



**UNIVERSIDADE DO SUL DE SANTA CATARINA**  
**GABRIEL AFONSO PICKLER**

**DIAGNÓSTICO E SEGMENTOS DE IMAGEM COM AUXÍLIO DE DEEP  
LEARNING:  
UM ESTUDO SOBRE APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL NA ÁREA MÉDICA**

Palhoça

2021

**GABRIEL AFONSO PICKLER**

**DIAGNÓSTICO E SEGMENTOS DE IMAGEM COM AUXÍLIO DE DEEP  
LEARNING:  
UM ESTUDO SOBRE APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL NA ÁREA MÉDICA**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Sistemas de Informação na Universidade do Sul de Santa Catarina, como requisito parcial à obtenção do título de Bacharel em Sistemas da Informação.

Orientador: Aran Bey Tcholakian Morales, Dr. Eng.

Palhoça

2021

**GABRIEL AFONSO PICKLER**

**DIAGNÓSTICO E SEGMENTOS DE IMAGEM COM AUXÍLIO DE DEEP  
LEARNING:  
UM ESTUDO SOBRE APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL NA ÁREA MÉDICA**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Sistemas de Informação na Universidade do Sul de Santa Catarina, como requisito parcial à obtenção do título de Bacharel em Sistemas da Informação.

Palhoça, 14 de junho de 2021.

---

Professor e orientador Aran Bey Tcholakian Morales, Dr.  
Universidade do Sul de Santa Catarina

---

Prof. Maria Inés Castiñeira, Dra.  
Universidade do Sul de Santa Catarina

---

Prof. Flávio Ceci, Dr.  
Universidade do Sul de Santa Catarina

Dedico este trabalho de conclusão de curso a todos os profissionais que vêm atuando de forma ética e comprometida a combater a pandemia do novo Coronavírus, aos meus professores que tanto me ensinaram e a minha família que me acompanhou em todos esses momentos.

## AGRADECIMENTOS

Gostaria de agradecer e dedicar essa dissertação às seguintes pessoas:

Minha família, minha mãe Jerusa e meu pai Alexandre, dois grandes incentivadores da minha carreira profissional e acadêmica, que nunca mediram esforços de tempo, dedicação e financeiro para investir em mim e na minha educação. Ao meu irmão Gustavo, que sempre se fez presente como um companheiro de dúvidas e discussão de ideias. A minha namorada, Anelise, que acompanhou, me ouvindo e aconselhando, durante todo o processo que passei imerso nesse trabalho de conclusão.

Aos meus orientadores e professores Aran Bey Tcholakian Morales, Maria Inés Castiñeira e Flávio Ceci pela imensa dedicação, paciência e amorosidade de compartilharem seus conhecimentos, repeti-los quantas vezes necessárias, sempre de forma profissional e ética. Não há possibilidade de trilhar a caminhada sem mestres que mostrem o caminho.

Aos meus amigos, Marcos, Vitor e Pedro, pelo apoio, pela compreensão dos momentos que estive ausente e por se mostrarem leais: a amizade é um porto seguro em todos os momentos da vida.

“Nós só podemos ver um pouco do futuro, mas é o suficiente para perceber que há muito a fazer” (TURING, 1950).

## RESUMO

Existem algumas crenças populares muito fortes que dizem que em breve o mundo será dominado por robôs, que os carros serão voadores e que a inteligência artificial dominará a raça humana: histórias que podem ser encontradas em qualquer rede social digitadas através de um *iphone* ou *android*. A tecnologia, a inteligência artificial, não é uma crença popular, é uma realidade. Um objeto, uma forma, um método que pode ser utilizado para melhorar aspectos do nosso dia a dia.

Quando se fala da interferência da inteligência artificial na área médica, é necessário pensar: Quantas vidas poderiam ser salvas com o uso de tecnologia avançada? Quantas horas na relação médico x paciente poderiam ser mais bem aproveitadas se o tempo em diagnóstico fosse aprimorado com *Deep Learning*? Quanto sobre nossa própria biologia seria passível de descoberta com a ajuda de *softwares* e experimentos tecnológicos?

Essa monografia se propõe a discutir e analisar por meio de uma prova de conceito as possibilidades de atuação da Inteligência Artificial dentro da área médica, buscou-se com uso da Deep Learning, diagnosticar pulmões saudáveis, com pneumonia viral e afetados por COVID-19, através da leitura de imagens. Para além dos termos técnicos, buscou-se criar uma ponte entre a medicina e a tecnologia, comprovando que a via de conversa e pesquisa entre ambos, não é apenas inovadora, mas também extremamente necessária para as práticas diárias em busca de saúde e qualidade de vida. Nesse processo, visitou-se a história do diagnóstico por imagem, a história e a estrutura da *Machine Learning*, até compreender como funciona a *Deep Learning*. Criou-se hipóteses e comprovação por meio do projeto a aplicabilidade desses conceitos de forma prática.

Palavras-chave: Machine Learning. Deep Learning. Diagnóstico por imagem. Medicina. Inteligência Artificial. Coronavírus.

## ABSTRACT

There are some very strong popular beliefs that say that soon the world will be dominated by robots, that cars will be flying and that artificial intelligence will dominate the human race: stories that can be found on any social network typed through an iPhone or Android. Technology, artificial intelligence, is not a popular belief, it's a reality. An object, a shape, a method that can be used to improve aspects of our daily lives.

When talking about the interference of artificial intelligence in the medical field, it is necessary to think: How many lives can be saved with the use of advanced technology? How many hours in the doctor x patient relationship could the time in improved diagnosis be better used with Deep Learning? How much about our own biology would be discoverable with the help of software and technological experiments?

This monograph proposes to discuss and analyze, through a proof of concept, the possibilities of Artificial Intelligence acting within the medical field, using Deep Learning to diagnose healthy lungs, with viral pneumonia and affected by COVID-19, by reading images. In addition to technical terms, we sought to create a bridge between medicine and technology, proving that the way of conversation and research between them is not only innovative, but also extremely necessary for daily practices in search of health and quality of care. life. In this process, we visited the history of diagnostic imaging, the history and structure of Machine Learning, until we understood how Deep Learning works. Hypotheses and proof through the project were created for the applicability of these concepts in a practical way.

Keywords: Machine learning. Deep learning. Diagnostic imaging. Medicine. Artificial intelligence. Coronavirus..

## LISTA DE ILUSTRAÇÕES

|  |    |
|--|----|
| FIGURA 1 – ESTRUTURA DE UM NEURÔNIO.....   | 23 |
| FIGURA 2 – MODELO MATEMÁTICO DE UM NEURÔNIO.....   | 24 |
| FIGURA 3 – MODELO DE UMA REDE NEURAL ARTIFICIAL.....   | 25 |
| FIGURA 4 – COMPARÇÕES ENTRE UMA REDE NEURAL SIMPLES E A DEEP<br>LEARNING.....                              | 26 |
| FIGURA 5 – GRÁFICO SITUACIONAL SOBRE DEEP LEARNING.....  | 27 |
| FIGURA 6 – LEITURA DE IMAGEM EM DEEP LEARNING ATRAVÉS DE REDES NEURAIIS<br>CONVOLUCIONAIS.....             | 28 |
| FIGURA 7 – EXEMPLO DE DOWNSAMPLING (POOLING).....  | 28 |
| FIGURA 8 – REDE NEURAL CONVOLUCIONAL COMPLETA.....   | 29 |
| FIGURA 9 – EXEMPLO DE COMUNICAÇÃO DENTRO DA ESTRUTURA DICOM.....   | 32 |
| FIGURA 10 – RADIOGRAFIA DE UM PULMÃO SAUDÁVEL.....   | 35 |
| FIGURA 11 – RADIOGRAFIA DE UM PULMÃO DIAGNOSTICADO COM SARS-COV-2.....                                     | 35 |
| FIGURA 12 – RADIOGRAFIA DE UM PULMÃO DIAGNOSTICADO COM PNEUMONIA VIRAL NÃO<br>PROVENIENTE DE COVID-19..... | 36 |
| FIGURA 13 – ESTRUTURA DA PROVA DE CONCEITO COM SUAS TECNOLOGIAS.....                                       | 43 |
| FIGURA 14 – PYCHARM.....   | 44 |
| FIGURA 15 – TENSORFLOW.....  | 44 |
| FIGURA 16 – KERAS.....   | 45 |
| FIGURA 17 – KAGGLE.....  | 45 |
| FIGURA 18 – IMAGENS BASE DE PULMÃO COM COVID-19.....   | 45 |
| FIGURA 19 – DEFINIÇÃO DE CAMADAS PARA REDE NEURAL PROFUNDA.....  | 47 |
| FIGURA 20 – CAMADAS DE NORMALIZAÇÃO.....   | 47 |
| FIGURA 21 – DROPOUT: UMA MANEIRA SIMPLES DE EVITAR QUE AS REDES NEURAIIS<br>OVERFITTING.....               | 49 |
| FIGURA 22 – OPERAÇÃO DE FLATTEN.....   | 49 |
| FIGURA 23 – TREINAMENTO DE REDE NEURAL.....  | 50 |
| FIGURA 24 – PREVISÃO DE DIAGNÓSTICO DE IMAGEM.....   | 53 |
| FIGURA 25 – MATRIZ DE CONFUSÃO.....  | 54 |
| <br>   |    |
| GRÁFICO 1 – ACURÁCIA DOS DADOS DE TREINO E VALIDAÇÃO.....  | 51 |
| GRÁFICO 2 – PERDA DOS DADOS DE VALIDAÇÃO E TREINO.....   | 52 |
| <br>   |    |
| QUADRO 1 – CLASSES DE OBJETOS DE INFORMAÇÃO DICOM.....   | 31 |

**TABELA 1 – DADOS DE PREDIÇÃO.....53**

## SUMÁRIO

|  |           |
|--|-----------|
| <b>1 INTRODUÇÃO.....</b>                                   | <b>13</b> |
| 1.1 Problemática.....                                      | 14        |
| 1.2 Objetivo Geral.....                                    | 14        |
| 1.2.1 Objetivos Específicos.....                           | 15        |
| 1.2.3 Justificativa.....                                   | 15        |
| 1.4 Estrutura.....   | 17        |
| <b>2. REVISÃO BIBLIOGRÁFICA .....</b>                      | <b>18</b> |
| 2.1 Diagnóstico por imagem.....                            | 18        |
| 2.2 Deep Learning: conceitos, aplicações e estruturas..... | 21        |
| 2.3 Deep Learning no diagnóstico por imagem.....           | 29        |
| 2.4 SARS-COV-2 (COVID-19).....                             | 34        |
| 2.5 Considerações Finais .....                             | 37        |
| <b>3. METODOLOGIA.....</b>                                 | <b>38</b> |
| 3.1 Caracterização da Pesquisa.....                        | 38        |
| 3.2 Atividades Metodológicas.....                          | 39        |
| 3.3 Objeto de Estudo.....                                  | 40        |
| 3.4 Delimitações.....                                      | 40        |
| <b>4. PROPOSTA DE SOLUÇÃO.....</b>                         | <b>41</b> |
| 4.1 Requisitos.....  | 41        |
| 4.1.2 Desenvolvimento da Prova de Conceito.....            | 42        |
| 4.2 Pycharm.....   | 43        |
| 4.2.1 Tensorflow.....                                      | 44        |
| 4.2.2 Keras.....   | 44        |
| 4.2.3 Kaggle.....  | 45        |
| 4.3 Camadas de Deep Learning.....                          | 46        |
| 4.4 Early Stopping.....                                    | 50        |
| 4.5 Resultados.....  | 50        |
| 4.6 Considerações Finais.....                              | 54        |
| <b>5. CONCLUSÕES E TRABALHOS FUTUROS.....</b>              | <b>57</b> |
| 5.1 Conclusões.....  | 56        |
| 5.2 Trabalhos Futuros.....                                 | 56        |
| <b>REFERÊNCIAS.....</b>                                    | <b>58</b> |

APENDICE .....63

## 1 INTRODUÇÃO

Antes de ponderar qualquer aspecto sobre o conceito de inteligência artificial, torna-se necessário compreender o conceito de inteligência humana, tendo em vista, que o desenvolvimento de uma se deu em detrimento da observação e entendimento sobre a outra, e portanto, seguem interligadas em conceito, estudo e novas possibilidades de teorias.

A luz da teoria construtivista, de Piaget, o aprendizado provém de uma relação de equilíbrio entre assimilação e acomodação, que permite a ação do sujeito sobre o meio de forma mais elaborada, o aperfeiçoamento acontece a partir das inúmeras experiências de assimilação e acomodação do sujeito ao longo da existência (NOGUEIRA; LEAL, 2018 p. 126).

Dessa forma, quando relatamos a experiência de Inteligência Artificial, espera-se não somente um sistema executor de ordens programadas previamente, mas também de ser um sistema de encontrar novas soluções à medida que novos desafios são impostos, tornando-se parte da ação do ambiente.

O sistema de inteligência artificial não é capaz apenas de armazenar e manipular dados, como também adquirir, representar e manipular conhecimento. A manipulação inclui a capacidade de deduzir ou inferir novos conhecimentos ou relações sobre fatos e conceitos a partir do conhecimento já existente e utilizar métodos de representação e manipulação para resolver problemas complexos que são frequentemente não quantitativos por natureza. (SILVA; LENZ; ET AL, 2019 p. 14)

Embora os conceitos de inteligência transitem entre inúmeras teorias e ainda tenha uma quantidade considerável de dúvidas e questionamentos sobre uma possível definição, como citado anteriormente, a Inteligência Artificial caminha junto com a inteligência humana e por consequência, estão sempre em desenvolvimento, das suas funções e definições.

É necessário ressaltar também, que apesar do imaginário popular e do tom futurístico da ideia, o conceito de Inteligência Artificial não é novo e vem sendo trabalhado ao longo de muitos anos de história, segundo Silva et al, “essa tecnologia começou a ser desenvolvida na década de 1950, com o Dartmouth Summer Research Project Artificial Intelligence (Projeto de Pesquisas de Verão em Inteligência Artificial de Dartmouth), no Dartmouth College, em Hanover, New Hampshire, Estados Unidos”. Dessa forma, o conceito em AI (Inteligência Artificial) vem sendo aprimorada ao longo de décadas de estudo, principalmente nas áreas de tecnologia e ciências exatas.

Contudo, de maneira mais recente, outras áreas, além das ciências exatas e tecnologias, iniciaram o uso da Inteligência Artificial para atingir resultados mais precisos e satisfatórios. É

o caso da medicina, área da qual procuraremos mostrar nesse estudo, a ligação com a AI e os resultados dessa relação.

Desde algum tempo, busca-se desenvolver sistemas computadorizados de apoio ao diagnóstico clínico. Howard Bleish, há mais de 50 anos, já oferecia um sistema que, avaliando dados de um paciente, sugeria ações para restabelecer seu equilíbrio hidroeletrolítico. Vários sistemas foram desenvolvidos com o objetivo de oferecer uma lista de possíveis diagnósticos para um problema de saúde, com as probabilidades de acerto, usando dados da gênese e evolução desse problema, avaliando sinais e sintomas de pacientes, analisando resultados de exames realizados e propondo possibilidades diagnósticas (LOBO, 2017 p. 03).

Compreende-se assim, que o uso da tecnologia deixou há muito de ser um resultado de processos e passou a ser agente ativo do desenvolvimento, não só teórico, mas pessoal e social do meio onde está inserida.

## 1.1 PROBLEMÁTICA

Atualmente, ainda que o diagnóstico por imagem tenha ampliado a capacidade de execução, muitos exames tornam-se custosos ou trabalhosos demasiadamente: com o surgimento de novas doenças, como a COVID-19, a rapidez em diagnosticar pode significar uma vida salva. Em um cenário como o que vivemos, onde cada minuto é importante a precisão no resultado tanto quanto, buscamos aprimorar o diagnóstico por imagem através da tecnologia *Deep Learning*, facilitando o diagnóstico e agindo de forma assertiva sobre a leitura de imagens.

## 1.2 OBJETIVO GERAL

Criar um experimento com a tecnologia de *Deep Learning* que possa ser utilizado na área de diagnóstico por imagem para reconhecimento de imagens de pulmões comprometidos com a doença de SARS-Cov-2 (COVID 19) , pensando seu funcionamento a partir de estudos bibliográficos.

### 1.2.1 OBJETIVOS ESPECÍFICOS

- Aplicar a teoria da *Deep Learning* na área médica por meio de prova de conceito;
- Mapear imagens de pulmões comprometidos pela COVID 19 e compará-los a outras comorbidades, a fim de ter um diagnóstico claro e preciso.
- Construir o protótipo de prova de conceito para detecção do COVID 19;
- Analisar os resultados obtidos;
- Projetar cenário de uso da tecnologia em casos futuros;

### 1.2.3 JUSTIFICATIVA

O uso da tecnologia é cada vez mais crescente e presente na sociedade coetânea, desde o uso para distrações do dia a dia, interação entre iguais e uso em diversas áreas de conhecimento. A tecnologia, uma vez material de estudo das áreas de física, engenharia, sistemas de informação e seus pares, hoje, abrange também áreas como neuropsicologia, marketing, publicidade, gastronomia e medicina. Existe uma relação de interdependência entre cultura, economia, política, sociedade e tecnologia, como pode-se apreciar através do pensamento de Diogo

É neste quadro de apropriação do saber técnico utilizável que podemos compreender a questão da valoração do sistema tecnológico. O século XIX tem uma visão claramente otimista da tecnologia na medida em que ela potencializa um progresso material conotado positivamente. A máquina funciona, física e metaforicamente, como o centro do sistema técnico, permitindo o acesso as dimensões quantitativa e qualitativa presentes no conceito de progresso. (DIOGO, 2009 p. 8)

A tecnologia tem a conotação de funcionalidade, maximizando os conhecimentos. Ao longo dessa monografia, discutiremos o paralelo entre tecnologia *Deep Learning* no contexto médico, avaliando as diversas formas de intervenção tecnológica para experienciar a melhora qualitativa da performance médica, refletindo, conseqüentemente, na expectativa de vida e tratamento dos pacientes. Um dos aspectos mais característicos da medicina no período atual tem sido as excepcionais invenções e inovações tecnológicas especializadas no combate a diferentes enfermidades e sua rápida, senão imediata, aceitação e incorporação às práticas médicas

(ALMEIDA; ANTAS JUNIOR, 2015).

O conceito de *Deep Learning*, por sua vez, apesar de ser recente, é proveniente da *Machine Learning*, conceito que foi incorporado em sociedade na última década e baseia-se na utilização de algoritmos para extrair informações de dados brutos e representá-los através de algum tipo de modelo matemático (ACADEMY, 2019). Porém o *Deep Learning*, surge de um aprofundamento desse conceito, é a capacidade de inteligência da máquina de forma mais aprofundada. Esse conceito, tende a impactar com muita força a área da saúde. A ideia de que o impacto será grande, com provável transformação da prática clínica do dia a dia em algumas áreas como radiologia, patologia, oftalmologia e diagnósticos oftalmológicos tem sido corroborada por publicações científicas (AMATO, 2013 p. 47 - 58 apud LEITE, 2019 p. 3).

Sabe-se que as decisões médicas dependem diretamente das hipóteses de diagnóstico para o tratamento assertivo, sem esses dados cruciais, decisões incertas podem ser tomadas, comprometendo a saúde do paciente. Em contrapartida, sabemos também que, a busca pelo diagnóstico mais apropriado, requer uma série de exames, gerando gastos altos ao paciente ou aos cofres públicos.

Em 2009, verificou-se que 32% dos erros médicos nos EUA resultavam da diminuição do tempo de interação do médico com os pacientes, produzindo diagnósticos equivocados, não reconhecimento da urgência ou piora da evolução do paciente que demandariam prescrever ou realizar ações pertinentes. Mesmo em hospitais que disponham de prontuários médicos eletrônicos, com a possibilidade de melhor coleta de dados, admite-se que 78,9% dos erros médicos estariam relacionados a problemas na relação médico-paciente, exame clínico deficiente, falha de avaliação dos dados do paciente ou falta de exames que comprovassem a hipótese diagnóstica. (LOBO, 2017 p. 06).

O uso da tecnologia, nesse sentido, apresenta-se como uma saída para essa problemática, pois através do seu uso, torna o diagnóstico mais rápido e assertórico, melhorando quantitativamente o tempo de relação entre médico e paciente. Médicos e farmacêuticos se beneficiam muito com esses sistemas que confrontam dados e prescrições, evitando casos de medicações inadequadas e diagnósticos errôneos (LOBO, 2017). Com o intuito de envolver a tecnologia como uma solução a problemas sociais, justifica-se esse projeto.

### 1.3 ESTRUTURA

No capítulo a seguir, desenvolveremos a revisão bibliográfica, que será dividido em quatro partes. Inicialmente, desenvolveremos o conceito de diagnóstico por imagem, como é feito e quais critérios qualificam o exame. Em seguida, desenvolveremos o conceito de *Deep Learning*, sua estrutura, funcionamento e exemplos. A terceira parte, unifica os conceitos, trabalhando o Deep Learning dentro do diagnóstico por imagem, como essa abordagem pode revolucionar o meio médico. Por fim, temos as considerações finais, onde finalizamos as ideias desenvolvidas ao longo da Monografia.

## 2 REVISÃO BIBLIOGRÁFICA

Nesse capítulo, abordaremos através da revisão bibliográfica, os conceitos que tangem nosso trabalho: diagnóstico por imagem, *Deep Learning*, a leitura de imagens de radiográficas através da tecnologia *Deep Learning*, bem como os parâmetros gerais sobre SARS-COV-2 (COVID-19), pneumonia viral e pulmão saudável. Nosso objetivo é construir um texto de forma clara e bem sólida, a fim de servir-nos de base para a construção da prova de conceito.

### 2.1 DIAGNÓSTICO POR IMAGEM

O diagnóstico por imagem, revolucionou a área da medicina, e ainda vem revolucionando a medida que se atualiza em uma relação íntima com a tecnologia. Porém, antes de tudo, precisamos compreender um pouco da sua história, em paralelo, entenderemos a dimensão da importância desse segmento dentro da área da saúde.

De acordo com a Sociedade Paulista de Radiologia e Diagnóstico Por Imagem (SPR), essa história começa em 1895, quando o físico alemão Wilhelm Conrad Roentgen, através de experimentos com radiação, consegue a primeira imagem de raio x da história, contendo a mão de sua esposa.

No dia 8 de novembro de 1895, Wilhelm Conrad Röntgen, então professor de física na Universidade de Würzburg, Bavária, Alemanha, descobre uma nova espécie de radiação produzida pela passagem de uma corrente elétrica por um tubo de vidro sob vácuo, e que possuía a singular qualidade de, embora invisível a olho nu, produzir fluorescência ao incidir sobre um papel impregnado por cianureto de bário e platina. Mais impressionante era a capacidade destes raios de atravessar corpos sólidos (madeira, papel, partes do corpo humano), com maior ou menor intensidade, dependendo da natureza do material. Em 28 de dezembro de 1895, seu trabalho "Über eine neue Art von Strahlen" ("Sobre uma nova espécie de raios"), de 10 páginas, foi submetido para publicação e descreve de forma sucinta e objetiva a sua descoberta. (ARRUDA, 1996 p. 525)

De fato, o experimento com radiação de Rontgen trouxe a possibilidade em ver o corpo humano por dentro, sem precisar abri-lo, como era de costume na época, fazendo-o inclusive, ganhar o prêmio Nobel. Porém, os efeitos dos tratamentos com a radiação, foram extremamente maléficis para a população da época. Há inúmeros relatos de pessoas que sobreviveram a tiros,

mas sucumbiram à radiação quando os médicos recorriam ao invento de Roentgen para localizar a bala. (VALE, 2009 p. 60).

O diagnóstico por imagem, se trata em essência da tecnologia aplicada a medicina: desde o início, quando o físico Wihelman Conrad faz descobertas sobre o raio-x (FENELON, p. 01), já podemos associar o uso desse objeto como uma também da tecnologia. Porém, essa mesma tecnologia passou por diversos níveis de desenvolvimento.

A grande evolução da Radiologia deu-se a partir dos anos 70-80, com grandes avanços tecnológicos, que permitiram um diagnóstico muito mais preciso. Desde então, a radiologia, vem obtendo grande espaço na prática médica. O advento dos novos métodos diagnósticos, tais como a ultra-sonografia, mamografia digital, desintometria óssea, tomografia computadorizada e multislice, PT/CT e PET/RM, ressonância magnética 3T e radiologia digital, fez surgir uma nova especialidade, a imaginologia. Isto é, conjunto de das técnicas de diagnóstico que fornecem ao médico uma imagem visual das diversas partes do corpo humano, qualquer que seja a radiação ou a forma como ou a onda utilizada para exploração do paciente. (OLIVEIRA et al, 2008, p.02)

Nesse mesmo período, junto com essa nova possibilidade de diagnóstico dentro da medicina, surge também os médicos especializados na área, com o intuito de se tornar um especialista na leitura dessas imagens e facilitar o diagnóstico do paciente.

Ainda assim, o movimento médico, passou com a ajuda de físicos e demais especialistas, a aprimorar o invento de Wilhelm, expandindo a área de diagnóstico por imagem. Atualmente contamos com diferentes exames, como: Radiologia Convencional, Tomografia Computadorizada, Ressonância Magnética e Ultrassonografia (BORGES, 2014). A radiologia convencional, já foi destaca anteriormente na descrição deste texto, portanto, não adentraremos profundamente em seus aspectos. A tomografia computadorizada, por sua vez, permite um estudo ampliado do encéfalo, com imagens, como se fossem pequenas fatias de toda a área.

O aparelho consiste em uma fonte de raios-X que é acionada ao mesmo tempo em que realiza um movimento circular ao redor da cabeça do paciente, emitindo um feixe de raios-X em forma de leque. No lado oposto a essa fonte, está localizada uma série de detectores que transformam a radiação em um sinal elétrico que é convertido em imagem digital. Dessa forma, as imagens correspondem a seções ("fatias") do crânio. A intensidade (brilho) reflete a absorção dos raios-X e pode ser medida em uma escala (unidades Hounsfield). (YAMASHITA e JUNIOR, 2001 p. 02).

A ressonância magnética, pode ser subdividida em funcional, ou não. Em algumas revisões bibliográficas, também foi permitido encontrar a subdivisão como sendo ressonância magnética nuclear, ou ressonância magnética funcional. De forma geral, a ressonância magnética, pode ser dividida em três etapas, a primeira delas, diz respeito ao alinhamento

O alinhamento se refere à propriedade magnética de núcleos de alguns átomos, que tendem a se orientar paralelamente a um campo magnético (como uma bússola em relação ao campo magnético da terra). Por razões físicas e pela abundância, o núcleo de hidrogênio (próton) é o elemento utilizado para produzir imagens de seres biológicos. (YAMASHITA e JUNIOR, 2001 p. 04).

A segunda etapa, sugere a excitação.

Sabe-se que cada núcleo de hidrogênio "vibra" numa determinada frequência proporcional ao campo magnético em que está localizado. Assim, em 1,5 T, o hidrogênio tem frequência de 63,8 MHz. O aparelho emite então uma onda eletromagnética nessa mesma frequência. Existe uma transferência de energia da onda emitida pelo equipamento para os átomos de hidrogênio, fenômeno conhecido como ressonância. (YAMASHITA e JUNIOR, 2001 p. 04).

E a terceira e última etapa, diz respeito a detecção da radiofrequência

Quando os núcleos de hidrogênio receberam a energia, tornaram-se instáveis. Ao retornar ao estado habitual, eles emitem ondas eletromagnéticas na mesma frequência (63,8 MHz - faixa de ondas de rádio). Então o equipamento detecta essas ondas e determina a posição no espaço e a intensidade da energia. Essa intensidade é mostrada como "brilho" na imagem, sendo utilizada a nomenclatura "intensidade de sinal". (YAMASHITA e JUNIOR, 2001 p. 04).

É preciso falar também sobre a ultrassonografia, esse tipo de exame, diferente do que vimos até o momento, não faz uso de radiação para obter resultados. A tecnologia da ultrassonografia é baseada na frequência de ondas sonoras, permitindo verificar qualquer tipo de variação anatômica destoante do convencional, atualmente, é possível realizar diagnóstico de diversas áreas do corpo utilizando a ultrassonografia

Assim como a tecnologia, os princípios da ultrassonografia são bem conhecidos e sua utilização como modalidade terapêutica e diagnóstica primária na prática radiológica é bem fundamentada. Nos últimos anos, a tecnologia da ultrassonografia evoluiu e, hoje, é usada fora da especialidade da radiologia. É comum o uso da ultrassonografia em obstetrícia e cardiologia. A aplicação da ultrassonografia em outras áreas, como na medicina emergencial e na unidade de terapia intensiva, cresce rapidamente. Em virtude da expansão de seu uso para além do domínio da radiologia tradicional, os fabricantes precisaram adaptar o equipamento, construindo aparelhos menores e portáteis que pudessem ser usados no local de atendimento. (FARMER e SLONIM, 2013 p. 06).

Compreender o funcionamento e especificações do diagnóstico por imagem, é crucial para o desenvolvimento deste trabalho, pois, através dessa compreensão, conseguimos definir quais os principais problemas e de que forma a tecnologia de deep learning pode operar sobre eles, contribuindo para o crescimento da área médica e sobretudo, para o tratamento mais adequado para os pacientes. De acordo com Briani a influência do mercado de trabalho e da

adoção de recursos tecnológicos cada vez mais avançados na prática médica traz reflexos inegáveis para o ensino (BRIANI, 2001, p. 25 -73 apud OLIVEIRA, 2014, p. 21), portanto, a necessidade da tecnologia no meio médico torna-se inquestionável.

Segundo Wanderlei (2020) existe uma gama de diversos exames a partir do diagnóstico de imagem, porém, algumas aceitam melhor a interferência da tecnologia Deep Learning no seu processo diagnóstico. A Tomografia computadorizada, destaca-se dentre elas, pois, através dela, os médicos podem visualizar estruturas internas como ossos, órgãos e outros tecidos. Além das imagens serem obtidas de vários ângulos. Porém, no processo da tomografia computadorizada, são geradas em média 320 lâminas de imagiologia, o que torna o processo deveras custoso (WANDERLEI, 2020).

Não pode-se também, deixar de citar a importância de questões éticas e de responsabilidade profissional que os especialistas da área podem enfrentar. Questões que Fenelon (2003) citando por Imperícia, Imprudência e Negligência. Ainda de acordo com o autor, a Imperícia é caracterizada por despreparo prático ou insuficiência de conhecimento, A Imprudência por sua vez, caracteriza-se como ato de precipitação, insensatez mediante a imagem do diagnóstico. A Negligência, como faz-se referência a própria denominação, é o momento em que o médico deixa de tomar determinadas decisões, provocando danos ao paciente. O uso da tecnologia de *Deep Learning* aplicada a exames de diagnóstico por imagem, vem com o intuito de minimizar, principalmente os erros de Imprudência e Imperícia.

## 2.2 DEEP LEARNING: CONCEITOS, APLICAÇÕES E ESTRUTURAS

Quando traduzido para o português, o termo inglês conhecido como *Deep Learning* significa aprendizado profundo. Logo, inicialmente, não se trata apenas de um termo utilizado na área das ciências da computação, mas sim, um termo geral que nos fala sobre o aprofundamento do aprendizado, conhecimento e/ou inteligência.

Dessa forma, é crucial que entendamos o que significa inteligência/aprendizado humano, para então entendermos a base da inteligência artificial. Ainda que a inteligência humana tenha passado por diversos conceitos, desde testagem quantitativas do Quociente de Inteligência (Q.I.), até análise de dimensões afetivas, passando também por conceitos como as Inteligências Múltiplas de Howard Gardner e a teoria da Inteligência Emocional de Daniel Goleman e ainda que a sua definição seja diversa e esteja apoiada em múltiplos fatores, um fator

importante a ser levado em consideração é a capacidade de resolução de problemas, adaptando o cérebro a novas aprendizagens (SOBRAL, 2013). Nesse sentido, com a evolução histórica do conceito de inteligência, e de suas concepções e tipologia, é possível, na atualidade, percebê-la como a capacidade humana de solucionar problemas de diversas ordens: afetiva, volitiva e cognitiva. (SOBRAL, 2013 p. 14).

O conceito de Inteligência Artificial começou a ser utilizada e estudada a partir do 1956, quando o cientista da computação, John McCarthy e um grupo de colegas estudantes, de propõem a pensar na utilização de linguagem humana, capacidade de resolver problemas, formar abstrações e conceitos pelas máquinas de computador. Ou seja, mais que realizar funções das quais já há uma programação definida, com funcionamento estabelecido, John McCarthy e seus colegas, acreditavam na capacidade das máquinas em reproduzirem aspectos da cognição humana. (REIS ET AL, 2019). Desde então, esse conceito de inteligência dentro da Ciência da Computação, não para de evoluir, a cada ano, novos estudos e aprimoramentos surgem na área, de forma que hoje, chegamos a conceitos como *Machine Learning* e *Deep Learning*.

O mundo denominado “*technology*” evolui na velocidade do volume de *Big Data*, que são dados produzidos bem além dos *Petabytes*, *Exabytes* ou mesmo do *Zettabyte* – que representa um bilhão de Terabyte. Essa evolução leva a IA também a evoluir, formando a *Machine Learning* “aprendizagem das máquinas” que, por sua vez, está evoluindo para *Deep Learning* “aprendizagem profunda baseada em gráficos”. Embora a aprendizagem de máquina tenha se tornado parte integrante do processamento de dados, uma das principais diferenças em relação à aprendizagem profunda é que ela exige uma intervenção manual na seleção dos recursos a serem processados, enquanto a aprendizagem profunda é intuitiva, residindo-se nestes assuntos para os próximos estudos. (REIS ET AL, 2019 p. 10).

Dessa forma, os conceitos de *Machine Learning* e *Deep Learning*, são camadas da Inteligência Artificial. O primeiro conceito criado por John McCarthy e seus amigos, transformou-se a tal ponto, que desenvolvemos o conceito de *Machine Learning*, o conceito deste último, evoluiu de tal maneira, com estruturas cada vez mais complexas, que hoje estamos desenvolvendo o *Deep Learning*.

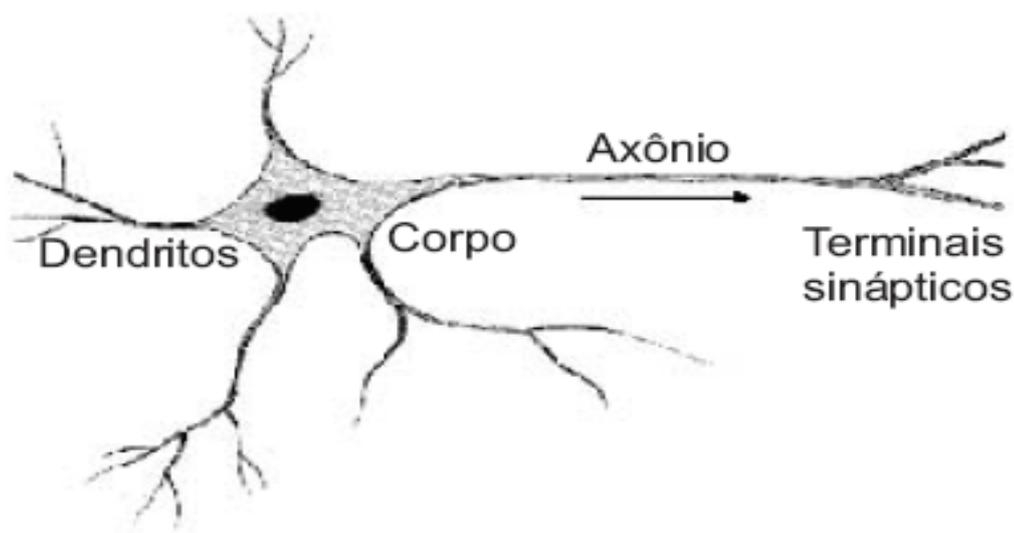
O termo *Machine Learning*, com tradução para o português, é entendido como Aprendizado da Máquina, onde o propósito do cientista da computação é, enviar dados para as máquinas, para que a partir desses dados, seja possível criar conceitos, em um processo de comparação sistêmica, onde depois de inúmeras aproximações, tentativas e erros, se torna possível construir um padrão de assertividade, ou seja, de aprendizagem. Esse padrão irá gerar estimativas através de vários algoritmos diferentes. A classificação através do *Machine Learning* pode ser binária ou não. Claramente, nos referimos até o momento a uma classificação ampla do que pode ser a *Machine Learning*, porém, a partir desse contexto, iniciaremos a discussão sobre especificidades desse modelo dentro da Inteligência Artificial.

Um conceito extremamente importante para o entendimento do funcionamento da *Machine Learning*, é o conceito de Redes Neurais. O princípio de Redes Neurais aplicadas na Inteligência Artificial, mais especificamente na *Machine Learning*, surge inspirada nas redes neurais humanas.

As redes neurais humanas, dizem respeito ao funcionamento cerebral, sabendo que, o encéfalo é composto por milhões de neurônios. Os neurônios realizam o movimento que chamamos de sinapses: as sinapses são a troca de informação entre esses neurônios, que acontecem em diversos níveis, contínuas vezes (FERNEDA, 2006).

Um neurônio é uma célula formada por três seções com funções específicas e complementares: *corpo*, *dendritos* e *axônio*. Os dendritos captam os estímulos recebidos em um determinado período de tempo e os transmitem ao corpo do neurônio, onde são processados. Quando tais estímulos atingirem determinado limite, o corpo da célula envia novo impulso que se propaga pelo axônio e é transmitido às células vizinhas por meio de sinapses. Este processo pode se repetir em várias camadas de neurônios. Como resultado, a informação de entrada é processada, podendo levar o cérebro a comandar reações físicas. (FERNEDA, 2006 P. 02)

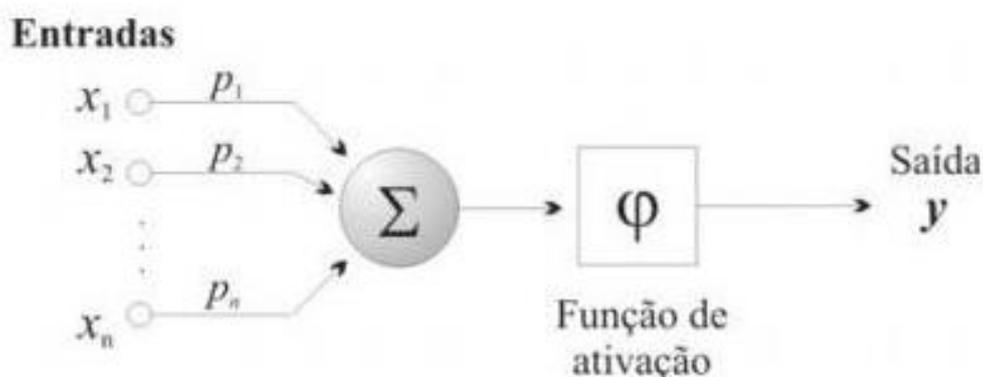
Figura 1 – Estrutura de um neurônio



Fonte: Ferneda (2006)

Dessa forma, a habilidade em realizar funções complexas, aprendizado e capacidade cognitiva dos seres humanos, advém da estrutura de comunicação entre os neurônios. Portanto, a melhor forma de criar um sistema de inteligência artificial, baseia-se no funcionamento do encéfalo humano. O formato e processamento de um neurônio artificial é muito similar ao neurônio humano, como observar na figura conseguinte, a morfologia deste e a estrutura através de um modelo matemático

Figura 2 – Modelo matemático de um neurônio



Fonte: FERNEDA (2006)

Neste modelo, temos três elementos básicos na composição que precisam ser compreendidos: os conjuntos de conexões de entrada (representados pelos fatores  $X^1$ ,  $X^2$  e  $X_n$ ), cada uma dessas conexões representadas por diferentes pesos ( $P^1$ ,  $P^2$  e  $P_n$ ). Um somador, que acumula e realiza a soma dos pesos, representada pelo símbolo  $\Sigma$  e a função de ativação,  $\phi$ , que delimita a frequência da propagação da informação na saída ( $y$ ) com um valor fixo (FERNEDA, 2006).

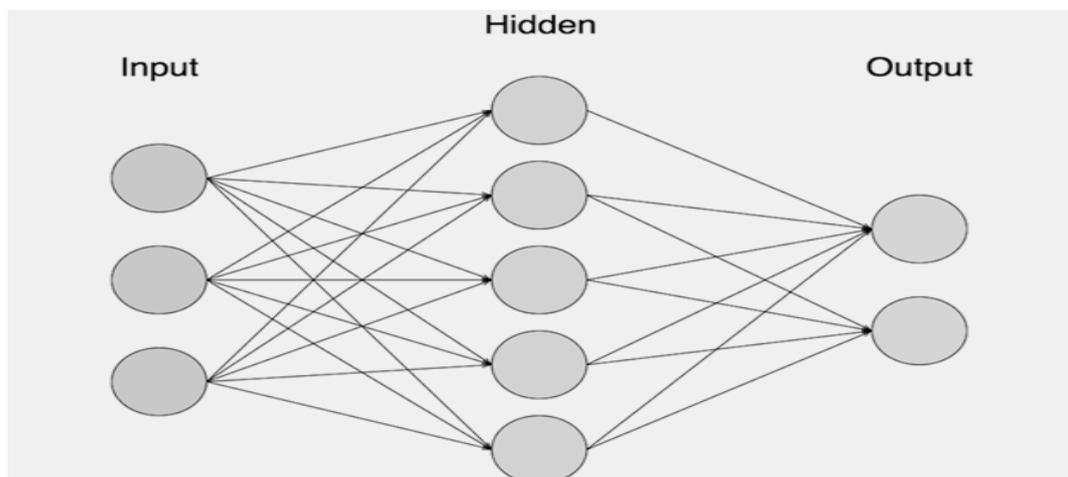
O comportamento das conexões entre os neurônios é simulado por meio de seus pesos. Os valores de tais pesos podem ser negativos ou positivos, dependendo de as conexões serem inibitórias ou excitatórias. O efeito de um sinal proveniente de um outro neurônio é determinado pela multiplicação do valor (intensidade) do sinal recebido pelo peso da conexão correspondente ( $X^1 P^1$ ). É efetuada a soma dos valores  $X^1 P^1$  de todas as conexões, e o valor resultante é enviado para a função de ativação, que define a saída ( $y$ ) do neurônio. (FERNEDA, 2006 p. 26).

Porém, ainda que a inspiração das funções da *Machine Learning* e da *Deep Learning* venham do funcionamento do cérebro humano, não podemos dizer que sua estrutura é exatamente igual, tanto em morfologia quanto em funcionalidade. A tarefa de tentar criar uma cópia do cérebro humano, é responsabilidade da neurociência computacional (OLIVEIRA, 2019). A *Machine Learning* e posteriormente, da *Deep Learning*, se utilizam do conceito de compartilhamento de informações através de redes neurais, com o intuito de resolver problemas complexos, com ou sem a intervenção humana durante esse processo. Logo, podemos deduzir, como nos afirma Oliveira, que uma rede neural artificial, trata-se sobretudo, de um processador de dados

Uma rede neural é um processador paralelamente distribuído constituído de unidades de processamento simples. Essas unidades armazenam conhecimentos experimentais. O processo para realizar o aprendizado é por meio de um algoritmo de Machine

Learning, cuja função é modificar os pesos da rede para alcançar um objetivo final. (OLIVEIRA, 2019 p. 02)

Figura 3 – Modelo de uma rede neural artificial



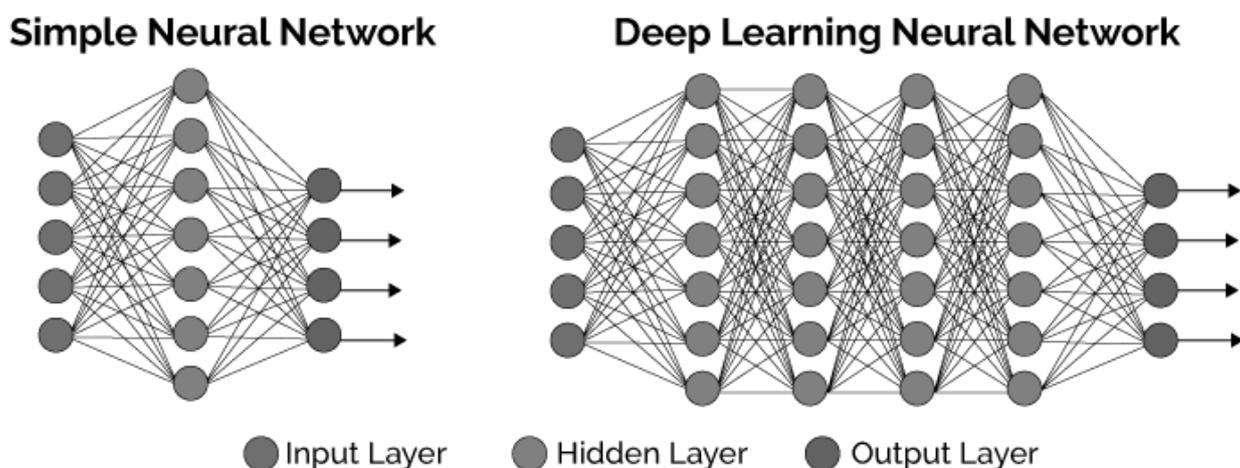
Oliveira, 2019

Pode-se pensar a imagem acima, como um neurônio artificial, porém, mais desenvolvido para realizar as funções designadas. Assim como o modelo neuronal, existe um canal para entrada de dados, um para processamento e um para valor final, ou resultados. Nesse caso o *Input* é responsável por receber as informações que serão decodificadas, o setor denominado *Hidden*, é responsável pelo processamento desses dados iniciados na *Input*, quanto mais camadas de *Hidden* uma rede apresentar, maior será sua capacidade de extrair estatísticas mais elaboradas, e por fim, o setor *Output*, baseado em todas as estatísticas extraídas do *Hidden*, consegue responder com um valor final, ou com uma estimativa final. É importante ressaltar que existe uma diferença latente entre esse modelo de rede neural e os modelos de redes neurais mais profundos, que é o caso da tecnologia de *Deep Learning*, como veremos a seguir.

A tecnologia de *Deep Learning* surge como um aprimoramento da *Machine Learning*: um tipo de algoritmo mais sofisticado de *Machine Learning*, construído a partir do princípio das redes neurais. Porém, diferentemente dos primeiros algoritmos existentes, é capaz de suportar e trabalhar com grande fluxo de dados, chamado de *Big Data*, e funcionar como uma mente própria através de sobreposição de camadas não lineares de processamento de dados. Enquanto a *Machine Learning* é uma tecnologia estudada e aplicada desde os anos 80, a *Deep Learning* surgiu por volta dos anos 2000, quando dispusemos de computadores mais sofisticados, com grande número de dados acessíveis (CHAGAS, 2019). De forma simplificada, podemos dizer que *Deep Learning* são algoritmos complexos construídos a partir de um empilhamento de diversas camadas de “neurônios”, alimentados por quantidades imensas de dados, que são capazes de

reconhecer imagens e fala, processar a linguagem natural e aprender a realizar tarefas extremamente avançadas sem interferência humana. A principal aplicação dos algoritmos de *Deep Learning* são as tarefas de classificação, em especial, reconhecimento de imagens.

Figura 4 – Comparações entre uma rede neural simples e a Deep Learning

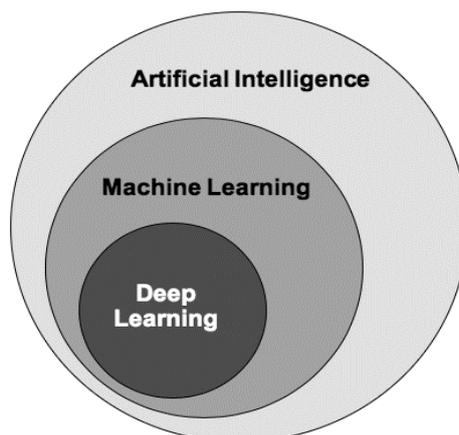


(Vázquez, 2017)

Claramente demonstrado na figura 4, é possível perceber a evolução da rede neural artificial, se antes era necessário computar muitos dados para chegarmos a um resultado, agora a rede neural tornou-se mais rápida e precisa.

Dadas essas circunstâncias, uma família de algoritmos em especial prosperou mais: redes neurais. No passado, algumas das desvantagens das redes neurais eram a grande quantidade de dados necessários para obter bons resultados e a baixa velocidade do treinamento. Os eventos recentes ajudaram a mitigar essas desvantagens, possibilitando o desenvolvimento de redes neurais com várias camadas, daí o nome Aprendizagem Profunda ou Deep Learning. O Deep Learning em si não é uma técnica, mas uma rede neural com várias camadas. Mais interessante ainda, existem algumas especializações. Alguns deles tiveram resultados muito promissores: Redes Neurais Convolucionais (*Convolutional Neural Networks* ou CNNs) e Redes Adversas Generativas (*Generative Adversarial Networks* ou GANs). (KENJI, 2019)

Figura 5 – Gráfico situacional sobre Deep Learning



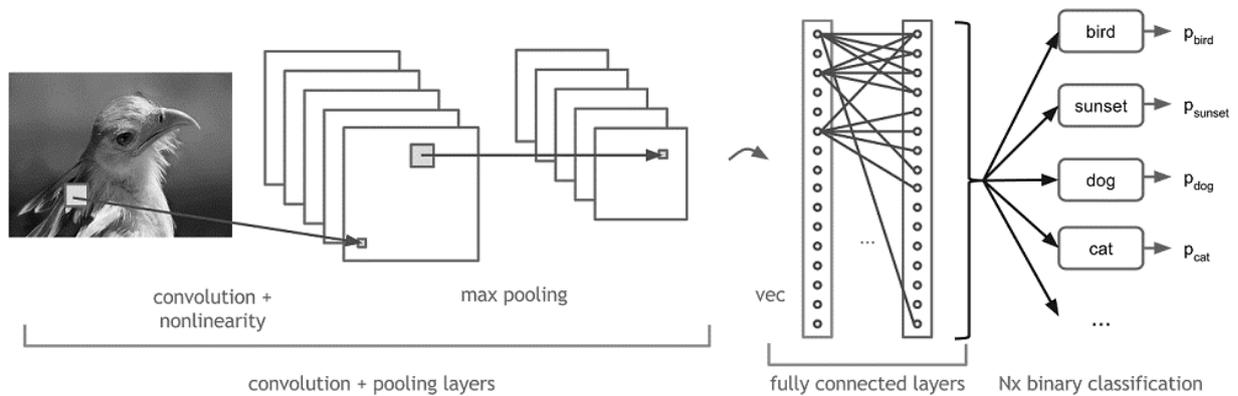
(Kenji, 2019)

Nesse estudo, nos atermos às redes neurais convolucionais, pois essas redes são próprias para desenvolvermos nosso objetivo: o diagnóstico de imagem. As redes convolucionais trata-se de um modelo de rede neural, dentro da *Deep Learning*, capaz de realizar ações sem a necessidade da supervisão de um cientista de dados, configurando-se como uma rede neural autônoma, permitindo que a Inteligência Artificial seja treinada com uma lógica que se aproxima ao esquema de tentativa e erro (ALIGER, 2020). Essa espécie de rede neural é muito eficaz para leitura de imagens, por exemplo, sendo muito utilizada em tecnologias de carros autônomos, robótica, drones, segurança, diagnóstico de imagem e tratamentos para deficientes visuais (DATA SCIENCE, 2016). Porém, precisamos ter como ponto de partida, a certeza de que, as redes neurais convolucionais não enxergam uma imagem da mesma forma que um ser humano, e isso faz toda a diferença no momento que nos propomos a entender a lógica dessa rede neural. Para leitura de imagens, as redes convolucionais fazem uso de tensores, que são matrizes de números com várias dimensões, dessa forma, as imagens são percebidas como volumes, como objetos tridimensionais, sendo medidas para além da lógica altura x largura. Isso acontece porque as cores digitais, tem por padrão uma codificação de cores: vermelho – verde – azul (RGB – Red – Green – Blue), misturando essas três cores para criar o espectro de cores percebidas pela visão humana. (DATA SCIENCE, 2016).

À medida que as imagens se movem através de uma rede convolucional, descrevemos em termos de volumes de entrada e saída, expressando-as matematicamente como matrizes de múltiplas dimensões dessa forma:  $30 \times 30 \times 3$ . De camada em camada, suas dimensões mudam à medida que atravessam a rede neural convolucional até gerar uma série de probabilidades na camada de saída, sendo uma probabilidade para cada possível classe de saída. Aquela com maior probabilidade, será a classe definida para a imagem de entrada, um pássaro por exemplo. (DATA SCIENCE, 2016).

A seguir, na figura 6, demonstra-se com clareza como é realizado o processo de cada pedaço da imagem por uma rede neural, onde cada pequeno pedaço é amplamente analisado antes de qualquer resultado.

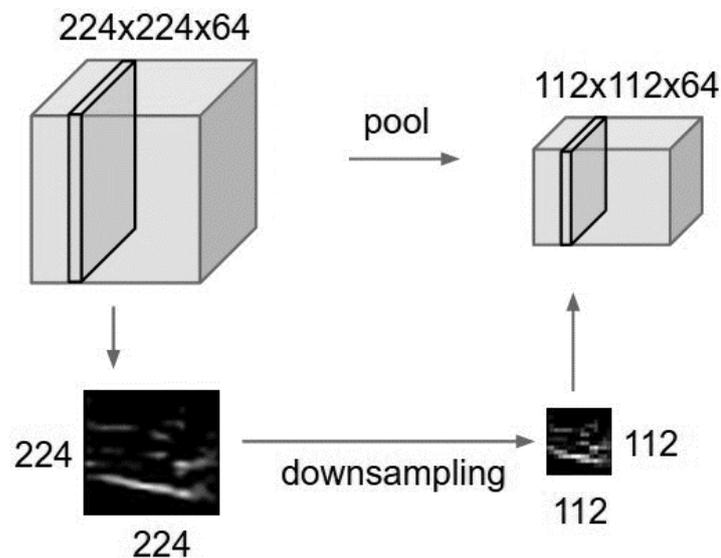
Figura 6 – Leitura de imagem em Deep Learning através de Redes Neurais Convolucionais



(Data Science, 2016)

Dentro do processamento de imagens através das redes convolucionais, também encontramos outro aspecto importante, que são as camadas de agrupamento dentro dessas redes, a esses, nomeamos como *Pooling*. As camadas de *pooling* são responsáveis por simplificar as informações na saída da camada convolucional. O *pooling* é, em outras palavras, um processo de redução da dimensão da imagem, de forma simplória, poderíamos dizer que é uma redução do tamanho da imagem. O principal objetivo dessa operação é diminuir a variância a pequenas alterações, e, também reduzir a quantidade de parâmetros treinados pela rede (CLAPPIS, 2019)

Figura 07 – Exemplo de downsampling (pooling)

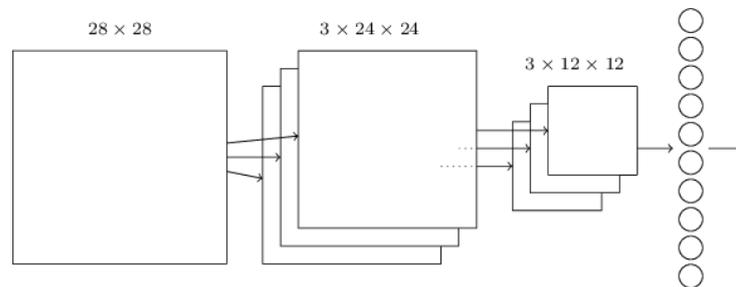


(CLAPPIS, 2019).

Os processos de *pooling* podem ser divididos de três formas, de acordo com suas operações: *Max Pooling*, *Sum Pooling* e *Average Pooling*. Todas seguem o mesmo princípio, diferenciando-se somente na forma como calculam o valor final. A técnica mais utilizada atualmente é a *Max Pooling* (CLAPPIS, 2019).

Podemos pensar em Max-Pooling como uma forma de a rede perguntar se um determinado recurso é encontrado em qualquer lugar de uma região da imagem. Em seguida, elimina a informação posicional exata. A intuição é que, uma vez que um recurso tenha sido encontrado, sua localização exata não é tão importante quanto sua localização aproximada em relação a outros recursos. Um grande benefício é que há muito menos recursos agrupados e, portanto, isso ajuda a reduzir o número de parâmetros necessários nas camadas posteriores (DATA SCIENCE, 2016 p. 43)

Figura 8 – Rede Neural Convolutiva Completa



(Data Science, 2016)

A rede começa com  $28 \times 28$  neurônios de entrada (cada imagem de cada dígito do dataset MNIST tem  $28 \times 28$  pixels), que são usados para codificar as intensidades de pixel para uma imagem no dataset MNIST. Este é então seguido por uma camada convolutiva usando um campo receptivo local de  $5 \times 5$  e três mapas de características. O resultado é uma camada de  $3 \times 24 \times 24$  neurônios ocultos. A próxima etapa é uma camada de Max-Pooling, aplicada a regiões  $2 \times 2$ , em cada um dos três mapas de recursos. O resultado é uma camada de  $3 \times 12 \times 12$  neurônios ocultos. (Data Science, 2016 p. 46)

Dessa forma, a partir dessa lógica, temos acesso a uma rede composta de muitas unidades simples, onde os comportamentos são determinados por seus pesos e vieses, em busca da maior assertividade possível na leitura de imagens.

### 2.3. DEEP LEARNING NO DIAGNÓSTICO POR IMAGEM

A tecnologia de Inteligência Artificial vem aprimorando várias áreas, em específico, na área médica, a engenharia de *Deep Learning*, apresenta resultados muito satisfatórios,

conquistando cada vez mais espaço, por serem mais rápidas e mais assertivas que aguardar a opinião de diferentes especialistas. Precisamos entender, antes de tudo, que nos últimos anos, a popularização dos exames por imagens apresenta uma crescente importância, gerando um grande número de dados a serem estudados e compreendidos (PAIVA, PREVEDELLO, 2017). Para cada grande leva de dados, são necessários vários profissionais para análise mais conclusiva dos exames, e, ainda assim, o diagnóstico nem sempre é propositivo, podendo ocorrer erros consequentes no tratamento dos pacientes.

O desenvolvimento de redes neurais artificiais permitiu solucionar alguns problemas de outras técnicas de *machine learning*. Nos métodos tradicionais, que são a base de funcionamento de alguns *softwares* de auxílio diagnóstico — por exemplo, *computer-aided diagnosis* —, o aumento da quantidade de dados condiciona uma melhora da acurácia até um certo ponto. Com o *deep learning*, técnica que se utiliza de camadas ocultas de redes neurais artificiais, a acurácia tende a continuar aumentando à medida que novos dados são adicionados. Isso permitiu, por exemplo, que em 2015, pela primeira vez, em uma competição anual de reconhecimento de objetos em imagens cotidianas, o desempenho da máquina superasse o humano. (PAIVA ANTUNES E PREVEDELLO, 2017 p. 02)

No entanto, a tecnologia ainda está sendo implementada nas áreas da medicina gradativamente. Como exemplo, realizaremos uma análise de um *software* comumente usado na leitura de imagens: *PAC*. A partir da análise desse modelo, construiremos hipóteses de interferência da *Deep Learning* para a melhoria no processo do *software*.

*PACS* é uma terminologia vinda do inglês, que significa *Picture Archiving and Communication System*, ou traduzido para o português Sistema de Arquivamento e Comunicação de Imagens. A ideia desse *software* é criar um ambiente, onde todas as imagens médicas, em formato digital, possam ser acessadas, de qualquer espaço da clínica ou hospital. Assim, podemos dizer que um *PACS* deve oferecer acesso às imagens digitais de um paciente através do acesso remoto, utilizando as redes locais. Uma das principais características do *PACS* é ser um dos sistemas mais utilizados no meio médico, criando no hospital um ambiente amplo e integrado, focado na comunicação interna por meio de espaços radiológicos digitais. (MARQUES AZEVEDO E SALOMÃO COVAS, 2009).

Porém, para que essa comunicação aconteça de forma clara e cumpra seus objetivos, precisa-se de uma organização na ordem da distribuição de informações. Dessa forma, é seguida uma estrutura hierárquica com base de distribuição *top-down*, entre outras palavras, as informações são propagadas a partir do sistema de informação mais geral (HIS), passando pelo

sistema de informação intermediário (RIS) até alcançar o sistema de informação mais específico (PACS) (MARQUES AZEVEDO E SALOMÃO COVAS, 2009 p. 02). Para que todo esse processo seja possível, existem dois pré requisitos a serem cumpridos, são eles: uma estrutura de rede adequada, que permita a fluidez da comunicação. E um padrão de comunicação, sendo que, o mais comum na radiologia digital chama-se *DICOM* (*Digital Imaging na Communications in Medicine*), ou ainda, Imagens Digitais e Comunicação na Medicina.

Quadro 1 – Classes de objetos de informação DICOM

| Normalizado            | Composto                        |
|------------------------|---------------------------------|
| Paciente               | Radiografia computadorizada     |
| Estudo                 | Tomografia computadorizada      |
| Resultados             | Imagem de filme digitalizado    |
| Fonte de armazenamento | Imagem digital de subtração     |
| Anotações da imagem    | Imagem de ressonância magnética |
|                        | Imagem de medicina nuclear      |
|                        | Imagem de ultrassom             |
|                        | Gráficos                        |
|                        | Curvas                          |

(Marque Azevedo e Salomão Covas, 2009)

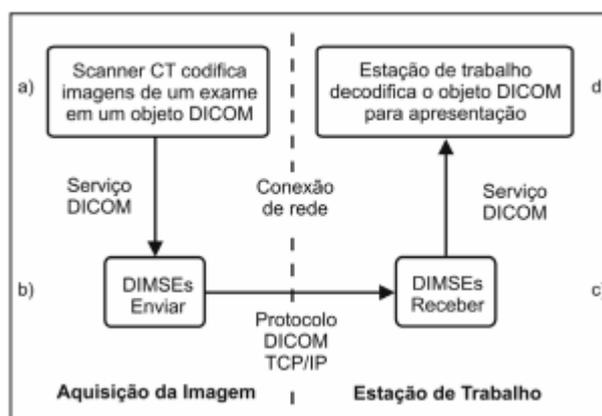
O *DICOM* tornou-se um padrão global na transferência de imagens radiológicas e aos poucos, foi integrado a outras áreas de conhecimento, como por exemplo, a odontologia. A ponto de ser mantido e atualizado por um comitê multidisciplinar internacional.

O *DICOM* atual, publicado em 1993 e geralmente identificado como 3.0, evoluiu das versões anteriores de um padrão desenvolvido pelo Colégio Americano de Radiologia (American College of Radiology, ACR) em conjunto com a NEMA (ACR-NEMA 1.0, de 1985, e ACR-NEMA 2.0, de 1988). A conectividade prevista pelo padrão é muito importante no que diz respeito à razão custo-benefício para áreas da saúde que fazem uso de imagens médicas. Usuários *DICOM* podem prover serviços de radiologia entre instalações localizadas em diferentes regiões geográficas, aproveitar recursos de tecnologia da informação já existentes e manter os custos baixos através da compatibilidade e interoperabilidade de novos equipamentos e sistemas (Marque Azevedo e Salomão Covas, 2009 p. 2)

Para exercer as funções necessárias, o *DICOM*, faz uso de linguagens já existentes, baseando-se principalmente no Modelo de Referência para a Interconexão de Sistemas Abertos, também conhecido como Modelo *OSI* (*Open Systems Interconnection Reference Model*). O modelo em questão, é dividido em sete camadas, que vão desde a composição de interfaces de aplicação com o usuário, considerada está a camada mais alta, até camadas mais baixas, como

fios e cabos. Quando a comunicação ocorre dentro do mesmo dispositivo, chamamos de serviço. Quando a comunicação ocorre entre dois dispositivos diferentes, consideramos um protocolo. (MARQUES AZEVEDO E SALOMÃO COVAS, 2009). A imagem a seguir, nos exemplifica, através de uma ação imaginária, como a estrutura *DICOM* reagiria com o envio de uma gama de imagens de tomografia computadorizada: O escâner codifica todas as imagens em um objeto *DICOM*. (b) O escâner invoca uma série de serviços para mover o objeto até a camada física do modelo *OSI*. (c) A WS utiliza uma série de serviços para receber o objeto através da camada física e depois movê-lo para camadas de maior nível. (d) A WS decodifica o objeto *DICOM*. (MARQUES AZEVEDO E SALOMÃO COVAS, 2009 p. 03).

Figura 9 - Exemplo de comunicação dentro da estrutura DICOM



(Marques Azevedo e Salomão Covas, 2009)

Médicos e profissionais da radiografia esperam que o *DICOM* seja um serviço eficiente ao enviar, receber, armazenar e recuperar imagens. Porém, o *PACS* também pode apresentar algumas limitações, como vimos anteriormente, é um excelente sistema para leitura de imagens, baseado principalmente no tamanho da imagem. Contudo, alguns pequenos nódulos, por exemplo, não podem ser diagnosticados via *PACS*, é necessário o uso de instrumentos especializados na leitura de imagens através de cores e contrastes, a fim de diagnosticar doenças prematuramente, preparando o paciente para o melhor tratamento e até mesmo, intervindo antes que a doença em questão precise de interferências mais agressivas.

Essa preocupação é extremamente necessária, a intervenção no software ou a criação de novos softwares apoiados na tecnologia da Inteligência Artificial, pode diminuir consideravelmente o diagnóstico de falsos positivos, assim como evitar que o paciente se exponha a radiações e cirurgias desnecessárias. Por outro lado, com o auxílio da Inteligência Artificial, em especial, a *Deep Learning*, será possível organizar a análise de imagens,

priorizando em escalas os casos de mais graves a mais simples, otimizando a produtividade e gestão de trabalho pelos profissionais de radiologia (SABBATINI, 2018).

Podemos exemplificar, de maneira mais clara, a seguir, com o caso de um software de Inteligência Artificial criado pelo Google:

Para avaliar o potencial da IA no apoio ao diagnóstico de imagens médicas, em fevereiro de 2018, o Google anunciou que uma de suas empresas subsidiárias, a Verily Life, criou um programa de escaneamento ocular (exame de fundo da retinoscopia). Nele, um algoritmo específico consegue identificar dados da retina que são usados para detectar riscos de doenças cardiovasculares e outras doenças perceptíveis através de alterações oculares. De acordo com os dados divulgados pela organização, a ferramenta registrou 70% de acertos nos testes de imagens de pessoas reais que poderiam ter um ataque cardíaco ou um derrame em cinco anos. (SABBATINI, 2018 p.01)

Outro exemplo de uso de *Deep Learning* implicada na área médica, é o processo de detecção da Doença de Alzheimer de forma prematura. O diagnóstico precoce da DA (Doença de Alzheimer) é essencial para seu controle, ao mesmo tempo que, os métodos tradicionais se apresentam pouco eficazes em realizar esse diagnóstico. (NEURALMIND, 2020). A Deep Learning, nesse sentido, pode auxiliar através do processamento de imagens de ressonância magnética, junto com avaliação física e testes de memória, realizada pelos profissionais pertinentes a área.

A portuguesa NeuroPsyCAD é um exemplo de startup pioneira na área que já realiza testes para detecção da fase inicial da DA e demais doenças semelhantes por meio de inteligência artificial. O objetivo é reunir uma base de dados com imagens de cérebros de pacientes que tenham DA ou outras doenças muito parecidas – como Déficit Cognitivo Ligeiro. O desafio é treinar os algoritmos para analisar esses dados e encontrar justamente um padrão que diferencia a Doença de Alzheimer do Déficit Cognitivo Ligeiro, algo muito difícil de ser distinguido, por exemplo, em consultas e outros exames médicos. (NEURALMIND, 2020 p. 01).

Ainda que, essa tecnologia esteja em desenvolvimento e não tenha data certa para ser implementada nos serviços médicos, os softwares baseados em Inteligência Artificial representam uma esperança para a humanidade, de um futuro mais seguro e com mais possibilidades de cura.

## 2.4 SARS-COV-2 (COVID-19)

Desde 2019, o mundo tem passado por uma das suas fases mais difíceis: a pandemia pelo novo Coronavírus tem feito vítimas por todos os países, gerado crises sanitárias e econômicas, além do colapso nos sistemas de saúde. Os coronavírus pertencem a uma grande família viral e são conhecidos há 60 anos como causadores de infecções respiratórias em humanos e animais. Estima-se que o surgimento da nova variante do vírus esteja relacionado a uma mutação do coronavírus que infecta morcegos, quebrando a barreira genética para conseguir se adaptar a uma nova espécie. O local inicial de transmissão foi um mercado de frutos do mar e animais vivos na cidade de Wuhan, China. (MEDEIROS, 2020). Entre os sintomas mais comuns do vírus, podemos elencar: febre, tosse seca, dor de cabeça, e principalmente, falta de ar. Esses sintomas sugerem uma infecção respiratória aguda ou anormalidades pulmonares detectadas radiologicamente.

Os indivíduos gravemente enfermos por COVID-19 têm diferentes apresentações pulmonares. Gattinoni et al (2020) divide os fenótipos pulmonares em tipo L (low) e tipo H (high). O tipo L apresenta baixa elasticidade (complacência normal), baixa razão de ventilação e perfusão (VA/Q), baixo peso pulmonar (mesmo com padrão vidro fosco, não há grande alteração do peso pulmonar) e baixa recrutabilidade alveolar (os alvéolos estão insuflados, então manobras de recrutamento tem baixo impacto). O tipo H, por sua vez, apresenta alta elasticidade (aumento de edema que leva a diminuição do volume de ar), alto shunt direitaesquerda, alto peso pulmonar e alta recrutabilidade alveolar (aumento dos tecidos não aerados que podem ser efetivamente recrutados) (MARTINEZ et al. apud NIELSEN e SILVA, p 05, 2020).

Portanto, a força com que o COVID-19 age sobre as vias respiratórias e pulmões, é indiscutível, ainda que em maior ou menor grau, é possível perceber seus efeitos no organismo dos indivíduos afetados pelo vírus. Abaixo, contemplaremos as imagens de três pulmões, um saudável, um diagnosticado com SARS-COV-2 e outro com pneumonia viral, não proveniente do vírus da COVID-19. Estabeleceremos o paralelo entre esses três exemplos, pois nossa prova de conceito estará apoiada na classificação desses diagnósticos.

Figura 10 – Radiografia de um pulmão saudável



(KAGGLE, 2021)

Figura 11 – Radiografia de um pulmão diagnosticado com SARS-COV-2



(KAGGLE, 2021)

Figura 12 – Radiografia de um pulmão diagnosticado com pneumonia viral, não proveniente de COVID19



(KAGGLE, 2021)

De forma geral, percebe-se que as radiografias com pulmões comprometidos por alguma comorbidade, apresentam uma mancha branca na sua extensão. Isso acontece pois o pulmão adquire mais densidade, devido a infiltrações.

Quando há aumento da pressão pulmonar, as margens dos vasos passam a ter limites mal definidos devido ao extravasamento de líquido para o interstício, os vasos dos ápices ficam mais alargados e a circulação é visível até a periferia. Ocorre também o aumento difuso da densidade nas regiões hilares. Os septos interlobulares pode se espessar com o acúmulo de líquido e surgem linhas curtas, horizontais e perpendiculares à pleura, as “linhas de Kerley”, que indicam edema intersticial. Quando existe edema alveolar, os vasos pulmonares podem não ser mais vistos, porque o pulmão adquire densidade de líquido, que é a mesma densidade dos vasos. (BOHRER BRENTANO, SCHNORR et al. 2015, p 03)

Essa característica é muito comum em pacientes com SARS-COV-2, embora o formato dessa densidade seja diferente, as características específicas da COVID 19 também se alteram ao longo da doença. A prova de conceito, se utilizará dessa mudança de formato e outras características próprias da comorbidade para fazer a leitura adequada das radiografias.

## 2.5 CONSIDERAÇÕES FINAIS

Acompanhando ao longo desse estudo, a Inteligência Artificial, em especial a *Deep Learning* tem muito a acrescentar na área médica, assim como vem influenciando outras diversas áreas da vida humana. Ainda que os estudos sejam recentes, vêm representando uma revolução na saúde e expectativa de vida dos pacientes, bem como, otimização dos trabalhos médicos.

### 3. METODOLOGIA

Neste trabalho, temos como objetivo, pesquisar e aplicar técnicas voltadas a Inteligência Artificial. Classifica-se a pesquisa como sendo qualitativa e voltada para a pesquisa-ação, pois, além de debruçar-nos sobre o estudo e revisão bibliográfica do que já foi produzido até então na área, será desenvolvido também uma prova de conceito que interage e interfere no ambiente que estará inserido, tornando-nos o que Thiollent descreve como agentes da ação.

Trata-se de um método, ou de uma estratégia de pesquisa agregando vários métodos ou técnicas de pesquisa, com os quais se estabelece uma estrutura coletiva, participativa e ativa ao nível da captação de informação. A metodologia das ciências considera a pesquisa-ação como qualquer outro método. Isto quer dizer que ela a toma como objeto para analisar suas qualidades, potencialidades, limitações e distorções. A metodologia oferece subsídios de conhecimento geral para orientar a concepção da pesquisa-ação e controlar o seu uso (THIOLLENT, 1986, p. 25-26).

Inicialmente, buscamos revisar materiais sobre o material do qual buscaremos inferir, o diagnóstico por imagem, entendendo do que se trata e a forma como é realizado atualmente.

Posteriormente, propomos um estudo aprofundado sobre a *Deep Learning*, uma subárea da Inteligência Artificial, a fim de compreender suas estruturas, a forma como é aplicada e como podemos trabalhar com essa tecnologia. Em seguida, sugerimos a interferência da *Deep Learning* na leitura de imagens médicas, visando a possibilidade de interferência da Inteligência Artificial no meio médico.

#### 3.1. CARACTERIZAÇÃO DA PESQUISA

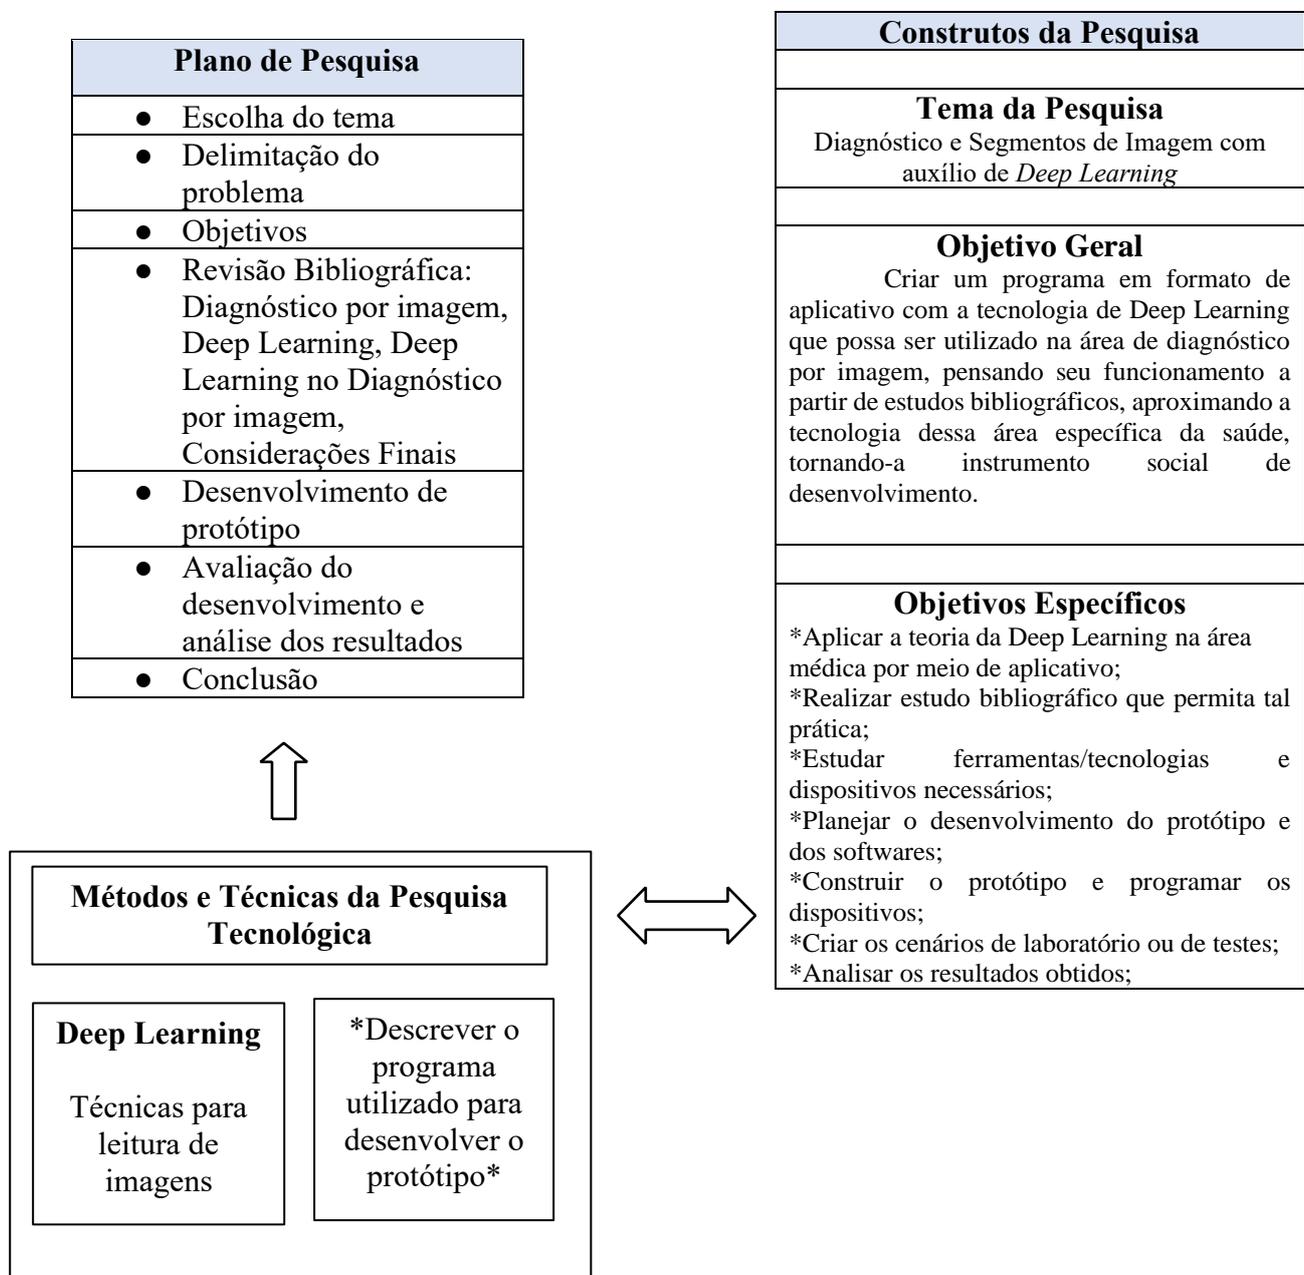
Para além da produção teórica, neste trabalho temos a ambição de agir sobre o problema levantado, influenciando, através da criação de um software de Inteligência Artificial, com foco em *Deep Learning*, na segmentação de imagens médicas. O intuito é repensar a qualidade de vida

dos pacientes, visando tecnologias que possam prestar auxílio médico antecipando a ocorrência e possibilidade de doenças futuras.

Nesse contexto, de acordo com Silva (2005 p. 20) nossa pesquisa refere-se a uma pesquisa aplicada, que objetiva gerar conhecimentos para aplicação prática e dirigidos à solução de problemas específicos. Envolve verdades e interesses locais.

Levando em consideração nossos objetivos nesta monografia, também podemos classificar nossa pesquisa como exploratória, pois através de estudos de casos reais, levantamento de dados biográficos, buscamos proporcionar a compreensão do assunto, de forma simples. (SILVA, 2005).

### 3.2 ATIVIDADES METODOLÓGICAS



### 3.3 OBJETO DE ESTUDO

O objeto de estudo desta monografia é estudar especificamente como a Deep Learning pode auxiliar médicos e profissionais da radiologia a detectar mais facilmente possíveis doenças que são diagnosticadas por imagens.

### 3.4 DELIMITAÇÕES

Esse trabalho delimitou-se a análise de diagnóstico e segmento de imagem de apenas um software na área de reconhecimento de padrões atualmente e de distribuição gratuita.

## 4. PROPOSTA DE SOLUÇÃO

No decorrer deste capítulo, descreveu-se o processo de desenvolvimento do software, as principais dificuldades, linguagem e estrutura do código, bem como o banco de imagens e análise de resultados obtidos com o projeto desenvolvido. O principal objetivo, mostrar como um software baseado em *Deep Learning* classifica uma imagem e realiza previsibilidades de comorbidades, em específico as doenças de SARS-Cov-2 e Pneumonia, diferenciando um pulmão saudável de um pulmão doente.

É importante registrarmos também, que não nos atemos em desenvolver um software que pudesse ser utilizado por médicos ou profissionais da saúde, o foco desse projeto é demonstrar como a tecnologia de *Deep Learning* pode interferir no processo de Diagnóstico de Imagens através de uma prova de conceito (POC).

### 4.1 REQUISITOS

Quando esse projeto começou a ser idealizado, partiu-se do princípio do que seria o futuro na Ciência de Dados, de que forma os conceitos que foram trabalhados diariamente dentro da vida acadêmica transformam a realidade a ponto de se tornar uma parte da vida da humanidade. Claramente, isso já acontece em algum nível, através dos *smartphones*, *tablets* e computadores pessoais, porém, nosso intuito é agir diretamente em conjunto com outros conhecimentos, mostrando que a Ciência de Dados atrelada a outras áreas, como da saúde, age diretamente na qualidade de vida dos indivíduos.

A partir dessas informações, iniciou-se um trabalho de pesquisa, para entender um pouco mais das áreas emergentes, dentre tantas, a tecnologia de *Deep Learning* foi a que se mostrou mais promissora, sendo utilizada em diversos segmentos de áreas em parceria com a Ciência de Dados.

Na década de 1950 o desejo dos pesquisadores era construir computadores que possuíssem as mesmas características do cérebro humano (máquinas com inteligência artificial). Hoje temos técnicas de inteligência artificial que podem auxiliar em várias tomadas de decisão. O mercado de A.I. ajuda milhões de empresas a utilizar dados para converter objetivos em ação. A IDC global divulgou um estudo recente que diz que o mercado de inteligência artificial terá um crescimento anual (CAGR) de 46,2%, chegando a US \$52 bilhões em 2021. Os gastos com inteligência artificial triplicarão até 2022, com isso temos uma projeção de que o valor chegará a US \$77,6 bilhões daqui

a quatro anos, três vezes mais do que os US \$24 bi de 2018. O *machine learning* e o *deep learning* serão tendências que deverão crescer mais rápido na categoria de tecnologia em crescimento ao longo da previsão, representando cerca de 40% de todos os gastos cognitivos e de inteligência artificial com um CAGR de cinco anos de 43,1%. (MONTINI, 2019 p. 01)

No momento que optou-se a escolha pela *Deep Learning*, o próximo passo foi entender do que se tratava, os processos envolvidos e como seria desenvolvido o software. Destaca-se esse período como sendo uma das maiores dificuldades, pois nunca havia-se trabalho com essa ferramenta, não sabíamos a real forma de aplicação, ou que programas utilizar para o desenvolvimento do projeto. Por ser uma parte da ciência relativamente nova no Brasil, também houve muita dificuldade em encontrar referências nacionais, grande parte dos estudos em *Deep Learning* são estudos internacionais, principalmente, norte-americanos. Fez-se necessário a busca constante de conhecimento através de cursos, artigos e palestras na área, além de conhecimento básico em outros idiomas para entendimento destes.

Como todo software ou prova de conceito, desenvolvemos também uma lista de requisitos funcionais básicos para o desenvolvimento do nosso projeto. Requisito funcional destaca-se por ser um conjunto de capacidades do que precisam ser implementadas para que a prova de conceito exerça sua funcionalidade de forma plena. Apontamos como nossos requisitos funcionais:

- Criar camadas de rede neural;
- Classificar imagens radiográficas de acordo com as comorbidades pré-estabelecidas;
- Gerar gráficos da acurácia dos dados de treino e validação;
- Gerar gráficos dos dados de perda de treinos e validação;
- Gerar gráfico de matriz de confusão;
- Prever comorbidade a partir de imagens selecionadas;

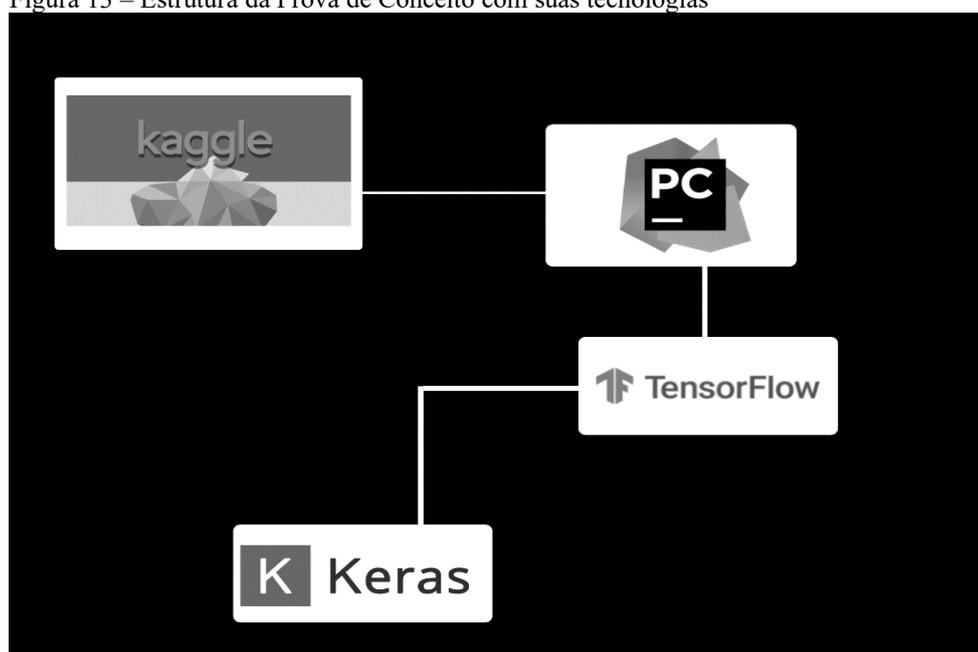
#### 4.1.2 DESENVOLVIMENTO DA PROVA DE CONCEITO

Sendo definido os objetivos da nossa prova de conceito e tendo sido o projeto idealizado,

partimos em busca de imagens diagnósticas das comorbidades a serem classificadas através da *Deep Learning*. Para a seleção dessas imagens, utilizamos a biblioteca Kaggle, que disponibiliza para cientistas de dados um conjunto de *datasets*. Dessa forma, foi possível encontrar todas as imagens analisadas na prova de conceito. Em seguida, selecionamos a *Integrated Development Environment (IDE) Pycharm* para realizar a compilação e fornecer ferramentas de apoio na inscrição do código da prova de conceito.

Após essas duas primeiras seleções, foi necessário encontrar uma plataforma de códigos próprio para *Machine Learning*, onde selecionamos o *TensorFlow*. Plataforma esta, que foi responsável por executar todos os cálculos complexos necessários na prova de conceito. Para auxiliar a construção do código, utilizamos a biblioteca *Keras*, que é uma plataforma mais sofisticada, que utiliza os cálculos complexos do *TensorFlow*, para construir de formas rápidas as redes neurais, de forma assertiva, diminuindo esse processo matemático longo e complexo do *TensorFlow*. A figura abaixo demonstra a estrutura que foi utilizada para realizar a prova de conceito.

Figura 13 – Estrutura da Prova de Conceito com suas tecnologias



## 4.2. PYCHARM

Durante o desenvolvimento do projeto, utilizamos a ferramenta PYCHARM, uma IDE (Integrated Development Environment) que facilita o processo de desenvolvimento do software. Entre os recursos presentes no PYCHARM que podem ser destacados (PYCHARM, 2018), tem-se: *Debugger* gráfico, unidade de testes integrada, integração com sistemas de controle de versão,

como *Git*, *Mercurial* e *Subversion*, análise de códigos, *code completion*, sintaxe e erro destacados, refatoração e suporte a desenvolvimento com *Django* (GUEDES, 2018).

Figura 14 – PyCharm



(JetBrains, 2021)

#### 4.2.1 TENSORFLOW

*Tensorflow* por sua vez, é uma biblioteca do Google específica para projetos de *Deep Learning* e *Machine Learning*. Sua principal função é simplificar cálculos complexos, representando-os em gráficos. Foi escolhida essa biblioteca, pois apresentou ser a ferramenta com maior documentação em sua base e de fácil acesso para uso, possui capacidade de interferência em várias plataformas, é flexível o suficiente para experimentação de pesquisas voltadas para *Deep Learning*.

Outro fator importante a ser destacado, é que o *Tensorflow* permite a criação fácil de modelos, permitindo a criação de um código limpo, que, segundo Martin, é o que nos permite o desenvolvimento a longo prazo, ou seja, é o que permite que o software permaneça e em evolução a partir do momento em que, em projetos futuros entenda-se claramente o código e possa dar seguimento ao processo de desenvolvimento. Em suma, um programador que escreve um código limpo é um artista que pode pegar uma tela em branco e submetê-la a uma série de transformações até que se torne um sistema graciosamente programado. (MARTIN, 2011 p 07).

Figura 15 – Tensorflow



(Tensorflow, 2015)

#### 4.2.2 KERAS

A biblioteca Keras, também possui extensa documentação e guias do desenvolvedor,

oferece API 's consistentes e simples, minimizando o número de ações do usuário. A principal vantagem do uso dessa biblioteca, é a rapidez na execução de novos experimentos, permitindo maior aproveitamento do tempo durante a programação do software.

Figura 16 – Keras



(Keras.io, 2017)

#### 4.2.3 KAGGLE

*Kaggle* é uma plataforma de aprendizado e de competição para cientistas de dados. O *Kaggle* permite que usuários publiquem, encontrem *datasets*, construam diversos modelos e trabalhem com cientistas de dados.

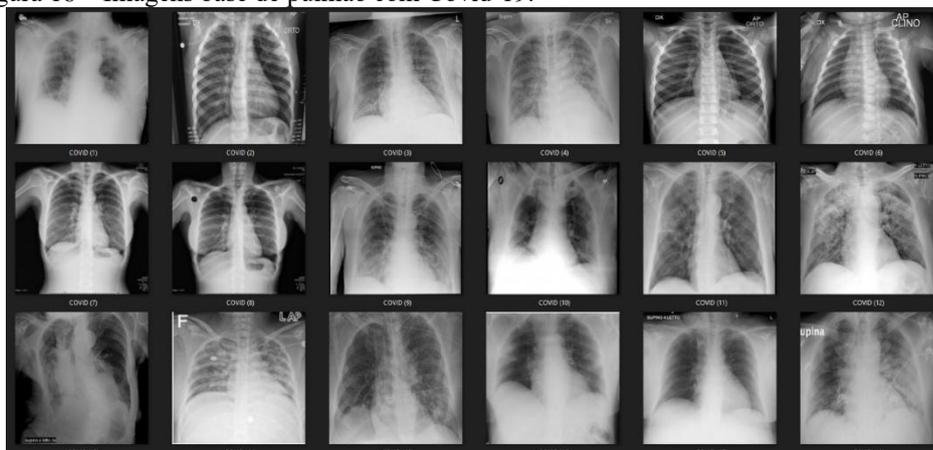
Figura 17 – Kaggle



(Kaggle, 2010)

A partir dessa plataforma, foi possível ter acesso a uma base de dados que possui um conjunto enorme de imagens de raio X de pulmões normais e com enfermidades tais como: Covid-19 e Pneumonia viral. Esse banco de dados de imagens foi campeão de *dataset* de COVID-19 premiado pela comunidade do *Kaggle*, de acordo com os usuários da plataforma esse banco de imagens foi o melhor dentre os outros *datasets* disponíveis na plataforma em questão de qualidade e disponibilidade de imagem. A partir deste *dataset* que foi realizada a prova de conceito.

Figura 18 – Imagens base de pulmão com Covid-19.



(Kaggle, 2020)

### 4.3 CAMADAS DE DEEP LEARNING

Para definir as camadas do nosso modelo utilizamos a classe *Sequential* do Keras, que agrupa uma pilha linear de camadas dentro de um modelo. Essas camadas são responsáveis por processar os dados de entradas, no caso do protótipo realizado, esses dados são as imagens radiográficas. Durante o desenvolvimento do protótipo foram usadas 13 camadas para realizar o processamento da imagem, cada camada tem sua função específica e impactará de formas diferentes na rede neural. Foram utilizadas algumas camadas dentre elas algumas classes como: *Batch Normalization*, *Conv2D*, *MaxPooling2D*, *Dropout*, *Flatten* e *Dense*. Veremos neste capítulo como essas camadas funcionam dentro do tratamento de imagens. A imagem a seguir mostra a definição das camadas dentro do protótipo.

Figura 19 – Definição de camadas para rede neural profunda.

```

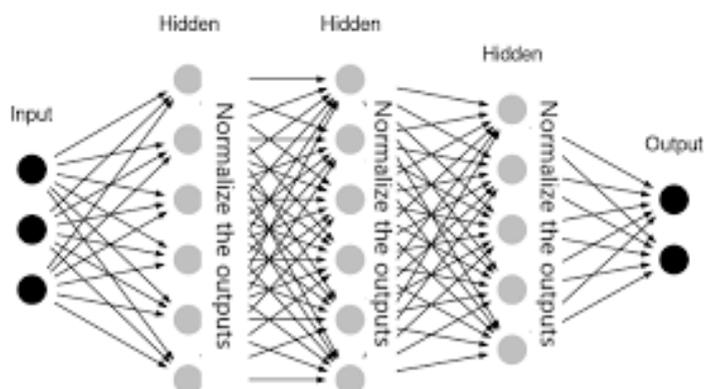
model = tf.keras.models.Sequential([
    layers.BatchNormalization(),
    layers.Conv2D(32, 3, activation='relu'),
    layers.MaxPooling2D(),
    layers.Conv2D(64, 3, activation='relu'),
    layers.MaxPooling2D(),
    layers.Dropout(0.3),
    layers.Conv2D(128, 3, activation='relu'),
    layers.MaxPooling2D(),
    layers.Dropout(0.2),
    layers.Flatten(),
    layers.Dense(256, activation='relu'),
    layers.Dropout(0.15),
    layers.Dense(3, activation='softmax')
])

early = tf.keras.callbacks.EarlyStopping(monitor='val_loss', patience=5)
model.compile(optimizer='adam', loss='sparse_categorical_crossentropy', metrics=['accuracy'])
history = model.fit(train_data, validation_data=test_data, batch_size=32, epochs=20, callbacks=[early])
model.evaluate(test_data)

```

As camadas de Normalização de Lotes (*Batch Normalization*) foram utilizadas para normalizar as camadas de entrada e as camadas ocultas, com o objetivo de ajustar a média e o dimensionamento das ativações. Esse efeito de normalização faz com que a rede neural possa usar uma taxa mais alta de aprendizado sem desaparecer ou explodir os gradientes.

Figura 20 – Camadas de normalização



(LaptrinhX, 2020)

Para entendermos a camada de Convolução (Conv2D), precisamos entender como são formadas nossas imagens. As entradas são normalmente matrizes tridimensionais com largura e altura e profundidade, determinada quantidade de canais de cores.

As convoluções funcionam como filtros que enxergam pequenos quadrados e vão “escorregando” por toda a imagem captando os traços mais marcantes. Explicando melhor, com uma imagem 32x32x3 e um filtro que cobre uma área de 5x5 da imagem com movimento de 2 saltos (chamado de *stride*), o filtro passará pela imagem inteira,

por cada um dos canais, formando no final um *feature map* ou *activation map* de  $28 \times 28 \times 1$ . A profundidade da saída de uma convolução é igual a quantidade de filtros aplicados. Quanto mais profundas são as camadas das convoluções, mais detalhados são os traços identificados com o *activation map*. (ALVES, 2018)

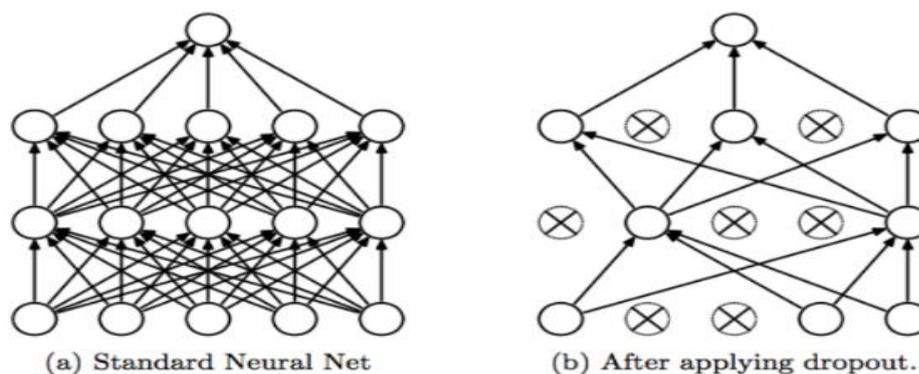
Logo, a camada de convolução, em resumo, condensa a matriz da imagem em uma matriz menor, deixando-a mais enxuta. Utilizamos uma função de ativação chamada “*ReLU*”, por ser mais eficiente computacionalmente e para evitar perdas na acurácia.

A função *ReLU* retorna 0 para todos os valores negativos, e o próprio valor para valores positivos. É uma função computacionalmente leve, entretanto não é centrada em zero. Como seu resultado é zero para valores negativos, ela tende a “apagar” alguns neurônios durante um passo *forward*, o que aumenta a velocidade do treinamento, mas por outro pode fazer com que esses neurônios “morram” e não aprendam nada se eles só receberem valores negativos. Além disso, ela pode produzir ativações explodidas, já que não possui um limite positivo. Mesmo com suas limitações, a função *ReLU* é hoje uma das funções de ativação mais utilizadas no treinamento de redes neurais, e não costuma ser utilizada na camada de saída. (CECCON, 2020)

Outra camada utilizada na nossa rede neural artificial profunda, é a camada de *pooling*. Essa camada servirá para simplificar a camada anterior, semelhante a camada de convolução é selecionado uma unidade de área. Essa unidade tem a responsabilidade de resumir a informação em único valor. Por exemplo, se a camada anterior for  $24 \times 24$ , após o *pooling* a saída será  $12 \times 12$ . Então para isso, utilizamos a função *Max Pooling 2D* do *Keras*, no qual ele irá percorrer a camada anterior e apenas selecionar a camada de maior valor e em seguida passar para a saída. (ALVES, 2018)

De acordo com Bianchi, essa função se torna importante não somente para diminuir as variâncias a pequenas alterações, mas também para reduzir a quantidade de parâmetros. (BIANCHI, 2020 p 01)

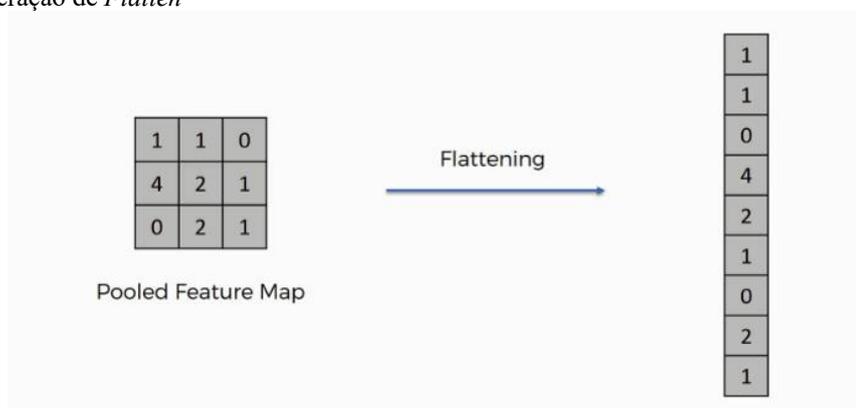
Como forma de evitar o *overfitting* (estatística de quando o modelo se ajusta muito bem aos dados de treino, porém se torna ineficaz ao prever novos resultados), utilizamos a camada de *Dropout*. Essa função é utilizada para desligar alguns neurônios e suas conexões aleatoriamente durante o treinamento. Durante a predição esses neurônios são ativados novamente. Portanto, o *Dropout* irá forçar uma rede neural a aprender novos recursos mais robustos, evitando a generalização.



(Srivastava, Nitish, et al. APUD Budhiraja, 2016)

Durante a camada *Flatten*, as matrizes resultantes de camadas anteriores como as de *pooling* e convoluções são redimensionadas para se tornar um *array* linear, de uma única dimensão. Esta etapa é um preparo para entrar na camada principal da rede neural totalmente conectada (BIANCHI, 2020 p 02)

Figura 22 – Operação de *Flatten*



(SuperDataScience APUD Clappis, 2019)

Por fim, utiliza-se a camada *Dense* que tem como objetivo calcular uma função de ativação de acordo com nossos dados e pesos, dessa forma cada neurônio dentro de uma camada densa irá se conectar totalmente a cada neurônio da camada anterior. Para ativar essa camada utilizou-se a função *Softmax*, essa função matemática irá converter o vetor de números em um vetor de probabilidades, onde cada valor é proporcional a escala relativa de cada valor no vetor.

#### 4.4 EARLY STOPPING

O *Keras* possui uma função de *callback* (*função de monitoramento dos dados de treino*) muito utilizada para evitar o *overfitting* também. O *Early Stopping* permite que seja especificado uma medida de desempenho que irá ser monitorada e quando disparado essa função ele irá parar o processo de treinamento.

Utilizaremos dois argumentos nesse método: o monitor e o *patience*. O monitor será a medida que nós iremos querer que a função monitore, nesse caso iremos querer que nossa função monitore os nossos dados de perda do nosso conjunto de validação. Então dessa forma o treinamento será interrompido quando nossos dados monitorados parem de melhorar.

O argumento *patience*, irá definir um atraso no acionador da função *Early Stopping* em relação ao número de *epochs* no qual não gostaríamos de ver nenhuma melhora. Isso é feito porque o primeiro sinal de que não há melhoras pode não ser o melhor momento para interromper o treinamento, pois pode ter uma perda no início seguida de uma grande melhora.

## 4.5 RESULTADOS

Após a definição de nossas camadas, o nosso modelo já está pronto para ser compilado e treinado, utilizando a função `compile` do *Keras* para treinar esta rede neural. Com a função `fit` do *Keras*, fez-se com que a rede fosse treinada por um número determinado de *epochs* (número de iterações do *dataset*) escolhidas, no caso desta rede, as iterações foram realizadas 20 vezes, como podemos acompanhar na imagem a seguir, retirada do próprio desenvolvimento da prova de conceito.

Figura 23 – Treinamento de rede neural

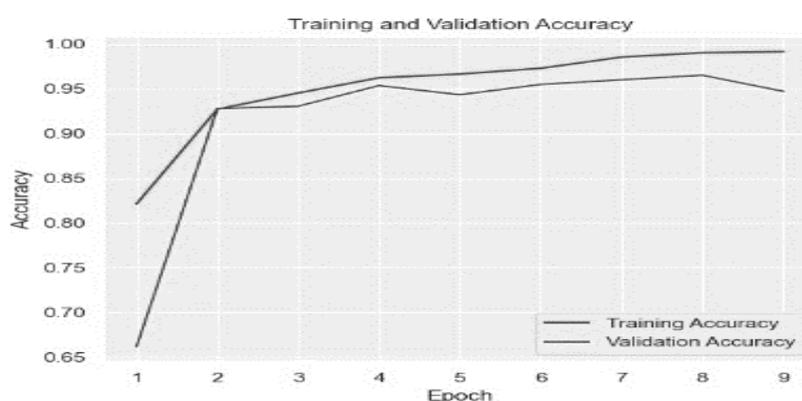
```
Found 3886 files belonging to 3 classes.
Using 777 files for validation.
Viral pneumonia
NORMAL
COVID-19
Epoch 1/20
2021-05-23 23:31:49.769754: I tensorflow/compiler/mlir/mlir_graph_optimization_pass.cc:145] None of the MLIR Optimization Passes are enabled (re
2021-05-23 23:31:54.418515: I tensorflow/stream_executor/platform/default/dso_loader.cc:49] Successfully opened dynamic library cudnn64_8.dll
2021-05-23 23:31:55.157254: I tensorflow/stream_executor/cuda/cuda_dnn.cc:334] Loaded cuDNN version 8100
2021-05-23 23:31:56.425629: I tensorflow/stream_executor/platform/default/dso_loader.cc:49] Successfully opened dynamic library cublas64_11.dll
2021-05-23 23:31:57.048081: I tensorflow/stream_executor/platform/default/dso_loader.cc:49] Successfully opened dynamic library cublasLt64_11.dll
98/98 [=====] - 75s 669ms/step - loss: 2.4219 - accuracy: 0.7136 - val_loss: 0.6157 - val_accuracy: 0.7992
Epoch 2/20
98/98 [=====] - 69s 671ms/step - loss: 0.2157 - accuracy: 0.9305 - val_loss: 0.1989 - val_accuracy: 0.9228
Epoch 3/20
98/98 [=====] - 68s 658ms/step - loss: 0.1751 - accuracy: 0.9479 - val_loss: 0.1982 - val_accuracy: 0.9369
Epoch 4/20
98/98 [=====] - 67s 652ms/step - loss: 0.1193 - accuracy: 0.9593 - val_loss: 0.1312 - val_accuracy: 0.9511
Epoch 5/20
98/98 [=====] - 68s 665ms/step - loss: 0.0823 - accuracy: 0.9716 - val_loss: 0.1083 - val_accuracy: 0.9601
Epoch 6/20
98/98 [=====] - 69s 670ms/step - loss: 0.0636 - accuracy: 0.9828 - val_loss: 0.1346 - val_accuracy: 0.9627
Epoch 7/20
98/98 [=====] - 68s 663ms/step - loss: 0.0500 - accuracy: 0.9818 - val_loss: 0.1259 - val_accuracy: 0.9601
Epoch 8/20
98/98 [=====] - 67s 652ms/step - loss: 0.0383 - accuracy: 0.9866 - val_loss: 0.2031 - val_accuracy: 0.9498
Epoch 9/20
98/98 [=====] - 66s 639ms/step - loss: 0.0416 - accuracy: 0.9843 - val_loss: 0.1244 - val_accuracy: 0.9640
Epoch 10/20
98/98 [=====] - 68s 662ms/step - loss: 0.0118 - accuracy: 0.9977 - val_loss: 0.1412 - val_accuracy: 0.9653
25/25 [=====] - 12s 312ms/step - loss: 0.1412 - accuracy: 0.9653
```

Como é possível acompanhar, através da figura da rede sendo treinada (figura 23), o processo de treinamento finalizou apenas com 10 iterações, não de 20 iterações. Isso se dá devido a função de *callback Early Stopping* que colocou-se no desenvolvimento da prova de conceito.

A acurácia dos dados de validação começou a declinar, então a função de *callback* foi incluída, realizando a finalização do treinamento.

Acompanhando as métricas apresentadas durante as iterações, podemos perceber que os dados de treino iniciaram com uma taxa média de acurácia 71%, porém conforme o modelo passou por treinamento, essas taxas comprovaram crescimento expressivo, saindo de uma acurácia de 71% para até 96%. Os dados de validação também iniciaram com taxa de 79% até atingirem a faixa de acurácia de 95% e permanecerem com apenas leves alterações. Pode-se acompanhar a evolução da acurácia a partir do gráfico abaixo, também gerido em código da prova de conceito.

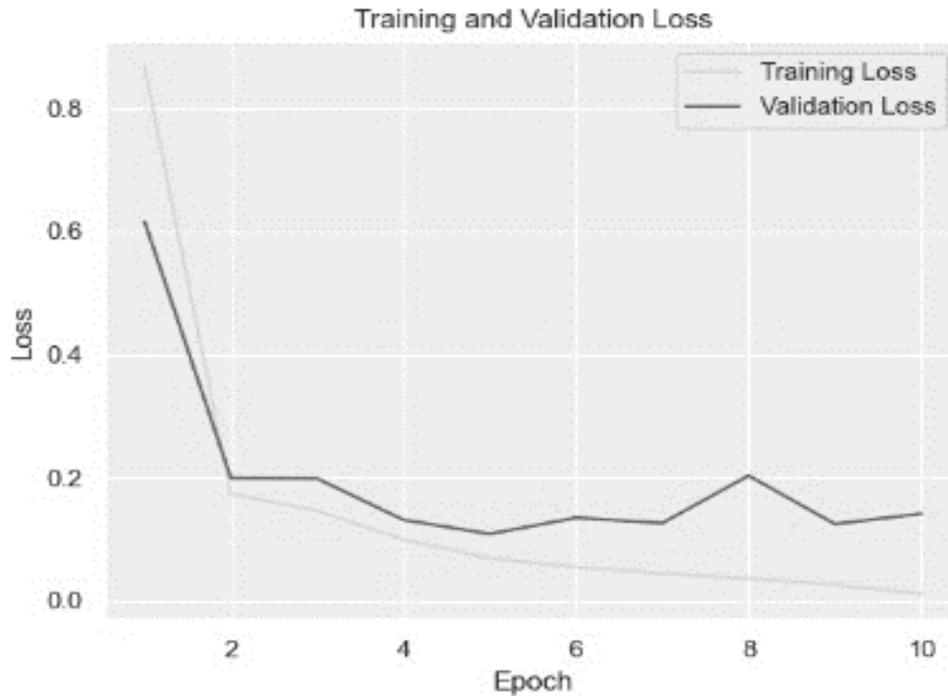
Gráfico 1 – Acurácia dos dados de treino e validação



Em relação a taxa de perda de dados, ou seja, os números que indicam o quão mau foi a previsão de uma imagem, podemos visualizar no gráfico abaixo que os dados de treinos iniciaram com uma taxa alta cerca de 21% e ao longo das iterações diminuíram, chegando a números muito baixos como 1% de perda.

Os dados de validação também iniciaram com número de perdas elevados, cerca de 61% e decaíram ao longo do processo, porém em uma escala menor que os dados de treino. Os números de perda nos dados de validação foram maiores que nos dados de treino, ficando na faixa de 14%, conforme nos mostra o gráfico a seguir, gerido em código. É possível verificar esses resultados a partir do gráfico a seguir gerado através do protótipo.

Gráfico 2 – Perda dos dados de validação e treino



Após o treinamento dos dados, foi produzido o método para realizar a previsão das imagens no qual transforma-se a imagem em um vetor e expande as suas dimensões, para que seja possível usar a função para *predict* do *Keras*, que corporificam as previsões finais. Nesse método, foi necessário apenas passar o caminho da localização da imagem que é desejada prever e a rede neural processou e disponibilizou no console a qual classe de dados a imagem pertence: pulmão normal/saudável, pulmão com COVID-19 ou pulmão com pneumonia viral. Foram realizadas três previsões para testar a rede neural. E como resultado o modelo acertou corretamente as três doenças apenas a partir das imagens, conforme a imagem 23 que mostra a função que foi criada para a predição das imagens radiográficas:

Figura 24 – Previsão de diagnóstico de imagem

```

115
116
117 def predict(path):
118     new_img = image.load_img(path, target_size=(244, 244))
119     img = image.img_to_array(new_img)
120     img = np.expand_dims(img, axis=0)
121     prediction = model.predict(img)
122     prediction = np.argmax(prediction, axis=1)
123     print(CLASS_NAMES[prediction[0]])
124     plt.imshow(new_img)
125     plt.show()
126
127
128 predict("datasets/Viral_Pneumonia/Viral_Pneumonia (318).png")
129 predict("datasets/NORMAL/NORMAL (2).png")
130 predict("datasets/COVID/COVID (67).png")
131

```

```

Run: main
Epoch 2/20
98/98 [=====] - 69s 671ms/step - loss: 0.2157 - accuracy: 0.9305 - val_loss: 0.1989 - val_accuracy: 0.9228
Epoch 3/20
98/98 [=====] - 68s 658ms/step - loss: 0.1751 - accuracy: 0.9479 - val_loss: 0.1982 - val_accuracy: 0.9369
Epoch 4/20
98/98 [=====] - 67s 652ms/step - loss: 0.1193 - accuracy: 0.9593 - val_loss: 0.1312 - val_accuracy: 0.9511
Epoch 5/20
98/98 [=====] - 68s 665ms/step - loss: 0.0823 - accuracy: 0.9716 - val_loss: 0.1083 - val_accuracy: 0.9681
Epoch 6/20
98/98 [=====] - 69s 670ms/step - loss: 0.0636 - accuracy: 0.9828 - val_loss: 0.1346 - val_accuracy: 0.9627
Epoch 7/20
98/98 [=====] - 68s 663ms/step - loss: 0.0500 - accuracy: 0.9818 - val_loss: 0.1259 - val_accuracy: 0.9681
Epoch 8/20
98/98 [=====] - 67s 652ms/step - loss: 0.0383 - accuracy: 0.9866 - val_loss: 0.2031 - val_accuracy: 0.9498
Epoch 9/20
98/98 [=====] - 66s 639ms/step - loss: 0.0416 - accuracy: 0.9843 - val_loss: 0.1244 - val_accuracy: 0.9648
Epoch 10/20
98/98 [=====] - 68s 662ms/step - loss: 0.0118 - accuracy: 0.9977 - val_loss: 0.1412 - val_accuracy: 0.9653
25/25 [=====] - 12s 312ms/step - loss: 0.1412 - accuracy: 0.9653
Viral_Pneumonia
NORMAL
COVID-19

```

O protótipo também gerou uma matriz de confusão, que se trata de uma tabela onde é possível verificar todas as classificações que a rede neural fez a partir dos dados de treino. Com essa tabela pode-se visualizar as previsões que o protótipo realizou e também realizar o cálculo para saber a acurácia da rede neural, ou seja, quanto o modelo conseguiu acertar a partir das previsões realizadas.

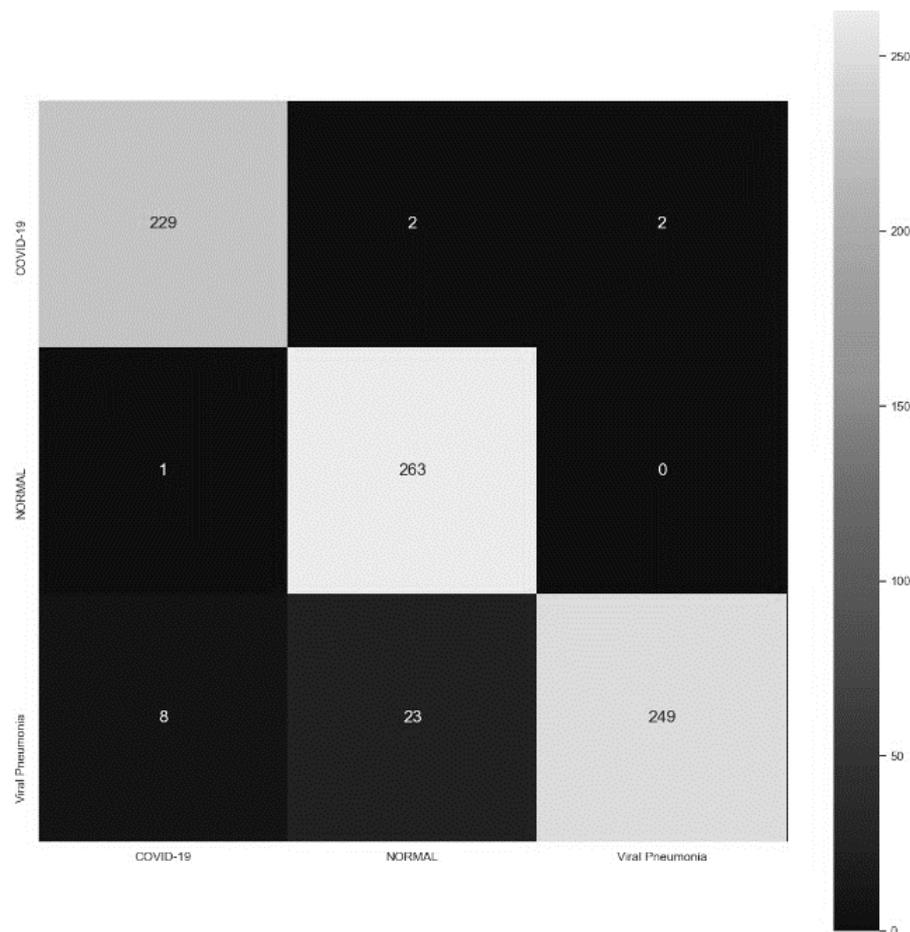
Tabela 01 – Dados de predição

|                  | Predição |        |       |
|------------------|----------|--------|-------|
|                  | Covid    | Normal | Viral |
| Valor Verdadeiro |          |        |       |
| Covid            | 229      | 2      | 2     |
| Normal           | 1        | 263    | 0     |
| Viral            | 8        | 23     | 249   |

De acordo com a tabela 01 que exibe a matriz de confusão gerada do modelo, pode-se visualizar que das 233 instâncias que são pulmões com covid, o modelo prevê 229 como covid, 2 como normal e 2 como viral. Das 264 instâncias normais, o modelo prevê 263 como normal e 1 como viral. Das 280 instâncias como viral, o modelo prevê 249 como viral, 8 como covid e 23 como normal. Entendendo a matriz podemos extrair a partir de um cálculo a acurácia da rede neural. O cálculo para saber a acurácia do modelo é a soma da diagonal principal dividido pela soma de todos valores da matriz. Portanto, os valores com predição correta (diagonal principal) são:  $229 + 263 + 249 = 741$ . O valor de todos os valores da matriz resulta em 777, logo para

obtermos a acurácia de nossa rede neural, será necessário realizar a divisão da diagonal principal por todos valores da matriz (741/777), resultando em 0,953. A imagem a seguir demonstra a matriz de confusão gerada dentro do nosso protótipo.

Figura 25 – Matriz de confusão



#### 4.6 CONSIDERAÇÕES FINAIS

O desenvolvimento do protótipo permitiu mostrar que é possível realizar a predição de imagens radiográficas a partir de uma rede neural profunda. A elaboração da prova de conceito permitiu mostrar a utilização de tecnologias que estão sendo muito utilizadas na área de *Machine Learning*, como o *TensorFlow* e o *Keras*. Com essas ferramentas foi possível criar e treinar um modelo de rede neural profunda com treze camadas ocultas. Cada camada realizando um papel importante no tratamento da imagem e da rede neural e suas conexões. Foram utilizadas 3109 imagens para o treinamento da nossa rede neural e 777 imagens para a validação. Foi possível observar durante o treinamento também que nosso treino parou com apenas 10 epochs, sendo que havíamos colocado 20 epochs. Isso aconteceu devido ao poder da nossa função de call-back

*Early Stopping* que agiu durante o treinamento ao ver que nossa acurácia estava começando a decair, então ele parou o treinamento antecipadamente para manter um nível alto de acurácia.

Com o treinamento finalizado, conseguimos tirar algumas métricas. Foram gerados alguns gráficos como um gráfico de acurácia que nos permitiu visualizar o nível de acerto conforme as epochs da etapa de treinamento. Foi possível visualizar que a acurácia subiu de 71% para 95% permanecendo nesse nível até o fim do treinamento. Observou-se também o gráfico de perdas, onde o treinamento começou com uma perda alta, cerca de 21%, diminuindo drasticamente para 1% se mantendo nessa média.

Gerou-se também uma matriz de confusão, no qual permitiu visualizar o número de acertos e erros das predições de acordo com os dados de validação. Realizou-se a divisão da diagonal principal pelo número total de resultados da matriz e a acurácia que foi de 95%. Das 233 instancias de Covid-19, a rede neural previu 229 corretamente, previu 2 como um pulmão normal erroneamente e 2 como pneumonia viral. Das 264 instancias definidas de pulmões normais, o modelo previu 263 corretamente e uma como pulmão covid. Por fim, 280 instancias eram de pulmões com pneumonia, o modelo acertou 249, previu 23 como pulmões normais e 8 como Covid-19. A partir desses dados, conseguimos visualizar que o modelo conseguiu um número alto de acurácia acertando boa parte das imagens e com um número muito baixo de erros.

Portanto, a prova de conceito utilizou-se de um método do qual a partir do parâmetro de uma imagem, o modelo conseguiu realizar uma previsão. Passou-se três caminhos de imagem aleatórios, com 100% de eficácia da prova de conceito.

Portanto, a rede neural mostrou-se muito eficiente em relação a leitura e classificação das radiografias. Apresentou taxa alta de acurácia (95%) e baixa taxa de perda (1%). O protótipo realizado mostra que é possível utilizar a tecnologia de *Deep Learning* para a classificação de imagens, como radiografias na área médica. Com resultados desses níveis, podemos ver que é possível essa aplicação na área da saúde e que essa tecnologia ainda tem muito a contribuir.

## 5. CONCLUSÕES E TRABALHOS FUTUROS

### 5.1 CONCLUSÕES

Ao final desta monografia, pode-se constatar a importância da Ciência da Computação como um apoio à área médica, reconhecendo a importância do conhecimento de Inteligência Artificial como transversal e indispensável ao cotidiano de todos.

Destacamos a comprovação das estruturas de Deep Learning na leitura de diagnósticos por imagem, sendo assertivamente precisa as constatações da prova de conceito, se mostrando uma tecnologia confiável ao uso médico, que ainda tem muito a ser desenvolvida, muitas possibilidades de expansão e aplicação, visando sempre o comprometimento com a qualidade de vida de todos.

As estruturas de *Deep Learning*, ainda podem ser mais bem exploradas, porém, a pesquisa, o estudo, as tentativas são as bases que levarão adiante o desenvolvimento da Inteligência Artificial.

Portanto, fica comprovado a eficácia da Inteligência Artificial, com foco em *Deep Learning* para o diagnóstico de imagem, com acurácia 95% conforme prova de conceito.

### 5.2 TRABALHOS FUTUROS

Graças ao desenvolvimento médico, a expectativa de vida da humanidade vem em crescimento gradual ao longo dos anos. Mesmo em frente a novas doenças e variações, a medicina se mostra rápida e evolutiva. Muito, porque essa mesma área vem aceitando as intervenções da ciência de dados na sua rotina.

Nosso trabalho demonstra com excelência como esses dois polos, antes incomunicáveis, têm um caminho a seguir juntos. A inteligência artificial não substituirá em nenhum momento a força ou inteligência humana, mas agregará tanto valor que será possível aumentar drasticamente a expectativa e qualidade de vida dos indivíduos.

A inteligência artificial (IA) é, de uma forma muito simplista, a capacidade de fazer com que uma máquina consiga imitar um comportamento inteligente humano. As técnicas de IA e de aprendizagem automática (ML, do inglês machine learning) têm o potencial de transformar os cuidados de saúde ajudando a processar as grandes quantidades de informação produzida no dia-a-dia da atividade médica e retirando novas inferências desses mesmos conjuntos de dados. Enquanto o conhecimento

humano é limitado pela capacidade de aprendizagem, acesso às bases de conhecimento e experiência própria, máquinas dotadas de IA podem rapidamente sintetizar informação de um número ilimitado de fontes de informação médica. Para otimizar o potencial da IA, o ideal são grandes bases de dados (como por exemplo os registros médicos eletrônicos realizados todos os dias por milhares de médicos) que possam ser analisadas computacionalmente, relevando tendências e associações que, caso contrário, seriam difíceis de extrair para o ser humano (MARTINS, 2020 p. 10)

De acordo com Martins, a Inteligência Artificial pode agir na área médica em ao menos quatro categorias distintas: avaliando riscos de início de doença (previsão), gerir ou avaliar complicações (quando a doença já está se desenvolvendo há algum tempo), assistência em cuidados (de forma ativa durante o processo de tratamento) e na investigação destinada a elucidação de mecanismos patológicos (tomada de decisão para o tratamento ideal) (MARTINS, 2020).

Dessa forma, a aplicação da *Deep Learning* na leitura de radiografia, ainda que seja revolucionário, é um processo primário mediante tudo que a Inteligência Artificial ainda pode propor à área da saúde. Dentro da nossa proposta de monografia, apenas buscamos comprovar a possibilidade dessa intervenção. Uma vez realizando essa comprovação, pretendemos ainda desenvolver um protótipo que possa ser usado de forma prática no dia a dia médico, não somente na leitura de imagens de radiografia, mas também de outros tipos de diagnóstico de imagens, sobretudo, não tratando apenas da doença em sua fase de desenvolvimento, mas também, possibilitando previsões através de exames de rotinas, onde o médico que utilizará a tecnologia, poderá criar um plano de ação sobre a possibilidade de desenvolvimento da doença.

## REFERÊNCIAS

ACADEMY, Data Science. **Deep Learning Book**. São Paulo, 2016. <http://deeplearningbook.com.br/deep-learning-a-tempestade-perfeita/>

ALMEIDA, Rafael da Silva. ANTAS JUNIOR, Ricardo Mendes. **Diagnóstico médico e uso corporativo do território brasileiro: uma análise do circuito espacial produtivo dos reagentes para diagnóstico**. Saúde Soc. São Paulo, v.24, n.2. 2015. <https://www.scielo.org/pdf/sausoc/2015.v24n2/674-690/pt>. Acesso em: 02 out. 2020.

ALVES, Gisely. **Entendendo Redes Convolucionais (CNNs)**. Medium. 2018. Disponível em: <https://medium.com/neuronio-br/entendendo-redes-convolucionais-cnns-d10359f21184> Acesso em: 02 mai 2021

ARRUDA, Walter Oleschko. **Wilhelm Conrad Rontgen: 100 anos da descoberta dos raios x**. Arquivo de Neuropsiquiatria. Curitiba, PR. 1996. Disponível em: <https://www.scielo.br/pdf/anp/v54n3/27.pdf> . Acesso em: 05 nov. 2020.

BÁRTHOLO, Thiago Prudente. BÁRTHOLO, Rogério de Mattos. **Pneumonia Viral**. UFRJ, Rio de Janeiro, RJ. 2009. Disponível em: [http://www.sopterj.com.br/wp-content/themes/sopterj\\_redesign\\_2017/revista/2009/suplemento-pneumonia/pneumonia-viral.pdf](http://www.sopterj.com.br/wp-content/themes/sopterj_redesign_2017/revista/2009/suplemento-pneumonia/pneumonia-viral.pdf) Acesso em: 20 mai. 2021

BIANCHI, Alexandr Luiz. **Arquiteturas de Redes Neurais Convolucionais para reconhecimento de imagens**. Viceri. 2020. Disponível em: <https://www.viceri.com.br/insights/arquiteturas-de-redes-neurais-convolucionais-para-reconhecimento-de-imagens> Acesso em: 04 mai 2021.

BORGES, Naida Cristina. **Diagnóstico por Imagem**. Universidade Federal de Goiás. GO. 2014. Disponível em: [https://files.cercomp.ufg.br/webby/up/66/o/Diagnostico\\_por\\_imagem\\_2014\\_-\\_aula\\_1.pdf](https://files.cercomp.ufg.br/webby/up/66/o/Diagnostico_por_imagem_2014_-_aula_1.pdf) . Acesso em: 04 nov. 2020.

BOHRER BRENTANO, Vicente. SCHNORR, Amanda. Et Al. **Interpretando a Radiografia de Tórax na Emergência**. Acta Médica. Porto Alegre, RS. 2015. Disponível em: <https://docs.bvsalud.org/biblioref/2018/04/882682/interpretando-a-radiografia-de-torax-na-emergencia.pdf> Acesso em: 20 mai. 2021

BUDHIJARA, Amar. **Dropout in (Deep) Machine Learning**. Medium. 2016. Disponível em: <https://medium.com/@amarbudhiraja/https-medium-com-amarbudhiraja-learning-less-to-learn-better-dropout-in-deep-machine-learning-74334da4bfc5> Acesso em: 21 mai. 2021.

CECCON, Denny. **Funções de ativação: definição, características e quando usar cada uma**. Expert Academy. 2020. Disponível em: <https://iaexpert.academy/2020/05/25/funcoes-de-ativacao-definicao-caracteristicas-e-quando-usar-cada-uma/> Acesso em 02 mai 2021.

CHAGAS, Edgar Thiago De Oliveira. **Deep Learning e suas aplicações na atualidade**. Revista Científica Multidisciplinar Núcleo do Conhecimento. Ano 04, Ed. 05, Vol. 04. São Paulo, SP. 2019. Disponível em: <https://www.nucleodoconhecimento.com.br/administracao/deep-learning> Acesso em: 20 nov. 2020.

CLAPPIS MELO, Alan. **Uma introdução as redes neurais convolucionais utilizando o Keras**.

Data Hackers. 2019. Disponível em: <https://medium.com/data-hackers/uma-introdu%C3%A7%C3%A3o-as-redes-neurais-convolucionais-utilizando-o-keras-41ee8dcc033e>  
Acesso em: 21 nov. 2020

DIOGO, Maria Paula. **Tecnologia e Progresso. História da Tecnologia.** Universidade Federal de Pelotas, RS. 2009. <https://www.docsity.com/pt/historia-da-tecnologia/4706285/> Acesso em: 18 set. 2020

FARMER, Joseph S. SLONIM, Anthony D. **Ultrassonografia à Beira do Leito na Medicina Clínica.** AMGH. Virgínia. EUA. 2013. Disponível em: <https://statics-submarino.b2w.io/sherlock/books/firstChapter/113916111.pdf> . Acesso em 05 nov. 2020

FENELON, Sandro. **A Evolução da Radiologia – Os Avanços da Imagiologia e Radiologia Diagnóstica.** Disponível em: <http://www.imaginologia.com.br/dow/A-evolucao-da-Radiologia.pdf>  
<http://www.imaginologia.com.br/dow/A-evolucao-da-Radiologia.pdf> Acesso em: 28 out. 2020.

FERNEDA, Edberto. **Redes Neurais e sua aplicação em sistemas de recuperação de informação.** Ci. Inf., v. 35, n.1. Brasília, DF. Disponível em: <https://www.scielo.br/pdf/ci/v35n1/v35n1a03.pdf> . Acesso em: 11 nov. 2020.

GARCIA, Ana Cristina Bicharra. GOMES, Angelo Ferreira. Et Al. **Análise de iniciativas com técnicas de Machine Learning para detecção de casos de pneumonia causada pela COVID-19 através de imagens de raio-x.** UFRJ, Rio de Janeiro, RJ. 2020. Disponível em: <http://wwwp.uniriotec.br/cristinabicharra/wp-content/uploads/sites/16/2020/04/AN%C3%81LISE-DE-INICIATIVAS-COVID19-RAIOX-DOC.pdf> Acesso em 05 mar. 2021.

GUEDES, Danila. **Linguagem de Programação Python e Arduino como ferramenta para motivar estudantes iniciantes em programação.** UTFPR. Curitiba, Paraná. 2018. Disponível em: [http://repositorio.utfpr.edu.br/jspui/bitstream/1/9709/1/CT\\_COTEL\\_2018\\_1\\_03.pdf](http://repositorio.utfpr.edu.br/jspui/bitstream/1/9709/1/CT_COTEL_2018_1_03.pdf)

KAGGLE. **Imagem de logotipo.** Kaggle.com. 2010. Disponível em <https://www.kaggle.com/>  
Acesso em 15 abr 2021

KENJI, Bruno. **Machine Learning para leigos.** Venturos. Campinas, SP. 2019. Disponível em: <https://www.venturus.org.br/machine-learning-para-leigos/> Acesso em: 20 nov. 2020

KERAS. **Imagem de logotipo.** Keras.io. 2017. Disponível em <https://keras.io/about/> Acesso em 20 abr 2021

LAPTRINHX. **Hands-On guide to implemente Barch Normalization in Deep Learning models.** LaptrinhX. 2020. Disponível em: <https://laptrinhx.com/hands-on-guide-to-implement-batch-normalization-in-deep-learning-models-1672105356/> Acesso em: 02 mai 2020

LEITE, Cláudia da Costa. **Inteligência artificial, radiologia, medicina de precisão e medicina personalizada.** Radiol Bras vol. 52 no.6 São Paulo Nov./Dec. 2019. Epub Nov 25, 2019. [https://www.scielo.br/scielo.php?pid=S0100-39842019000600002&script=sci\\_arttext&tlng=pt#B5](https://www.scielo.br/scielo.php?pid=S0100-39842019000600002&script=sci_arttext&tlng=pt#B5). Acesso em: 02 out. 2020.

LOBO, Luiz Carlos. **Inteligência Artificial e Medicina.** Rev. Brasileira de Educação Médica. Vol 4. Rio de Janeiro. 2017. Disponível em : <https://www.scielo.br/pdf/rbem/v41n2/1981-5271->

[rbem-41-2-0185.pdf](#). Acesso em: 02 out. 2020.

LUGER, George F. **Inteligência Artificial**. 6ª edição. Pearson. Novo México, 2013. Disponível em: <https://plataforma.bvirtual.com.br/Leitor/Publicacao/180430/pdf/0>. Acesso em: 02 out. 2020.

MAEDA, Teresinha. NORONHA, Arnaldo José. **O pulmão e as infecções virais**. Rev. Hospital Universitário Pedro Ernesto, UERJ. Rio de Janeiro, RJ. 2010. Disponível em: <file:///C:/Users/Anelise/Downloads/9180-32142-1-PB.pdf> Acesso em: 04 mar. 2021

MARQUES AZEVEDO, Paulo. SALOMÃO COVAS, Samuel. **PACS: Sistemas de Arquivamento e Distribuição de Imagens**. Revista Brasileira de Física Médica. Vol 03. São Paulo, SP. 2009. Disponível em: [https://edisciplinas.usp.br/pluginfile.php/75402/mod\\_resource/content/1/RBFMv4n3a\\_Paulo\\_Mazzoncini.pdf](https://edisciplinas.usp.br/pluginfile.php/75402/mod_resource/content/1/RBFMv4n3a_Paulo_Mazzoncini.pdf) Acesso em: 22 nov. 2020

MARTIN, Robert. **Código Limpo: Habilidades Práticas do Agile Software**. Alta Books. 1ª Ed. Rio de Janeiro, RJ. 2011.

MARTINS, Inês Tomas Marques. **A medicina do futuro nos dias de hoje: aplicações da inteligência artificial**. Trabalho Final de Mestrado Integrado. Universidade de Lisboa. Lisboa, Portugal. 2020. Disponível em: <https://repositorio.ul.pt/bitstream/10451/46808/1/InesTMargarido.pdf> Acesso em: 30 mai. 2021

MEDEIROS, Luciano Frontino De. **Inteligência Artificial Aplicada: uma abordagem introdutória**. Ed. Intersaberes. Curitiba, PR. 2018

MONTINI, Alessandra. **Machine e Deep Learning: fortes tendências para o Brasil em 2019**. 2019. Disponível em: <https://noomis.febraban.org.br/especialista/alessandra-montini/machine-e-deep-learning-fortes-tendencias-para-o-brasil-em-2019> Acesso em: 24 abr. 2021.

NEURALMIND. **Diagnóstico de Alzheimer pode ser otimizado com tecnologia Deep Learning**. Campinas, SP. 2020. Disponível em: <https://neuralmind.ai/2017/11/22/diagnostico-de-alzheimer-pode-ser-otimizado-com-tecnologia-deep-learning/> Acesso em: 23 nov. 2020

NIELSEN, Camille Cardoso. SILVA, Cristiane Campos. **Reabilitação pulmonar em pacientes após COVID-19: uma proposta**. UFF, Rio de Janeiro, RJ. 2020. Disponível em: [https://bdex.eb.mil.br/jspui/bitstream/123456789/7498/1/Cap\\_Camille%20Cardoso%20Nielsen.pdf](https://bdex.eb.mil.br/jspui/bitstream/123456789/7498/1/Cap_Camille%20Cardoso%20Nielsen.pdf) Acesso em: 20 mai. 2021

NOGUEIRA, Makeliny Oliveira Gomes; LEAL, Daniela. **Teorias da Aprendizagem: um encontro entre os pensamentos filosófico, pedagógico e psicológico**. Ed. Intersaberes. Curitiba, PR. 2018. Disponível em: <https://plataforma.bvirtual.com.br/Leitor/Publicacao/158417/pdf/0>. Acesso em: 02 out. 2020.

OLIVEIRA, Aparecido Ferreira ; LEDERMAN, Henrique Manoel; BATISTA, Nildo Alves. **O aprendizado sobre a tecnologia no diagnóstico por imagem. Radiol Bras**. São Paulo, v.47, n.1. 2014. Disponível em: [https://www.scielo.br/pdf/rb/v47n1/pt\\_0100-3984-rb-47-01-18.pdf](https://www.scielo.br/pdf/rb/v47n1/pt_0100-3984-rb-47-01-18.pdf). Acesso em: 28 out. 2020.

OLIVEIRA, Lucas. **Introdução a Deep Learning – Redes neurais e TensorFlow**. 2019. Disponível em: <https://medium.com/@lucasoliveiras/introdu%C3%A7%C3%A3o-a-deep->

[learning-redes-neurais-e-tensorflow-77d8618464e6](#) . Acesso em 11 nov. 2020

PAIVA ANTUNES, Omir. PREVEDELLO, Luciano M. **O potencial impacto da inteligência artificial na radiologia**. Radiol. Bras. Vol 50. São Paulo, SP. Disponível em: [https://www.scielo.br/scielo.php?pid=S0100-39842017000500001&script=sci\\_arttext&tlng=pt](https://www.scielo.br/scielo.php?pid=S0100-39842017000500001&script=sci_arttext&tlng=pt) Acesso em: 22 nov. 2020

PYCHARM. **Imagem de logotipo**. PyCharm. Versão 2021.1.1 Disponível em: <https://www.jetbrains.com/pt-br/pycharm/download/#section=windows> Acesso em: 10 mai 2021.

RADIOLOGIA, **Início da. Sociedade Paulista de Radiologia e Diagnóstico por Imagem**. 2018. Disponível em: <https://www.spr.org.br/a-spr/historia-da-radiologia> . Acesso em: 04 nov. 2020.

REIS, Henrique Marcelo Guérin. Et Al. **A Inteligência Artificial – IA: À disposição de Operadores do Direito**. Revista do Curso de Direito do Centro Universitário Brazcubas. 2019. Disponível em: <https://revistas.brazcubas.br/index.php/revdubc/article/view/695/725> . Acesso em: 08 nov. 2020.

SABBATINI, Renato. **Aplicações da Inteligência Artificial na Radiologia**. Portal Píxeon. 2018. São Paulo, SP. Disponível em: <https://www.pixeon.com/blog/aplicacoes-da-inteligencia-artificial-na-radiologia/> Acesso em: 23 nov 2020.

SANTOS KOENIGKAM, Marcel. Et. Al. **Inteligência Artificial, aprendizado de máquina, diagnóstico auxiliado por computador e radiômica: avanços da imagem rumo à medicina de precisão**. Radiol. Bras. Vol 52. São Paulo, SP. Disponível em: [https://www.scielo.br/scielo.php?pid=S0100-39842019005017103&script=sci\\_arttext&tlng=pt](https://www.scielo.br/scielo.php?pid=S0100-39842019005017103&script=sci_arttext&tlng=pt) Acesso em: 22 nov. 2020

SILVA, Fabrício Machado; LENZ, Maikon Lucian; Et Al. **Inteligência Artificial**. Ed. Sagah. Porto Alegre, 2019. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788595029392/cfi/1!/4/4@0.00:58.2>. Acesso em: 02 out. 2020.

SOBRAL, Osvaldo José. **Inteligência Humana: Concepções e Possibilidades**. Revista Científica FacMais, volume III, Número 1. 2013. Disponível em: <https://revistacientifica.facmais.com.br/wp-content/uploads/2013/05/3.-INTELIG%C3%80NCIA-HUMANA-CONCEP%C3%87%C3%95ES-E-POSSIBILIDADES-Osvaldo-Jos%C3%A9-Sobral.pdf> . Acesso em: 08 nov. 2020.

TENSORFLOW. **Imagem de logotipo**. TensorFlow.Org. 2015. Disponível em: <https://www.tensorflow.org/datasets?hl=pt-br> Acesso em 08 mai 2021.

THIOLLENT, Michel. **Metodologia da Pesquisa-ação**. 4. ed. São Paulo: Cortez, 1986. Disponível em: [academia.edu/32028417/Metodologia Da Pesquisa Acao Michel Thiolle](academia.edu/32028417/Metodologia_Da_Pesquisa_Acao_Michel_Thiolle) Acesso em: 29 nov. 2020

VALE, Simone do. **Pequena História da Radiografia**. Contemporânea. Rio de Janeiro, RJ. 2009. Disponível em: [http://www.contemporanea.uerj.br/pdf/ed\\_13/contemporanea\\_n13\\_05\\_simone.pdf](http://www.contemporanea.uerj.br/pdf/ed_13/contemporanea_n13_05_simone.pdf) . Acesso em: 04 nov. 2020

VÁZQUEZ, Flavio. **Deep Learning made easy with Deep Conection**. Becoming Human: Artificial Intelligence Magazine. 2017. Disponível em: <https://becominghuman.ai/deep-learning-made-easy-with-deep-cognition-403fbe445351> Acesso em: 20 nov. 2020

YAMASHITA, Helio. JÚNIOR, Edson Amaro. **Aspectos Básicos de tomografia computadorizada e ressonância magnética**. Ver. Brasileira de Psiquiatria, vol 23. São Paulo, SP. 2001. Disponível em: [https://www.scielo.br/scielo.php?pid=S1516-44462001000500002&script=sci\\_arttext&tlng=pt](https://www.scielo.br/scielo.php?pid=S1516-44462001000500002&script=sci_arttext&tlng=pt) . Acesso em 03 nov. 2020

## APÊNDICE

O objetivo dessa monografia, é servir de base para estudos futuros. Através da nossa discussão até aqui, comprovamos a intervenção da Deep Learning na área da saúde, esse campo de estudo ainda está no início e as possibilidades são inúmeras. Precisaremos discutir regras éticas básicas, assim como avançar a tecnologia e preparar mais nossos estudantes para uma formação mais multidisciplinar.

Tendo em vista esses pressupostos, disponibilizamos a prova de conceito no site Github, um repositório online, ou seja, uma plataforma de hospedagem de código-fonte, permitindo que outros trabalhos surjam a partir do código construído. Dessa forma, é possível acessá-lo através do link <https://github.com/GabrielPickler/Radiography-Predictions-Deep-Learning> .

Para poder desenvolver qualquer trabalho a partir disso, é necessário conhecimento e acesso ao Python, versão 3.8, também instalado a IDE Pycharm. Todas as dependências do projeto podem ser baixadas com o Pycharm, através do arquivo requirements.txt, disponível na página. Caso tenha problemas durante o desenvolvimento do projeto, como por exemplo com configuração, é recomendado verificar os requisitos do sistema do TensorFlow. Demais informações podem ser acessadas através do repositório, no arquivo README.md.