep Learning**. [s.n.], 2020. Disponível em: <<https://arxiv.org/abs/2002.02497>>.

_____. Torchxrayvision: A library of chest x-ray datasets and models. In: **Medical Imaging with Deep Learning**. [s.n.], 2021. Disponível em: <<https://arxiv.org/abs/2111.00595>>.

DADA, A. Open Source Dataset, **Liver diseases Dataset**. Roboflow, 2022. <https://universe.roboflow.com/liver-t5yvf/liver-diseases>. Visited on 2023-10-15. Disponível em: <<https://universe.roboflow.com/liver-t5yvf/liver-diseases>>.

DENG, J. et al. ImageNet: A Large-Scale Hierarchical Image Database. In: **CVPR09**. [S.l.: s.n.], 2009.

GANTENBEIN, R. E. Watson, come here! the role of intelligent systems in health care. In: **2014 World Automation Congress (WAC)**. [S.l.: s.n.], 2014. p. 165–168.

GHANEM, Y. Open Source Dataset, **Brain Tumor Detection Dataset**. Roboflow, 2022. <https://universe.roboflow.com/yousef-ghanem-jzj4y/brain-tumor-detection-fpf1f>. Visited on 2023-10-15. Disponível em: <<https://universe.roboflow.com/yousef-ghanem-jzj4y/brain-tumor-detection-fpf1f>>.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 3. ed. O'Reilly Media, 2022. ISBN 9781098125974; 1098125975. Disponível em: <libgen.li/file.php?md5=d6756726683d9aacb09b8b71a2e76319>.

HUANG, G. et al. Densely connected convolutional networks. In: . [S.l.: s.n.], 2017.

IRVIN, J. et al. **CheXpert: A Large Chest Radiograph Dataset with Uncertainty Labels and Expert Comparison**. 2019.

JOHNSON, A. E. W. et al. **MIMIC-CXR-JPG, a large publicly available database of labeled chest radiographs**. 2019.

KUBAT, M. Neural networks: a comprehensive foundation by simon haykin, macmillan, 1994, isbn 0-02-352781-7. **The Knowledge Engineering Review**, Cambridge University Press, v. 13, n. 4, p. 409412, 1999.

PENG, Y. et al. NegBio: a high-performance tool for negation and uncertainty detection in radiology reports. **AMIA Jt Summits Transl Sci Proc**, United States, v. 2017, p. 188–196, maio 2018.

POOLE, D.; MACKWORTH, A. **Artificial Intelligence: Foundations of Computational Agents**. 2. ed. Cambridge, UK: Cambridge University Press, 2017. ISBN 978-0-521-51900-7. Disponível em: <<http://artint.info/2e/html/ArtInt2e.html>>.

PRANAV, R. et al. **CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning**. 2017.

RAJPURKAR, P. et al. Ai in health and medicine. **Nature Medicine**, v. 28, n. 1, p. 31–38, Jan 2022. ISSN 1546-170X. Disponível em: <<https://doi.org/10.1038/s41591-021-01614-0>>.

REDMON, J.; FARHADI, A. Yolov3: An incremental improvement. In: **2018 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2018.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: NAVAB, N. et al. (Ed.). **Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015**. Cham: Springer International Publishing, 2015. p. 234–241. ISBN 978-3-319-24574-4.

SHIH, G. et al. Augmenting the national institutes of health chest radiograph dataset with expert annotations of possible pneumonia. **Radiology: Artificial Intelligence**, v. 1, n. 1, p. e180041, 2019. PMID: 33937785. Disponível em: <<https://doi.org/10.1148/ryai.2019180041>>.

WANG, X. et al. Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. In: **2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. IEEE, 2017. Disponível em: <<http://dx.doi.org/10.1109/CVPR.2017.369>>.

YE, W. et al. **Weakly Supervised Lesion Localization With Probabilistic-CAM Pooling**. 2020.

ZHOU, B. et al. Learning deep features for discriminative localization. In: **2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. Los Alamitos, CA, USA: IEEE Computer Society, 2016. p. 2921–2929. ISSN 1063-6919. Disponível em: <<https://doi.ieeecomputersociety.org/10.1109/CVPR.2016.319>>.

ZUNAIR, H.; Ben Hamza, A. Sharp u-net: Depthwise convolutional network for biomedical image segmentation. **Computers in Biology and Medicine**, v. 136, p. 104699, 2021. ISSN 0010-4825. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0010482521004935>>.

APÊNDICE A – QUESTIONÁRIO DE AVALIAÇÃO

Feedback da ferramenta

renancecchin07@gmail.com [Switch account](#)

Not shared

* Indicates required question

Informações do Usuário

Nome

Your answer _____

Qual sua posição principal na área da saúde? *

Estudante

Residente

Médico Profissional

Other: _____

Quantos anos de experiência você possui na área? *

Your answer _____

Avaliação geral da ferramenta

Qual eram suas expectativas ao ouvir a ideia da ferramenta? *

Your answer _____

Com que frequência você utilizou a ferramenta? (diariamente, a cada dois dias, etc.)

Your answer _____

Houve alguma dificuldade técnica que você identificou ao utilizar a ferramenta? *
Em caso afirmativo, poderia fornecer mais detalhes sobre a situação?

Your answer _____

Como você avaliaria a interface da ferramenta? *

1 2 3 4 5 6 7 8 9 10

Muito ruim Muito bom

Como você avaliaria a ferramenta no geral? *

1 2 3 4 5 6 7 8 9 10

Muito ruim Muito bom

Este é o espaço para você expressar qualquer pensamento adicional que possa ter sobre a ferramenta. Se houver sugestões, preocupações ou elogios que você gostaria de compartilhar, ficariamos gratos por ouvi-los.

Your answer _____

Fonte: Os autores.

NUP: 23081.159672/2023-78

Prioridade: Normal

Homologação de ata de defesa de TCC e estágio de graduação

125.322 - Bancas examinadoras de TCC: indicação e atuação

COMPONENTE

Ordem	Descrição	Nome do arquivo
8	Trabalho de conclusão de curso (TCC) (125.32)	TCC_RENAN.pdf

Assinaturas

23/12/2023 14:17:57

RENAN DE SIQUEIRA CECCHIN (Aluno de Graduação - Aluno Regular)
07.09.05.02.0.0 - Ciência da Computação - Bacharelado - 13881

Código Verificador: 3697342

Código CRC: 87968fce

Consulte em: <https://portal.ufsm.br/documentos/publico/autenticacao/assinaturas.html>

