



UFRR

UNIVERSIDADE FEDERAL DE RORAIMA
DEPARTAMENTO DE CIÊNCIA DA COMPUTAÇÃO
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

Software de Apoio ao Diagnóstico de Pneumonia na
Infância Utilizando Rede Neural Convolutacional
Profunda para Reconhecimento de Padrões em
Imagens de Raio X

Larissa Santos Silva

Boa Vista - RR

Outubro de 2021

Larissa Santos Silva

Software de Apoio ao Diagnóstico de Pneumonia na
Infância Utilizando Rede Neural Convolutacional
Profunda para Reconhecimento de Padrões em
Imagens de Raio X

Monografia de Graduação apresentada ao Departamento de Ciência da Computação da Universidade Federal de Roraima como requisito parcial para a obtenção do grau de bacharel em Ciência da Computação.

Orientador(a)

Prof. Dr. Herbert Oliveira Rocha.

Universidade Federal de Roraima
Departamento de Ciência da Computação

Boa Vista - RR

Outubro de 2021

Dados Internacionais de Catalogação na publicação (CIP)
Biblioteca Central da Universidade Federal de Roraima

S586s Silva, Larissa Santos.

Software de apoio ao diagnóstico de pneumonia na infância utilizando rede neural convolucional profunda para reconhecimento de padrões em imagens de Raio X / Larissa Santos Silva. – Boa Vista, 2021.

74 f. : il.

Orientador(a) Professor Doutor Herbert Oliveira Rocha.

Monografia (graduação) – Universidade Federal de Roraima, Curso de Ciência da Computação.

1 – Inteligência Artificial. 2 – Rede Neural Convolucional. 3 – Aprendizado Profundo. 4 – Pneumonia. I – Título. II – Rocha, Herbert Oliveira (orientador).

CDU – 681:61

DECLARAÇÃO DE AUTORIA

Eu, **Larissa Santos Silva** (código de matrícula **1201324456**), autor da(o) monografia/TCC (Trabalho de Conclusão de Curso) sob o título **Software de Apoio ao Diagnóstico de Pneumonia na Infância Utilizando Rede Neural Convolutacional Profunda para Reconhecimento de Padrões em Imagens de Raio X**, declaro que o trabalho em referência é de minha total autoria e de minha inteira responsabilidade o texto apresentado. Declaro, ainda, que as citações e paráfrases dos autores estão indicadas com as respectivas obras e anos de publicação. Declaro, para os devidos fins que estou ciente:

- dos Artigos 297 a 299 do Código Penal, Decreto-Lei n. 2.848 de 7 de dezembro de 1940;
- da Lei n. 9.610, de 19 de fevereiro de 1998, sobre os Direitos Autorais; e
- que plágio consiste na reprodução de obra alheia e submissão da mesma como trabalho próprio ou na inclusão, em trabalho próprio, de ideias, textos, tabelas ou ilustrações (quadros, figuras, gráficos, fotografias, retratos, lâminas, desenhos, organogramas, fluxogramas, plantas, mapas e outros) transcritos de obras de terceiros sem a devida e correta citação da referência.

O corpo docente responsável pela avaliação deste trabalho poderá não aceitar o referido trabalho caso os pontos mencionados acima sejam descumpridos, por conseguinte, considerar-me reprovado.

Assinatura do acadêmico(a)

Boa Vista - RR, 22 de Outubro de 2021.

FOLHA DE APROVAÇÃO

Monografia de Graduação sob o título **Software de Apoio ao Diagnóstico de Pneumonia na Infância Utilizando Rede Neural Convolutacional Profunda para Reconhecimento de Padrões em Imagens de Raio X** apresentada por **Larissa Santos Silva** e aceita pelo Departamento de Ciência da Computação da Universidade Federal de Roraima, sendo aprovada por todos os membros da banca examinadora abaixo especificada:

Prof. Dr. Herbert Oliveira Rocha
Orientador(a)
Departamento de Ciência da Computação
Universidade Federal de Roraima

Prof. Dr. Felipe Leite Lobo
Departamento de Ciência da Computação
Universidade Federal de Roraima

Prof. MSc. Thais Oliveira Almeida
Departamento de Ciência da Computação
Universidade Federal de Roraima

Boa Vista - RR, 22 de Outubro de 2021.

Com muita satisfação, dedico este trabalho de pesquisa aos meus pais Maria Dalva dos Santos e Ivaldo Pereira da Silva e a minha irmã Rayssa Santos Silva, meus maiores incentivadores na vida. Com muito amor.

Agradecimentos

Primeiramente gostaria de agradecer a Deus, a oportunidade que me foi concedida.

Agradeço a minha mami Maria Dalva e ao meu papito Ivaldo, que deixaram suas vidas no interior para embarcar nessa jornada comigo, e sempre me deram todo o suporte necessário, para chegar aqui, além de nunca me deixarem desistir e acreditarem na minha capacidade, muito obrigado.

Agradeço a minha irmã, Rayssa, pelo amor e por sempre ser minha luz, trazendo alegria nos momentos difíceis.

Agradeço ao meu orientador por acreditar no meu trabalho, pelo o suporte oferecido e dedicação.

E finalmente agradeço a todos que estiveram presente nessa jornada, aqueles que de forma direta ou indireta me deram suporte necessário, para enfrentar todos obstáculos que foi me colocado durante esses anos de faculdade.

À todos o meu mais sincero obrigado.

"Cada sonho que você deixa pra trás, é um pedaço do seu futuro que deixa de existir."

—Steve Jobs

Software de Apoio ao Diagnóstico de Pneumonia na Infância Utilizando Rede Neural Convolutacional Profunda para Reconhecimento de Padrões em Imagens de Raio X

Autor: Larissa Santos Silva

Orientador: Prof. Dr. Herbert Oliveira Rocha.

Resumo

A pneumonia é uma doença respiratória que acomete milhares de crianças no mundo todo. O principal método de diagnosticar a pneumonia é através do exame radiológico de tórax (ou radiografia do tórax). Os diagnósticos são desafiadores, pois a semelhança com outras doenças, a falta de nitidez na imagem ou até mesmo o posicionamento do paciente pode dificultar a interpretação do raio x e acarretar em um diagnóstico demorado ou no pior caso errado. Neste sentido, este trabalho propõe a construção e avaliação de um sistema computacional capaz de auxiliar os profissionais da saúde no diagnóstico de pneumonia, usando redes neurais convolucionais (CNNs) para reconhecimento e classificação de imagens de raio x do tórax. Na avaliação experimental executada, os resultados apontam para resultados promissores no modelo de classificação, obtendo uma precisão de 75% , a acurácia 79% e o recall com 99%.

Palavras-chave: Inteligência Artificial, Rede Neural Convolutacional, Aprendizado Profundo, Pneumonia.

Software de Apoio ao Diagnóstico de Pneumonia na Infância Utilizando Rede Neural Convolutacional Profunda para Reconhecimento de Padrões em Imagens de Raio X

Autor: Larissa Santos Silva

Orientador: Prof. Dr. Herbert Oliveira Rocha.

Abstract

Pneumonia is a respiratory disease that affects thousands of children worldwide. The main method of diagnosing pneumonia is through a chest x-ray (or chest x-ray). Diagnoses are challenging, as the similarity to other diseases, the lack of sharpness in the image or even the positioning of the patient can make the interpretation of the x-ray difficult and lead to a delayed diagnosis or in the worst case wrong. In this sense, this work proposes the construction and evaluation of a computer system capable of assisting healthcare professionals in diagnosing pneumonia, using convolutional neural networks (CNNs) for recognition and classification of chest x-ray images. In the experimental evaluation performed, the results point to promising results in the classification model, obtaining an precision of 75% , an accuracy of 79% and a recall of 99%.

Keywords: Artificial Intelligence, Convolutional Neural Network, Deep Learning, Pneumonia.

Lista de figuras

Figura 1 – Radiografia Negativa de Pneumonia	20
Figura 2 – Radiografia positiva para pneumonia	20
Figura 3 – Visão axiais da TC de tórax de um menino de 7 (sete) anos com tosse produtiva e febre.	21
Figura 4 – Ultrassonografia pulmonar em posição supina de uma menina de 5 anos com tosse produtiva e febre.	23
Figura 5 – Filtro para remoção de ruído.	27
Figura 6 – Categorias da inteligência artificial	29
Figura 7 – Rede Convolutacional com ReLU.	32
Figura 8 – Rede recorrente sem laço de auto realimentação e sem neurô- nios ocultos	34
Figura 9 – Rede recorrente com neurônios ocultos	34
Figura 10 – Arquitetura original YOLO	36
Figura 11 – A arquitetura do modelo proposto (DarkCovidNet).	39
Figura 12 – Representação esquemática do esquema de treinamento e validação empregado no procedimento de validação cruzada de 5 (cinco) etapas.	40
Figura 13 – Arquitetura do modelo de Chaudhary et al. (2019)	41
Figura 14 – Estrutura AlexNet Krizhevsky et al. (2012)	43
Figura 15 – Arquitetura do modelo de Gonsalves e Ye (2021)	44
Figura 16 – Como funciona o sistema de detecção de pneumonia.	48
Figura 17 – Diagrama de fluxo.	49
Figura 18 – Banco de Dados.	52
Figura 19 – Arquitetura de Gonsalves e Ye (2021)	53
Figura 20 – Mapa de recursos para uma imagem de pneumonia	54
Figura 21 – Arquivo model.h5	55
Figura 22 – Estrutura do sistema web	56
Figura 23 – Trecho do código do arquivo app.py	57

Figura 24 – Trecho do código do arquivo app.py	57
Figura 25 – Interface	58
Figura 26 – Previsão correta da normal na imagem	58
Figura 27 – Previsão correta da pneumonia na imagem	59
Figura 28 – Previsão incorreta da imagem.	62
Figura 29 – Previsão correta da pneumonia na imagem.	62
Figura 30 – Gráficos da acurácia e perda do modelo proposto.	63
Figura 31 – Gráfico da curva roc do modelo.	64
Figura 32 – Gráfico QP1	65
Figura 33 – Gráfico QP2	66
Figura 34 – Gráfico QP3	66
Figura 35 – Gráfico QP4	67
Figura 36 – Gráfico QP5	67
Figura 37 – Gráfico QP6	68
Figura 38 – Gráfico QP7	68
Figura 39 – Gráfico QP8	69

Lista de tabelas

Tabela 1 – Classificação dos artigos por técnicas.	47
--	----

Sumário

1	INTRODUÇÃO	14
1.1	Motivação	15
1.2	Definição do Problema	16
1.3	Objetivos	17
1.3.1	Objetivo Geral	17
1.3.2	Objetivos Específicos	17
1.4	Organização do Trabalho	18
2	FUNDAMENTOS TEÓRICOS	19
2.1	Tecnologias para Análise e Diagnóstico de Pneumonia	19
2.1.1	Radiografia do Tórax	19
2.1.2	Tomografia Computadorizada	21
2.1.3	Ultrassonografia	22
2.2	Visão Computacional	23
2.2.1	Representação de Imagem Digital	24
2.2.2	Processamento de Imagens	25
2.2.2.1	Filtros para Eliminação de Ruídos	26
2.2.2.2	Softwares para Processamento de Imagem	27
2.2.2.3	OpenCV: Uma biblioteca de visão computacional	27
2.3	Inteligência Artificial	28
2.4	Aprendizagem de Máquina	29
2.4.1	Aprendizado Profundo	30
2.4.1.1	Redes Neurais Convulsionais - CNN	31
2.4.1.2	Redes Neurais Recorrentes - RNN	33
2.4.2	Frameworks de Classificação e Detecção de Objetos em Imagens	35
2.4.2.1	Tensorflow	35
2.4.2.2	Yolo - You Only Look Once	36
2.4.2.3	PyTorch	37

3	TRABALHOS CORRELATOS	38
3.1	<i>Automated detection of COVID-19 cases using deep neural networks with X-ray images</i>	38
3.2	<i>Diagnosis of Chest Diseases in X-Ray images using Deep Convolutional Neural Network</i>	41
3.3	<i>Pneumonia Radiograph Diagnosis Utilizing Deep Learning Network</i>	42
3.4	<i>Using Convolutional Neural Nets And Tensorflow To Detects The Presence Of Pneumonia In A Patient</i>	43
3.5	Correlações entre os trabalhos e a pesquisa	45
4	MÉTODO DA SOLUÇÃO PROPOSTA	48
4.1	Arquitetura	48
4.2	Ferramentas e Implementações	50
5	AVALIAÇÃO EXPERIMENTAL	60
5.1	Planejamento e projeto dos experimentos	60
5.2	Execução dos experimentos e análise dos resultados	61
5.2.1	Prova de conceito	61
5.2.2	Análise da classificação da pneumonia	63
5.2.3	Análise do sistema proposto como suporte a especialistas da área da saúde	64
6	CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS	70
	Referências	71

1 Introdução

A pneumonia ou pneumonite é uma doença epidêmica provocada por micro-organismo (bactérias, vírus, fungos ou pela inalação de produtos tóxicos) é caracterizada pela inflamação aguda que acomete um ou ambos pulmões (KALIL, 2013). Na pneumonia os alvéolos pulmonares são preenchidos com secreção, reduzindo a entrada de oxigênio, tornando-se difícil respirar.

Segundo a Unicef (2019), a pneumonia mata mais crianças do que qualquer outra doença infecciosa, matando mais de 800.000 (oitocentos mil) crianças com menos de 5 (cinco) anos e globalmente existem mais de 1.400 (mil e quatrocentos) casos de pneumonia por 100.000 (cem mil) crianças.

Atualmente existem vários meios de diagnosticar a pneumonia, tais como (O'QUINN et al., 2019): o uso de exame de sangue para verificar a contagem de glóbulos brancos; teste de gases no sangue arterial; exames de escarro; escultura de líquido pleural; oximetria de pulso; e broncoscopia. Apesar de existirem muitos métodos disponíveis, a radiografia de tórax continua sendo o principal método utilizado, tanto nos hospitais públicos, quanto no privado para o diagnóstico, devido ao seu baixo custo e a facilidade locomoção.

A radiografia de tórax é um método bastante complicado e necessita de especialistas altamente treinados para analisar as imagens. Além disso, alguns fatores podem ocasionar erros ao interpretar uma radiografia do tórax, como sangramento, posicionamento do paciente, qualidade da radiografia, entre outros (O'QUINN et al., 2019). Essas inconsistências entre os profissionais da saúde no diagnóstico podem gerar administração de medicação errada e até mesmo levar o paciente a morte.

Segundo COSTA et al. (2012), os antimicrobianos são utilizados para o combate de pneumonia e estão entre a classe de medicamentos mais utilizada, sendo responsável de 20% a 50% das despesas hospitalares. O uso convulsivo de antibiótico pode acarretar no aumento de resistência dos microrganismos causadores da pneumonia apresentando resistência aos antibióticos. Portanto,

é necessário eliminar o máximo possível os falso-positivo no diagnóstico de pneumonia.

Diante dos dados apresentados acima, surgiu a necessidade de técnicas para auxiliar no diagnóstico da pneumonia, visando contribuir para otimizar o tempo e insumos hospitalares. Neste sentido, a aprendizagem profunda (em inglês, *Deep Learning*) vem progredindo rapidamente e é frequentemente usada apenas para classificar as imagens naturais, mas também para classificar diferentes tipos de imagens médicas (CHAUDHARY et al., 2019). Desempenhado um papel cada vez mais importante na análise de dados médicos, métodos baseados em redes neurais convolucionais (CNN), já foram aplicadas com sucesso para classificar doenças, localizar regiões anormais ou lesões segmentares nas imagens de radiografia de tórax (LI et al., 2019).

Visando contribuir no diagnóstico de pneumonia em crianças, visto principalmente que este é um público que demanda agilidade no diagnóstico e início do tratamento. Este trabalho tem como intuito projetar e desenvolver um sistema computacional, capaz de classificar casos de pneumonia em crianças. Utilizando imagens de radiografias de tórax que serão processadas com técnicas de visão computacional e algoritmos de classificação de imagens para a identificação de padrões que estão relacionados a pneumonia. Assim, o sistema proposto irá informar a estimativa de ausência ou presença de pneumonia, visando auxiliar e otimizar o tempo no trabalho dos especialistas para a conclusão do diagnóstico.

1.1 Motivação

Segundo Ayan e Ünver (2019), o diagnóstico de pneumonia nas imagens de raio x normalmente não é compreensivo, pode confundir-se com outras doenças e pode se comportar como uma anormalidade benigna. Essas inconsistências causam notáveis decisões e variedades subjetivas entre os profissionais da saúde no diagnóstico de pneumonia. Portanto, há uma necessidade de um sis-

tema de suporte computadorizado para ajudar esses profissionais a interpretar as imagens de raio x do tórax para diagnosticar a pneumonia.

Atualmente aprendizagem profunda tem desempenhado um papel cada vez mais importante na análise automática e no diagnóstico clínico de imagens médicas. Em particular, alguns métodos baseados em redes neurais convolucionais (CNN) foram aplicadas com sucesso para classificar doenças, localizar regiões anormais ou lesões segmentares nas imagens de radiografia de tórax (LI et al., 2019).

Por exemplo, Rajpurkar et al. (2017) utilizou o modelo de classificação de ponta a ponta baseada na CNN propondo um modelo que usa como entrada imagens do raio-x do tórax e gera 14 (quatorze) probabilidade patológicas, incluindo prognóstico de pneumonia, alcançado 78% de acurácia. Sistemas de classificação ainda não são utilizados em hospitais, para a detecção/prognóstico de pneumonia, mas vem ganhando grande visibilidade, devido a sua alta precisão em trabalhos já realizados.

1.2 Definição do Problema

O diagnóstico de pneumonia é um grande problema enfrentado pelos os profissionais da saúde, devido a uma série de fatores, como sobrecarga de líquido (edema pulmonar), sangramento, câncer de pulmão, alterações pós-radiação ou alteração cirúrgicas. Outros fatores, como posicionamento do paciente podem alterar a imagem de uma radiografia (O'QUINN et al., 2019). Podendo assim, acarretar em um diagnóstico errado e conseqüentemente no tratamento errado.

A radiografia de tórax é o principal método utilizado para o diagnóstico de pneumonia, devido seu baixo custo. Além disto, os exames de raio X podem ser feitos no leito do paciente quando estiver impossibilitado de se locomover (RAOOF et al., 2012). Exames como tomografia computadorizada e ultrassonografia são de caráter não invasivo, no entanto a sua utilização rotineira, por exemplo, em UTIs são dificultadas pelos problemas inerentes aos pacientes

críticos.

Diante dos dados e desafios apresentados, o problema apontado neste trabalho é expresso na seguinte questão: **Como auxiliar médicos utilizando classificação de imagens de raio x do tórax para a realização de diagnóstico de pneumonia infantil?**

1.3 Objetivos

1.3.1 Objetivo Geral

Este trabalho tem como objetivo, projetar, desenvolver e avaliar um sistema computacional, para auxiliar os médicos na análise de imagens de radiografia, para o diagnóstico de pneumonia infantil, via classificação da anatomia pulmonar e diâmetro cardíaco em imagens de raio x.

1.3.2 Objetivos Específicos

Os objetivos específicos são:

1. Avaliar modelos de classificação de imagens capaz de identificar ausência ou presença de pneumonia;
2. Analisar algoritmos de pré-processamento de imagens;
3. Propor um método para identificar pneumonia em imagens de raio x do tórax utilizando fatores de modificação da anatomia pulmonar e diâmetro cardíaco;
4. Validar a solução proposta, através de testes experimentais utilizando banco de imagens da literatura e validação de médicos, com o intuito de examinar a sua eficácia e aplicabilidade.

1.4 Organização do Trabalho

A introdução deste trabalho apresentou: o contexto, definição do problema, motivação, objetivos, metodologia e contribuições desta pesquisa. Os capítulos restantes são organizados da seguinte forma:

- No Capítulo 2, **Fundamentos Teóricos**, são apresentados os conceitos abordados neste trabalho, especificamente: pneumonia, radiografia do tórax, processamento de imagens, redes neurais e frameworks.
- No Capítulo 3, **Trabalhos Correlatos**, são analisados os trabalhos correlatos a solução proposta.
- No Capítulo 4, **Método da Solução Proposta**, é descrito as etapas de execução do método da solução proposta para o sistema de diagnóstico de pneumonia na infância utilizando rede neural convolucional profunda para reconhecimento de padrões em imagens de raio x.
- No Capítulo 5, **Avaliação Experimental**, é apresentada a execução da avaliação da solução proposta.
- E por fim no Capítulo 6, **Considerações Finais E Trabalhos Futuros**, apresenta-se as considerações final e análise das atividades desenvolvidas.

2 Fundamentos Teóricos

Neste capítulo serão apresentados os principais conceitos e definições utilizados para o desenvolvimento deste trabalho.

2.1 Tecnologias para Análise e Diagnóstico de Pneumonia

Segundo Organization (2019) a pneumonia é uma forma de infecção respiratória aguda que acomete os pulmões. Os pulmões são formados por pequenos sacos chamados de alvéolos, que se enchem de ar quando uma pessoa saudável respira. Quando a pessoa está com pneumonia, os alvéolos são preenchidos com pus e líquido quando respira, tornando a respiração dolorosa e limita a ingestão de oxigênio.

A pneumonia apresenta maiores riscos para recém-nascido, crianças menores de 5 (cinco) anos e idosos. Podendo ser transmitida pelo ar, saliva, secreção e transfusão de sangue (KALIL, 2013). Diagnosticar a pneumonia é um trabalho desafiador e deve ser realizado por especialistas, através de exames como radiografia do tórax, tomografia, ultrassonografia e entre outros.

2.1.1 Radiografia do Tórax


Segundo Raoof et al. (2012) o raio x do tórax ainda é o teste de triagem mais solicitado, fornecendo uma janela para o tórax do paciente. A razão para isso incluem a facilidade com que uma radiografia torácica pode ser realizada (incluindo estudos à beira do leito), familiaridade de radiologistas e alguns pneumologistas em sua interpretação, menos exposição à radiação para o paciente e menores custos em comparação com tomografias computadorizadas.

Um diagnóstico preciso, requer bastante atenção e experiência, pois geralmente o aparecimento de pneumonia nas radiografias não são claros,

devido algumas condições como sobrecarga de líquido (edema pulmonar), perda de volume, câncer de pulmão e outros fatores que acabam dificultando a interpretação das imagens (O'QUINN et al., 2019). Um exemplo desse desafio pode ser visto nas imagens abaixo.


As Figuras 1 e 2 são exemplos de radiografias de um paciente saudável e outro com pneumonia, as duas apresentam a falta de diferenças visuais, pois a Figura 1 está mais cheia de cor, ou seja, mais nítida do que a Figura 2 que está mais apagada, mais difícil de compreender, assim dificultando a interpretação.

Figura 1 – Radiografia Negativa de Pneumonia



Fonte: Artigo (O'QUINN et al., 2019)

Figura 2 – Radiografia positiva para pneumonia




Fonte: Artigo (O'QUINN et al., 2019).

Com o objetivo de classificar e codificar as anormalidades radiográficas o método de referência para a análise de radiografias convencionais de tórax é a Classificação Radiológica da OIT (organização internacional do trabalho). Permite que as radiografias sejam interpretadas e codificadas de uma forma padronizada, pela utilização de radiografias padrão comparativas e folhas de registro apropriadas (BRASIL et al., 2006).

2.1.2 Tomografia Computadorizada

Segundo Raof et al. (2012) a tomografia computadorizada permitiu a imagem em corte transversal e melhorou a visualização das anormalidades em comparação com as radiografias, aumentando o contraste e eliminando a sobreposição de estruturas como resultados do corte tomográfico, agora em praticamente qualquer plano. A tomografia computadorizada permitiu melhor visualização das vias aéreas, mediastino e vascular pulmonar. A Figura 3 apresenta um exemplo de tomografia computadorizada (TC) de uma criança de 7 (sete) anos, a seta preta indica áreas do pulmão pouco realçadas ou liquefeitas ou áreas dos pulmões de baixa densidade. A seta amarela indica um aumento dos pulmões. A seta azul indica necrose dos pulmões.

Figura 3 – Visão axiais da TC de tórax de um menino de 7 (sete) anos com tosse produtiva e febre.




Fonte: Artigo (YAN et al., 2020)

A tomografia computadorizada de tórax é o método mais sensível em comparação ao raio x do tórax, podendo ser útil, em casos que a acurácia do raio x, seja baixa. Por exemplo, em pacientes obesos, imunossuprimidos e outros. Por outro lado, as limitações são várias, entres elas o custo, a logísticas é os efeitos adversos da radiação ao longo prazo, que muitos radiologistas ainda estão preocupados, limitando assim o seu uso. Outra grande limitação, é a locomoção dos pacientes em estado crítico (RAOOF et al., 2012; ALZHRANI et al., 2017).

2.1.3 Ultrassonografia

Segundo Reissig et al. (2012) a ultrassonografia pode ser realizada com qualquer aparelho de ultrassonografia do abdômen. A seleção da sonda mais adequada é crítica: as sondas vasculares têm a resolução mais alta nas camadas superficiais, mas tornam a identificação do artefato mais difícil. Sondas convexas ou micro convexas (3,5–5 MHz) são as mais adequadas para diagnosticar pneumonia por ultrassonografia pulmonar. Na Figura 4 apresenta um exemplo de ultrassonografia de uma criança de 5 anos, A seta amarela indica derrame pleural do pulmão. A seta azul indica edema inflamatório perilesional.

Figura 4 – Ultrassonografia pulmonar em posição supina de uma menina de 5 anos com tosse produtiva e febre.



Fonte: Artigo (YAN et al., 2020)

A ultrassonografia não é um exame convencional, para o diagnóstico de pneumonia, mais vem mostrando eficácia, visto que, mostra com alta precisão muitas doenças pulmonares, além do exame pode ser feito na beira do leito possibilitando um tratamento imediato (ALZHRANI et al., 2017; REISSIG et al., 2012). Por outro lado, a ultrassonografia é dependente de um operador e requer ultrassonografistas habilitados, dificultando o uso rotineiro na clínica como um método de diagnóstico para pneumonia em crianças (YAN et al., 2020).

2.2 Visão Computacional

A visão computacional tenta se igualar a visão humana, pois também possui como entrada, uma imagem, contudo a saída é uma exibição de imagem como um todo, ou parcialmente (MARENGONI; STRINGHINI, 2009). Ferramentas de diagnóstico auxiliado por computador (CADx) visam complementar a tomada de decisão clínica. Eles combinam elementos de visão computacional e inteligência artificial com processamento de imagem radiológica para reconhecer padrões

(RAJARAMAN et al., 2018).

Segundo Bradski e Kaehler (2008) visão computacional é a transformação de dados de uma câmera fotográfica ou de vídeo em uma decisão ou em uma nova representação. Todas essas transformações são feitas para atingir algum objetivo específico. Os dados de entrada podem incluir algumas informações contextuais, como a câmera está montada em um carro ou o medidor de alcance do laser que indica que um objeto está a 1 (um) metro de distância. Uma nova representação pode significar transformar uma imagem colorida em uma imagem em tons de cinza ou remover o movimento da câmera de uma sequência de imagens.

Segundo Marengoni e Stringhini (2009) a visão computacional pode ser dividida em 3 (três) níveis de processamento de imagem, sendo eles, baixo-nível, nível-médio e alto-nível. Os processos de baixo-nível envolvem operações primitivas, tais como a redução de ruído ou melhoria no contraste de uma imagem. Os processos de nível-médio são operações do tipo segmentação (particionamento da imagem em regiões) ou classificação (reconhecimento dos objetos na imagem). Os processos de alto nível estão relacionados com as tarefas de cognição associadas com a visão humana.

2.2.1 Representação de Imagem Digital

Uma imagem consiste em uma matriz bidimensional de números. A cor ou sombra de cinza exibida para um determinado elemento de imagem (pixel) depende do número armazenado na matriz para aquele pixel (PHILLIPS, 1994). O objetivo usual da imagem digital é produzir a apresentação pretendida no dispositivo de exibição final (POYNTON; FUNT, 2014).

De acordo com Poynton e Funt (2014) os dados de imagem são normalmente referenciados a um conjunto de primários aditivos. Depois de detectados e registrados, os dados da imagem são associados à representação de cores definida em um padrão de intercâmbio. Por exemplo, o padrão RGBs que

se aplica na computação geral; o padrão BT.709 se aplica ao HD. (Não por coincidência, esses padrões compartilham o mesmo conjunto de primárias). A exibição fiel é obtida em um dispositivo de exibição que está em conformidade com o padrão colorimétrico pretendido.

Em muitas aplicações de imagem digital, não há câmeras digitais, por exemplo nas modalidades de imagens médicas (radiografia e tomografia computadorizada), esses dados são produzidos por algoritmos e não correspondem a nenhuma imagem óptica. Outro exemplo é em artes gráficas, onde é comum usar software (como o Photoshop), produzindo uma imagem que não tem contato direto com o mundo físico. Nesses casos, a uniformidade perceptiva deve ser referenciada apenas ao display (POYNTON; FUNT, 2014).

Segundo Poynton e Funt (2014) pesquisadores de visão computacional estão desenvolvendo novas abordagens para reconhecimento e detecção de objetos que são baseadas quase que diretamente em imagens e evitam o uso de modelos tridimensionais intermediários. Muitas dessas técnicas dependem de uma representação de imagens que induz uma estrutura de espaço vetorial linear e, em princípio, requer correspondência de recursos densa. Esta representação de imagens permite a utilização de técnicas de aprendizagem tanto para a análise de imagens (para visão computacional) como para a síntese de imagens (para computação gráfica).

2.2.2 Processamento de Imagens

De acordo com Marengoni e Stringhini (2009) os processos de visão computacional, muitas vezes, necessitam de uma etapa de pré-processamento envolvendo o processamento de imagens. As imagens de onde queremos extrair alguma informação, em alguns casos precisam ser convertidas para um determinado formato ou tamanho e precisam ainda ser filtradas para remover ruídos provenientes do processo de aquisição da imagem.

O processamento de imagens tem como objetivo, eliminar perturbações

sistemáticas da imagem ou melhorar a visualização de algumas funcionalidades da imagem, podendo assim, transformar uma imagem em outra imagem, e muitas vezes com o mesmo suporte. Perturbações típicas são ruído de aquisição de alta frequência, variações de luminância de fundo, geometria da câmera distorções, eco, etc. Métodos de pré- processamento são frequentemente aplicados de forma sistemática em todas as imagens criadas por um determinado dispositivo. Portanto, muitas vezes são dependentes do dispositivo; além, deles precisarem ser rápidos e eficientes (PHILLIPS, 1994).

2.2.2.1 Filtros para Eliminação de Ruídos

No contexto de classificação de imagens, usualmente estas imagens precisam ser manipuladas, visando converter para um determinado formato ou tamanho, além de, precisarem ser filtradas para remover ruídos provenientes do processo de aquisição da imagem. Os ruídos podem seguir de diversas fontes. Por exemplo, o tipo de sensor utilizado, a iluminação do ambiente, posicionamento do objeto, entre outros. O ruídos podem dificultar a interpretação ou reconhecimento de objetos nas imagens (MARENGONI; STRINGHINI, 2009).

Os filtros são ferramentas responsáveis por remover os ruídos das imagens, os filtros podem ser espaciais, onde atuam diretamente na imagem ou de frequência, onde a imagem é inicialmente transformada para o domínio de frequência usando da transformada de Fourier e então é filtrada neste domínio e em seguida a imagem filtrada é transformada de volta para o domínio de espaço (MARENGONI; STRINGHINI, 2009). A Figura 5 apresenta um exemplo de uma imagem com ruído (à esquerda) e da imagem filtrada (à direita).

Figura 5 – Filtro para remoção de ruído.



Fonte: Artigo (MARENGONI; STRINGHINI, 2009)

2.2.2.2 Softwares para Processamento de Imagem

Nesta sessão, serão expostos os softwares para processamento de imagens, em companhia com suas definições, vantagens e desvantagens em relação aos métodos convencionais e tecnológicos que o mesmo foi utilizado.

2.2.2.3 OpenCV: Uma biblioteca de visão computacional

Segundo Sobral (2013) o OpenCV ¹ (Open Source Computer Vision Library) é uma biblioteca multiplataforma, totalmente livre ao uso acadêmico e comercial, para o desenvolvimento de aplicativos na área de Visão Computacional. Esta biblioteca é composta por mais de 500 (quinhentos) algoritmos e foi desenvolvida nas linguagens de programação C/C++.

OpenCV foi idealizada com o objetivo de tornar a visão computacional acessível a usuários e programadores, em áreas como, a interação humano-computador em tempo real e a robótica. Para isto, a biblioteca foi dividida em 5 (cinco) grupos de funções, que são, processamento de imagens, análise estrutural, análise de movimento e rastreamento de objetos, reconhecimento de

¹ <https://opencv.org>

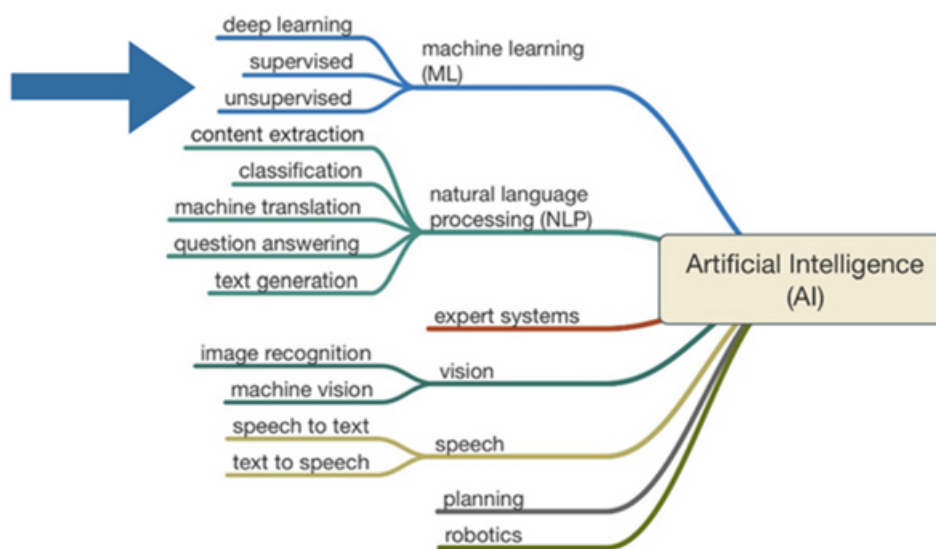
padrões e calibração de câmera e reconstrução 3D (MARENGONI; STRINGHINI, 2009).

2.3 Inteligência Artificial

De acordo com Ongsulee (2017) a inteligência artificial (IA) é a inteligência exibida por máquinas. Na ciência da computação, o campo de pesquisa em IA se define como o estudo de agentes inteligentes: qualquer dispositivo que percebe seu ambiente e realiza ações que maximizam sua chance de sucesso em algum objetivo. Coloquialmente, o termo inteligência artificial é aplicado quando uma máquina imita funções cognitivas que os humanos associam a outras mentes humanas, como aprendizado e solução de problemas.

A inteligência artificial, atualmente é um campo próspero com aplicações ativas, podendo ser categorizada conforme a Figura 6, no trabalho proposto será usado 2 (duas) categorias da IA, sendo elas, *machine learning* (ML) e *vision* que aborda as categorias de visão computacional. A capacidade de classificação da IA incluem compreender com sucesso a fala humana, competindo em alto nível em sistemas de jogos estratégicos (como xadrez), carros autônomos, roteamento inteligente em redes de distribuição de conteúdo, simulações militares e interpretação de dados complexos (ONGSULEE, 2017).

Figura 6 – Categorias da inteligência artificial



Fonte: Artigo (COELHO, 2020)

2.4 Aprendizagem de Máquina

Os sistemas de inteligência artificial, baseados em aprendizado de máquina, atualmente se destacam em uma série de tarefas complexas, que vão desde a detecção de objetos em imagens e a compreensão de linguagens naturais (SAMEK et al., 2017). De acordo com Simon (2013) o aprendizado de máquina é como um campo de estudo que dá aos computadores a habilidade de aprender sem serem explicitamente programados.

O aprendizado de máquina em geral, explora o estudo e construções de programa que podem aprender e fazer previsões sobre quaisquer dados obtidos, e está intimamente relacionado a estática computacionais, que também se concentra em fazer previsões através do uso de computadores (ONGSULEE, 2017). Além disto, há vários tipos de aprendizado de máquina, que são eles:

- Aprendizagem supervisionada: onde o algoritmo gera uma função que mapeia entradas para saídas desejadas. Uma formulação padrão da tarefa de aprendizagem supervisionada é o problema de classificação: o aluno

deve aprender (para aproximar o comportamento de) uma função que mapeia um vetor em uma das várias classes, observando vários exemplos de entrada-saída da função (AYODELE, 2010).

- **Aprendizagem não supervisionada:** são aqueles que modelam um conjunto de entrada. Por exemplo, a dona de uma loja quer conhecer o perfil das suas clientes. Nesse caso, o computador precisará descobrir os perfis dos clientes sem dados anotados.
- **Aprendizagem semi supervisionada:** são as que combinam exemplos marcados e não marcados, com o objetivo de gerar uma função ou classificador apropriado.
- **Aprendizagem por reforço:** onde o algoritmo aprende uma política de como agir dada uma observação do mundo. Cada ação tem algum impacto no ambiente, e o ambiente fornece feedback que orienta o algoritmo de aprendizagem (AYODELE, 2010).
- **Transdução:** trabalha com previsão, tenta prever novas saídas com base nas entradas de treinamento, saídas de treinamento e novas entradas.
- **Aprender a aprender:** onde o algoritmo aprende sua própria tendência indutiva com base na experiência anterior (AYODELE, 2010).

2.4.1 Aprendizado Profundo

O aprendizado profundo é o estudo de redes neurais artificiais e algoritmos de aprendizado de máquina relacionados, que contém mais de uma camada oculta (ONGSULEE, 2017). De acordo com LeCun et al. (2015) o aprendizado profundo, permite que modelos computacionais, compostos de várias camadas de processamento, aprendam representações de dados com vários níveis de abstração. Esses métodos melhoraram drasticamente o estado da arte em reconhecimento de fala, reconhecimento de objeto visual, detecção de objeto e muitos outros domínios, como descoberta de drogas e genômica.

Uma imagem, por exemplo, vem na forma de uma matriz de valores de pixel, e os recursos aprendidos na primeira camada de representação normalmente representam ausência ou presença de bordas em locais específicos. A segunda camada normalmente identifica arranjos particulares de bordas. A terceira camada reúne motivos em combinação maiores que correspondem à parte de objetos familiares. Sendo elas, aprendidas a partir de dados usando um procedimento de aprendizado de propósito geral (LECUN et al., 2015).

Capaz de compreender estruturas de difícil compreensão em grandes conjuntos de dados, o aprendizado profundo vem avançando muito na resolução de problemas como reconhecimento de objetos. Uma das promessas do aprendizado profundo é substituir recursos feitos à mão por algoritmos eficientes para aprendizado de recursos não supervisionado ou semi supervisionado e extração de recursos hierárquicos (ONGSULEE, 2017).

2.4.1.1 Redes Neurais Convulsionais - CNN


A neural convolucional é um algoritmo de aprendizado profundo que pode ter como entrada uma imagem, e assim, atribuir sua importância a vários aspectos aos objetos da imagem, podendo assim ser capaz de diferenciar uma imagem da outra. Para isto, a rede utiliza operações matemáticas chamadas de convolução, sendo que a convolução é um tipo especializado de operação linear, ou seja, as redes convolucionais são simplesmente redes neurais que usam convolução no lugar da multiplicação geral da matriz em pelo menos uma de suas camadas (BENGIO et al., 2017).

Segundo Bengio et al. (2017) as redes convulsionais são um tipo especializado de rede neural para processamento de dados que tem uma topologia conhecida como grade. Os exemplos incluem dados de série temporal, que podem ser considerados como uma grade 1D que coleta amostras em intervalos de tempo regulares, e dados de imagem, que podem ser considerados como uma grade 2D de pixels.

De acordo com Ravi et al. (2016) a arquitetura das redes neurais convulsionais (CNN) mostrada na Figura 7 pode ser definida como um conjunto intercalado de *feed-forward* camadas que implementam filtros convolucionais seguidos por camadas de redução, camadas de retificação ou camada de pooling. Cada camada da rede origina um recurso abstrato de alto nível.

Nesta rede convolucional as saídas (não os filtros) de cada camada (horizontalmente) de uma arquitetura de rede convolucional típica aplicada à imagem de um cachorro Samoyed (canto inferior esquerdo da Figura 7; e entradas RGB (vermelho, verde, azul), canto inferior direito). Cada imagem retangular é um mapa de recursos correspondente à saída de um dos recursos aprendidos, detectado em cada uma das posições da imagem. As informações fluem de baixo para cima, com recursos de nível inferior atuando como detectores de borda orientados, e uma pontuação é calculada para cada classe de imagem na saída.

Figura 7 – Rede Convolucional com ReLU.



Fonte: Artigo (LECUN et al., 2015)

Na arquitetura das redes neurais convulsionais (CNN), ainda temos as funções de ativações que são usadas para trazer a não linearidade ao sistema, fazendo assim, a rede pode aprender qualquer tipo de habilidade. As principais

funções de ativações são `sigmoid`, `tanh` e `softmax`, sendo que a mais indicada para rede neural a `Relu`, devido a sua eficiência computacional.

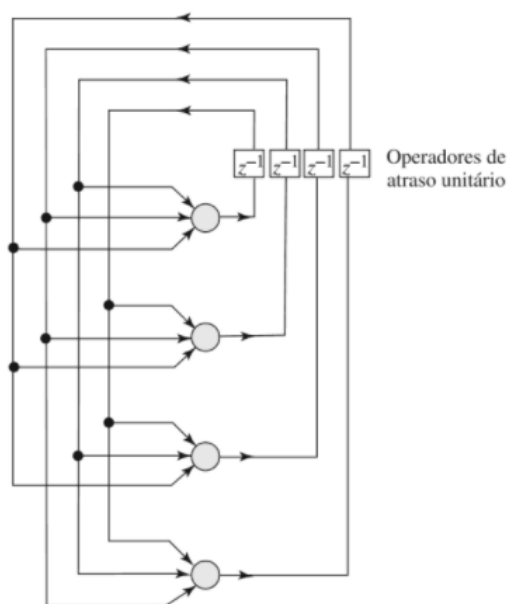
2.4.1.2 Redes Neurais Recorrentes - RNN

As redes neurais recorrentes (RNNs) são uma arquitetura de aprendizagem profunda que segundo Lemley et al. (2017) são projetadas para operar em uma sequência de dados como entrada, como uma sequência de quadros de um vídeo. Isso pode ser considerado como um sistema com memória que pode lembrar a entrada no estágio anterior e tomar decisões para a entrada atual com base na sequência de dados anteriores.

A memória de uma rede RNN é conhecida como o estado oculto da rede. O estado oculto da rede é atualizado com base no estado atual. A entrada para a rede e a saída do RNN são calculadas com base no estado da rede em cada sequência (LEMLEY et al., 2017). Por esse motivo, costuma-se dizer que os RNNs contém uma memória, embora os RNN sejam apenas um modelo simples e poderoso, que obteve grande sucesso no reconhecimento de voz e cena de vídeo, onde muitas vezes são combinados com camadas convolucionais.


De acordo com Haykin (2007) uma rede recorrente pode consistir, por exemplo, de uma única camada de neurônios com cada neurônio alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios, como ilustrado na Figura 8. Na estrutura representada nesta figura, não há laços de auto realimentação na rede; auto realimentação se refere a uma situação onde a saída de um neurônio é realimentada para a própria entrada. A rede recorrente ilustrada na Figura 9 também não tem neurônios ocultos. Na Figura 9 ilustramos outra classe de redes recorrentes com neurônios ocultos. As conexões de realimentação mostrada na Figura 9 se originam dos neurônios ocultos bem como dos neurônios de saída.

Figura 8 – Rede recorrente sem laço de auto realimentação e sem neurônios ocultos



Fonte: Artigo (HAYKIN, 2007)

Figura 9 – Rede recorrente com neurônios ocultos



Fonte: Artigo (HAYKIN, 2007)

A função de ativação da RNN é responsável por limitar a saída do neurônio, assim evitando a expansão contínua. As mais usadas para esse processo

são a sigmóide logística, tangente hiperbólica, gaussiana, função linear, função degrau e função degrau bipolar.

2.4.2 Frameworks de Classificação e Detecção de Objetos em Imagens

Nesta sessão, serão apresentados os frameworks para classificação e detecção de objetos em imagens, juntamente com seus conceitos, vantagens e desvantagens em relação ao método convencional e tecnológico que utilizam frameworks para suas atividades.

2.4.2.1 Tensorflow


Segundo Abadi et al. (2016) o TensorFlow é um sistema de aprendizado de máquina que opera em grande escala e em ambientes heterogêneos. O TensorFlow usa gráficos de fluxo de dados para representar computação, estado compartilhado e as operações que alteram esse estado. Ele mapeia os nós de um gráfico de fluxo de dados em várias máquinas em um cluster e em uma máquina em vários dispositivos computacionais.

O TensorFlow oferece uma flexibilidade ao desenvolver, além de permitir, experimentos de novas otimizações e algoritmos de treinamento. Este sistema é compatível com uma variedade de aplicativos, com foco no treinamento e inferência em redes neurais profundas. Vários serviços do Google usam o TensorFlow na produção, sendo o TensorFlow um projeto de código aberto e ele se tornou amplamente usado para pesquisas de aprendizado de máquina (ABADI et al., 2016).

2.4.2.2 Yolo - You Only Look Once

O Yolo é uma nova abordagem para a detecção de objeto, sendo capaz, de detectar objetos com problemas de regressão, para caixas delimitadoras e probabilidades de classes associadas, que são previstas como única rede neural de imagens completas em uma avaliação (DU, 2018). O Yolo é composta por 27 (vinte e sete) camadas CNN, com 24 (vinte e quatro) camadas convolucionais, seguidas por 2 (duas) camadas Fully Connected e 1 (uma) camada de detecção final, conforme mostrado na Figura 10 (PUTRA et al., 2018).

Figura 10 – Arquitetura original YOLO



Fonte: Artigo (PUTRA et al., 2018)

Segundo Putra et al. (2018) a imagem de entrada é dividida em células de grade $S \times S$ e dentro de cada grade, a célula prevê caixas delimitadoras B e uma pontuação para cada uma das classes C . Cada caixa delimitadora consiste em 5 (cinco) previsões que são centro x , centro y , largura, altura e confiança da caixa delimitadora. Para cada célula da grade, haverá apenas um conjunto de pontuações de classe C para todas as caixas delimitadoras naquela região. Portanto, a saída da rede YOLO será um vetor de números $S \times S \times (5B + C)$ para cada imagem.

As camadas totalmente conectadas, juntamente com os recursos extraídos das camadas convolucionais e as informações para prever as probabilidades do objeto desejado, são usadas ao mesmo tempo, para as construções da caixa

delimitadora. A camada de detecção final YOLO é uma regressão que mapeia a saída da última camada totalmente conectada para a caixa delimitadora final e atribuições de classe (PUTRA et al., 2018).

2.4.2.3 PyTorch

PyTorch é uma biblioteca de tensores otimizada para aprendizado profundo e de código aberto, que permite a prototipagem rápida para projetos analíticos sem se preocupar com a complexidade da estrutura. PyTorch não segue a abordagem simbólica usada em muitas outras estruturas de aprendizagem profunda, mas se concentra na diferenciação do puramente imperativo programas, com foco na extensibilidade e baixa sobrecarga (PASZKE et al., 2019).

Segundo Paszke et al. (2019), o principal caso de uso para PyTorch é treinar modelos de aprendizado de máquina em GPU. Como uma das maiores limitações das GPUs é a baixa capacidade de memória, o PyTorch toma muito cuidado para certificar-se de que todos os valores intermediários sejam liberados assim que se tornarem desnecessários.

3 Trabalhos Correlatos

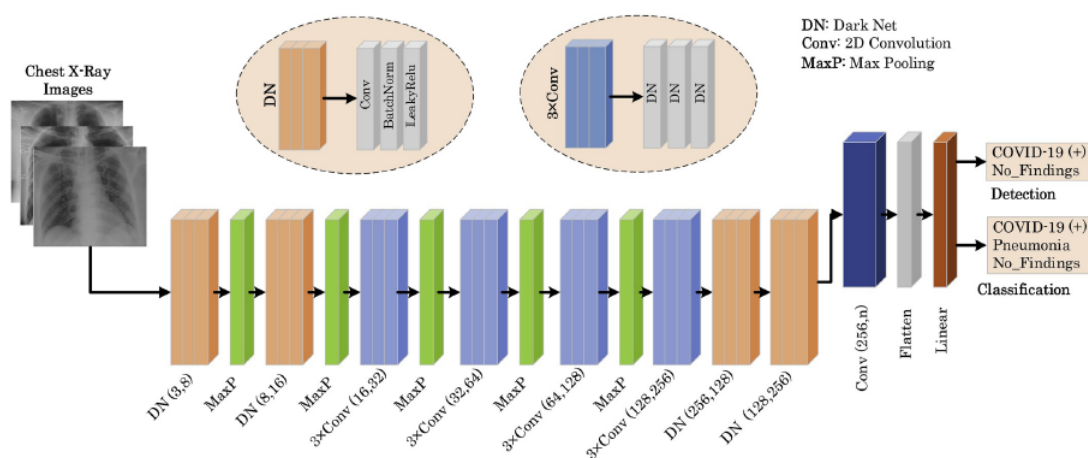
Neste capítulo serão expostos os principais trabalhos existentes, na literatura, que se relacionam com o sistema proposto neste trabalho. Os trabalhos em específico abordam os seguintes tópicos: Pré-processamento de Imagem de Raio X de Tórax, Aprendizagem Profunda, Detecção de Objetos e Reconhecimento de Padrões.

3.1 *Automated detection of COVID-19 cases using deep neural networks with X-ray images*

No trabalho de Ozturk et al. (2020) é proposto um sistema para classificação binária (COVID vs. No-Findings) e classificação multiclasse (COVID vs. No-Findings vs. Pneumonia) para fornecer o diagnóstico automático de COVID-19. O modelo de aprendizado profundo DarkCovidNet conta com arquitetura de ponta a ponta, e utiliza-se o (YOLO) (REDMON; FARHADI, 2018) para detectar os objetos em tempo real.

O modelo DarkCovidNet foi utilizado como classificador, funciona da seguinte maneira, cada camada DN (DarkNet) tem uma camada convolucional seguida por uma operação BatchNorm e LeakyReLU, já a camada 3xconv tem a mesma configuração 3 (três) vezes consecutivas. O LeakyReLU é uma modificação da operação ReLU usada para prevenir a morte de neurônios, mas ao contrário de ReLU, o LeakyReLU tem um pequeno valor ϵ para superar o problema do neurônio moribundo. O método Maxpool é utilizado para reduzir o tamanho de uma entrada, assim obtendo o máximo de uma determinada região por seu filtro. A Figura 11 apresenta a arquitetura do modelo proposto.


Figura 11 – A arquitetura do modelo proposto (DarkCovidNet).



Fonte: Artigo (OZTURK et al., 2020)

Segundo Ozturk et al. (2020) foi treinado o modelo de aprendizado profundo DarkCovidNet para classificar imagens de raios-X em 3 (três) categorias: COVID-1, No-Findings, Pneumonia. O modelo DarkCovidNet foi treinado para detectar duas classes: as categorias COVID-19 e No-Findings. O desempenho do modelo proposto é avaliado usando o procedimento de validação cruzada de 5 vezes para o problema de classificação binária e tripla, sendo 80% das imagens de raios-X usadas para treinamento e 20% para validação. Os experimentos foram repetidos cinco vezes, conforme mostrado na Figura 12.

Figura 12 – Representação esquemática do esquema de treinamento e validação empregado no procedimento de validação cruzada de 5 (cinco) etapas.



Fonte: Artigo (OZTURK et al., 2020)

Ozturk et al. (2020) utilizou dois banco de dados, sendo o primeiro desenvolvido por Cohen et al. (2020) que aproveitou imagens de raio X, com o diagnóstico de COVID-19 de várias fontes de acesso aberto, sendo que atualmente existem 127 (cento e vinte e sete) imagens de raio X diagnosticada com COVID-19. Outro banco de dados utilizado, foi o ChestX fornecido por Wang et al. (2017), usada para imagens normais é de pneumonia, sendo usadas 500 (quinhentas) imagens de classe normal e 500 imagens de raio X de tórax frontal de classe de pneumonia.

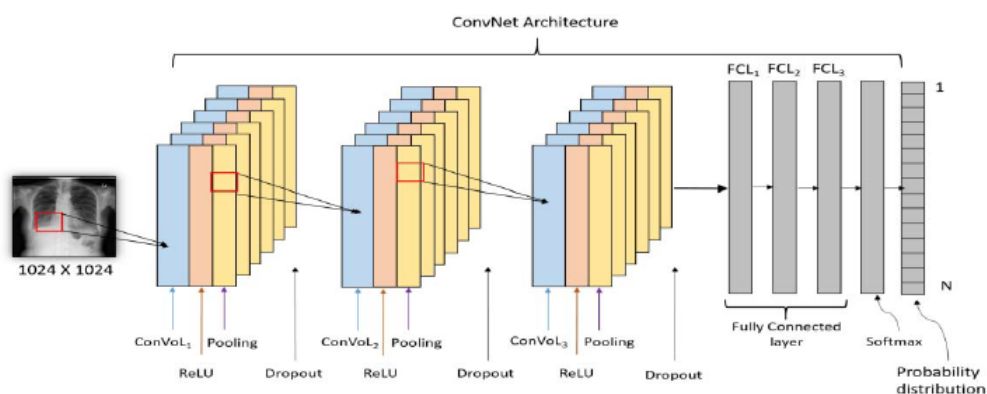
O sistema desenvolvido por Ozturk et al. (2020) é capaz de realizar atividades binárias e multiclasse com uma precisão de 98,08% e 87,02%, mostrando que o modelo está pronto para ser testado em banco de dados maior. Este sistema pode ser utilizado em locais remotos, em países afetados pelo COVID-19, é usado para diagnosticar outras doenças relacionadas ao tórax, como pneumonia.

3.2 *Diagnosis of Chest Diseases in X-Ray images using Deep Convolutional Neural Network*

No estudo de Chaudhary et al. (2019) é apresentado e avaliado uma rede neural profunda, capaz de classificar as doenças torácicas. Para isso, foi usado camadas convolucionais, ativações de Unidades Lineares Retificadas (ReLU), camada Pooling e camada totalmente conectada, sendo que, a última camada conectada completamente é composta por 15 unidade de saída, visto que cada unidade de saída preverá a probabilidade de uma das 15 doenças, tais como: pneumonia, pneumotórax, fibrose, enfisema e outros.

A arquitetura proposta na Figura 13 consiste em 12 camadas, podendo ser dividida da seguinte maneira, 3 camadas convolucionais, 3 camadas de ativação ReLU não linear, que proporciona uma execução mais rápida e auxilia a rede neural a entender as funções complexas, 3 camadas pool máximo, para reduzir o número de parâmetro e tentar reduzir o problema de excesso de ajuste, seguida por três camadas totalmente conectadas. A saída da camada totalmente conectada é encaminhada para a função Softmax que fornece a probabilidade de cada classe para uma determinada entrada.

Figura 13 – Arquitetura do modelo de Chaudhary et al. (2019)



Fonte: Artigo (CHAUDHARY et al., 2019)

O conjunto de dados usado para treinamento do trabalho proposto, foi o Chest X-Ray (WANG et al., 2017) de acesso aberto, composto com 112.120


imagens de radiografia de tórax, sendo que, nelas estão contidas 15 classes chamadas atelectasia, cardiomegalia, efusão, infiltração, massa, nódulo, pneumonia, pneumotórax, consolidação, edema, enfisema, fibrose, pleural, espessamento, hérnia e não encontrada. Este modelo alcançou 89,77% de precisão na classificação destas diferentes doenças.

3.3 *Pneumonia Radiograph Diagnosis Utilizing Deep Learning Network*

O trabalho de O'Quinn et al. (2019) desenvolveu um algoritmo utilizando redes neurais convolucionais (CNNs) para detectar sinais visuais de pneumonia em imagens médicas e fazer um diagnóstico. Para o desenvolvimento deste trabalho, uma rede de aprendizado profundo AlexNet (KRIZHEVSKY et al., 2012) foi utilizada através do aprendizado de transferência, com capacidade de reconhecer sintomas de pneumonia.

O AlexNet foi criado como uma profunda rede neural convolucional (estrutura na Figura 14), inicialmente treinada para classificar mais de 1.000 classes diferentes. No trabalho de O'Quinn et al. (2019) as últimas camadas do AlexNet foram retiradas e substituídas por uma nova camada, totalmente conectada, para classificar duas categorias. A camada softmax, também foi colocada, aplicando a função softmax na entrada. Por último, foram adicionadas as camadas de classificação.

Figura 14 – Estrutura AlexNet Krizhevsky et al. (2012)



Fonte: Artigo (O'QUINN et al., 2019)

O conjunto de dados usado para o treinamento desta rede, foi o banco de dados de acesso livre, do Desafio de Detecção de Pneumonia da Sociedade Radiológica da América do Norte - RSNA (AMERICA, 2018), que consiste em 5.659 imagens de radiografia de tórax. As imagens utilizadas para treinamento foram armazenadas em no formato DICOM (do inglês *formato digital imaging and communications in medicine*) que é o formato padrão do arquivo usado pelo dispositivo radiológico.

A precisão de diagnóstico preliminar alcançado foi de 72%, isso é significativo, já que, as imagens usadas para validação eram diferentes das imagens de treinamento, fornecendo assim, uma representação mais precisa de como funcionará a rede em aplicativos no mundo real. As imagens classificadas incorretamente, deve-se à sua baixa qualidade, ou foram tiradas em ângulos errados, ou continham um dispositivo médico, por exemplo, um marca-passo.

3.4 Using Convolutional Neural Nets And Tensorflow To Detects The Presence Of Pneumonia In A Patient

No estudo de Gonsalves e Ye (2021) têm como objetivo a concepção, desenvolvimento e implantação de um modelo de rede neural convolucional capaz de detectar a presença ou ausência de pneumonia, a partir de uma imagem


de radiografia. Este modelo proposto é treinado do zero usando a linguagem python com o auxílio de suas diferentes bibliotecas de apoio.

O modelo foi construído do zero, usando o modelo sequencial que sequênciam cada camada do modelo. Cada camada tem pesos que correspondem à camada que segue. Para a construção do modelo foram usadas as combinações de redes neurais convolucionais e camadas de Max-Pooling, que é responsável por simplificar as informações na saída da camada convolucional.

Dada uma imagem como entrada, uma camada convolucional faz a aplicação de filtros aprendidos, assim gerando um mapa de características que então é usado para resumir a presença do filtro na entrada. Segundo Gonsalves e Ye (2021) a camada de Maxpool é seguida pela camada convolucional que faz o *downsampling* do mapa de feições e cria um novo conjunto com o mesmo número de mapas de feições agrupadas.

Na Figura 15 temos a visão geral do modelo construído, onde a primeira camada é um filtro Conv2D (3, 3) sendo aplicado na imagem de entrada e criando 32 imagens de saída (convolutas). Depois disto a camada MaxPooling2D reduzirá os tamanhos das 32 saídas. As próximas 3 combinações de camadas Conv2D e Max-Pooling tem 64 e 128 unidades, respectivamente. Portanto, é criado 64 saídas convolutas na segunda rodada de camada Conv e Max-Pooling e 128 imagens de saídas convolutas nas duas rodadas restantes.

Figura 15 – Arquitetura do modelo de Gonsalves e Ye (2021)



Fonte: Artigo (GONSALVES; YE, 2021)

O conjunto de dado usado para treino do modelo é chamado Chest Xray, onde foi importado e baixado do site Kaggle (MOONEY, 2018) é organizado em 3 diretórios separados: o diretório de treinamento, o diretório de teste, o diretório de validação, sendo que todo possuindo subdiretório para cada categoria de imagem (pneumonia/normal). Portanto possuindo no total de 5.863 imagens de raio X do tórax.

Segundo Gonsalves e Ye (2021) a perda de validação e a precisão da validação foram impressionantemente altas, devido à adição de uma camada Dropout nos dados normalizados que desligou neurônios aleatórios na rede e o pré-processamento de dados que ajudou o modelo a não memorizar os dados de treinamento e, finalmente, não se ajustar. Isso fez com que o modelo atingisse a precisão de validação de até 91,35% e a perda de validação de 0,24.

3.5 Correlações entre os trabalhos e a pesquisa

A seguir analisamos as técnicas (ver Tabela 1) adotadas para a classificação de imagens de radiografias do tórax nos trabalhos apresentados anteriormente. Vale ressaltar que as técnicas identificadas foram:

- **Rede Neural Convolutacional (RNC).** Analisando os métodos baseadas na rede neural convolutacional, podemos observar que a rede neural convolutacional fornece um apoio significativo no desenvolvimento de programa para classificação de doenças;
- **Aprendizado de Transferência (AT).** Essa técnica tem o objetivo de tirar as camadas não desejadas e colocar outras na rede, assim ajustando o modelo pré-treinado.
- **Técnica de Processamento de Imagem (TPI).** Essa técnica é constituída por diversas etapas para o processamento da imagem, tais como, aquisição da imagem, dilatação, segmentação, classificação, reconhecimento e outras.

- **Filtros.** São ferramentas adotadas para remover ruídos das imagens e convertê-las.
- **Tamanho do Dataset.** Tem como objetivo mostrar o tamanho dos banco de dados utilizado durante o processo de desenvolvimento.
- **Resultado da Acurácia.** O objetivo do resultados da acurácia é apurar e analisar os dados obtidos.

Por meio da Tabela 1 podemos notar, que todos os elementos apresentados, foram utilizados nos artigos, assim fazendo correlações com o que está sendo proposto. O Trabalho 1 de Ozturk et al. (2020), por exemplo, podemos notar que foram utilizado rede neural convolucional, aprendizado profundo, filtros e dois bancos de dados, assim atingido a acurácia de 98,08% e 87,02%, sendo de grande auxílio para o desenvolvimento de trabalho de conclusão do curso, já que, essas ferramentas serão utilizadas para fazer as classificação de imagens.

No trabalho de Chaudhary et al. (2019) (Trabalho 2), foi usado método de rede neural convolucional, aprendizado profundo, com o intuito de melhorar o treinamento da rede, os filtros para retirar os ruídos das imagens, melhorando, assim, as imagens para serem analisadas. Além disso, o banco de dados usado possui um tamanho significativo, contendo 112.120 imagens de raio x de tórax, com presença e ausência de pneumonia de acesso aberto, e a acurácia obtida de 89,77%.

O Trabalho 3 de O'Quinn et al. (2019), relata como métodos, rede neural convolucional, aprendizado profundo e aprendizado de transferência, capazes de contribuir com o desenvolvimento do trabalho de conclusão de curso, juntamente com o banco de dados, pois o banco de dados tem acesso aberto e possui 5.659 imagens de raio x de tórax, podendo ser facilmente utilizado para treinamento e testes na rede.

Similar ao trabalho proposto por (GONSALVES; YE, 2021), o Trabalho 4 utiliza rede neural convolucional, aprendizagem por transferência, aplicação

de filtros e conta com um banco de dados chamado Chest Xray, que contém 5.863 imagens de raio X do tórax com presença e ausência de pneumonia. Este modelo conseguiu obter a acurácia de 91,35%.

Tabela 1 – Classificação dos artigos por técnicas.

Artigos	Técnicas					
	RNC	AT	TPI	Filtros	Dataset	Acurácia
Trabalho 1	X			X	Cohen JP (COHEN et al., 2020) e ChetX-ray8 (WANG et al., 2017)	98,08% e 87,02%
Trabalho 2	X			X	ChestX-Ray14 (WANG et al., 2017)	89,77%
Trabalho 3	X	X			RSNA (AMERICA, 2018)	72%
Trabalho 4	X	X		X	Chest Xray (MOONEY, 2018)	91.35%

Fonte: Própria do autor.

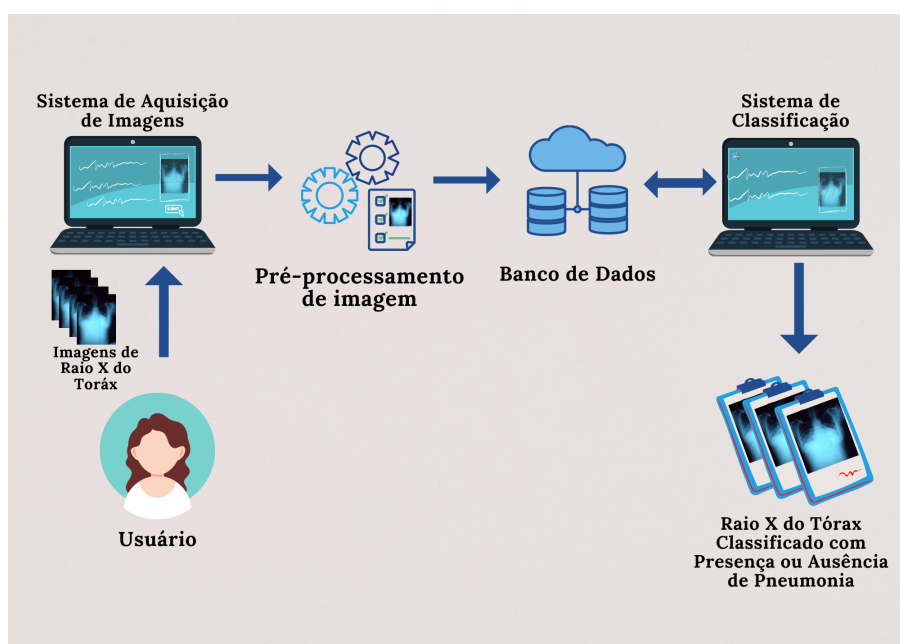
4 Método da Solução Proposta

Este capítulo apresenta o software para o diagnóstico de pneumonia na infância, onde se descreve a solução em termos de sua arquitetura computacional, software e frameworks adotados, e o seu respectivo fluxo de dados e artefatos gerados.

4.1 Arquitetura

O software proposto visa identificar, de forma automática, a presença ou ausência de pneumonia em imagens de raio X do tórax, assim facilitando o diagnóstico de pneumonia infantil. A Figura 16 apresenta uma visão geral da solução proposta que conta com um sistema web para a aquisição da imagem, processamento, reconhecimento de padrões e classificação de pneumonia.

Figura 16 – Como funciona o sistema de detecção de pneumonia.

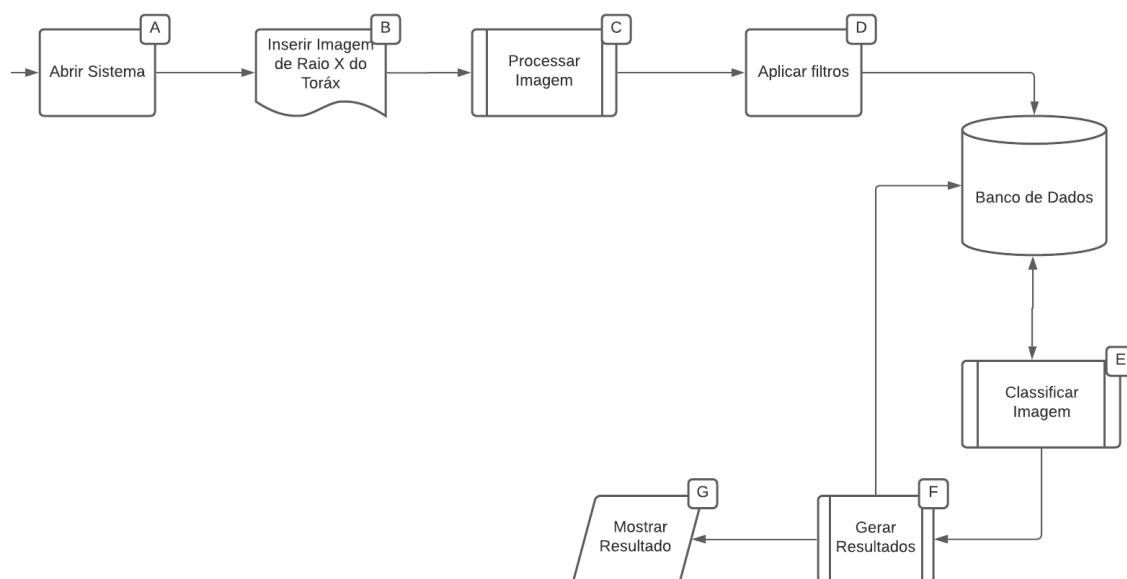


Fonte: Própria do autor.

A Figura 17 apresenta o fluxo de execução da solução, sendo a posição

inicial definida por uma seta (do lado esquerdo no quadrado **A**) que indica a sequência de passos que o sistema seguirá, dando opção para o usuário abrir a aplicação para classificar e gerar o resultado (normal ou pneumonia) obtido a partir da análise da imagem.

Figura 17 – Diagrama de fluxo.



Fonte: Própria do autor.

O fluxo de funcionamento do sistema (apresentado na Figura 17), consiste em o usuário dar como entrada (via upload) a imagem a ser analisada, em seguida o sistema processa a imagem e aplica camadas de filtros. Para isto, foi utilizada uma combinação de redes neurais convolucionais (ConvNets) e camadas de MaxPooling.

ConvNets são responsáveis por captar a imagem de entradas e atribuir importância (pesos e vieses que podem ser aprendidos) fazendo com que seja possível diferenciar uma imagem da outra. Enquanto alguns métodos os filtros são feitos à mão, com treinamento suficiente, as ConvNets têm a capacidade de aprender esses filtros/características. A camada de Maxpool juntamente com a camada convolucional são responsáveis por fazer o downsample do mapa de feições e criar um novo conjunto, com o mesmo número de mapas de feição

agrupados.

Os itens do fluxograma na Figura 17 são apresentados abaixo, sendo que o fluxograma é iniciado por uma seta sem origem, na qual são realizadas checagens básicas, como abrir o sistema e em seguida o módulo que indica a inserção de imagens (Módulo A e B).

- **Módulo A e B:** Representam a alimentação do sistema com a imagem de raio X a ser analisada pelo software.
- **Módulo C:** Módulo responsável pelo processamento de imagem, que consiste em um conjunto de técnicas de rede neural convolucional (RNC), aprendizagem de transferência (AT) e aplicação de filtros com o objetivo de capturar, representar e transformar a imagem do raio x do tórax.
- **Módulo D:** Responsável pela aplicação de filtros Conv2D e MaxPooling, com o objetivo de deixar a imagem mais nítida e remoção de objetos desnecessários para a próxima etapa do processo.
- **Módulo E:** Classificação de imagem, responsável por analisar a imagem, ou seja, verificar se a imagem analisada consta padrões dos mapas de feições que caracterizam pneumonia ou não.
- **Módulo F:** Responsável por gerar os resultados/relatório em formato JSON para ser exibido no próximo módulo.
- **Módulo G:** Responsável por mostrar os resultados gerados na parte web ao usuário.

4.2 Ferramentas e Implementações

A solução proposta conta com um sistema web que tem como motor principal, uma ferramenta de reconhecimento e classificação de imagens de código escrito em Python (v3.7.3) baseado no trabalho proposto por Gonsalves e Ye

(2021), assim adotando o modelo de classificação já avaliado, com o objetivo de reproduzir e gerar novos resultados.

A solução utiliza como *front-end* para os programas escritos em Python o Flask (GRINBERG, 2018) para que seja feita a aquisição das imagens e exibição dos resultados gerados pelo o sistema proposto, proporcionando um ambiente mais agradável para o usuário interagir diretamente com o modelo de classificação.

O software proposto adota técnicas da área de visão computacional, rede neural, aprendizado profundo, aprendizado por transferência e aprendizado de máquina no módulo de pré-processamento de imagem, sabendo disto, foi desenvolvido utilizando a linguagem de programação Python juntamente com as bibliotecas Tensorflow ¹ (v2.6.0), Numpy ² (v1.19.5) , Pandas ³ (v1.1.5) e Keras (CHOLLET et al., 2015).

A biblioteca tensorflow é uma biblioteca de código aberto usada para analisar imagens, definir e executar computação usando tensores. Um tensor é uma generalização de vetores e matrizes para dimensões maiores; a biblioteca Numpy é utilizada para suporte de grande quantidade de dados para o pré-treinamento; o Keras para a modelagem da rede neural; e por último a biblioteca Pandas usada para manipulação e análise de dados.

A Figura 18 apresenta um exemplo do conjunto de dados Chest Xray (MOONEY, 2018) usado para treinamento e está organizado em 3 diretórios: o treinamento, teste, e validação e cada um deles contendo subdiretório para cada categoria/classe de imagem, que são eles pneumonia e normal. Contabilizando em um total de 5.863 imagens de raio X.


O conjunto de imagens do Chest Xray foi importado e baixado de um repositório de banco de imagens, chamado Kaggle (KAGGLE, 2010) que é usado para treinamento e avaliação do modelo de classificação deste trabalho. Todas as imagens usadas do banco de dados foram inicialmente rastreadas para controle de qualidade, removendo as imagens de baixa qualidade e as ilegíveis.

¹ <https://tensorflow.org/>

² <https://numpy.org/>

³ <https://pandas.pydata.org/>

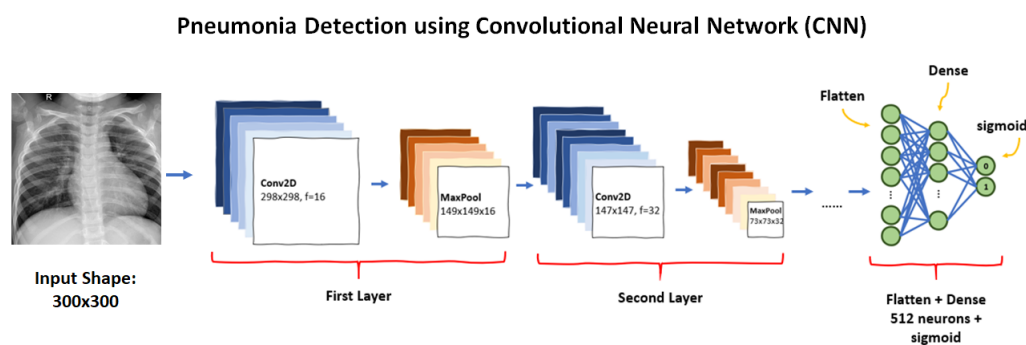
Figura 18 – Banco de Dados.



Fonte: Própria do autor.

Neste trabalho foi usado a arquitetura (ver Figura 19) apresentado por Gonsalves e Ye (2021) que projetou a arquitetura de um modelo do zero com estrutura sequencial, onde sequênciada cada camada do modelo, para isso foi utilizadas camadas de Conv2D e Maxpool.

Figura 19 – Arquitetura de Gonsalves e Ye (2021)




Fonte: (GONSALVES; YE, 2021)

As camadas finais do modelo proposto por Gonsalves e Ye (2021) têm a função de ativação que são as camadas Densa com 521 neurônios com RELU, onde a função de ativação produzirá um se a entrada se for positiva, caso contrário, ela produzirá zero. Na Figura 20 podemos ver com mais detalhes cada camadas do modelo, onde demonstra a aplicação de filtros na imagem de entrada contendo pneumonia. Assim, fornecendo informações sobre as representações internas para cada camada convolucional usada no modelo.

Na primeira camada e retida quase toda forma da imagem e a maioria das informações apresentada na imagem, a medida que o que a rede se aprofunda no modelo, pode-se notar que as camadas de ativação acabam se tornando mais complexas, com recurso de alto nível como por exemplo bordas, curvas e ângulos, responsável por identificar pneumonia nas imagens. Além disso, alguns filtros não estão sendo ativados, como por exemplo na `max_pooling2d_2` representando que o modelo atingiu sua capacidade de aprendizado.

Finalizado o treino do modelo é avaliado o seus resultados (ver Capítulo 5) foi desenvolvido o sistema web para a interação com o modelo de classificação.

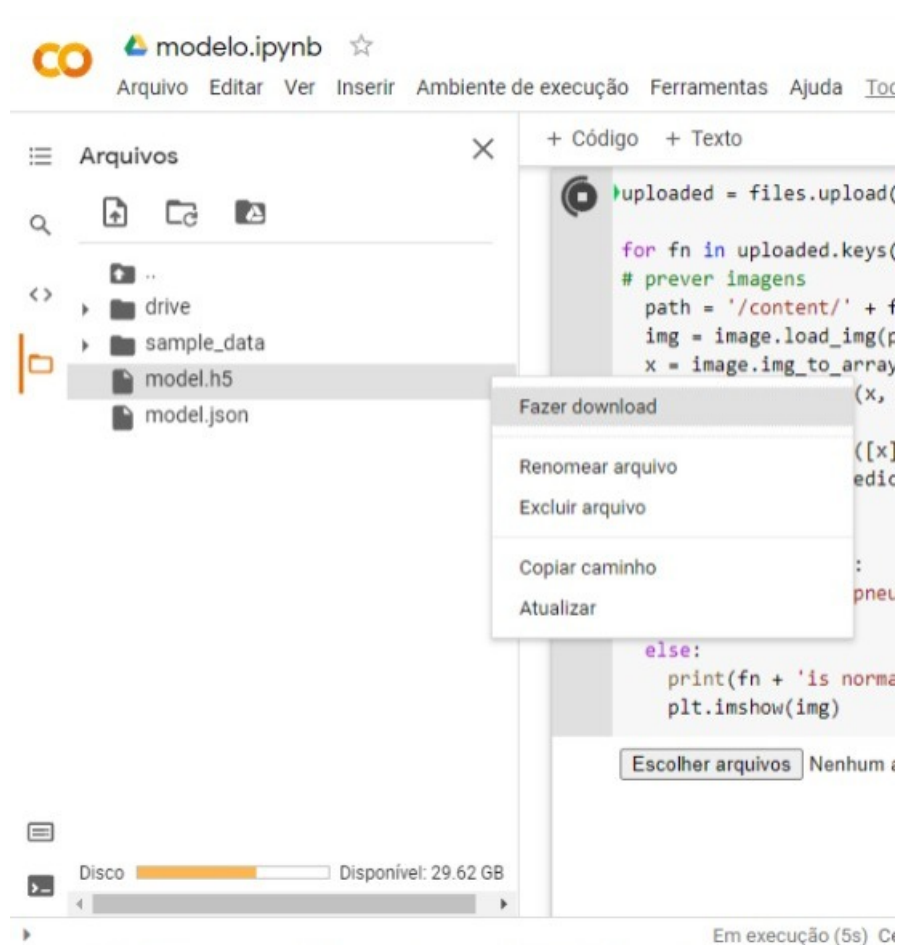
Figura 20 – Mapa de recursos para uma imagem de pneumonia



Fonte: Própria do autor.

A exportação do modelo foi feita utilizando o método `model.save("model.h5")` do Tensorflow para salvar o modelo já treinado, assim separando o modelo do código desenvolvido para o treinamento, ou seja, sem acesso ao código original Python. Após isto, o arquivo `model.h5` foi exportado do ambiente Colab, como mostrado na Figura 21 e adicionado na pasta do projeto referente ao sistema web.

Figura 21 – Arquivo model.h5

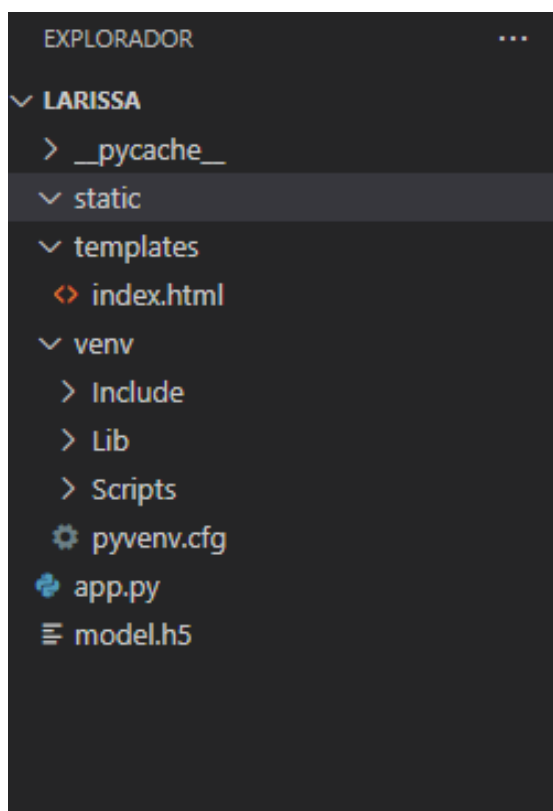


Fonte: Própria do autor.

Para o desenvolvimento do sistema web foi usado o framework Flask e Keras, devido a familiaridade do autor, e o suporte de Flask a web usando Python para a integração e execução do modelo de classificação gerado. A estrutura do sistema web é apresentado na Figura 22, as imagens são inseridas pelo o usuário via upload, classificadas (normal ou pneumonia) e armazenadas

na pasta `static`. Já na pasta `templates` é armazenado o arquivo HTML. Por último a pasta `venv` é onde os pacotes usados são instalados, como o pacote `flask`.

Figura 22 – Estrutura do sistema web



Fonte: Própria do autor.

Para a criação do servidor web, foi usado uma estrutura de conexão como mostrado na Figura 23 usando requisições do tipo `GET` e `POST`, o trecho do código do arquivo `app.py`. Após a conexão estando em execução no servidor web (via comando `run flask`) o sistema web fica disponível para interação com o usuário. No projeto, foi implementado algumas funções para a execução do modelo de classificação, tais como: `load-model('model.h5')` responsável por importar o modelo já treinado e pronto para inferência, e a função `predict-label()` (ver Figura 24) que irá percorrer e analisar a imagem inserida pelo o usuário de acordo com o modelo já treinado, assim verificando suas características e então inferindo se constata pneumonia ou não na imagem

analisada.

Figura 23 – Trecho do código do arquivo app.py

```
6
7  app = Flask(__name__)
8
9  # routes
10 @app.route("/", methods=['GET', 'POST'])
11 def main():
12     return "teste"
13
14
15 if __name__ == '__main__':
16     app.run(debug = True)
```

Fonte: Própria do autor.

Figura 24 – Trecho do código do arquivo app.py

```
def predict_label(img_path):
    img = image.load_img(img_path, target_size=(300,300))
    i = image.img_to_array(img)
    i = np.expand_dims(i, axis=0)

    images = np.vstack([i])
    p = model.predict(images, batch_size = 10)

    return p[0]
```

Fonte: Própria do autor.

Na Figura 25 é apresentado o resultado da interface pronto para o uso, onde o usuário entrará com a imagem do raio x do tórax e submeterá no sistema a imagem para que o sistema analise e classifique a imagem, apresentado como resposta se a imagem é classificada como Normal (ou seja, ausência de pneumonia como apresentado um exemplo na Figura 26) ou Pneumonia

(onde o modelo identificou a presença de pneumonia como é apresentado na Figura 27).

Figura 25 – Interface




Fonte: Própria do autor.

Figura 26 – Previsão correta da normal na imagem



Fonte: Própria do autor.

Figura 27 – Previsão correta da pneumonia na imagem



Fonte: Própria do autor.

5 Avaliação Experimental

Este capítulo descreve a avaliação experimental da solução proposta, incluindo: o planejamento e projeto para a execução de um estudo experimental.

5.1 Planejamento e projeto dos experimentos

Esta avaliação tem como objetivo avaliar o método proposto para o reconhecimento e classificação de pneumonia na infância que irá auxiliar os profissionais da saúde no diagnóstico. O estudo foi conduzido aplicando o método proposto sobre o *dataset* público Chest Xray (MOONEY, 2018) e avaliado por meio de questionários por profissionais da área de saúde. Os experimentos foram conduzidos no ambiente virtual Colab ¹ que possui as GPU como a Nvidia K80s, T4s, P4s e P100s (a escolha da GPU é feita aleatoriamente). O Colab também disponibiliza 12.72GB RAM e 68.40GB de disco temporário. Esta avaliação investiga as seguintes questões de pesquisa (QP):

QP1 : O modelo de classificação no sistema proposto consegue identificar a pneumonia em imagens de raio-X?

QP2 : A acurácia e a precisão do sistema proposto é suficiente para provar sua confiabilidade?

QP3 : O sistema proposto é capaz de contribuir com os profissionais da área para um diagnóstico correto de pneumonia?

Visando responder às questões da pesquisa, a execução deste experimento será dividida em 3 partes: Na **primeira parte**, foi avaliado o modelo de classificação do trabalho proposto por Gonsalves e Ye (2021) (que é adotado na solução proposta), para este experimento foram separados 80% da imagem de raio X para treino e 20% para teste do banco de dados Chest Xray baixado no

¹ <https://colab.research.google.com/>

Kaggle (2010). Na **segunda parte**, o modelo proposto foi avaliado pela utilização de métricas de aprendizagem de máquina, tais como: ROC (*Receiver Operating Characteristics*), *model loss*, precisão, acurácia, F1-score, e *recall*. E por último a **terceira parte**, o sistema proposto foi avaliado em termo de suporte e eficiência com profissionais da área da saúde via questionário, usando resposta na escala de Likert.

5.2 Execução dos experimentos e análise dos resultados

Nessa seção analisa-se os resultados obtidos pelos experimentos, procurando responder às perguntas de pesquisa criadas para validação do sistema de detecção de pneumonia.

5.2.1 Prova de conceito

Visando responder a **Questão de Pesquisa 1** (QP1) proposto neste capítulo foram executados alguns testes utilizando as imagens do banco de dados Chest Xray (KAGGLE, 2010) que atualmente tem no total de 624 imagens, sendo 234 imagens normal e 390 imagens com pneumonia. Para a execução deste teste tentamos buscar imagens de baixa qualidade, alta qualidade, posicionamento ruim e posicionamento bom, assim buscando uma gama de variação de ambiente a ser analisado.

A Figura 28 é do diretório TEST e no subdiretório NORMAL do *dataset* e o modelo prevê incorretamente a classe da imagem, ou seja, apresentando um falso positivo. Logo, mostrando que melhorias ainda podem ser empregadas no modelo de classificação. A Figura 29 é do diretório TEST e no subdiretório PNEUMONIA que avaliada pelo modelo é classificada corretamente, ou seja, identificando a pneumonia via a imagem de raio-X.

Figura 28 – Previsão incorreta da imagem.

Classificação de Imagem de Raio X

Insira a imagem : Nenhum arquivo selecionado



Predição : *Pneumonia*

Fonte: Própria do autor.

Figura 29 – Previsão correta da pneumonia na imagem.

Classificação de Imagem de Raio X

Insira a imagem : Nenhum arquivo selecionado




Predição : *Pneumonia*

Fonte: Própria do autor.

5.2.2 Análise da classificação da pneumonia

Para resolver a **Questão de Pesquisa 2** (QP2) foi definido algumas métricas tais como a perda de validação (*model loss*) e a precisão que são métricas fundamentais. Logo, analisando a Figura 30 observa-se que uma grande variação (distanciamento) tanto na precisão e perda, devido a camada Dropout que fez com que os neurônios aleatórios fossem desligados e o pré-processamento de dados que ajudou o modelo a não memorizar os dados de treinamento, assim não se ajustando. Assim, observa-se que o modelo provavelmente poderia ser treinado um pouco mais, incluindo novas amostras de imagens, visando regularizar a tendência de precisão do modelo.


Figura 30 – Gráficos da acurácia e perda do modelo proposto.



Fonte: Própria do autor.

Para medir o desempenho do modelo, em vários pontos de corte, foi utilizado a área (UAC) sob a curva ROC, que obteve uma UAC de 64%, então o modelo consegue ser manter acima da linha do corte como mostra na Figura 31. Logo, a probabilidade de que o modelo classifique um exemplo positivo aleatório mais alto do que um exemplo negativo aleatório. Assim, mostrando que curva formada pelo gráfico entre a taxa de exemplos positivos, que realmente são positivos, e a taxa de falsos positivos.

Figura 31 – Gráfico da curva roc do modelo.



Fonte: Própria do autor.

Por último, foram analisadas as seguintes métricas de desempenho: acurácia com 79%, precisão com 75%, recall com 99% e a pontuação F1 com 85%. Logo, observa-se que o modelo de classificação apresenta resultados significativos. Contudo, estes resultados devem ser melhorados considerando a taxa de precisão, visto que o contexto da aplicação em relação a custos de falso positivos são altos, exemplo, podendo aumentar a fila de pacientes a serem atendidos. O resultado do recall apresenta-se como um ponto forte do modelo, tendo em conta a relação com resultados positivos verdadeiros (ou seja, classificar corretamente uma imagem com pneumonia), visto que o custo associado aos resultados falso negativo pode ser extremamente alto se a doença não for tratada.


5.2.3 Análise do sistema proposto como suporte a especialistas da área da saúde

Após a aplicação do questionário, tendo como requisito leitura e interpretação de raio x do tórax, com um grupo de 12 (doze) profissionais da área de saúde. O questionário aplicado conta oito perguntas que fazem parte de uma análise quantitativa do sistema. As respostas foram coletadas usando a escala de Likert,

sendo 0 uma resposta completamente negativa e 5 completamente positiva. As perguntas realizadas podem ser vistas abaixo juntamente com sua análise e resultados.

QP1 : O uso de um sistema computacional de identificação (positivo ou negativo) de pneumonia pode auxiliar durante a triagem de pacientes? (de 0 a 5). Com 41,7% das respostas (ver Figura 32) na opção 4, próximo ao completamente positivo em relação a aceitação, indica que o sistema pode ser bem aceito na sua utilização na triagem em hospital, assim auxiliando no atendimento mais rápido de pacientes identificados como positivo para pneumonia.


Figura 32 – Gráfico QP1



Fonte: Própria do autor.

QP2 : Você considera radiografia o método mais comum para a detecção de pneumonia? (de 0 a 5). Com a porcentagem de 41,7% (ver Figura 33) na escala 4 (aceitação positiva) mostrando que o raio X de tórax ainda é muito utilizado no diagnóstico de pneumonia, apesar de existirem outros métodos para o mesmo. Assim, também este resultado consolida a imagem de raio X como forma de entrada para o método proposto, visto que este já é uma forma tradicional tanto no diagnóstico como na triagem no hospital.


Figura 33 – Gráfico QP2



Fonte: Própria do autor.

QP3 : Diagnosticar pneumonia a partir de radiografias é uma tarefa desafiadora? (de 0 a 5). Nesta, obtive 33,3% (ver Figura 34) nas opções de resposta 3, 4 e 5 demonstram que apesar da radiografia ser um método bastante comum para o diagnóstico de pneumonia, ainda sim continua sendo um grande desafio para os profissionais diagnosticar a pneumonia a partir dela, assim pontuando a importância do método proposto em contribuir com estes profissionais.

Figura 34 – Gráfico QP3




Fonte: Própria do autor.

QP4 : Na sua rotina é adotado algum sistema computacional para detectar a ausência ou presença de pneumonia? (de 0 a 5). A maior porcentagem foi na opção 1 (indicando uma completa negativa a resposta) atingindo

33,3% (maioria) das respostas, onde mostra que é pouco comum a utilização de um sistema computacional para auxiliar a detecção de presença ou ausência de pneumonia em hospitais.


Figura 35 – Gráfico QP4



Fonte: Própria do autor.

QP5 : Na imagem de raio-X abaixo, qual seria o nível de dificuldade em identificar a PRESENÇA de pneumonia? (de 0 a 5).

Figura 36 – Gráfico QP5




Fonte: Própria do autor.

Esta questão mostrou que dos 12 profissionais mais 41,7% acharam (marcando as opções de 3 a 5) a imagem apresentada de difícil interpretação.

QP6 : Qual seria o seu nível de confiança em usar um sistema web capaz de identificar a presença de pneumonia com a de precisão de mais

de 75%? (de 0 a 5). Nesta questão foi identificado que mais 58,3% responderam entre as opções 4 e 5. Apresentando assim, uma forte indicação da aceitação para a implementação do sistema proposto em um hospital.


Figura 37 – Gráfico QP6



Fonte: Própria do autor.

QP7 : Você acredita que o sistema de identificação (positivo ou negativo) de pneumonia seria capaz de diminuir a taxa dos falsos positivos nos hospitais? (de 0 a 5). Com 41,7% das respostas na opção 5 (ver Figura 38), ou seja, acreditam fortemente que sim (a pontuação máxima) que o sistema proposto iria contribuir e mesmo respaldar o diagnóstico pelos profissionais da saúde.


Figura 38 – Gráfico QP7



Fonte: Própria do autor.

QP8 : Ter um modelo de identificação (positivo ou negativo) elimina dois erros humanos, que são violações e erros? (de 0 a 5). Nesta questão, a maior porcentagem foi na opção 4 (ver Figura39), uma concordância quase total a afirmação feita, com 41,7% das respostas, onde acreditam que o sistema pode ser capaz de eliminar os dois erros humanos.

Figura 39 – Gráfico QP8



Fonte: Própria do autor.

As respostas recebidas mostram que o sistema proposto apresenta uma forte aceitação pelo público entrevistado, principalmente no que se refere a ser capaz de contribuir com os profissionais da área para um diagnóstico correto de pneumonia.

6 Considerações Finais e Trabalhos Futuros

O presente trabalho apresentou o desenvolvimento de um sistema computacional capaz de diagnosticar pneumonia, em específico no público infantil, usando uma rede neural convolucional profunda para reconhecimento de padrão em imagem de raio X do tórax proposto por Gonsalves e Ye (2021). auxiliar os profissionais de saúde e melhorar o tempo de diagnóstico de pneumonia em hospitais.

Os experimentos realizados no decorrer do trabalho proposto (ver Capítulo 5), mostram que o sistema é uma solução viável na forma de auxiliar os profissionais de saúde no diagnóstico de pneumonia infantil de forma ágil. Considerando, principalmente, dois tipos de erros humanos, que são as violações e os erros. Além disso, em uma investigação inicial do uso do sistema proposto foi aceito entre os profissionais da área.

Parte do objetivo do sistema proposto é identificar ausência e presença de pneumonia. O sistema demonstrou grande potencial, classificando as imagens com pneumonia corretamente, visto que o recall atingiu 99%. Porém, a taxa da acurácia com 79% deixou a desejar, já que os falsos positivos são altos. Mostrando assim, que o modelo precisa melhorar neste quesito. Contudo, o sistema proposto está preparado para ser testado e treinado com uma quantidade maior de imagem, possibilitando que o sistema aprenda mais.

Como trabalhos futuros, planeja-se estudar métodos para distinguir imagem de raio x do tórax que contém pneumonia e coronavírus. Por exemplo, expandindo a rede neural convolucional e treinando com imagem de raio x do tórax de indivíduos diagnosticados com o COVID-19 (coronavírus), principalmente considerando o contexto pandêmico atual.

Referências

- ABADI, M.; BARHAM, P.; CHEN, J.; CHEN, Z.; DAVIS, A.; DEAN, J.; DEVIN, M.; GHEMAWAT, S.; IRVING, G.; ISARD, M. et al. Tensorflow: A system for large-scale machine learning. **12th Symposium on Operating Systems Design and Implementation (OSDI - USENIX)**, p. 265–283, 2016.
- ALZHRANI, S. A.; AL-SALAMAH, M. A.; AL-MADANI, W. H.; ELBARBARY, M. A. Systematic review and meta-analysis for the use of ultrasound versus radiology in diagnosing of pneumonia. **Critical ultrasound journal**, Springer, v. 9, n. 1, p. 1–11, 2017.
- AMERICA, R. S. of N. **RSNA Pneumonia Detection Challenge**. [S.l.]: <https://www.kaggle.com/c/rsna-pneumonia-detection-challenge/leaderboard>, 2018. [Online; Acessado em Março de 2021].
- AYAN, E.; ÜNVER, H. M. Diagnosis of pneumonia from chest x-ray images using deep learning. In: IEEE. **2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT)**. [S.l.], 2019. p. 1–5.
- AYODELE, T. O. Types of machine learning algorithms. **New advances in machine learning**, InTech, v. 3, p. 19–48, 2010.
- BENGIO, Y.; GOODFELLOW, I.; COURVILLE, A. **Deep learning**. [S.l.]: MIT press Massachusetts, USA., 2017. v. 1.
- BRADSKI, G.; KAEHLER, A. **Learning OpenCV: Computer vision with the OpenCV library**. [S.l.]: O'Reilly Media, Inc., 2008.
- BRASIL; SAÚDE, M. da; SAÚDE, S. de Atenção á; ESTRATÉGICAS, D. de A. P. Pneumoconioses. - Brasília : Editora do Ministério da Saúde, 2006.
- CHAUDHARY, A.; HAZRA, A.; CHAUDHARY, P. Diagnosis of chest diseases in x-ray images using deep convolutional neural network. In: IEEE. **2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT)**. [S.l.], 2019. p. 1–6.
- CHOLLET, F. et al. **Keras**. 2015. <<https://keras.io>>. [Online; Acessado em Abril de 2021].
- COELHO, N. Inteligência artificial e computação cognitiva em unidades de informação: conceitos e experiências. **Logeion: Filosofia da Informação**, v. 7, n. 1, p. 186–205, set. 2020. Disponível em: <<http://revista.ibict.br/fiinf/article/view/5260>>.
- COHEN, J. P.; MORRISON, P.; DAO, L.; ROTH, K.; DUONG, T. Q.; GHASSEMI, M. Covid-19 image data collection: Prospective predictions are the future. **arXiv 2006.11988**, 2020. Disponível em: <<https://github.com/ieee8023/covid-chestxray-dataset>>.

COSTA, A.; WANNMCHER, L.; COSTA, L. H.; TIERLING, V. L. **Uso Racional de Medicamentos–temas selecionados**. 2012. 38 p.

DU, J. Understanding of object detection based on CNN family and YOLO. **Journal of Physics: Conference Series**, IOP Publishing, v. 1004, p. 012029, apr 2018. Disponível em: <<https://doi.org/10.1088/1742-6596/1004/1/012029>>.

GONSALVES, S.; YE, X. Using neural networks and tensorflow to detect the presence of pneumonia in a patient. **SIGNATURE**, v. 4, p. 28, 2021.

GRINBERG, M. **Flask web development: developing web applications with python**. [S.l.]: "O'Reilly Media, Inc.", 2018.

HAYKIN, S. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2007.

KAGGLE. **Kaggle: Your Machine Learning and Data Science Community**. 2010. [Online; Acessado em Abril de 2021].

KALIL, I. **Pneumonia: especialista esclarece sintomas e formas de prevenção**. [S.l.]: <https://portal.fiocruz.br/noticia/pneumonia-especialista-esclarece-sintomas-e-formas-de-prevencao>, 2013. [Online; Acessado em Maio de 2020].

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. **Advances in neural information processing systems**, v. 25, p. 1097–1105, 2012.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.

LEMLEY, J.; BAZRAFKAN, S.; CORCORAN, P. Deep learning for consumer devices and services: Pushing the limits for machine learning, artificial intelligence, and computer vision. **IEEE Consumer Electronics Magazine**, IEEE, v. 6, n. 2, p. 48–56, 2017.

LI, B.; KANG, G.; CHENG, K.; ZHANG, N. Attention-guided convolutional neural network for detecting pneumonia on chest x-rays. In: IEEE. **2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. [S.l.], 2019. p. 4851–4854.

MARENGONI, M.; STRINGHINI, S. Tutorial: Introdução à visão computacional usando opencv. **Revista de Informática Teórica e Aplicada**, v. 16, n. 1, p. 125–160, 2009.

MOONEY, P. **Chest X-Ray Images (Pneumonia) | Kaggle**. 2018. <<https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia/metadata>>. (Acessado em 09/14/2021).

ONGSULEE, P. Artificial intelligence, machine learning and deep learning. In: **2017 15th International Conference on ICT and Knowledge Engineering (ICT KE)**. [S.l.: s.n.], 2017. p. 1–6.

- ORGANIZATION, W. H. **Pneumonia**. [S.l.]: <https://www.who.int/news-room/fact-sheets/detail/pneumonia>, 2019. [Online; Acessado em Junho de 2020].
- OZTURK, T.; TALO, M.; YILDIRIM, E. A.; BALOGLU, U. B.; YILDIRIM, O.; ACHARYA, U. R. Automated detection of covid-19 cases using deep neural networks with x-ray images. **Computers in biology and medicine**, Elsevier, v. 121, p. 103792, 2020.
- O'QUINN, W.; HADDAD, R. J.; MOORE, D. L. Pneumonia radiograph diagnosis utilizing deep learning network. In: IEEE. **2019 IEEE 2nd International Conference on Electronic Information and Communication Technology (ICEICT)**. [S.l.], 2019. p. 763–767.
- PASZKE, A.; GROSS, S.; MASSA, F.; LERER, A.; BRADBURY, J.; CHANAN, G.; KILLEEN, T.; LIN, Z.; GIMELSHEIN, N.; ANTIGA, L. et al. Pytorch: An imperative style, high-performance deep learning library. **arXiv preprint arXiv:1912.01703**, 2019.
- PHILLIPS, D. **Image processing in C**. [S.l.]: R & D Publications Lawrence, 1994. v. 724.
- POYNTON, C.; FUNT, B. Perceptual uniformity in digital image representation and display. **Color Research & Application**, Wiley Online Library, v. 39, n. 1, p. 6–15, 2014.
- PUTRA, M.; YUSSOF, Z.; LIM, K.; SALIM, S. Convolutional neural network for person and car detection using yolo framework. **Journal of Telecommunication, Electronic and Computer Engineering (JTEC)**, v. 10, n. 1-7, p. 67–71, 2018.
- RAJARAMAN, S.; CANDEMIR, S.; KIM, I.; THOMA, G.; ANTANI, S. Visualization and interpretation of convolutional neural network predictions in detecting pneumonia in pediatric chest radiographs. **Applied Sciences**, Multidisciplinary Digital Publishing Institute, v. 8, n. 10, p. 1715, 2018.
- RAJPURKAR, P.; IRVIN, J.; ZHU, K.; YANG, B.; MEHTA, H.; DUAN, T.; DING, D.; BAGUL, A.; LANGLOTZ, C.; SHPANSKAYA, K. et al. Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. **arXiv preprint arXiv:1711.05225**, 2017.
- RAOOF, S.; FEIGIN, D.; SUNG, A.; RAOOF, S.; IRUGULPATI, L.; III, E. C. R. Interpretation of plain chest roentgenogram. **Chest**, Elsevier, v. 141, n. 2, p. 545–558, 2012.
- RAVÌ, D.; WONG, C.; DELIGIANNI, F.; BERTHELOT, M.; ANDREU-PEREZ, J.; LO, B.; YANG, G.-Z. Deep learning for health informatics. **IEEE journal of biomedical and health informatics**, IEEE, v. 21, n. 1, p. 4–21, 2016.
- REDMON, J.; FARHADI, A. **YOLOv3: An Incremental Improvement**. 2018.
- REISSIG, A.; GRAMEGNA, A.; ALIBERTI, S. The role of lung ultrasound in the diagnosis and follow-up of community-acquired pneumonia. **European journal of internal medicine**, Elsevier, v. 23, n. 5, p. 391–397, 2012.

SAMEK, W.; WIEGAND, T.; MÜLLER, K.-R. Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models. **arXiv preprint arXiv:1708.08296**, 2017.

SIMON, P. **Too big to ignore: the business case for big data**. [S.l.]: John Wiley & Sons, 2013. v. 72.

SOBRAL, A. Bgslibrary: An opencv c++ background subtraction library. In: **IX Workshop de Visão Computacional**. [S.l.: s.n.], 2013. v. 27.

UNICEF. **Pneumonia**. [S.l.]: <https://data.unicef.org/topic/child-health/pneumonia/>, 2019. [Online; Acessado em Maio de 2020].

WANG, X.; PENG, Y.; LU, L.; LU, Z.; BAGHERI, M.; SUMMERS, R. M. Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2017. p. 2097–2106.

YAN, C.; HUI, R.; LIJUAN, Z.; ZHOU, Y. Lung ultrasound vs. chest x-ray in children with suspected pneumonia confirmed by chest computed tomography: A retrospective cohort study. **Experimental and therapeutic medicine**, Spandidos Publications, v. 19, n. 2, p. 1363–1369, 2020.