

Detecção de tumor cerebral a partir de análise de imagens médicas usando inteligência artificial

Discente: Lais da Silva Calandrine de Azevedo



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
INSTITUTO DE FÍSICA

Discente: Lais da Silva Calandrine de Azevedo

**Detecção de tumor cerebral a partir de análise
de imagens médicas usando inteligência artificial**

Orientador: Prof. Dr. Lucio Pereira Neves

Agradecimentos

Agradeço primeiramente a Deus por estar sempre presente, mesmo em momentos complicados onde me faltava fé.

Agradeço ao meu anjo da guarda, porque eu sempre dei muito trabalho.

Agradeço imensamente à minha mãe e meu pai, por estarem sempre ao meu lado e permitir com que eu tenha me tornado a pessoa que sou, por serem essas pessoas incríveis que me guiam e me protegem em todos os momentos, sem eles eu não teria nem seria absolutamente nada.

Agradeço à minha irmã, por me aturar em todos os momentos, e também por estar sempre comigo.

Agradeço à meus dois pets, Dennahy e Scotty, que me acompanharam durante toda essa trajetória.

Agradeço ao meu orientador e amigo, Prof. Dr. Lucio Pereira Neves por sempre acreditar em mim, sempre me motivar e me acompanhar nessa trajetória, por toda preocupação, apoio, paciência e carinho.

Agradeço à Profa. Dra. Ana Paula Perini, que também sempre acreditou em mim, com o mesmo carinho e preocupação durante todo esse caminho.

Agradeço também aos demais professores que marcaram minha trajetória como Gerson, Mariana, Boselli, George e Cássio que também seguraram minha mão e me ajudaram a construir a pessoa que sou hoje.

Agradeço ao meu mestre de luta e amigo, Sihing Bruno, por todos os ensinamentos e conselhos.

Agradeço também à todas as pessoas que duvidam da minha capacidade, por me proporcionarem motivação extra.

Agradeço a mim, por não ter desistido todas as vezes que falei que desistiria.

Este trabalho foi realizado com o apoio das agências de fomento Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) por meio das bolsas de Produtividade em Pesquisa 312124/2021 – 0 (Ana Paula Perini) e 314520/2020 – 1 (Lucio Pereira Neves), pelo Programa MAI DAI 403556/2020 – 1, pelo Projeto UNIVERSAL 407493/2021 – 2 e Projeto INCT 406303/2022 – 3; e FAPEMIG, por meio dos projetos *APQ* – 02934 – 15, *APQ* – 03049 – 15 e *APQ* – 04215 – 22.

Resumo

O uso de imagens médicas é comum em diversas áreas hospitalares. Este trabalho traz uma atenção especial para imagens de ressonância magnética em pacientes com cérebros saudáveis ou com tumores. Nesse contexto, é interessante fazer uma conexão entre a área médica e a área computacional a fim de suprir a necessidade do estudo de abordagens mais eficientes em relação à qualidade de imagens, tempo de execução, análise de resultados e benefício do paciente. Uma das áreas mais estudadas atualmente no mundo da computação é a Inteligência Artificial (IA). Aplicando à este caso ela será utilizada como uma ferramenta de detecção de tumores a partir das imagens já pré processadas e, caso retorne um resultado positivo, ser capaz de localizar cada região classificada como tumor cerebral. Para isso, foi criada uma rede neural convolucional por meio da linguagem de programação *Python* com o auxílio de algumas bibliotecas, como *Pytorch*, e uma técnica chamada *data augmentation*. Tal rede foi ensinada a partir do conjunto de imagens médicas reunidas em um *dataset* disponível no site Figshare ([CHENG, 2017](#)). Com isso, foram obtidos resultados satisfatórios com assertividade de 98%, onde o modelo gerado pela rede foi capaz de encontrar imagens com tumores e apontar a localização destes.

Palavras-chave: Imagens Médicas, Tumor Cerebral, Inteligência Artificial, Rede Neural, *Python*.

Abstract

The use of medical imaging is evident in several hospital areas. This work brings special attention to magnetic resonance imaging in patients with healthy brains or with tumors. Therefore, it is interesting to make a connection between the medical and the computational areas in order to meet the need to study more efficient approaches in relation to image quality, execution time, analysis of results and patient benefit. One of the most studied areas currently in the world of computing is Artificial Intelligence (AI). Applying in this work it will be used as a tool for detecting tumors from pre-processed images and if it returns a positive result, be able to locate each region classified as a brain tumor. For this, a convolutional neural network was created using the *Python* programming language with the help of some libraries, such as *Pytorch*, and a technique called *data augmentation*. Such a network was taught from the set of medical images gathered in a *dataset* available on the Figshare website ([CHENG, 2017](#)). With this, satisfactory results were obtained with accuracy of 98%, where the model generated by the network was able to find images with tumors and point out their location.

Keywords: Medical Imaging, Brain Tumor, Artificial Intelligence, Neural Network, Python.

Sumário

1	INTRODUÇÃO	11
1.1	Imagens Médicas	11
1.2	Inteligência Artificial	17
1.3	Aplicação da IA na Física Médica	23
2	OBJETIVOS	25
2.1	Objetivo Geral	25
2.2	Objetivos Específicos	25
3	METODOLOGIA	27
3.1	Materiais	27
3.2	Procedimento Prático	28
3.2.1	Dataset	28
3.2.2	Construção da Rede Neural	28
4	RESULTADOS E DISCUSSÕES	29
4.1	Dataset	29
4.2	Análise do treinamento	30
4.3	Teste do modelo final	31
4.4	Curiosidade	32
5	CONCLUSÃO	33
	BIBLIOGRAFIA	35
	APÊNDICES	39
	APÊNDICE A – APÊNDICE	41
A.1	Imagens usadas para treinamento da rede neural	41

A.2 **Resultados do teste do modelo final 42**

Introdução

A aplicação da inteligência artificial no diagnóstico médico por imagens tem aumentado de maneira significativa nos últimos anos ([TANG, 2020](#)), isso devido à eficiência e precisão ao encontrar padrões e anormalidades em imagens, fornecendo também uma análise mais rápida e de maior escopo. O intuito não é remover completamente a mão de obra humana, mas sim utilizar a inteligência artificial como uma ferramenta, ajudando também em campos onde o trabalho realizado por humanos apresentaria falhas. Sendo assim, uma das aplicações dessa análise de imagens é na criação de pré diagnósticos a partir de uma rede treinada com uma determinada quantidade de dados coletados ([ROUGER, 2019](#); [OREN](#); [GERSH](#); [BHATT, 2020](#); [SPRINGER, 2022](#)).

1.1 Imagens Médicas

O diagnóstico por imagem, também chamado de Radiologia, faz uso de um conjunto de técnicas que permite criar representações visuais do corpo analisado, bem como tecidos e órgãos, de maneira não invasiva, extraindo o máximo de informações possíveis de acordo com cada necessidade. Tais técnicas podem ser usadas em exames, cirurgias, tratamentos, detecção precoce de doenças, contribuição para escolhas de tratamentos mais adequados, acompanhamento de evoluções de doenças, monitoramento de saúde entre outros ([POST-DICOM, 2023](#)), ([MEDICINEWISE, 2022](#)). A física médica contribui bastante utilizando a radiologia, desde o descobrimento dos raios-X em 1895 pelo físico alemão Wilhelm Conrad Roentgen (1845-1923) ([UFRGS, 2022](#)) até as mais sofisticadas ferramentas de visão computacionais já criadas.

Dentro deste campo de estudo existem vários tipos de imagens utilizadas, dentre elas as mais importantes ([MEDICINEWISE, 2022](#)), ([UFRGS, 2022](#)):

1. Radiografia: Mais utilizado em diagnósticos médicos para examinar ossos, tumores, pneumonia, e diagnosticar doenças em regiões do corpo. Seu funcionamento é básico; dentro do tubo de raio-X, os elétrons são emitidos pelo cátodo aquecido e, devido a uma DDP (diferença de potencial), eles são acelerados em direção ao ânodo e ao colidir com o alvo metálico os feixes de raios-X são emitidos (pela desaceleração dos elétrons, chamado de *Bremsstrahlung* - alemão que significa freagem - e pela radiação característica), sendo que tais feixes são restringidos por um colimador ([DIAGRAD, 2022](#)), ([PORTAL EDUCACAO, 2022](#)). Uma representação do tubo de raio-X e de uma imagem formada é mostra na Figura 1.




Figura 1 – Representação do tubo de raio-X ([SILVA; RIGUE; CARARA, 2016](#)).

Então, a imagem é formada a partir da sensibilização do filme radiográfico (posicionado atrás do paciente e localizado dentro de um chassi) pelos raios-X, ou seja, quanto mais raios atravessarem do corpo até o filme mais o filme será escurecido ([TECNOLOGIA RADIOLOGICA, 2022](#)). Um exemplo da formação dessa imagem, é a primeira radiografia apresentado na figura Figura 2.



Figura 2 – Primeira imagem feita com raio-X (NOGUEIRA, 2010).

2. Mamografia: A mamografia segue o exato mesmo procedimento do raio-X, porém enquanto no raio-x o material usado para o alvo metálico geralmente é o tungstênio, na mamografia o material usado é o ródio ou o molibdênio. Essa mudança deve-se ao fato de que na mamografia a energia dos raios que atingem a mama pode ser menor, já que o exame comprime a mama melhorando o contraste e diminuindo a espessura de onde os raios irão percorrer até chegar no filme (SILVA; RIGUE; CARARA, 2016). A mostra um exemplo de um exame.




Figura 3 – Imagem obtida em um exame de mamografia (MARCOS, 2013).

3. Tomografia Computadorizada (CT - *Computed Tomography*): Essa técnica utiliza também a produção de raios-X, porém o equipamento gira 360 ° em torno do paciente produzindo imagens tridimensionais, e então juntamente com ferramentas computacionais, geram uma imagem muito mais detalhada, como se a visualização da imagem se comparasse à cortes de cada área estudada ([CEDUSP, 2023](#)).

Além disso, também existe a Tomografia Computadorizada por emissão de Pósitrons (PET) que é a junção da Medicina Nuclear com a tomografia, podendo assim detectar atividades metabólicas juntamente com as das atividades celulares do órgão estudado e analisar detalhadamente a anatomia interna do órgão ([MV, 2022](#)). Um exemplo desse exame é apresentado na Figura 4.



Figura 4 – Imagem mostrando cortes obtidos em um exame de tomografia computadorizada ([TOMOCENTER, 2022](#)).

4. Ressonância Magnética (MRI - *Magnetic Resonance Imaging*): Já este tipo de técnica pode ser utilizada para diagnosticar tumores cerebrais, infecções no cérebro e medula espinhal, tendinite, rompimento de ligamentos entre outros ([LABORATÓRIO EXAME, 2022](#)).

Basicamente, o equipamento de ressonância magnética (como mostra a Figura 5) possui ímãs supercondutores, que consistem em muitas bobinas através das quais uma corrente elétrica é passada, criando um campo magnético, ou seja, para esse exame não é utilizado radiação ionizante como no caso dos outros exames explicados acima. Para serem mantidos é preciso da energia obtida pela supercondutividade ou ao reduzir significativamente a resistência dos fios, para isso os fios são banhados em hélio líquido isolado por um vácuo resfriando os fios e mantendo as propriedades supercondutoras dos ímãs.




Figura 5 – Representação do equipamento de ressonância magnética (COYNE, 2018).

É importante ressaltar que o magneto desse equipamento fica ligado de maneira permanente, por isso é extremamente importante manter objetos que possam ser atraídos na distância mínima permitida. Caso algum acidente muito grave venha a acontecer a solução utilizada é o *quenching*, procedimento onde o hélio líquido é liberado em forma de gás através de um tudo parecido com uma chaminé, cancelando então o campo magnético existente. É uma medida de extrema emergência, já que tal procedimento pode causar danos ao equipamento e às pessoas próximas a ele (NEXXTO, 2020), (RUIZ, 2022).

Esses ímãs produzem um determinado campo magnético e faz com que os prótons do corpo alinhem-se com este campo. Então o equipamento aplica um pulso de radiofrequência através do paciente, estimulando os prótons e fazendo com que eles vibrem em ressonância com a frequência do pulso, desalinhando-se do campo magnético. Tal frequência forçada sobre os prótons é chamada de frequência de *Larmour* (SCIENCE DIRECT, 2023). Cesado o pulso de radiofrequência, os prótons tendem a retornar à sua posição inicial, alinhados ao campo magnético. Nesse processo, os prótons liberam energia em forma de ondas de rádio, que é detectada por sensores e, posteriormente, utilizada na criação de imagens (LABORATORIO EXAME, 2022), (MEDICINE, 2019), (BRASIL, 2022). Por fim, a imagem é criada, como mostra a Figura 6.



Figura 6 – Algumas imagens de exames de ressonância magnética. (CUMBERS, 2022).

O equipamento de ressonância é cilíndrico e cria esse grande campo magnético em torno do paciente, e assim que os átomos retornam à sua posição original, esses sinais são recebidos por um computador e então convertidos na imagem final (MEDICINE, 2019) (COYNE, 2018).

Com base nesses breves conhecimentos sobre tais técnicas, pode-se então propor maneiras de relacionar a computação com tal área da saúde. Usando as ferramentas de programação é possível criar um pós processamento das imagens, melhorando sua qualidade de maneira a diminuir a exposição do paciente à radiação, ou mesmo evitar que uma imagem ruim precise ser refeita. Ademais, este trabalho explora outra ferramenta muito importante no avanço da computação: o uso da inteligência artificial para diagnóstico de câncer.

Neste caso, o objetivo é realizar o treinamento da IA, utilizando uma base de dados médicos, para que esta seja capaz de diferenciar cérebros saudáveis daqueles com neoplasia a partir de imagens de ressonância magnética. Além disso, espera-se também poder identificar a localização do tumor nos cérebros enfermos.

1.2 Inteligência Artificial

A IA nada mais é do que a junção de técnicas de programação a fim de realizar a tentativa de replicar com exatidão o comportamento humano, simulando principalmente a inteligência do cérebro e todas as suas funções. Para isso é utilizada a combinação da ciência da computação com a aglomeração de dados, juntamente com estudos de análise comportamental, anatomia e neurociência. Portanto, o intuito principal da IA é criar sistemas como: processamento de linguagem natural (NLP - *Natural Language Processing*), reconhecimento de voz e visão computacional (TURING, 2009).

Sendo assim, é importante delimitar alguns métodos como *Machine Learning* e *Deep Learning*. Considerando que a IA é o pilar mais abrangente, ou seja, a junção de técnicas de *software* e *hardware* projetado para imitar o comportamento humano, pode-se dizer que o *Machine Learning* é apenas uma ferramenta para tal, e por fim o *Deep Learning* seria esta ferramenta mais aprimorada para problemas mais complexos (TURING, 2009), (SCHROER, 2017), (WOLFEWICZ, 2022). A Figura 7 apresenta como foi feita essa evolução de conceitos.

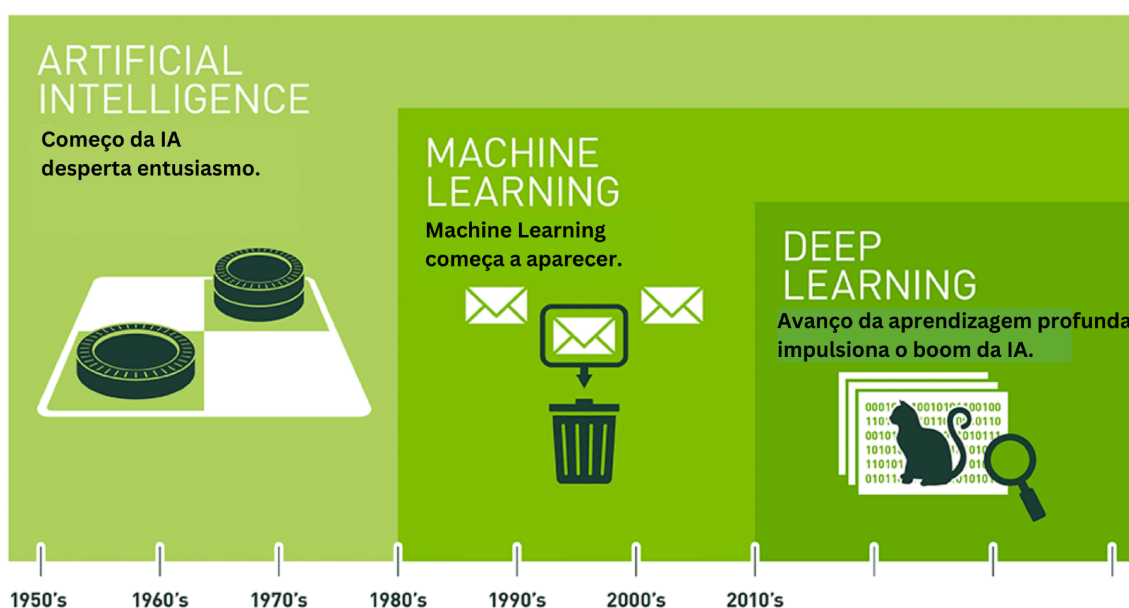


Figura 7 – Esquema representando as áreas de IA, *machine learning* e *deep learning*, através de uma relação com a ideia de conjuntos, sendo a IA o conjunto mais abrangente (COPELAND, 2016).

Logo, para que seja possível a criação de um projeto capaz de automatizar um processo de diagnóstico médico, é preciso empregar de tais ferramentas, criando um sistema neural que o computador possa associar ao funcionamento do cérebro humano e poder imitar seu comportamento. Para entender cada passo desse sistema é crucial a constante comparação com o próprio sistema nervoso humano, isto é, para que qualquer sentido seja processado é necessário que haja primeiro algum tipo de estímulo externo, que após passar por vários caminhos retorna de fato uma resposta ao corpo. Da mesma forma funciona a criação de um amontoado de códigos em uma IA: é necessário um *input* (uma entrada), de onde receberá o estímulo que passará por várias camadas de neurônios e por fim irá retornar um modelo de padrões bem definidos, constituindo então a reprodução de determinada característica humana (SCHROER, 2017) (COPELAND, 2016).

Para construir o *software* de uma IA é preciso entender que o algoritmo realmente é baseado em conexões neurais. Este é chamado de rede neural, um amontoado de camadas constituídas de neurônios ligados entre si por nós. A conexão entre essas camadas possuem pesos, que são responsáveis por separar as características dos dados a fim de ajudar a determinar a importância de uma variável fornecida. Juntamente com esses pesos, existe o *bias*. Tal elemento é utilizado para variar o grau de liberdade do ajuste dos pesos (CEREBROMENTE, 2022) (UPGRAD BLOG, 2020).

Dessa forma, na construção do código de tal algoritmo é necessário criar várias camadas de redes neurais (um exemplo simplificado de uma rede neural é apresentado na Figura 8), sendo que em cada uma delas existem vários neurônios que irão fazer um trabalho semelhante a um filtro, separando características específicas dos dados recebidos pela *input* (propagando essa tarefa para as demais camadas) através de atributos como pesos e o *bias*. As camadas de entrada e de saída da rede são as camadas visíveis, enquanto que as camadas interiores a estas duas são as camadas escondidas nas quais acontece o *backpropagation*, que utiliza a taxa de erro de uma propagação direta e alimenta essa perda através das diversas camadas a fim de ajustar os pesos até que chegue na camada de saída com um peso extremamente refinado.




Figura 8 – Representação esquemática simples de uma rede neural e seus atributos (CE-REBROMENTE, 2022).

Por conseguinte, a fim de criar *softwares* responsáveis por tais tarefas, é preciso focar nass ferramentas já mencionadas:

1. *Machine Learning*: A partir da tradução direta já é possível entender a base desta técnica que é o aprendizado de máquina dado pela utilização de algoritmos para organizar dados, reconhecer padrões e então aprender com eles de maneira a realizar previsões e orientar decisões. Esses algoritmos são treinados de maneira mais simples, ao invés de serem programados manualmente são alimentadas com dados a fim de aprender como realizar determinada tarefa. Esses processos podem ser divididos em:

- ❑ **Supervisionado:** neste método os dados que alimentam a rede são rotulados, ou seja, existe uma relação conhecida entre o *input* e o *output*, tal modelo é alimentado já sabendo as respostas corretas. Assim, existem algoritmos de regressão para prever valores contínuos e de classificação para classificar algo de acordo com uma etiqueta, com classes bem definidas (LOUKAS, 2020).
- ❑ **Não supervisionado:** ao contrário do modelo supervisionado, este recebe um *dataset* não rotulado para que o próprio algoritmo encontre alguma estrutura nos dados, logo este é mais usado em casos onde não existe um resultado previamente meditado (LOUKAS, 2020).
- ❑ **Aprendizagem por reforço:** neste modelo, o algoritmo aprende a partir da realização de tarefas, e então é recompensado caso se direcione para o caminho correto e punido caso erre, sendo aperfeiçoado a partir de tentativas e erros. Esse modelo visa encontrar o melhor caminho para maximizar o ganho final, e por isso geralmente é usado em jogos (LOUKAS, 2020) (ARORA, 2020).

Para ficar mais claro o entendimento entre as diferenças desses tipos de *Machine Learning*, a figura Figura 9 demonstra um esquema entre eles:

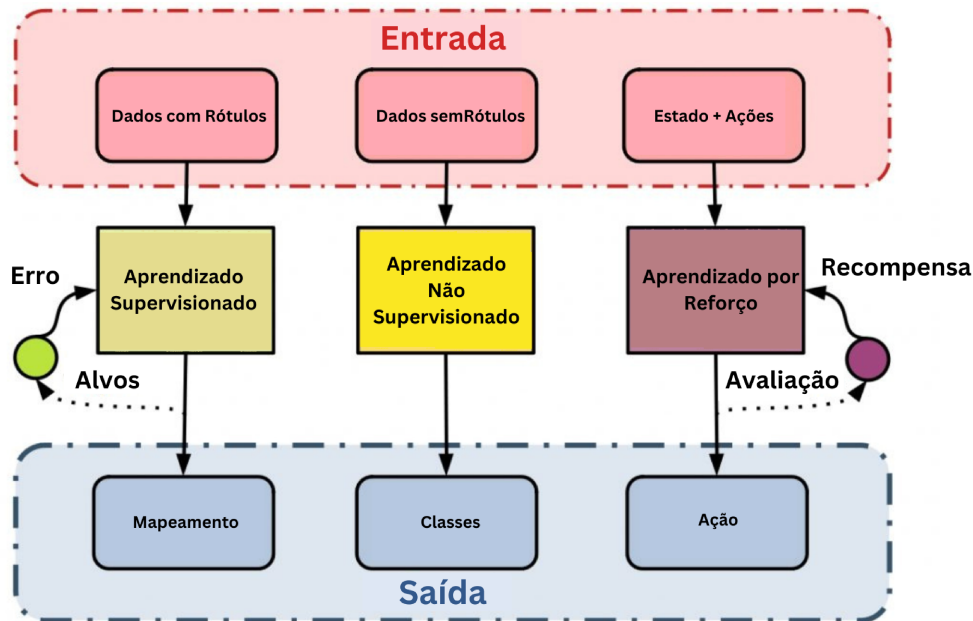


Figura 9 – Comparação entre os três tipos de aprendizado de máquina discutidos no texto (STARSHIP KNOWLEDGE, 2022).

2. *Deep Learning*: Como observado na Figura 7, é condizente afirmar que o *deep learning* é um subcampo do *machine learning*. Esta abordagem utiliza um algoritmo muito mais complexo estruturado a partir de redes neurais (na comparação direta com um ser humano, o *deep learning* seria o cérebro como um todo). Tais redes precisam ser alimentadas com uma quantidade muito extensa de dados. A construção destas redes apresentam uma particularidade muito importante, que é a criação de uma ou mais camadas escondidas a fim de otimizar e refinar a acurácia final do modelo (AWS, 2023).

Diferente do *machine learning*, o próprio algoritmo de *deep learning* é capaz de segmentar as características marcantes de cada parte do *dataset*, atributo que no *machine learning* só é possível ser feito manualmente no código, como exemplificado na figura Figura 10. Além disso, o *deep learning* requer muito mais potência computacional no quesito de *hardware*, para trabalhar com tal volume de dados é necessário GPUs (*Graphical Processing Units*) de alta performance (BROWNLIE, 2016) (MATHWORKS, 2019). Na Figura 11 pode-se observar a diferença estrutural entre *machine learning* e de *deep learning*.

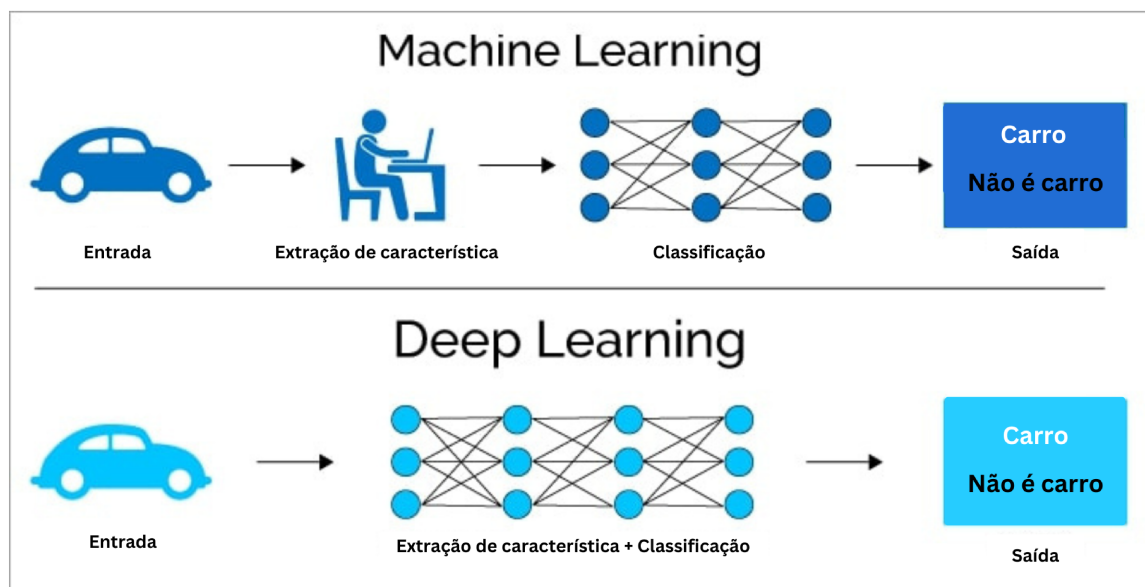


Figura 10 – Esquematização da diferença entre *machine learning* e *deep learning* (WOLFEWICZ, 2022).

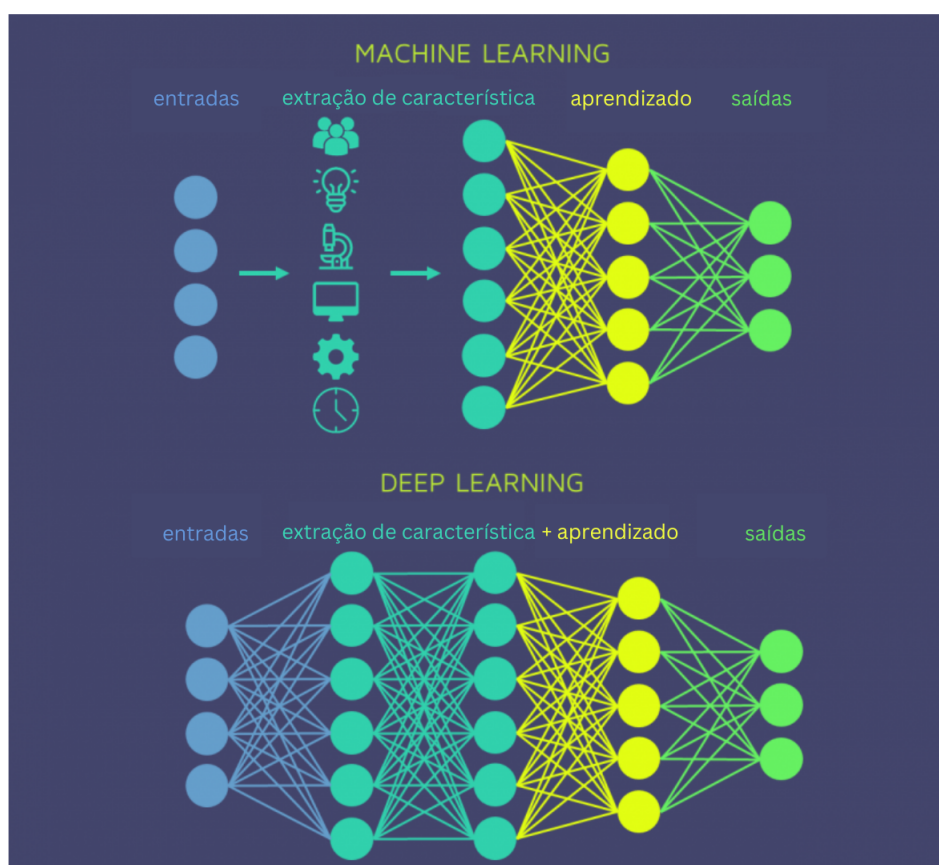


Figura 11 – Esquematização dos diferentes desenhos das redes de *machine learning* e de *deep learning* (QUANTDARE, 2019)].

Existem variações em cima do conceito básico do aprendizado profundo, as mais populares entre os programadores são:

- **MLP (*Multi-Layer Perceptrons*):** esta é a mais básica rede de *deep learning* constituídas por algumas camadas totalmente conectadas (*feedforward*), são boas redes de classificação.

- **RNN (*Recurrent Neural Networks*):** nesta rede, as conexões entre os nós podem criar um ciclo, fazendo com que a saída de uma camada afete a entrada da próxima, permitindo então um comportamento dinâmico temporal, diferenciando-se principalmente pela sua memória ao receber informação de outras entradas. Essa rede é muito usada em processamento de linguagem natural (NLP), reconhecimento de legenda e pesquisas por voz ([IBM, 2022](#)).

- **CNN (*Convolutional Neural Networks*):** essa será o tipo de rede usada para detectar e segmentar as neoplasias nas imagens de exames agrupadas, portanto é necessário um estudo mais aprofundado.

Este tipo de rede é um dos mais usados, principalmente para visão computacional. Ela geralmente é composta por camadas convolucionais as quais são as camadas base e possuem componentes como filtros, mapas de recursos, um *kernel* (enquanto os filtros representam o número de canais de saída após a execução da convolução, o *Kernel* é o tamanho de um filtro de convolução usado para realizar a convolução), entre outros. Depois de cada convolução esta camada aplica uma função de transformação linear (ReLU), trazendo então uma não linearidade para o modelo. A próxima camada é chamada de *pooling layer*, criada para diminuir a dimensão dos dados, reduzindo o número de parâmetros na entrada. Diferente da convolucional esta camada não possui pesos, em vez disso, o kernel aplica uma função de agregação aos valores da matriz de saída. A camada de *pooling* pode ser escrita em dois tipos: *max pooling* (seleciona o pixel que possui maior valor que será enviado para matriz de saída) e *average pooling* (calcula o valor médio dentro de uma área receptiva que será enviado para matriz de saída). Por fim, existe também a camada completamente conectada responsável por conectar cada nó da camada de saída à camada anterior, ela realiza uma tarefa de classificação baseando-se nas características previamente extraídas nas camadas anteriores. Essa camada utiliza uma função de ativação (a mais usada é a *softmax*) que encontra uma probabilidade de 0 a 1 ([CHOLLET, 2018](#)).

1.3 Aplicação da IA na Física Médica

Com toda essa base teórica, este trabalho irá comprovar a eficiência da junção entre a computação e a área da saúde onde o físico médico atua. A dizer, trabalhar com base de dados pode ser útil não apenas para aproveitamento de imagens, mas também em outros campos específicos como predição de doenças entre outros. Uma rede neural capaz de aprender com um determinado padrão, pode prever e apontar anomalias em muitos outros exames além do de ressonância magnética. Para que seja possível tais práticas é necessário apenas uma estrutura neural adequada para cada situação (esta determinação é feita após um breve estudo caso a caso) e um banco de dados de tamanho suficiente de acordo com a rede escolhida para alimentar a IA.

Objetivos

2.1 Objetivo Geral

O objetivo deste trabalho é demonstrar a importância da utilização de *Machine Learning* e IA aplicadas à Física Médica como ferramenta na área de análise de imagens médicas. Enfatizando o uso de uma tecnologia relativamente nova que utiliza um agrupamento de dados a fim de utilizar os conhecimentos tecnológicos da computação na área da saúde, por meio de imagens.

2.2 Objetivos Específicos

O objetivo específico é construir um sistema de IA constituída por uma rede neural que será capaz de discriminar um cérebro saudável de um cérebro com neoplasia. Além disso, caso seja encontrada a neoplasia, a IA deve ser capaz de apontar as áreas tumorais encontradas na imagem, comprovando assim a eficácia da IA na área da saúde.

Metodologia

3.1 Materiais

Para criar a rede neural foi utilizada a linguagem de programação *Python* e bibliotecas como *Matplotlib*, *Numpy*, *Pillow* e *Pytorch* (*torch* e *torchvision*), tais bibliotecas são usadas para o treinamento da rede e para a exposição de dados para predições e análises. O treinamento foi realizado utilizando a GPU (placa de video *NVIDIA GTX 1080 Ti*) com 8GB de GPU e um processador *intel core i3* de sétima geração, o que permitiu realizar o treinamento em aproximadamente 4 horas e meia. A base da rede neural foi construída a partir de um tipo de CNN chamada U-Net, que é uma das melhores arquiteturas para trabalhar com segmentação de imagens de maneira rápida e precisa através de uma técnica chamada *data augmentation*, que consiste em um algoritmo pra aumentar a quantidade de dados que alimentam a rede a partir desses próprios dados (TAKIMOGLU, 2021). Tal rede pode ser treinada de ponta a ponta e, mesmo sendo um tipo de *deep learning*, não exige uma grande quantidade de dados, ainda mais usando o *augmentation* (RONNEBERGER; FISCHER; BROX, 2015).

Além disso, para o treinamento também foi indispensável um conjunto de *datasets* de exames de ressonância magnética contendo três tipos diferentes de tumor: meningioma, glioma e tumor hipofisário, sendo que os rótulos são numerações de 1 até 3 respectivamente. Tais dados foram encontrado no site do *figshare* pelo autor Jun Cheng (CHENG, 2017) e dentre as versões disponibilizas nesse conjunto de *dataset*, a versão utilizada foi a 5.

3.2 Procedimento Prático

3.2.1 Dataset

Inicialmente foi feita uma pesquisa profunda em cima de imagens médicas que possam ser utilizadas para fins acadêmicos, seguida foi feito um estudo em cima de cada *dataset* a fim de criar um pré-processamento de imagens para que estas estejam aptas e estáveis para serem recebidas pela camada de entrada da rede neural. Em seguida, foi criada uma classe a fim de criar de fato a *data augmentation* (utilizando artifícios do *Pytorch Torchvision*) para diversificar as imagens de treinamento, e por fim, essas imagens foram separadas para treino e teste.

3.2.2 Construção da Rede Neural

A arquitetura da rede U-net (RONNEBERGER; FISCHER; BROX, 2015) foi feita a partir de uma versão usando *Pytorch* e em torno de apenas quatro blocos de profundidade devido à limitação do poder computacional utilizado. A rede não foi um modelo de transferência de aprendizado, portanto todas as camadas foram montadas uma por uma dentro dos quatro blocos, a camada de entrada possui dimensões (1, 512, 512) (canal, largura e altura), em seguida foi criada a camada de propagação com as mesmas dimensões da camada de entrada. Por fim a camada de saída utiliza a função sigmoide.

A rede foi treinada com 100 *epochs* (o ciclo em que a rede neural será treinada) e com um *batch size* de 6 (o número de dados de treinamento utilizados em uma *epoch*), a função de otimização usada foi a *Adam Optimizer* (CORNELL, 2023), para a taxa de aprendizado foi utilizado um recurso chamado *Reduce LR On Plateau* que monitora a melhoria da acurácia da rede de acordo com o valor da taxa de aprendizado (PYTORCH, 2023). Por fim, o coeficiente de perda foi calculado com base no *sorensen dice coefficient* (MATLAB, 2022).

Resultados e Discussões

4.1 Dataset

Para alimentar uma rede de *deep learning* é preciso um volume de dados muito grande. O *dataset* utilizado possui aproximadamente 3000 imagens totalizando os próprios exames e suas respectivas máscaras (delimitação do local onde os tumores estão localizados), tudo isso utilizado para treinamento. Sendo assim, foi criada uma classe para realizar a *data augmentation*, aumentando o *dataset* para 6000 imagens. Alguns exemplos de imagens usadas estão apresentadas na Figura 12 e no Apêndice A.1.




Figura 12 – Exame de uma ressonância magnética cerebral e sua respectiva máscara da neoplasia apresentada.

Para entender melhor como esse *dataset* foi pensado, a Figura 13 demonstra a sobreposição dessas máscaras sobre a imagem do exame original, após os tratamentos do pré-processamento de imagens.




Figura 13 – Sobreposição da máscara representando a neoplasia, na imagem do exame já tratado após passar pelo pré-processamento.

4.2 Análise do treinamento

Após o treinamento, foi possível acompanhar a evolução da rede durante as 100 *epochs*

Durante a criação de um modelo é de extrema importância acompanhar o comportamento da rede, principalmente para evitar fatores como *overfitting*, evento que ocorre quando o treinamento passa dos limites necessários e apresenta uma variação evidente nas métricas de acurácia e perda. Caso um modelo que sofreu *overfitting* seja testado, ele só irá comportar-se da forma esperada para imagens que ele já conhece, ou seja, uma imagem fora do campo de treinamento provavelmente não será classificada ou segmentada da forma correta [(IBM CLOUD, 2022)]. Existem várias formas e plataformas para acompanhar tais métricas e neste caso foi criado um gráfico que representa a diminuição do fator de perda durante o treinamento, apresentado na Figura 14.

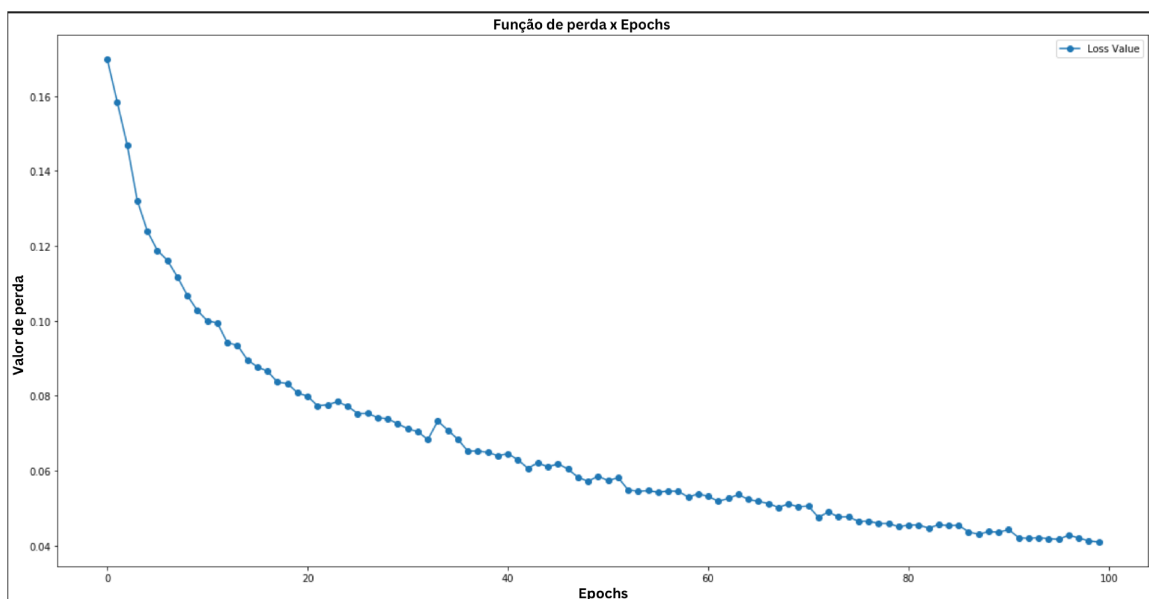


Figura 14 – Representação gráfica do comportamento da função de perda a cada ciclo de treinamento (a cada *epoch*). O eixo x apresenta as *epochs* e no eixo y o valor da perda.

Ademais, outro fator que merece atenção é a acurácia do modelo, ou seja, a capacidade de acerto. Tanto quanto a função de perda, a acurácia é um meio de avaliar o comportamento de um modelo durante e ao fim de seu treinamento. Então, enquanto a função de perda deve ter o menor valor possível para que as perdas sejam minimizadas, a acurácia, que nesse caso é a medida de quão semelhantes as máscaras das neoplasias são.

No caso deste estudo, foi escolhido lidar com a acurácia de uma maneira diferente do mais comum, usando o coeficiente *Sorensen Dice* [(MOORE, 2021)]. Tal escolha foi feita porque apresenta resultados satisfatórios para segmentação de imagem [(ZOU et al., 2004)] e também é bem usado na área de imagens médicas [(RESEARCHGATE, 2020), (ZOU et al., 2004), (CARASS et al., 2020)]. Sendo assim, para que a rede seja considerada de fato boa, o resultado do *Dice score* deve ser maior que 88% [(RESEARCHGATE, 2020)], e o maior valor obtido nos testes e durante o treinamento foi de 98%.

De maneira geral, o treinamento não demorou muito para ser concluído, os *hardwares* usados possuem pequenas limitações computacionais indicando que não há a extrema necessidade de um poder computacional grande para de fato atingir o objetivo de aplicar IA na área médica, as métricas obtidas foram satisfatórias e o modelo final cumpriu sua obrigação de segmentar os tumores nos exames apresentados.

4.3 Teste do modelo final

Por fim, foi criado um código simples, usando a biblioteca *Matplotlib*, para agrupar as imagens originais e as imagens construídas pela rede. É importante ressaltar que a rede reconstruiu apenas a máscara com a definição da neoplasia, preservando a posição deste no exame cerebral.

No começo do treinamento, o *dataset* completo foi dividido entre treinamento e teste, então as imagens separadas para teste foram usadas e alguns dos resultados obtidos podem ser analisados na Figura 15 e no Apêndice A.2. A acurácia observada de acordo com cada imagem variou de 0.94% até 0.98%, isso utilizando baixo poder computacional, 100 *epochs* e um *batch size* 6, ou seja, com um treinamento um pouco mais refinado, os resultados podem ser ainda mais precisos.




Figura 15 – Esquemática do exame original, juntamente com sua máscara, a imagem com a máscara prevista pelo modelo treinado, e o exame original.

4.4 Curiosidade

Cada tipo de rede também possui suas limitações. Outro meio de ter feito o treinamento de segmentação de imagens poderia ter sido a transferência de aprendizado, que consiste em utilizar uma rede robusta já treinada. Sendo assim, é necessário um estudo para encontrar a rede com melhor comportamento de evolução durante as *epochs* (dentre as possibilidades mais conhecidas existem a *VGG*, *Inceptionv3*, *GoogLeNet* e a *ResNet50*) e congelar os pesos até a camada necessária, já que, para que possa aproveitar o aprendizado de uma rede já treinada é necessário escolher as características resgatadas e então adicionar mais alguns blocos de rede para direcioná-la ao novo objetivo de treinamento [([CHOLLET, 2018](#)), ([MACHINE LEARNING MASTERY, 2019](#))].

Conclusão

Após o longo estudo sobre redes neurais e inteligência artificial, foi possível escolher uma rede boa o suficiente para trabalhar com segmentação de imagens médicas usando pouco poder computacional e um *dataset* suficientemente grande para tratar de um problema de *deep learning* e ainda utilizar dos conceitos de *data augmentation*, gerando mais imagens a partir das já disponibilizadas pela fonte mencionada.

Além disso, foi feito também um breve estudo sobre imagens médicas a fim de conseguir relacionar o diagnóstico de imagens à ferramenta de IA.

Juntando a área da ciência da computação com a física médica, foi possível criar um algoritmo que utilizou imagens e um breve pré-processamento, onde após o treinamento, o modelo criado foi capaz de identificar e localizar a posição dos tumores de maneira eficiente e rápida, criando um meio mais simples de diagnóstico, podendo agilizar o trabalho de profissionais da saúde ou até realizar detecções por conta própria.

Bibliografia

ARORA, S. **Supervised vs Unsupervised vs Reinforcement**. 2020. Disponível em: <<https://www.aitude.com/supervised-vs-unsupervised-vs-reinforcement/>>.

AWS, A. **O que é Aprendizado profundo? Explicações sobre Aprendizado profundo - AWS**. 2023. Disponível em: <<https://aws.amazon.com/pt/what-is/deep-learning/>>.

BRASIL, E. M. **Conheça os tipos de exames de imagem da Radiologia**. 2022. Disponível em: <<https://www.educamaisbrasil.com.br/cursos-e-faculdades/radiologia/noticias/conheca-os-tipos-de-exames-de-imagem-da-radiologia>>.

BROWNLEE, J. **What is Deep Learning?** 2016. Disponível em: <<https://machinelearningmastery.com/what-is-deep-learning/>>.

CARASS, A. et al. Evaluating white matter lesion segmentations with refined sorensen-dice analysis. **Scientific Reports**, v. 10, 05 2020. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7237671/>>.

CEDUSP. **O que é tomografia? Para que serve? Qual sua importância?** 2023. Disponível em: <<https://cedusp.com.br/o-que-e-tomografia-para-que-serve-qual-sua-importancia-descubra/>>.

CEREBROMENTE. **ARTIFICIAL NEURAL NETWORKS**. 2022. Disponível em: <https://cerebromente.org.br/n05/tecnologia/rna_i.htm>.

CHENG, J. Brain tumor dataset. **figshare**, 04 2017. Disponível em: <https://figshare.com/articles/brain_tumor_dataset/1512427/5>.

CHOLLET, F. **Deep Learning with Python**. [S.l.]: Manning, Cop, 2018.

COPELAND, M. **The Difference between AI, Machine Learning, and Deep Learning? - NVIDIA Blog**. 2016. Disponível em: <<https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/>>.

CORNELL, O. C. **Adam - Cornell University Computational Optimization Open Textbook - Optimization Wiki**. 2023. Disponível em: <<https://optimization.cbe.cornell.edu/index.php?title=Adam>>.

COYNE, K. **MRI: A Guided Tour - MagLab**. 2018. Disponível em: <<https://nationalmaglab.org/education/magnet-academy/learn-the-basics/stories/mri-a-guided-tour>>.

CUMBERS, J. **The Latest Quantified Self Trend: Whole-Body MRI**. 2022. Disponível em: <<https://www.forbes.com/sites/johncumbers/2021/03/24/the-latest-quantified-self-trend-whole-body-mri/?sh=298234d46d5c>>.

DIAGRAD. **Componentes do Aparelho de Raio-X: Como Ele Funciona?** 2022. Disponível em: <<https://diagrad.com.br/noticias/componentes-do-aparelho-de-raiox-como-ele-funciona/>>.

IBM. **What are Recurrent Neural Networks?** 2022. Disponível em: <<https://www.ibm.com/topics/recurrent-neural-networks>>.

IBM CLOUD. **What is Overfitting?** 2022. Disponível em: <<https://www.ibm.com/topics/overfitting>>.

LABORATORIO EXAME. **Ressonância Magnética: o que é e como é feito o exame**. 2022. Disponível em: <<https://laboratorioexame.com.br/saude/ressonancia-magnetica#:~:text=A%20resson>>.

LOUKAS, S. **What is Machine Learning: A Short Note on Supervised, Unsupervised, Semi-Supervised, Reinforcement learning methods**. 2020. Disponível em: <<https://towardsdatascience.com/what-is-machine-learning-a-short-note-on-supervised-unsupervised-semi-supervised-and-aed1573ae9bb>>.

MACHINE LEARNING MASTERY. **A Gentle Introduction to Transfer Learning for Deep Learning**. 2019. Disponível em: <<https://machinelearningmastery.com/transfer-learning-for-deep-learning/>>.

MARCOS, H. S. **Exames da Mama: aumentando a eficiência Mamografia - Ultrassom - Ressonância**. 2013. Disponível em: <<https://www.saomarcos.org.br/artigo/exames-da-mama-aumentando-a-eficiencia-mamografia-ultrassom-ressonancia>>.

MATHWORKS. **What Is Deep Learning? - How It Works, Techniques Applications**. 2019. Disponível em: <<https://www.mathworks.com/discovery/deep-learning.html>>.

MATLAB. **Sorensen-Dice similarity coefficient for image segmentation - MATLAB dice**. 2022. Disponível em: <<https://www.mathworks.com/help/images/ref/dice.html>>.

MEDICINE, J. H. **Magnetic Resonance Imaging (MRI)**. 2019. Disponível em: <<https://www.hopkinsmedicine.org/health/treatment-tests-and-therapies/magnetic-resonance-imaging-mri>>.

MEDICINEWISE, N. **Imaging explained**. 2022. Disponível em: <<https://www.nps.org.au/consumers/imaging-explained>>.

MOORE, C. M. **Dice similarity coefficient - Radiology Reference Article - Radiopaedia.org**. 2021. Disponível em: <<https://radiopaedia.org/articles/dice-similarity-coefficient>>.

- MV. **MV - Exames PET CT e RM: o que são e quando usá-los na medicina diagnóstica?** 2022. Disponível em: <<https://mv.com.br/pt/blog/exames-pet-ct-e-rm--o-que-sao-e-quando-usa-los-na-medicina-diagnosticar#:~:text=Enquanto%20o%20PET%20se%20ocupa>>.
- NEXXTO. **Ressonância Magnética e os riscos associados ao quenching.** 2020. Disponível em: <<https://nexxto.com/ressonancia-magnetica-e-riscos-do-quenching/>>.
- NOGUEIRA, A. **O Raio X: O primeiro raio-x do mundo - radiologia raio x.** 2010. Disponível em: <<https://hypescience.com/27195-primeiros-raios-x/>>.
- OREN, O.; GERSH, B. J.; BHATT, D. L. Artificial intelligence in medical imaging: switching from radiographic pathological data to clinically meaningful endpoints. **The Lancet Digital Health**, v. 2, p. e486–e488, 09 2020. Disponível em: <[https://www.thelancet.com/journals/landig/article/PIIS2589-7500\(20\)30160-6/fulltext](https://www.thelancet.com/journals/landig/article/PIIS2589-7500(20)30160-6/fulltext)>.
- PORTAL EDUCACAO. **Produção de raios X: entenda como funciona.** 2022. Disponível em: <<https://blog.portaleducacao.com.br/producao-de-raios-x-entenda-como-funciona/>>.
- POSTDICOM. **Medical Imaging Types and Modalities.** 2023. Disponível em: <<https://www.postdicom.com/pt/blog/medical-imaging-types-and-modalities>>.
- PYTORCH. **ReduceLRonPlateau PyTorch 1.9.0 documentation.** 2023. Disponível em: <https://pytorch.org/docs/stable/generated/torch.optim.lr_scheduler.ReduceLRonPlateau.html>.
- QUANTDARE. **What is the difference between Deep Learning and Machine Learning?** 2019. Disponível em: <<https://quantdare.com/what-is-the-difference-between-deep-learning-and-machine-learning/>>.
- RESEARCHGATE. **Dice score visualization.** [S.l.]: ResearchGate, 2020.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. **U-Net: Convolutional Networks for Biomedical Image Segmentation.** 2015. Disponível em: <<https://arxiv.org/abs/1505.04597>>.
- ROUGER, M. **The cost of AI in radiology: is it really worth it?** 2019. Disponível em: <<https://ai.myesr.org/articles/the-cost-of-ai-in-radiology-is-it-really-worth-it/>>.
- RUIZ, F. **Ressonância Magnética e os Riscos Associados ao Quench.** 2022. Disponível em: <<https://www.sisvida.com.br/index.php/ressonancia-magnetica-e-os-riscos-associados-ao-quench/>>.
- SCHROER, A. **What is Artificial Intelligence? How Does AI Work? - Built In.** 2017. Disponível em: <<https://builtin.com/artificial-intelligence>>.
- SCIENCE DIRECT. **Larmor Frequency - an overview - ScienceDirect Topics.** 2023. Disponível em: <<https://www.sciencedirect.com/topics/computer-science/larmor-frequency#:~:text=The%20corresponding%20Larmor%20frequencies%20are>>.
- SILVA, O. D.; RIGUE, J.; CARARA, M. **Study of Exchange Bias in Thin Films of NiFe/FeMn (Bilayers) and NiFe/IrMn (Multilayers).** Tese (Doutorado), 03 2016.

SPRINGER. **Artificial intelligence in medicine**. 2022. Disponível em: <https://link.springer.com/referencework/10.1007/978-3-030-58080-3?gclid=Cj0KCQjw1tGUBhDXARIsAIJx01nsYIaoZB6hD9pkD2l7PujZI49YI4mcUWomjnKOaz3sUn_-RccEK8IaAgeDEALw_wcB>.

STARSHIP KNOWLEDGE. **Supervised Vs Unsupervised Vs Reinforcement Learning - Knowing The Differences Is A Fundamental Part Of Properly Understanding Machine Learning**. 2022. Disponível em: <<https://starship-knowledge.com/supervised-vs-unsupervised-vs-reinforcement>>.

TAKIMOGLU, A. **What is Data Augmentation? Techniques, Benefit and Examples**. 2021. Disponível em: <<https://research.aimultiple.com/data-augmentation/>>.

TANG, X. The role of artificial intelligence in medical imaging research. **BJR Open**, v. 2, p. 20190031, 11 2020.

TECNOLOGIA RADIOLOGICA. **Formacao da Imagem Radiologica**. 2022. Disponível em: <https://www.tecnologiaradiologica.com/materia_c_imagem.htm>.

TOMOCENTER. **diagnostico-tomografia-computadorizada**. 2022. Disponível em: <<https://tomocenter.com.br/diagnostico-tomografia-computadorizada/>>.

TURING, A. M. Computing machinery and intelligence. In: **PARSING THE TURING TEST**. 2009. (Parsing the Turing Test), p. 23–65. Disponível em: <<https://www.csee.umbc.edu/courses/471/papers/turing.pdf>>.

UFRGS. **A Descoberta dos Raios X**. 2022. Disponível em: <https://www.if.ufrgs.br/tex/fis142/fismod/mod06/m_s01.html>.

UPGRAD BLOG. **Neural Network: Architecture, Components Top Algorithms**. 2020. Disponível em: <<https://www.upgrad.com/blog/neural-network-architecture-components-algorithms/>>.

WOLFEWICZ, A. **Deep learning vs. machine learning - What's the difference?** 2022. Disponível em: <<https://levity.ai/blog/difference-machine-learning-deep-learning>>.

ZOU, K. H. et al. Statistical validation of image segmentation quality based on a spatial overlap index. **Academic radiology**, v. 11, p. 178–189, 02 2004. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC1415224/>>.

Apêndice

Apêndice

A.1 Imagens usadas para treinamento da rede neural




Figura 16 – Amostra de imagens retiradas do conjunto de dados fornecidos em [(CHENG, 2017)].




Figura 17 – Amostra de imagens retiradas do conjunto de dados fornecidos em [(CHENG, 2017)].




Figura 18 – Amostra de imagens retiradas do conjunto de dados fornecidos em [(CHENG, 2017)].

A.2 Resultados do teste do modelo final




Figura 19 – Amostra de imagens com a comparação da imagem original e do que o modelo foi capaz de prever.




Figura 20 – Amostra de imagens com a comparação da imagem original e do que o modelo foi capaz de prever.




Figura 21 – Amostra de imagens com a comparação da imagem original e do que o modelo foi capaz de prever.




Figura 22 – Amostra de imagens com a comparação da imagem original e do que o modelo foi capaz de prever.




Figura 23 – Amostra de imagens com a comparação da imagem original e do que o modelo foi capaz de prever.




Figura 24 – Amostra de imagens com a comparação da imagem original e do que o modelo foi capaz de prever.