UNIVERSIDADE DE MOGI DAS CRUZES

CÉSAR ALEXANDRE SILVA LIMA

patologIA: PLATAFORMA *ONLINE* PARA APRIMORAMENTO DE TREINAMENTO BASEADOS EM IMAGENS APLICADA A ESTUDANTES DO CURSO DE MEDICINA

Mogi das Cruzes – SP

2024

UNIVERSIDADE DE MOGI DAS CRUZES

CÉSAR ALEXANDRE SILVA LIMA

patologIA: PLATAFORMA *ONLINE* PARA APRIMORAMENTO DE TREINAMENTO BASEADOS EM IMAGENS APLICADA A ESTUDANTES DO CURSO DE MEDICINA

Tese apresentada ao Programa de Pós-Graduação da Universidade de Mogi das Cruzes como parte dos requisitos para obtenção do grau de Doutor em Engenharia Biomédica. Área de concentração: Processamento de imagens e biossinais, visão computacional e reconhecimento de padrões

Professora Orientadora: Dra. Sílvia Cristina Martini

Co-Orientador: Dr. Clayton Eduardo dos Santos

Mogi das Cruzes – SP

2024

FINANCIAMENTO



Ficha catalográfica
Universidade de Mogi das Cruzes - Biblioteca Central

Lima, César Alexandre Silva
L732p Patologia: plataforma online para aprimoramento de treinamento baseados em imagens aplicada a estudantes do curso de medicina / César Alexandre Silva Lima. -- Mogi das Cruzes, SP: Universidade de Mogi das Cruzes, 2024.
255 f. : il.

Tese (Doutorado em Engenharia Biomédica) -- Universidade de Mogi das Cruzes, 2024.
Orientação: Profa. Dra. Silvia Cristina Martini.
Coorientação: Prof. Dr. Clayton Eduardo dos Santos.
Inclui bibliografia.

1. Interpretação de imagem radiográfica assistida por computador/métodos 2. Estudantes de Medicina 3. Educação continuada 4. Inteligência artificial 5.Tecnologias da Informação I. Martini, Silvia Cristina II. Universidade de Mogi das Cruzes III. Título

CDD 610.28

Elaborada por Maria Cristina Alves Silva Xavier – CRB-8/10077

Fls. 006-Livro II DR

ATAS

ATA DA SESSÃO PÚBLICA DE DEFESA DE TESE DE DOUTORADO EM ENGENHARIA BIOMÉDICA DA UNIVERSIDADE DE MOGI DAS CRUZES

Às nove horas e trinta minutos do dia vinte e dois de janeiro de dois mil e vinte e quatro, pela Universidade de Mogi das Cruzes, realizou-se a defesa da tese intitulada "PATOLOGIA: PLATAFORMA ONLINE PARA APRIMORAMENTO DE TREINAMENTO BASEADOS EM IMAGENS APLICADA A ESTUDANTES DO CURSO DE MEDICINA". para obtenção do grau de doutor(a) pelo(a) candidato(a) **César Alexandre Silva Lima.** Tendo sido o número de créditos alcançados pelo(a) mesmo(a) no total de 76 (setenta e seis), a saber: 40 unidades de crédito em disciplinas e atividades na pós-graduação e 36 unidades de crédito no preparo da tese, o(a) aluno(a) perfaz assim os requisitos para obtenção do grau de doutor(a). A comissão examinadora foi constituída pelos senhores professores doutores: Silvia Cristina Martini, Alessandro Pereira da Silva, e Marcia Aparecida Silva Bissaco, da Universidade de Mogi das Cruzes, e Marcelo Zancheta do Nascimento, da Universidade Federal de Uberlândia, e Hélder Pinto Oliveira, da Faculdade de Ciências da Universidade do Porto, sob a presidência da primeira como orientadora do(a) aluno(a). A sessão pública da defesa da tese foi aberta pela senhora presidenta da comissão que apresentou o(a) candidato(a). Em seguida o(a) candidato(a) realizou uma apresentação oral de seu trabalho, ao final da qual seguiram-se as arguições pelos membros da comissão examinadora. A seguir, a comissão, em sessão secreta, conforme julgamento discriminado por cada membro, considerou o(a) candidato(a)

Aprovado (aprovado(a) /reprovado(a)) por Unanimidade (unanimidade/maioria).

Mogi das Cruzes, 22 de janeiro de 2024.

Comissão Examinadora	Julgamento
gov.br Documento assinado digitalmente MARCELO ZANCHETTA DO NASCIMENTO Data: 24/01/2024 09:02:25-0300 Verifique em https://validar.iti.gov.br Prof. Dr. Marcelo Zancheta do Nascimento	Aprovado (aprovado(a)/reprovado(a))
Assinado por: Hélder Filipe Pinto de Oliveira Num. de Identificação: 11660648 Data: 2024.02.05 17:09:32+00'00' Prof. Dr. Hélder Pinto Oliveira	Aprovado (aprovado(a)/reprovado(a))
gov.br Documento assinado digitalmente ALESSANDRO PEREIRA DA SILVA Data: 23/01/2024 20:44:10-0300 Verifique em https://validar.iti.gov.br Prof. Dr. Alessandro Pereira da Silva	Aprovado (aprovado(a)/reprovado(a))
Profª Drª Marcia Aparecida Silva Bissaco	Aprovado (aprovado(a)/reprovado(a))
gov.br Documento assinado digitalmente SILVIA CRISTINA MARTINI Data: 22/01/2024 18:08:28-0300 Verifique em https://validar.iti.gov.br Profª Drª Silvia Cristina Martini	Aprovado (aprovado(a)/reprovado(a))

Scanned with CamScanner

DECATÓRIA

Dedico este trabalho aos meus pais Ely Gonçalves Lima e Rosa Maria Silva Lima que sempre deram suas vidas por mim e aos meus dois pilares, minha esposa Neide Paula de Oliveira Lima e minha filha Samara de Paula Macedo Lima que sempre transmitiram seu amor em todas as fases de minha vida.

AGRADECIMENTOS

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.
Agradeço a Jesus Cristo, minha rocha, onde sempre me apoiei em todos os instantes de minha vida.
Às minhas queridas irmãs que mesmo a distância transmitiam suas presenças.
À Professora Doutora Sílvia Cristina Martini por sua sabedoria e paciência que permitiram o desenvolvimento deste trabalho.
Ao meu amigo e irmão professor Clayton Eduardo dos Santos pelo apoio com ideias sempre relevantes e aplicáveis.
A todo o corpo docente da Universidade de Mogi das Cruzes que propiciaram com sua dedicação e profissionalismo no desenvolvimento deste projeto.
Ao professor Márcio Fernandes Robortella pelo auxílio à pesquisa em laboratório.
A todos aqueles que fizeram parte desse trabalho, direta ou indiretamente.

RESUMO

O exame do Conselho Regional de Medicina do Estado de São Paulo – CREMESP no ano de 2016 aplicado aos egressos dos cursos de Medicina no Estado de São Paulo, detectou que 80% dos profissionais submetidos a este exame não souberam interpretar um exame de radiografia. Inúmeras pesquisas afirmam que a experiência do profissional é fator preponderante para que a interpretação de imagens médicas seja decorrente em um diagnóstico positivo propiciando a diminuição das diferenças de interpretação entre médicos especialistas. Então, este projeto teve como objetivo desenvolver uma plataforma online responsiva para treinamento de estudantes em interpretação de imagens médicas visando seu aprimoramento mantendo contato com o tema dentro ou fora da sala de aula. O desenvolvimento contou com a utilização de tecnologias como *Django* para *backend*, JavaScript para *frontend* com integração de plug-ins como o *canvas*. Foi utilizado o MySql como gerenciador de banco de dados e desenvolvidos modelos de inteligência artificial na utilização de previsões de doenças como imagens de diagnóstico de tuberculose e está hospedada num servidor da AWS. A plataforma contém recursos como o desenvolvimento de questionários de múltipla escolha para testar o conhecimento dos estudantes, bem como, questionários de demarcação de regiões ou áreas em imagens médicas onde seria o foco do estudo e permite ao estudante e ao professor a consulta do resultado da pontuação do desempenho do estudante referente aos questionários respondidos. Este estudo foi aprovado pelo Comitê de Ética em Pesquisa da Universidade de Mogi das Cruzes, sob protocolo 5.863.020. A avaliação de usabilidade contou com a participação de vinte e dois avaliadores, e a avaliação de funcionalidade contou com 104 estudantes e 5 professores. A compilação de dados estatísticos utilizou a escala Likert sob testes U de Mann-Whitney onde não foram detectadas significância estatística entre os grupos de avaliadores. A conclusão é que a hipótese da pesquisa pode ser comprovada em todas as suas instâncias.

Palavras-Chave: treinamento; plataforma online; inteligência artificial; interpretação de imagens.

ABSTRACT

The exam by the Regional Council of Medicine of the State of São Paulo – CREMESP in 2016 applied to graduates of Medicine courses in the State of São Paulo, detected that 80% of professionals submitted to this exam did not know how to interpret an x-ray exam. Numerous studies states that the professional's experience is a preponderant factor for the interpretation of medical images to result in a positive diagnosis, reducing differences in interpretation between medical specialists. So, this project aimed to develop a responsive online platform for training students in interpreting medical images, aiming to improve them while maintaining contact with the topic inside or outside the classroom. The development included the use of technologies such as Django for the backend, JavaScript for the frontend with integration of plug-ins such as canvas. MySql was used as a database manager and artificial intelligence models were developed to use disease predictions such as tuberculosis diagnostic images and is hosted on an AWS server. The platform contains resources such as the development of multiple-choice questionnaires to test students' knowledge, as well as questionnaires to demarcate regions or areas in medical images where the focus of the study would be and allow the student and teacher to consult the results of the study. student performance score referring to the completed questionnaires. This study was approved by the Research Ethics Committee of the University of Mogi das Cruzes, under protocol 5.863.020. The usability evaluation included the participation of twenty-two evaluators, and the functionality evaluation included 104 students and 5 teachers. The compilation of statistical data used the Likert scale under Mann-Whitney U tests where no statistical significance was detected between the groups of evaluators. The conclusion is that the research hypothesis can be proven in all its instances.

Keywords: training. online platform. artificial intelligence. image interpretation.

LISTA DE ILUSTRAÇÕES

Figura 1 - Interface da Plataforma Epacs 28
Figura 2 - Interface Inicial do Sistema MINI-WEBPACS 31
Figura 3 - Tela de Busca pelo Nº de Matrícula / Nome do Paciente 31
Figura 4 – Visualizador de Imagens 32
Figura 5 - Interface Gráfica InVesalius 34
Figura 6 - Visualização Volumétrica padrão Brilhante 34
Figura 7 - Medição Linear Axial 35
Figura 8 - Medição Angular Axial 35
Figura 9 - Página Principal Radiopédia (Parcial) 36
Figura 10 - Estudo de Casos 37
Figura 11 - Tela de Questionário de Caso 38
Figura 12 - Tela de Apresentação do Questionário 39
Figura 13 - Tela das Imagens Referentes ao Caso do Questionário 39
Figura 14 - Tela de Diagnóstico e Discussão 40
Figura 15 - Interpretação de Imagens QualIM 41
Figura 16 - Telerradiologia 43
Figura 17 - Telerradiologia Outra Perspectiva 43
Figura 18 - Arquitetura da Nuvem 59
Figura 19 - Cérebro Humano 64
Figura 20 - Esquema simplificado de um Neurônio 65
Figura 21 - Representação Simplificada Neurônio Matemático 65
Figura 22 - Multiplicação de Matrizes entre Sinais de Entrada (x) e Pesos Sinápticos (w) (Versão Simplificada) 67
Figura 23 - Esquema de Funcionamento de Uma Rede Neural 69
Figura 24 - Estrutura de Quatro Dimensões 71
Figura 25 - Leitura dos Pixels da Imagem de um Número 72
Figura 26 - Convolução 73
Figura 27 - Pooling 75
Figura 28 - Fluxo da Estrutura do Sistema 89
Figura 29 - Fases de Desenvolvimento do Sistema 92
Figura 30 - Descrição da Barra de Menus 96
Figura 31 - Diagrama de Casos de Usos 102

Figura 32 – Diagrama de Atividades – Elaborar Questionários.....104
Figura 33 - Diagrama de Sequência – Elaborar Questionário de Múltipla Escolha.105
Figura 34 - Diagrama de Sequência – Elaborar Questões de Múltipla Escolha.....105
Figura 35 - Diagrama de Sequência – Elaborar Alterantivas de Múltipla Escolha...106
Figura 36 - Diagrama de Sequência – Questionário de Demarcação de Imagem Professor.....106
Figura 37 - Diagrama de Sequência – Questionário de Demarcação de Imagem Estudante.....106
Figura 38 – Protótipo Login.....107
Figura 39 – Protótipo Cadastro de Usuários.....108
Figura 40 - Protótipo Menu Principal.....108
Figura 41 - Protótipo Cadastro de Imagens.....109
Figura 42 - Protótipo Demarcação de Imagens.....109
Figura 43 - Protótipo Questionário Demarcação de Imagens.....110
Figura 44 - Protótipo Demarcação Feita por Professor e Estudante.....110
Figura 45 - Protótipo Elaboração de Questionário.....111
Figura 46 – Protótipo Resposta de Alternativa Correta.....111
Figura 47 - Protótipo Resposta de Alternativa Errada.....112
Figura 48 - Diagrama de Entidades e Relacionamentos.....113
Figura 49 - Fluxograma de Testes.....126
Figura 50 - Interface da Tela Principal.....127
Figura 51 - Interface da tela de Login.....128
Figura 52 - Interface de Cadastro do Usuário.....128
Figura 53 - Mensagem de Sucesso do Cadastro do Usuário.....129
Figura 54 - Lista de Opções para Categoria de Usuário.....129
Figura 55 - Mensagem de Sucesso na Autenticação da Plataforma.....130
Figura 56 - Cadastro de Imagens.....130
Figura 57 - Cadastro de Imagens.....131
Figura 58 - Lista de Tipos de Imagens.....131
Figura 59 - Especialidade da Imagem.....132
Figura 60 - Menu da Escolha do Tipo de Questionário.....132
Figura 61 - Selecionando o Tipo de Questionário.....133
Figura 62 - Elaboração do Questionário pelo Professor.....133
Figura 63 - Elaboração da Questão.....134

Figura 64 - Listagem de Imagens Cadastradas na Plataforma 134
Figura 65 - Interface de Elaboração de Alternativas 135
Figura 66 - Questão 0/2 a ser Respondido pelo Estudante.....136
Figura 67 - Resposta do Estudante com erro ao Questionário.....137
Figura 68 - Resposta do Estudante com acerto ao Questionário 138
Figura 69 - Resultado da Pontuação do Estudante.....138
Figura 70 - Selecionando o Tipo de Questionário para Demarcação de Imagens ..139
Figura 71 - Elaboração do Questionário de Demarcação de Imagens.....140
Figura 72 - Elaboração das Questões de Demarcação de Imagens 140
Figura 73 - Consultando o Número de Referência da Imagem 141
Figura 74 - Consultando o Número de Referência da Imagem 141
Figura 75 - Demarcação da Imagem Utilizando o Mouse 142
Figura 76 - Menu Questionário Acionado por um Estudante.....142
Figura 77 - Selecionando o Tipo de Questionário de Demarcação de Imagens 143
Figura 78 - Realizando a Demarcação na Região Errada da Imagem 143
Figura 79 - Resposta da Plataforma à Demarcação Errada na Imagem 144
Figura 80 - Resposta da Plataforma à Demarcação Correta na Imagem.....144
Figura 81 - Resultado do Questionário de Demarcação de Imagens.....145
Figura 82 - Cadastro de Estudo de Casos 147
Figura 83 - Predição para Detecção de Tuberculose 148
Figura 84 - Interpolação Pelo Vizinho mais Próximo.....161
Figura 85 - Diretórios de Treino e Validação.....166
Figura 86 - Esquema Simplificado da Rede Neural.....172
Figura 87 - Execução do Treinamento 175
Figura 88 - Matriz Confusão.....179
Figura 89 - Execução do Treinamento da 2ª Versão.....181
Figura 90 - Matriz Confusão da 2ª Versão 183
Figura 91 - Execução do Treinamento da 3ª Versão.....184
Figura 92 - Matriz Confusão da 3ª Versão 186
Figura 93 - Transferência de Aprendizado 188
Figura 94 - Transferência de Aprendizado 193
Figura 95 - Matriz Confusão.....194
Figura 96 - Métricas 196
Figura 97 - InceptionResNetV2 199

Figura 98 - InceptionV3 200
Figura 99 - ResNet50 201

LISTA DE TABELAS

Tabela 1 - Modalidade de Exames e Quantidade de Laudos Gratuitos por mês 29
Tabela 2 - Modalidade de Exames e Custo por Transmissão/Laudo unitário 29
Tabela 3 - Média e Desvio Padrão do Exame do CREMESP de 2005 a 2018.....84
Tabela 4 - Resultados da Matriz Confusão de cada Modelo.....195
Tabela 5 - Métricas dos modelos de redes 196
Tabela 6 - Cálculo da Usabilidade.....206
Tabela 7 - Resultados do Teste U de Mann-Whitney (não paramétrico) entre os grupos GC e GE utilizando as perguntas do Anexo B.....208
Tabela 8 - Respostas das 10 perguntas com relação as repostas dos estudantes.209
Tabela 9 - Respostas dos Professores com relação às Perguntas.....210

LISTA DE QUADROS

Quadro 1 – Exemplo de Questões com Alto índice de Erro 24
Quadro 2 - Média e Desvio Padrão do Exame do CREMESP de 2005 a 2018.....84
Quadro 3 - Recursos do Sistema 87
Quadro 4 - Requisitos Funcionais do Sistema 98
Quadro 5 - Requisitos Não Funcionais do Sistema.....99
Quadro 6 - Regras de Negócios.....100
Quadro 7 - Escala Likert.....122
Quadro 8 - Relação de Pacotes Utilizados.....152
Quadro 9 - Arquivos de Imagens.....155
Quadro 10 - Arquivos de Imagens acrescidos da coluna target.....156
Quadro 11 - Imagens do Hospital de Shenzhen.....157
Quadro 12 - Imagens do Hospital de Montgomery.....158
Quadro 13 - Metadados Extraídos das Imagens do Hospital de Shenzhen 159
Quadro 14 - Metadados Extraídos das Imagens do Hospital de Montgomery 159
Quadro 15 - Redimensionamento por Interpolação.....163
Quadro 16 - Criação da Coluna labels no Dataframe Concatenado 164
Quadro 17 - Divisão dos Dados de Treino e Teste/Validação.....165
Quadro 18 - Imagens Sintéticas com Giro de 10º 168
Quadro 19 - Hiperparâmetros.....169
Quadro 20 - Matriz Confusão Amostras 179
Quadro 21 - Hiperparâmetros para Imagens com Resolução 128 x 128 181
Quadro 22 - Hiperparâmetros para Imagens com Adição da 4ª Camada Oculta 184

LISTA DE ABREVIATURAS E SIGLAS

API - Application Programming Interface

AWS – Amazon Web Service

CAD – Computer Aided Diagnosis

CBIR - Content-Based Image Retrieval

CNN – Convolutional Neural Network

CPU – Central Processive Unidade

CREMESP – Conselho Regional de Medicina de São Paulo

CSS - Cascading Style Sheets

CUDA - Compute Unified Device Architecture

DICOM – Digital Imaging and Comunications in Medicine

GNU – General Public License

GPU – Grafical Processive Unit

HTML - HyperText Markup Language

IDE - Integrated Development Environment

IHC - Interação Humano-Computador

JPG - Joint Photographic Experts Group

LDAP - Lightweight Directory Access Protocol

PACS – Picture Archive and Comunication System

PNG - Portable Network Graphic

RF – Requisitos Funcionais

RNF – Requisitos Não Funcionais

TIF - Tag Image File Format

UI – User Interface

URL - Uniform Resource Locator

XML – eXtensible Markup Language

SUMÁRIO

1 Introdução 20
1.1 Motivação 23
1.2 Justificativa 24
1.3 Objetivo Geral 26
1.4 Objetivos Específicos 26
2 Referencial Teórico 27
2.1 Relação de Ambientes Computacionais 27
2.1.1 Epacs 27
2.1.2 Mini-Webpacs 30
2.1.3 In Vesalius 32
2.1.4 Radiopaedia 36
2.1.5 QualIM 40
2.1.6 Dr. Tis 42
2.2 – Processamento de Imagens 44
2.2.1 – Imagens Padrão DICOM 45
2.2.2 – Imagens Padrão JPG 45
2.2.3 – Imagens Padrão PNG 46
2.2.4 – Imagens Padrão TIFF 46
2.2.5 - E-Learning 46
2.2.6 – *Deep Learning* 47
2.3 Computação em Nuvem 48
2.3.1 Características da Computação em Nuvem 50
2.3.2 Outras Características da Computação em Nuvem 51
2.4 ESCOLHA DA TECNOLOGIA DE COMPUTAÇÃO EM NUVEM 55
2.4.1 Planos Gratuitos 56
2.5 ARQUITETURA DA NUVEM 57
2.6 Redes Neurais Artificiais 61
2.6.1 O Cérebro Humano 63
Fonte: OPENSTAX. Neurônios e Células Gliais, c2022 65
2.6.2 O Neurônio Matemático 65
2.6.3 Redes Neurais Convolucionais 67

Fonte: Medium. Understanding of Convolutional Neural Network (CNN) — Deep Learning. c2020 69
2.7 CONSIDERAÇÕES SOBRE EXAMES DO CREMESP 80
3 Materiais e Métodos 86
3.1 Análise de Recursos DA PLATAFORMA 86
3.2 Estrutura DA PLATAFORMA 87
Questionários 88
Estudo de Casos 88
Fórum 88
Predição 88
3.3 Softwares Utilizados no Desenvolvimento do Projeto 89
Draw.io 89
Balsamiq 90
Mobirise 90
HTML 90
CSS 90
Javascript 90
Django 90
MySql 91
Visual Studio Code 91
PyCharm 91
3.4 Desenvolvimento do Sistema 91
3.4.1 Etapa 1 - Fases da Estrutura para Desenvolvimento de Sistemas 92
3.4.2 Organização do Sistema 94
3.4.3 Requisitos do Sistema 96
3.4.4 Diagrama de Caso de Uso 101
3.4.5 Diagrama de Atividades 103
3.4.6 Diagramas de Sequências 104
3.4.7 Etapa 2 - Protótipos de Interfaces 106
3.4.8 Etapa 3 - Banco de Dados 112
3.4.9 Etapa 4 – Acesso à Plataforma 117
3.4.10 Etapa 5 – Metodologia de Validação e Verificação da Plataforma 117
3.5 Testes de Avaliação 117
3.5.1 Usabilidade 120

3.5.2 Teste de Funcionalidade 122
3.5.3 – Teste de Aprendizado 123
3.5.4 – Local e Realização da Pesquisa 123
3.5.5 – Amostragens 123
Amostragem para Teste de Usabilidade 123
Amostragem para Teste de Funcionalidade 124
4 – RESULTADOS 126
4.1 Implementação das Interfaces 127
4.1.1 – Elaboração de Questionário de Múltipla Escolha 132
4.1.2 – Elaboração do Questionário de Demarcação de Imagens 139
4.1.3 – A Interação do Estudante com o Questionário de Demarcação de Imagens 142
4.1.3.1 – Mecanismo de Captura de Coordenadas de Demarcação de Imagens 145
4.1.4 – Cadastro de Estudo De Casos 146
4.2 Desenvolvimento De Um Modelo De I.A. para Predição de Tuberculose 148
4.2.1 Conjunto de Raios X de Tórax do Condado de Montgomery (Mc) 150
4.2.2 Conjunto de Raios X de Tórax do Condado de Shenzhen 150
4.2.3 Compreensão dos Dados das Imagens 151
4.2.4 Linguagem de Programação e Pacotes 151
4.2.5 Arquitetura de Hardware 153
4.2.6 – Carregando o Repositório de Imagens 155
4.2.7 – Extraindo a Variável Target 155
4.2.8 – Visualização de Imagens 156
4.2.9 Ajustando e Organizando Imagens de Raios X 158
4.2.10 Redimensionamento e Padronização de Imagens 160
4.2.11 Separação dos Dados para Treino e Validação 163
4.2.12 Pré Processamento de Imagens 165
4.2.13 Aumento do Conjunto de Dados - Dataset Augmentation 166
4.2.14 Desenvolvimento do Modelo 168
4.2.15 Avaliação da Performance do Modelo 176
4.2.16 Avaliação da Performance do Modelo Utilizando Matriz Confusão 178
4.2.18 Segunda Versão do Modelo 180
4.2.19 Avaliação da Performance da 2ª Versão Modelo 182
4.2.20 Avaliação da Segunda Versão do Modelo Utilizando Matriz Confusão 182

4.2.21 Terceira Versão do Modelo 183
4.3 - Transferência de Aprendizagem para Categorização de Patologias 186
4.3.1 - Trabalhos Relacionados à Transferência de Aprendizado 188
4.3.2 - Metodologia Aplicada a Transferência de Aprendizado 189
4.1 - RESNET50 190
4.2 - INCEPTIONV3 190
4.3 - INCEPTIONRESNETV2 190
4.4 - BANCO DE IMAGENS 190
4.5 - HIPER-PARÂMETROS 191
4.6 - BALANCEAMENTO DE CLASSES 191
4.7 - ESQUEMA DE MÉTRICAS DA MATRIZ CONFUSÃO 193
4.7.1 – Relatório InceptionResNetV 197
4.7.2 – Relatório InceptionV3 197
4.7.3 – Relatório ResNet50 198
Capítulo 5 - Discussões e Resultados SOBRE A PLATAFORMA 203
5.1 – Compilação de Dados Estatísticos 204
5.1.1 – Testes de Usabilidade 204
5.1.2 – Testes de Funcionalidades com Estudantes 206
5.1.3 – Testes de Funcionalidades com Professores 209
6 – Conclusão 211
Referências 213
APÊNDICES 225
ANEXOS 248

1 INTRODUÇÃO

Imagens médicas têm como objetivo fornecer aos clínicos a possibilidade de visualizar internamente o corpo humano de forma não invasiva, além de tornar o diagnóstico mais preciso (AMORIM *et al.,* 2011).

A elaboração de laudos médicos a partir de exames com diagnósticos baseados em imagens, não é uma tarefa trivial. Além da complexidade envolvida no processo, outros fatores podem ser determinantes para ocasionar um eventual diagnóstico equivocado. Dentre eles, destacam-se a influência dos fenômenos físicos presentes no processo de formação de imagens radiográficas, a eficiência do sistema de registro e a ausência de um programa de controle de qualidade aplicado ao radiodiagnóstico nos equipamentos utilizados. Todos esses fatores fazem parte do cotidiano de um profissional da área de saúde, tendo em vista a utilização massiva de equipamentos de raios X, em especial em países como o Brasil e motivada sobretudo, pelo fator custo.

Tal realidade exige ainda mais dedicação por parte do profissional de saúde. É preciso que se tenha atenção redobrada na análise das imagens, levando-se em conta todos os fatores anteriormente enumerados. Sendo assim, é de fundamental importância que o estudante de medicina tenha contato com esse tipo de imagem já durante seu processo de formação e não somente na prática médica depois de formado. É importante também que o apontamento dos fatores que, eventualmente, o levaram a um diagnóstico equivocado sejam prontamente apontados pelo professor e principalmente corrigidos (LIMA *et al.*, 2021).

Kathy Boutis (BOUTIS, 2016) afirma que o domínio da interpretação de radiografias requer considerável treinamento formal e muitas horas de prática. Embora a estratégia de ensino mais comum seja o aprendizado ao lado de um profissional especialista, um dos recursos de aprendizagem mais consagrados pelo tempo é o arquivo de casos de ensino. Normalmente, trata-se de uma coleção de imagens selecionadas por especialistas por seu valor educacional. Mais recentemente, a tecnologia digital facilitou a montagem e o uso de grandes arquivos de ensino.

As imagens radiológicas podem ser extremamente complexas e a análise de exames com centenas de imagens, como a tomografia computadorizada (TC) e a ressonância magnética (RM), é um desafio reconhecido mesmo para especialistas experientes. As dificuldades vêm aumentado nos últimos anos, com o aumento exponencial do

número de exames realizados, a sub especialização das disciplinas médicas e a maior acurácia dos métodos, tornando um desafio para o médico radiologista “saber tudo sobre todos exames e regiões”. Em algumas imagens, regiões que possuem pixels semelhantes são distinguíveis por causa de suas diferentes texturas. As características de textura tornaram-se particularmente importantes porque podem refletir os detalhes de uma lesão identificada em uma imagem. (SANTOS *et al*, 2019).

Numa pesquisa sobre a inserção do biomédico no mercado de trabalho feita no Rio Grande do Sul, Guilherme da Costa (COSTA *et al*, 2017) verificou a importância da realização de disciplinas na área de Imagenologia para os futuros profissionais, bem como a realização de estágios na área. Identificaram-se algumas dificuldades principalmente na empregabilidade destes profissionais, bem como no âmbito da graduação devido ao déficit na oferta de disciplinas específicas em Imagenologia e queda na qualidade de seus conteúdos que impactam diretamente na qualificação do biomédico.

Ana Paula CARRARE aborda sobre a importância da imagem na área acadêmica uma vez que uma das formas básicas de aquisição de conhecimento é por meio da investigação dos detalhes nela contidos (CARRARE; AMARAL; MOURA, 2008).

Uma das formas utilizadas para amenizar tais dificuldades e aumentar a qualidade do aprendizado em imagens médicas, está no estudo auxiliado por computador.

Muitos pesquisadores têm trabalhado no desenvolvimento de sistemas computadorizados para detecção automatizada e quantificação de anormalidades em imagens radiológicas (MARQUES, 2001). Estes sistemas são dedicados ao diagnóstico auxiliado por computador. O computador seria utilizado como uma ferramenta de forma adicional onde o médico poderia ter uma segunda opinião para aumentar a sensibilidade do diagnóstico. Por ter base conceitual, genérica e ampla, a ideia do CAD pode ser aplicada a todas as modalidades de obtenção de imagem incluindo radiografia convencional, tomografia computadorizada, ressonância magnética, ultrassonografia e medicina nuclear. Pode-se, também, desenvolver esquemas de CAD para todos os tipos de exame de todas as partes do corpo como crânio, tórax, abdome, osso e sistema vascular entre outros. (MARQUES, 2001).

O uso de sistemas de imagens médicas digitais em instituições de saúde tem aumentado significativamente, e as grandes quantidades de dados nesses sistemas levaram à concepção de ferramentas de suporte poderosas: estudos recentes sobre recuperação de imagem baseada em conteúdo (CBIR) e recuperação de informação

no campo multimodal tem grande potencial no suporte à decisão, bem como para enfrentar vários desafios em sistemas de saúde, como diagnóstico auxiliado por computador (CAD). No entanto, o assunto ainda está sob intensa pesquisa e muito poucas soluções passaram a fazer parte dos Sistemas de Arquivamento e Comunicação de Imagens (PACS) em hospitais e clínicas (PINHO *et al*., 2017).

Choi, por exemplo, propõe desenvolver um simulador de treinamento de radiografia onde carrega as imagens de um banco de dados e as submete a um algoritmo que permite procedimentos de exame de imagens semelhantes a um exame real de raios X, porém, sem expor os estudantes de radiologia médica à radiação provinda dos aparelhos de raios X (CHOI; KIM; KIM, 2016).

Segundo MOREIRA (MOREIRA *et al.*, 2015) com o desenvolvimento de novas tecnologias de informação, há um excedente de software que pode ser usado para implementar sistemas de *e-learning*, variando de sites e e-mails a blogs, wikis e fóruns de discussão. Sistemas Dedicados de Gerenciamento de Aprendizagem ou *Learning Management Systems* (LMS) suportam o planejamento, organização e controle de acesso de processos de aprendizagem específicos. Na radiologia, existem algumas tecnologias LMS que melhoram a colaboração, a interatividade, a simulação e o autoteste. O *e-learning* é, portanto, uma ferramenta útil que ajuda não apenas os alunos, mas também os profissionais a se moverem em direção a uma visão de educação contínua e ao longo da vida.

O *e-learning* combinado com o aprendizado tradicional – ou seja, *blended learning*, ou *b-learning* – é considerado a melhor forma de obter maior ganho de conhecimento (MOREIRA *et al.*, 2015).

E-learning são atividades de aprendizagem que usam interativamente um computador para melhorar a aprendizagem (RUIZ; MINTZER; LEIPZIG, 2006).

Outro tema abordado neste trabalho é a inteligência artificial, cuja intenção será ajudar mostrar ao estudante as diferenças de pixels entre uma radiografia normal de outra com alguma determinada patologia.

Segundo Santos (SANTOS *et al*., 2019) temos observado o aumento exponencial do número de exames realizados, a subespecialização das disciplinas médicas e a maior acurácia dos métodos, tornando um desafio para o médico radiologista “saber tudo sobre todos exames e regiões”. Além disso, os exames de imagem deixaram de ser somente qualitativos e diagnósticos e passaram a fornecer

informações quantitativas e de gravidade de doença, identificando biomarcadores prognósticos e de resposta ao tratamento. Diante disso, sistemas computadorizados de auxílio diagnóstico vêm sendo desenvolvidos com o objetivo dar suporte ao diagnóstico por imagem e à decisão terapêutica. Com o advento da inteligência artificial, do *big data* e do aprendizado de máquina, caminhamos para a rápida expansão do uso dessas ferramentas no dia-a-dia dos médicos, tornando cada paciente único, levando a radiologia ao encontro do conceito de abordagem multidisciplinar e medicina de precisão.

1.1 MOTIVAÇÃO

Pesquisadores da Universidade de Maastrich na Holanda como Ellen M. KOK (KOK *et al*., 2017) fizeram a seguinte pergunta: “Como ensinar a interpretação de imagens médicas?”

Segundo estes pesquisadores, os educadores na interpretação de imagens médicas têm dificuldade em encontrar evidências científicas de como devem elaborar suas instruções.

> Nós, pesquisadores, revisamos e comentamos 81 artigos que investigaram o design instrucional na interpretação de imagens médicas. Distinguimos entre estudos que avaliaram cursos e currículos off-line completos, estudos que avaliaram módulos de e-learning e estudos que avaliaram intervenções educacionais específicas de ensino. 23% dos estudos avaliaram a implementação de cursos ou currículos completos e 44% dos estudos avaliaram a implementação de módulos de e-learning. Argumentamos que esses estudos têm resultados encorajadores, mas fornecem pouca informação para educadores: existem muitas diferenças entre as condições para atribuir, sem equívocos, os efeitos de técnicas de instrução específicas para aprendizagem do conteúdo. Concluiu-se que, os conceitos não são definidos de maneira uniforme e as deficiências metodológicas limitam ainda mais a utilidade das evidências fornecidas por esses estudos. Finalmente, a pesquisa sobre estratégias de estudo apoia a eficácia dos testes práticos, mas, mais estratégias de estudo podem ser aplicáveis ao aprendizado da interpretação de imagens médicas (KOK *et al.,* 2017, p.1).

No Brasil, uma pesquisa realizada com 879 estudantes de medicina de diversas faculdades do país entre julho e setembro de 2021, demonstrou que a radiologia diagnóstica é uma disciplina importante na prática clínica do ponto de vista dos estudantes de medicina; no entanto, seu treinamento e exposição em radiologia são heterogêneos em geral. Mais estudos são necessários para explorar diferentes

estratégias educacionais e seu impacto no conhecimento clínico dos principais conceitos radiológicos dos estudantes de medicina (HORVAT *et al.*, 2021).

Como pode ser verificado, não há uma única resposta definitiva sobre o assunto. Então, este trabalho está focado na estratégia da eficácia de testes práticos do aprendizado em interpretação sobre imagens médicas utilizando uma ferramenta computacional que visa auxiliar este aprendizado.

1.2 JUSTIFICATIVA

O Conselho Regional de Medicina de São Paulo – CREMESP, aplica um exame aos egressos do 6º ano de medicina que participam de forma voluntária. No ano 2016, 2677 participantes realizaram o exame que teve 43,6% aprovados e 56,4% reprovados. O relatório[1] possui um tópico onde informa o que os participantes erraram em questões básicas da medicina.

Segundo este relatório, Muitos dos recém-formados demonstraram não saber interpretar exames de imagem para diagnosticar e administrar a conduta terapêutica adequada a casos médicos básicos e problemas de saúde frequentes, como crises hipertensivas e doenças respiratórias. O Quadro 1 ilustra alguns exemplos de questões com altos índices de erro:

Quadro 1 – Exemplo de Questões com Alto índice de Erro

Relatório de Exame do CREMESP 2016	
Quantidade (%)	**Questões com Alto Índice de Erros**
80	Não souberam interpretar um exame de radiografia e erraram a conduta terapêutica de paciente idoso;
78	Não souberam interpretar o tipo de pesquisa científica e relevância para indicação de novos tratamentos;
76	Não souberam indicar qual medicação antipsicótica está associada a maior ganho de peso;
75	Não souberam identificar principais características e conduta a ser tomada no caso de paciente com deficiência respiratória;

[1] https://www.cremesp.org.br/pdfs/releasefinal2examecremesp2016.pdf

71	Não acertaram diagnóstico e tratamento para hipoglicemia de recém-nascido, problema comum nos bebês;
70	Não conseguiram diagnosticar tuberculose por meio da história clínica e exame físico;
70	Não souberam indicar a conduta adequada em paciente com crise hipertensiva, doença que acomete 25% da população brasileira. Esta é uma manifestação com potencial de morte e acidente vascular cerebral da hipertensão arterial – doença que acomete 25% da população brasileira;
65	Não acertaram a conduta medicamentosa recomendada a paciente com asma leve;
63	Não souberam interpretar um exame de tomografia abdominal no contexto da história clínica e exame físico para diagnosticar e indicar conduta mais adequada ao paciente.

Fonte: Fundação Carlos Chagas/CREMESP, 2016, P.3-4

Outras considerações sobre o exame do CREMESP estão discriminados em um tópico específico do capítulo 2 deste trabalho.

1.3 OBJETIVO GERAL

Este trabalho propõe desenvolver uma plataforma para *web,* responsiva, denominada patologIA para treinamento de estudantes que possam ser utilizados como apoio no auxílio do aprimoramento da interpretação de imagens na disciplina de imagenologia.

1.4 OBJETIVOS ESPECÍFICOS

A fim de que objetivo geral seja completado, foram estabelecidos os seguintes objetivos específicos:

- A plataforma deverá ter recursos para desenvolver questionários com questões objetivas onde o professor terá a flexibilidade para determinar quantidade de questões e alternativas em cada questão;
- Desenvolver questionários utilizando demarcações de regiões em imagens médicas.
- Realizar triagem para avaliação de imagens médicas contendo patologias ou não.
- Aplicar testes de interação entre professor e estudantes como questionários e demarcação de imagens.
- Desenvolvimento de banco de dados para armazenamento de imagens médicas e casos clínicos a serem utilizados em interação entre professor e estudantes.
- Aplicação de testes de usabilidade, funcionalidade e aprendizado após interação com a plataforma.
- Oferecer imagens com diferentes níveis de dificuldade, de diferentes órgãos e estruturas anatômicas, com imagens laudadas fornecidas previamente por especialistas ou auxiliados por algoritmos baseados em I.A. – Inteligência Artificial, com funcionalidades modulares e expansíveis devidamente mentoradas por professores e especialistas, com intuito de trazer contribuições significativas.

No capítulo 2, serão abordados temas que constituíram os fundamentos no desenvolvimento deste projeto.

2 REFERENCIAL TEÓRICO

Neste capítulo serão estudados temas relevantes ao desenvolvido deste projeto como o estado da arte onde estuda-se os sistemas computacionais semelhantes ao que será desenvolvido, processamento de Imagens, computação em nuvem onde o sistema será disponibilizado, redes neurais artificiais que é um dos recursos utilizados no desenvolvimento no módulo triagem de imagens e considerações sobre dados do exame do CREMESP aplicados aos alunos egressos das faculdades de medicina no estado de São Paulo.

Também, é relevante o estudo de temas como processamento de imagens e padrões, atividades de *e-learning* para aprendizagem utilizando computador e estudo de sistemas que possuem aderência ao que foi aqui proposto.

2.1 RELAÇÃO DE AMBIENTES COMPUTACIONAIS

A seguir, serão apresentadas, em ordem cronológica, alguns sistemas computacionais produzidos para a finalidade do ensino em imagens médicas que contenham relação com o projeto aqui proposto, ou seja, o atual estado da arte pesquisado.

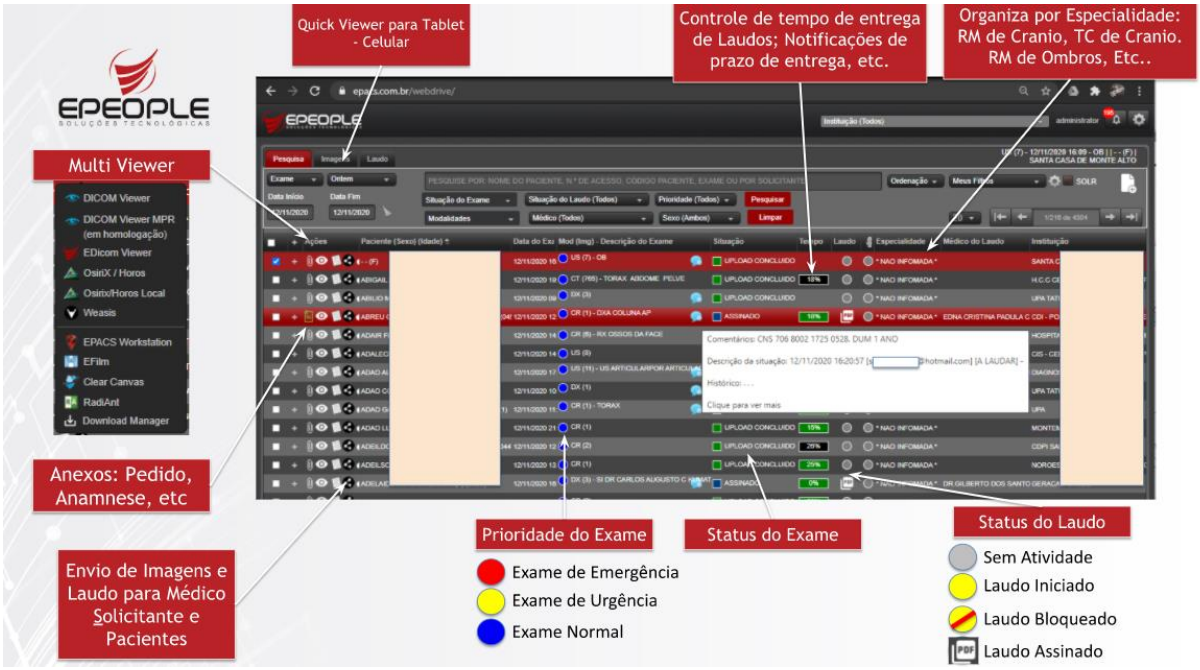
2.1.1 Epacs

O Epacs[2] é uma plataforma nacional desenvolvida no ano 2000 com o foco voltado para integração clínicas, centrais de laudos, hospitais e telemedicina. A sua última versão foi integrada à nuvem, onde várias funcionalidades estão disponibilizadas para visualizar imagens médicas nas áreas de radiologia, cardiologia, oftalmologia, dermatologia, dentre outras.

O sistema permite o envio de imagens médicas para serem laudadas utilizando algoritmos de inteligência artificial e enviados a médicos de diferentes especialidades para validação do diagnóstico. Na Figura 1 uma visão geral da interface deste sistema.

[2] www2.epacs.com.br

Figura 1 - Interface da Plataforma Epacs



Fonte: Conheça o EPACS. Funcionalidades, cEpeople

Por estar hospedado em nuvem, a plataforma possui mais de 250 milhões de imagens médicas armazenadas o que garante uma infraestrutura escalável e segura para transmissão, armazenamento e visualização de exames médicos. Permite a consulta ao exame pelo paciente ou médico para sua impressão, além de relatórios e *dashboards*. O serviço é oferecido parcialmente gratuito cujas quantidades de exames são determinadas conforme sua modalidade segundo a Tabela 1:

Tabela 1 - Modalidade de Exames e Quantidade de Laudos Gratuitos por mês

Modalidades Exames	Transmissões / Laudos por Mês
Raios X	100 Grátis
Ultrassonografia	100 Grátis
Mamografia	50 Grátis
Endoscopia	50 Grátis
Ressonância	50 Grátis
Tomografia	50 Grátis
Angiografia	50 Grátis
Eletrocardiograma	50 Grátis
Mapa	10 Grátis
Holter	10 Grátis
Laboratorial	100 Grátis
Outros (verificar)	50 Grátis

Fonte: Conheça o EPACS. Cadastre-se e Utilize Grátis, cEpeople.

Quantidades superiores aos valores anteriores são cobradas levando-se em consideração os seguintes custos demonstrados na Tabela 2:

Tabela 2 - Modalidade de Exames e Custo por Transmissão/Laudo unitário

Modalidades Exames	Custo por Transmissões / Laudo
Raios X	R$ 0,35
Ultrassonografia	R$ 0,60
Mamografia	R$ 0,35
Endoscopia	R$ 0,99
Ressonância	R$ 0,99
Tomografia	R$ 0,99
Angiografia	R$ 0,35
Eletrocardiograma	R$ 0,65
Mapa	R$ 0,65
Holter	R$ 0,45
Laboratorial (por Paciente)	R$ 0,45
Outros (verificar)	R$ 0,35

Fonte: Fonte: Conheça o EPACS. Após usar o Grátis, cEpeople.

O usuário deve estar vinculado a uma instituição de saúde como clínica, hospital, plano de saúde para que consiga acessar os serviços gratuitos oferecidos.

2.1.2 Mini-Webpacs

Este sistema web[3] foi projetado em 2001 para uso de plataformas de hardware de baixo custo e desenvolvido em softwares com licença pública GNU e desenvolvido na Unidade de Pesquisa e Desenvolvimento do Instituto do Coração – Incor, do Hospital das Clínicas da Faculdade de Medicina da Universidade de São Paulo - USP.

Seu objetivo é facilitar o intercâmbio entre instituições hospitalares para poder armazenar e disponibilizar em rede imagens digitais de diversas modalidades para fins clínicos, pesquisa ou didáticos, tornando possível baixar custos de manipulação de imagens digitais como tomografias, medicina nuclear, raios X, etc.

A metodologia do projeto baseou-se no uso de arquiteturas padrão (TCP/IP, DICOM, WEB) e software livre. O mini-WEBPACS é suportado por um servidor LINUX (plataforma Intel de 1Ghz, 256MB de RAM e 120GB de disco) com um banco de dados relacional MySql e um servidor DICOM (*Digital Imaging and Communications in Medicine*), desenvolvido para a RSNA (*Radiology Society of North America, Washington,USA*) pelo *Mllinckrodt Institute of Radiology* (St. Louis, Missouri, USA), ao qual é distribuído gratuitamente, incluindo os códigos fonte e a documentação que foi desenvolvido neste projeto utilizando linguagem Java, com o uso de um conjunto de classes oferecido por uma biblioteca DICOM, a dcm4che, distribuída sob os termos da GNU (FIGUEIREDO *et al.*, 2002).

Há também um servidor de *Java Server Pages* (*Apache TomCat*) configurado para operar as páginas de acesso e controle do sistema. O uso destas tecnologias dispensa qualquer custo de licença, reduzindo ainda mais o investimento dos usuários. Diversas aplicações, tais como sistemas de monitoração do servidor (*MRTGMulti Router Traffic Grapher*) ou mesmo serviços de consulta e preenchimento de laudos em XML, estarão presentes e integradas ao servidor. A segurança e o controle do acesso às informações serão feitos por um Serviço de Diretório utilizando o protocolo LDAP (*Lightweight Directory Access Protocol*).

[3] Fonte: http://miniwebpacs.sourceforge.net/

Embora seja gratuito, não é um ambiente para interação de estudantes de medicina, onde não existem funcionalidades que permitam aferir seu aprendizado.

A Figura 2, Figura 3 e Figura 4 exibem algumas interfaces visualizadas no sistema.

Figura 2 - Interface Inicial do Sistema MINI-WEBPACS



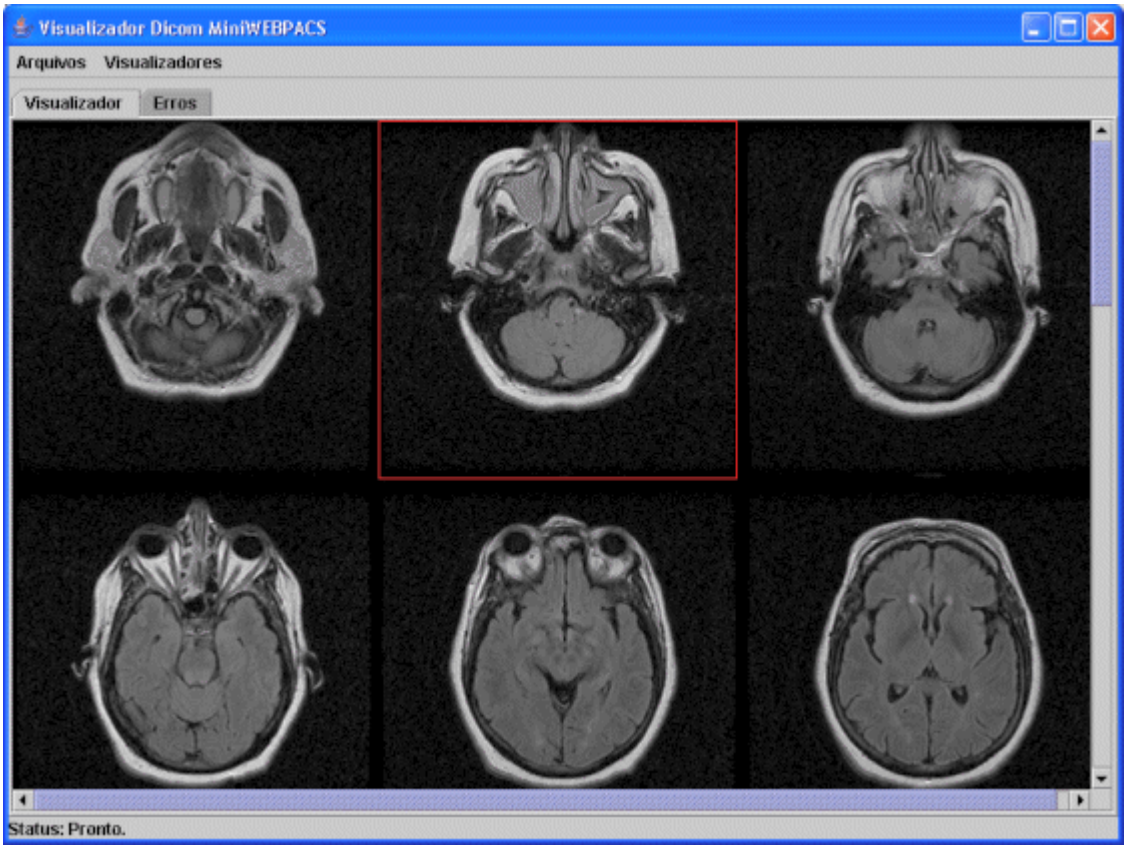
Fonte: URTIGA *et al*, 2004

Figura 3 - Tela de Busca pelo Nº de Matrícula / Nome do Paciente



Fonte: URTIGA *et al*, 2004

Figura 4 – Visualizador de Imagens



Fonte: URTIGA *et al*, 2004

2.1.3 In Vesalius

De acordo com AMORIM (AMORIM, 2011), este software foi desenvolvido pela equipe do Centro de Tecnologia da Informação Renato Archer – CTI em Campinas – SP, cujo um dos objetivos é a produção de modelos físicos para auxiliar profissionais de saúde em planejamento cirúrgico. O software teve seu desenvolvimento inicial em 2001 e hoje está na sua terceira versão. É um software livre desenvolvido sob a licença GNU – *General Public License* versão 2 que permite a profissionais de centro de pesquisas a implementar novos funcionalidades ao sistema bem como aplicar seus temas de pesquisas.

O projeto foi desenvolvido em linguagem de programação *python* por ser uma linguagem multiplataforma que permite ao software a execução em vários sistemas operacionais como *MS-Windows* (versões 7, 8 e 10), *GNU Linux* (*Ubuntu, Mandriva, Fedora*), *Apple MAC OS X*, e multiparadigma que permite o desenvolvimento de projetos em orientação a objetos, funcional, procedural e lógico. Grande parte deste

projeto foi desenvolvido sob o paradigma de orientação a objetos e, em alguns casos, utilizou-se o paradigma funcional e procedural.

O software permite a carga de arquivos DICOM (.dcm), analyze (.hrd), e em formatos de compressão de imagem como TIFF, JPG, JPEG, BMP OU PNG.

Utilizou-se a biblioteca *GDCM*[4] para suporte ao padrão DICOM e a biblioteca *nibabel*[5] para arquivos *analyze*.

Ao serem carregadas as imagens são convertidas numa matriz de três dimensões. Essa matriz é mantida gravada em arquivo de disco através de uma estrutura *memmap*, provida pela biblioteca *numpy* (KINSER, 2009) que, quando carregada é mapeada em memória RAM através de uma chamada de sistema *mmap*, comum a vários sistemas operacionais. Esta biblioteca permite operações matemáticas de vetores e matrizes no *python*. A vantagem desta técnica é manter na memória RAM apenas dados necessários da matriz. Caso novos dados sejam necessários, serão carregados do disco para a memória RAM da máquina. Esta técnica permite que arquivos de exames médicos com grande quantidade de fatias sejam carregadas ocupando menos memória do que se todas as fatias fossem carregadas de uma só vez.

Para o desenvolvimento da interface gráfica foi utilizada a biblioteca *wx-python* (RAPPIN *et al.*, 2006) que permite ao software se adequar à aparência nativa do sistema operacional que estiver sendo executado, sendo necessários alguns poucos ajustes.

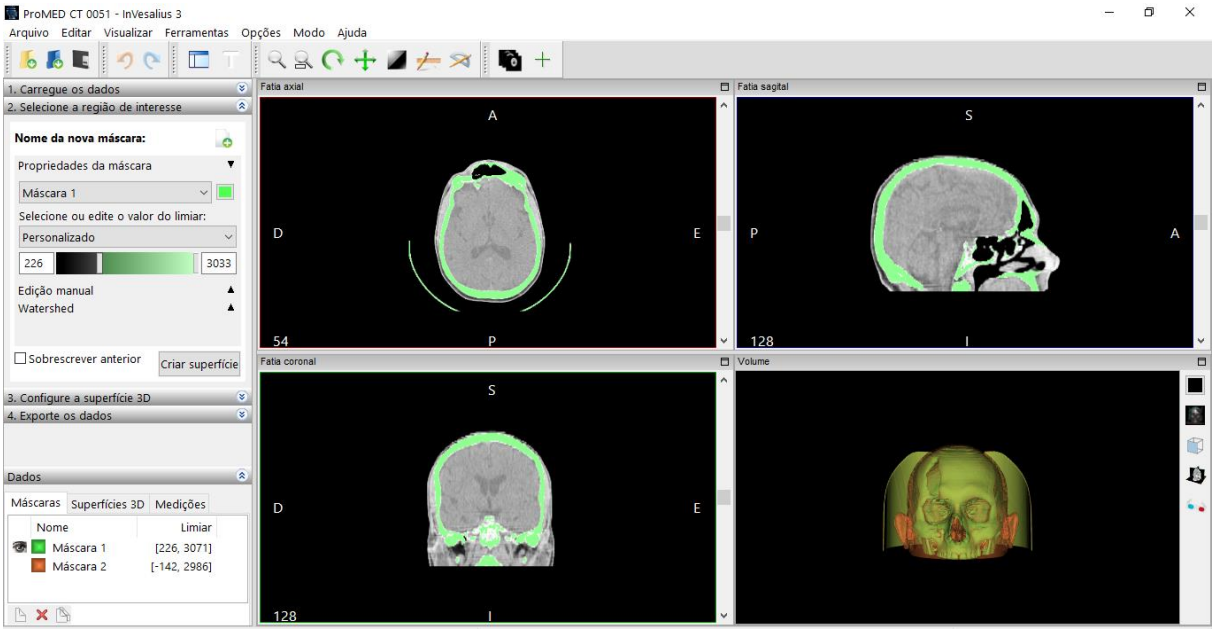
O software possui recursos como segmentação de imagens por limiar (*threshold*) onde são selecionados *voxels* entre valores mínimos e máximo e manual, onde o usuário poderá selecionar áreas de seu interesse, conforme ilustra a Figura 15.

Após selecionar a região de interesse é possibilitado ao usuário à opção de reconstrução de 3D da região selecionada, o que é feito através do algoritmo *Marching Cubes* (LORENSEN *et al*., 1987). A Figura 5 ilustra esse recurso:

[4] MALATERRE, M. Grassroots dicom - http://sourceforge.net/projects/gdcm/. 2011.

[5] NiBabel (2011). Access a cacophony of neuro-imaging file formats. http://nipy.sourceforge.net/nibabel/

Figura 5 - Interface Gráfica InVesalius



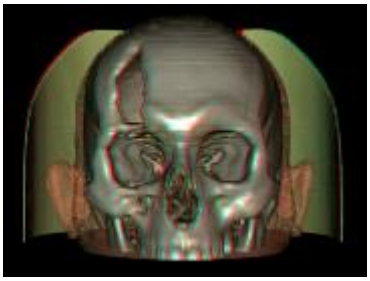
Fonte: AMORIM, 2011.

Ao carregar uma imagem o software exibe uma imagem nas orientações Axial, Sagital e coronal, além de uma janela para manipulação 3D.

O software oferece outros recursos de visualização 3D como o recurso de "Visualização Volumétrica" que permite visualizações mais realistas de uma imagem. Nesta técnica, para cada pixel da tela é traçado um raio de luz em direção ao objeto. A cor do pixel será baseada na cor e transparência de cada *voxel* interceptado pelo raio de luz (MANSSOUR *et al*., 2002).

Existem 30 padrões de visualização oferecidas por este recurso. A Figura 6 exibe a visualização volumétrica pelo padrão "Brilhante".

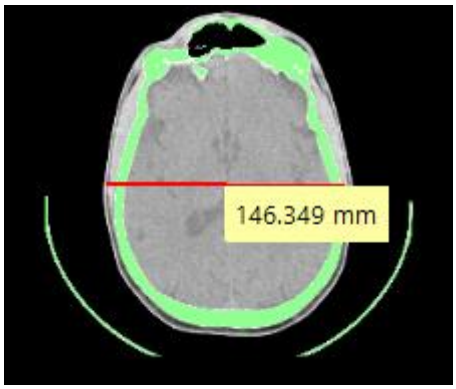
Figura 6 - Visualização Volumétrica padrão Brilhante



Fonte: AMORIM, 2011

Outro recurso oferecido pelo In Vessalius são as ferramentas de medidas linear e angular em planos 2D e 3D cuja finalidade é definir a distância entre dois pontos da imagem, como pode ser visto na Figura 7 onde a distância, em milímetros, entre dois pontos foi definida no plano axial da imagem.

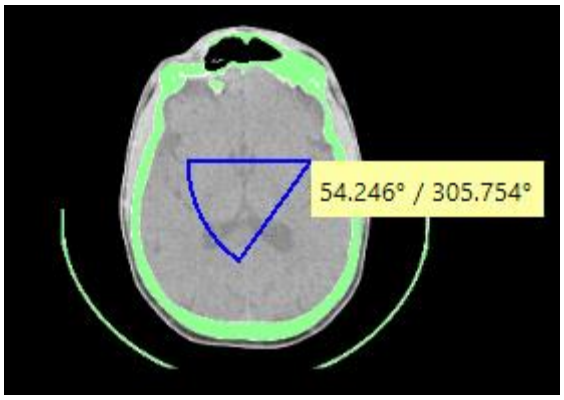
Figura 7 - Medição Linear Axial



Fonte: AMORIM, 2011

A medição angular é mostrada diante a determinação de três pontos pela ferramenta que exibe a medida dos ângulos formado pelos pontos, conforme pode ser observado na Figura 8.

Figura 8 - Medição Angular Axial



Fonte: AMORIM, 2011.

Estes recursos são utilizados para, por exemplo, medir avanços de um determinado tratamento ou cirurgia, estabelecendo as medidas em imagens antes e depois da cirurgia ou, ainda, para tratamento ou em planejamento cirúrgico.

O software não possui módulos para interação entre professor e estudantes que permita aferir o crescimento de conhecimento do aluno pelo professor. Não é um software integrado ao ambiente web.

2.1.4 Radiopaedia

O Radiopedia[6] se autodefine como um recurso educacional de radiologia de edição aberta desenvolvido por quatorze radiologistas distribuídos por países como Austrália, Reino Unido e Singapura. É um site de acesso livre criado em 2005 que se propõe a ser a melhor referência em radiologia no mundo e disponibilizar seu conteúdo gratuitamente. Por ser um site gratuito possui vários anúncios que permitem a hospedagem de casos e imagens médicas e provêm a manutenção do projeto. Exibe-se um contador de números de casos e artigos publicados no site, conforme a Figura 9.

Figura 9 - Página Principal Radiopédia (Parcial)



Fonte: Radiopedia, c2005-2024

O menu artigo permite a inclusão de novos artigos ou a edição colaborativa de artigos já publicados pelas pessoas cadastradas no site. O propósito é de que cada artigo possa estar com seu conteúdo sempre atualizado. Existe uma documentação na mesma página com um guia para servir como orientação ao usuário a desenvolver um artigo conforme a estrutura e padrão a ser implementado.

[6] https://radiopaedia.org/

Figura 10 - Estudo de Casos



Fonte: Fonte: Radiopedia, c2005-2024

O menu *Estojos* (casos), mostrado na Figura 10, são apresentados casos de estudo incluídos pela comunidade. Tais casos, podem ser vinculados a artigos, questionários e tutoriais disponibilizados no site.

Ainda neste menu é possível ter acesso a várias imagens radiológicas de várias partes e órgãos do corpo humano, fornecidas por radiologistas cadastradas no site, como ressonâncias, tomografias, raios X, ultrassom, medicina nuclear e terapia de radiação.

O menu cursos oferece vários cursos *online* no idioma inglês sobre imagens radiológicas gratuitos para 125 países de baixa e média renda, onde, não se inclui o Brasil. Para os outros países os cursos são pagos.

Este módulo contém um treinamento gratuito, em qualquer idioma, sobre o intestino delgado. Este treinamento é um jogo do tipo *PAC-MAN* que permite ao usuário percorrer o intestino onde ao longo do seu caminho onde o usuário aprende a monitorar e descobrir as várias causas diferentes de obstruções no intestino delgado. O jogo propõe 12 níveis de dificuldades ao usuário.

Para participar das interações com este jogo e com todas as funcionalidades do site, exige-se o cadastro gratuito de uma conta do usuário ao site.

O menu Questionário exibe os questionários de casos de uso que propõem auxiliar na melhoria da educação em saúde, permitindo que profissionais médicos em todo o mundo realizem aprendizagem autodirigida, complementando seu treinamento local. Os títulos e diagnósticos dos casos ficam ocultos nos questionários para que o usuário possa testar sua compreensão antes de compará-los com as descobertas do

caso. Cada caso permite que o usuário inicie um novo questionário a partir do caso selecionado, que continuará em outros casos semelhantes.

Ao acessar o menu de Questionário, é exibida na parte esquerda da tela uma listagem dos últimos casos disponibilizados pelo site onde se pode selecionar o assunto de preferência do usuário. Na parte direita da tela, é possível selecionar o questionário baseado na escolha de um assunto específico ou de todos se este for o caso.

As Figuras Figura 11, Figura 12, Figura 13 e Figura 14 ilustram a sequência da interação com o questionário 88267, o mais recente disponibilizado pelo site naquele momento.

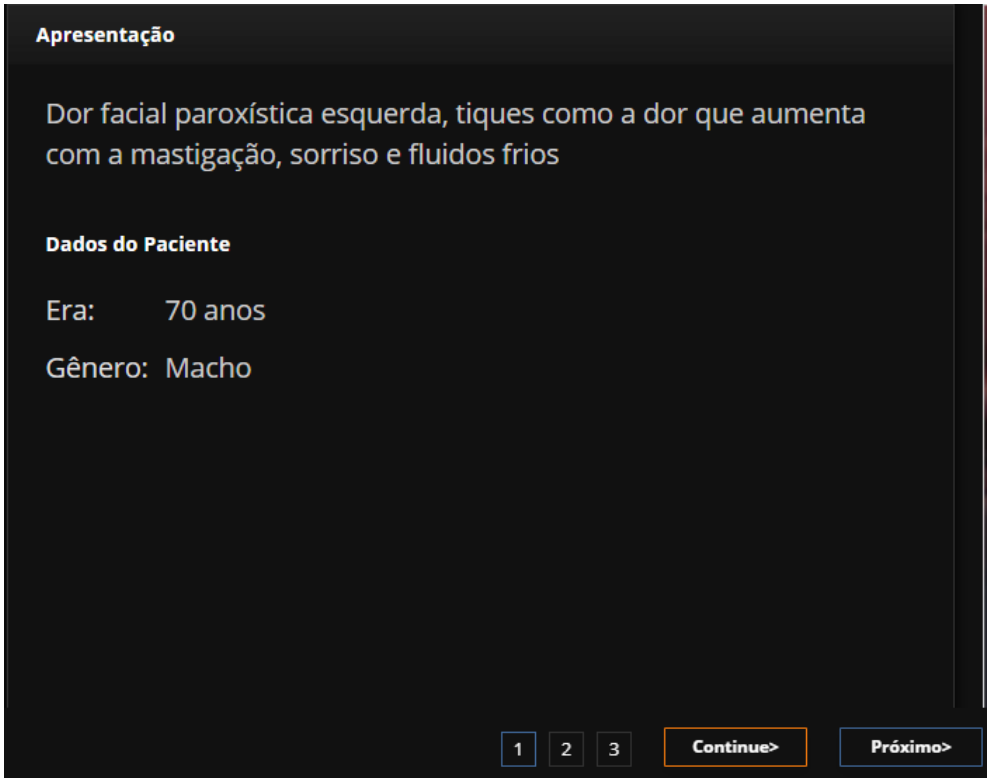
Figura 11 - Tela de Questionário de Caso



Fonte: Fonte: Radiopedia, c2005-2024

Ao selecionar o questionário surge a tela de apresentação do questionário, conforme ilustração da Figura 12.

Figura 12 - Tela de Apresentação do Questionário



Fonte: Fonte: Radiopedia, c2005-2024

Para prosseguir, basta clicar o mouse no botão de número 1 ou no botão “Continue” e será exibida a tela com as imagens referentes ao questionário na Figura 13:

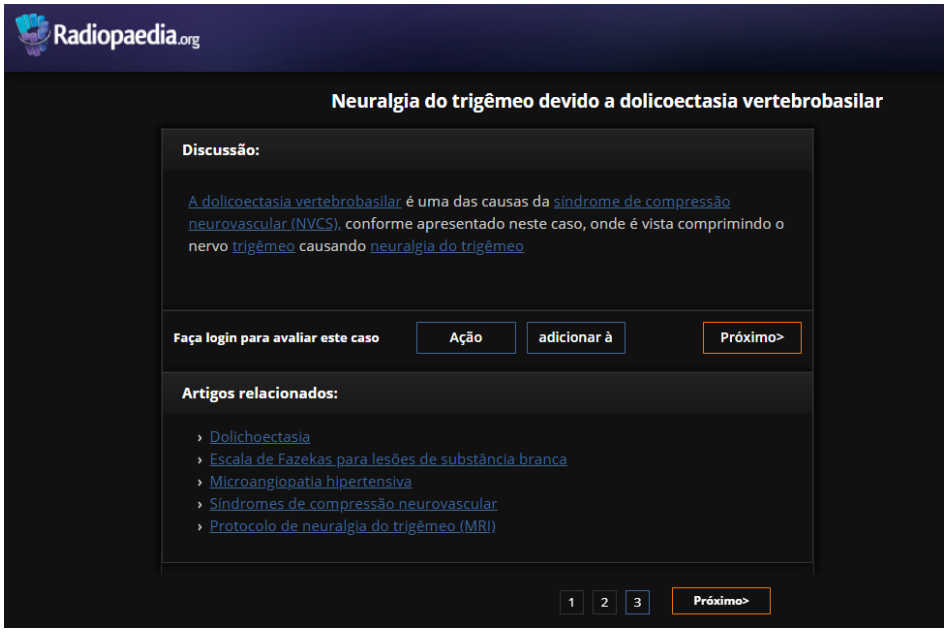
Figura 13 - Tela das Imagens Referentes ao Caso do Questionário



Fonte: Fonte: Radiopedia, c2005-2024

A Figura 14 ilustra a tela com o diagnóstico do caso para discussões.

Figura 14 - Tela de Diagnóstico e Discussão



Fonte: Fonte: Radiopedia, c2005-2024

Ao clicar no botão “Próximo”, um novo questionário será exibido pelo sistema.

Os termos de uso da plataforma explicam que o conteúdo de imagens (exceto o conteúdo da imagem contribuído pelo usuário) não pode ser modificado, copiado, distribuído, reutilizado, reproduzido, republicado, baixado, exibido, postado, transmitido ou vendido por quem quer que seja. Todos os direitos de qualquer conteúdo de texto que o usuário contribua para a Plataforma, mas não se limitando a artigos, descrições de casos e imagens, questões de múltipla escolha, postagens em blog, listas de reprodução, tutoriais e todas as comunicações que o usuário transmitir a qualquer pessoa através de qualquer Plataforma de conteúdo de texto torne-se propriedade da Radiopaedia. O site enfatiza que é somente para fins educacionais.

2.1.5 QualIM

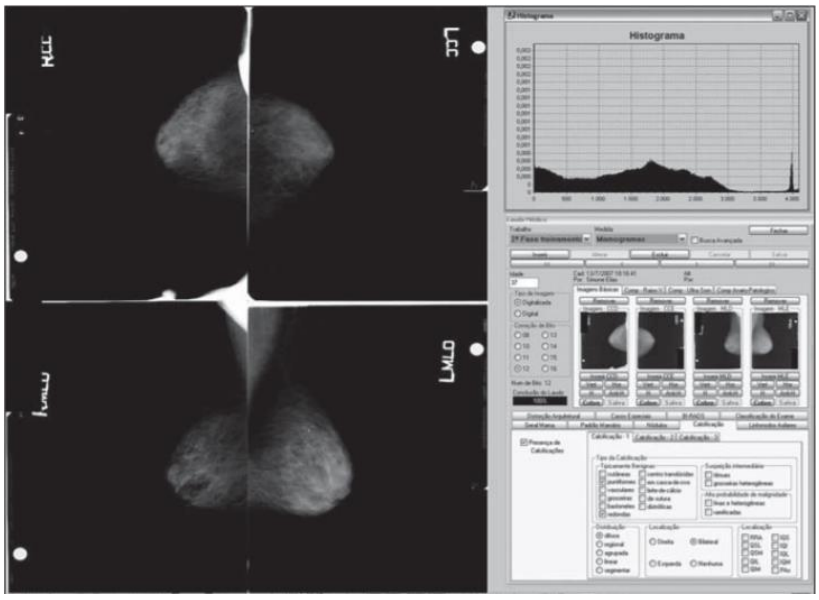
O QualIM[7] – Qualificação de Imagens, é um software concebido em 2007 pelo departamento de Diagnóstico de Imagens da UNIFESP – Universidade Federal de São Paulo. Possui a finalidade de oferecer treinamento para profissionais na interpretação de imagens digitais de mamografias. O projeto foi desenvolvido em

[7] http://dx.doi.org/10.1590/S0100-39842008000600009

Delphi 7 que se relaciona com um gerenciador de banco de dados MS-SQL Server 2000.

A principal função do software é o armazenamento dos laudos, em categorias BIRADS, resultante do treinamento na interpretação de imagens mamográficas. O software foi estruturado para a manutenção das informações contidas na base de dados, onde o acesso é realizado somente com senhas administrativas. A Figura 15 ilustra a interface de treinamento na interpretação de imagens (PIRES *et al.*, 2008).

Figura 15 - Interpretação de Imagens QualIM



Fonte: PIRES *et al.,* 2008, p. 392

O *software* contém um dispositivo que converte imagens geradas no padrão DICOM para o formato TIFF. Segundo FILHO (FILHO *et al.*, 2018) este formato permite comprimir imagens de grande dimensão em imagens do padrão bitmap com ou sem perda de dados em qualquer plataforma, permitindo a sua leitura em qualquer dispositivo computacional.

O *software* foi desenvolvido para treinamento em estações de trabalho equipadas com monitores específicos para mamografia com resoluções de até 5,0 megapixels e 14 bits/pixel em tons de cinza. São eles: monitor Barco modelo MFGD5421 e Clinton modelo DL-3000. Podem ser inseridas na base de dados imagens adquiridas por sistemas *computed radiography* (CR), *direct radiography* (DR) ou as geradas de forma convencional (filmes) por digitalização em scanner laser *Lumiscan* 75 (*Lumisys, Inc.; Sunnyvale, USA*) no formato TIFF com 12 bits/pixel. Todas as imagens digitais obtidas

no padrão DICOM foram coletadas em DVD, sem compressão de dados, e apresentam resolução espacial superior a 5,6 megapixels (matriz superior a 2.560 × 2.048 pixels) (PIRES *et al.*, 2008).

A operação de acesso às imagens é feita através de *menu* específico onde o *software* exibe imagens mamográficas com até oito incidências, em destaque para crânio-caudal e médio lateral (esquerdo e direito). É possível visualizar até seis imagens de ultrassom.

O treinamento do software é praticado em duas etapas. A primeira, baseia-se na manipulação das imagens onde emprega recursos disponibilizados pelo software onde o profissional pode discernir os padrões visuais da imagem e realçar através de controles de brilho e contraste o realce de estruturas que se pretende estudar.

A segunda, trabalha na interpretação de imagens digitais utilizando os conceitos das categorias BI-RADS. Este conceito foi definido e estruturado na quarta edição do Colégio Americano de Radiologia onde são checados a concordância das respostas e o tempo gasto na interpretação de imagens pelo profissional em treinamento.

A cada acesso do profissional ao sistema, novos casos são apresentados a ele com diversos graus de complexidade.

Embora seja um software consistente, em virtude das características de seu projeto, não está disponível para utilização via *Internet*. Não possui funcionalidades para aferição do aprendizado de estudantes.

2.1.6 Dr. Tis

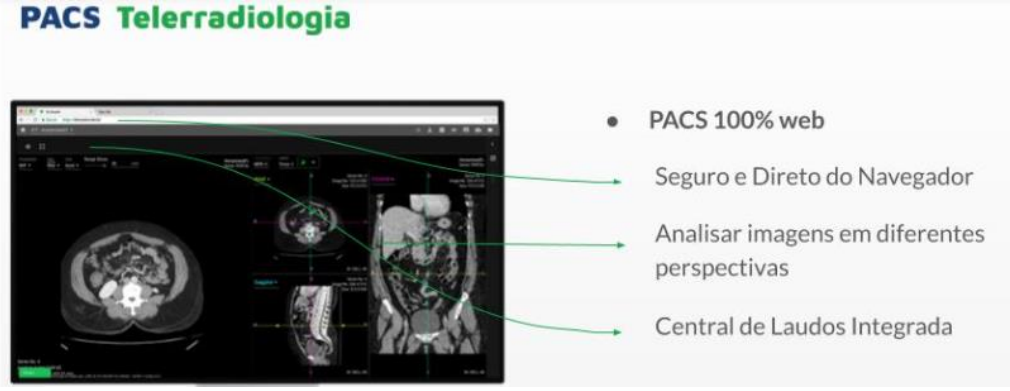
Este site[8] teve seu desenvolvimento finalizado em 2016 quando iniciou suas operações. Um de seus serviços é a telemedicina que possibilita a realização de consultas através da *Internet*. Este serviço, segundo o site, teve início através de uma parceria com o Ministério da Saúde e com tele saúde com o Rio Grande do Sul e evoluiu para telemedicina em unidades de terapia intensiva onde é utilizada a plataforma Dr. Tis. Em virtude da pandemia de Covid19 que atingiu o país no ano de 2020, este tipo serviço foi oferecido a mais de mil pacientes segundo informações do próprio site. O site afirma possuir protocolos médicos assistenciais para realizar o atendimento à distância.

[8] www.drtis.com.br

A plataforma foi desenvolvida e hospedada em nuvem, cujas características possibilitam armazenamento de grande quantidade de exames, imagens médicas e diagnósticos, fornecendo segurança e escalabilidade ao sistema.
A telerradiologia permite o acesso remoto a médicos e pacientes e compartilhamento dos dados. Fornece *dashboards*, relatórios e resultados *online* de exames.

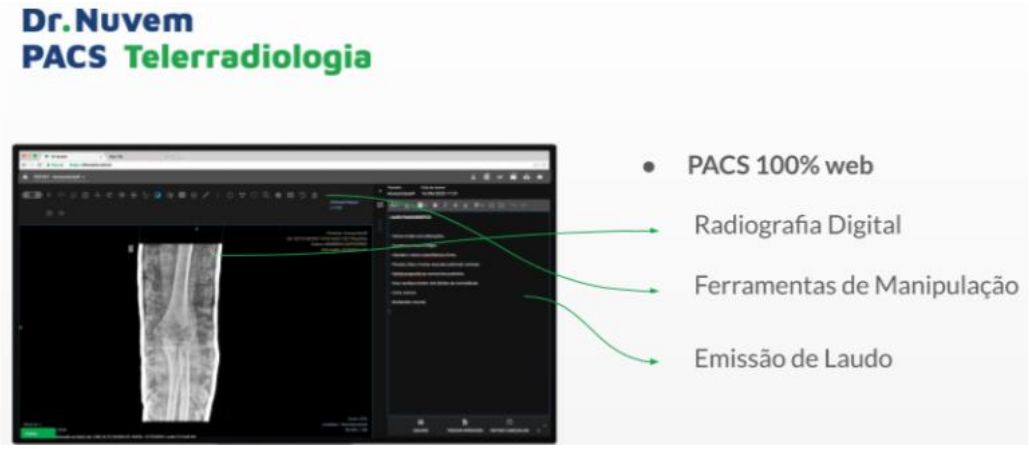
As Figura 16 e Figura 17 ilustram algumas interfaces das funcionalidades disponibilizadas pela plataforma:

Figura 16 - Telerradiologia



Fonte: Dr. TIS Tecnologia Inovação e Saúde c2021

Figura 17 - Telerradiologia Outra Perspectiva



Fonte: Dr. TIS Tecnologia Inovação e Saúde c2021

A plataforma destaca atributos de qualidade em segurança e confidencialidade das informações do paciente do profissional que o assiste. Oferece diagnóstico integrado

a uma central de laudos, e proporciona o compartilhamento do laudo a distância, aumentando a oferta de serviços às clínicas e pacientes. Possui visualizador de imagens médicas para web que permitem a visualização e comparação entre várias imagens com diferentes tecnologias.

Por estar hospedada em nuvem, a plataforma é compatível a todos os dispositivos como *desktops, notebooks, tablets* ou celulares. Possui registro de atendimento ao paciente com recomendações médicas pré-gravadas com possibilidade de edição durante a consulta médica. Possui como recurso o envio de e-mail com o resumo da consulta e a receita médica gerada ao paciente. Por fim, oferece o resultado de exames ao paciente através de consulta a esta funcionalidade disponível no site.

Embora bastante completo e com funcionalidades que se assemelham a alguns módulos da plataforma a ser construída, não é um site voltado para o ambiente acadêmico como treinamento e aprendizagem de estudantes.

2.2 – PROCESSAMENTO DE IMAGENS

A área de processamento digital de imagens vem evoluindo continuamente ao longo dos anos, com um aumento significativo de estudos envolvendo morfologia matemática, redes neurais, processamento de imagens coloridas, compressão de imagens, reconhecimento de imagens e sistemas de análise de imagens baseados em conhecimento (GONZALES *et al*., 2010).

O processamento de imagens tem como funções facilitar a visualização da imagem ou adequá-la para análises quantitativas através de correções de defeitos ou realces das regiões de interesse nas imagens; e a extração e tratamento de dados quantitativos, feitos pelo próprio computador (GOMES *et al*., 2002).

O acesso e visualização remota de imagens médicas através da web está sendo implementado para atividades de treinamento, pesquisa e consulta a especialistas em imagens médicas. Com um navegador da web, os profissionais de saúde podem acessar e navegar pelas imagens médicas de qualquer lugar e a qualquer hora, por meio de diferentes dispositivos (computador, dispositivo móvel), sem instalação e manutenção de software cliente adicional. O acesso remoto às imagens ajuda a aumentar a produtividade dos profissionais de saúde e oferece uma solução mais

eficiente para sistemas de telerradiologia e compartilhamento de dados de imagens médicas (MILLAN & YUNDA, 2014).
Serão discriminados alguns padrões e formatos utilizados em imagens médicas.

2.2.1 – Imagens Padrão DICOM

O DICOM é um padrão para comunicação e armazenamento de imagens médicas e informações associadas, atualmente utilizado por quase todas as modalidades de exames. O padrão DICOM contém uma arquitetura para troca de informações e também para definição de protocolos de comunicação (CARITÁ *et al.*, 2004, *apud* HORII, 1997).
O padrão foi desenvolvido por um comitê de trabalho, formado por membros do *American College of Radiology* (ACR) e da *National Electrical Manufacturers Association* (NEMA), que iniciou os trabalhos em 1983, tendo por objetivo o desenvolvimento de um padrão para comunicação digital de informações e imagens (CARITÁ *et al.*, 2004, *apud* NEMA, 2005).
O padrão DICOM diferencia-se dos outros formatos de imagens, como JPEG, TIFF, GIF e outros, por permitir que as informações dos pacientes sejam armazenadas juntamente com a imagem, mas de forma estruturada. Isto é, elas são armazenadas contendo delimitadores, conhecidos como "*tags*", que identificam e limitam as informações. A imagem propriamente dita no padrão DICOM é baseada no formato JPEG, com ou sem compressão, dependendo do equipamento que a gerou. A grande vantagem dessa estrutura é permitir a leitura do arquivo e extração das informações necessárias para uma comunicação direta, ou seja, gerenciar as imagens e informações dos pacientes de forma coerente, mantendo sua integridade (CARITÁ *et al.*, 2004, *apud* KIMURA, 1998).

2.2.2 – Imagens Padrão JPG

O formato *Join Photografic Expert Group* é um tipo de arquivo de compressão de imagens com perda de dados em decorrência da redução de qualidade. Reduz-se a qualidade da imagem para se obter um arquivo em menor tamanho. É um tipo de imagem utilizada na *Internet* para que possa ser carregada num browser com rapidez.

É um arquivo com razoável qualidade de imagem e de pequeno tamanho quando comparado a outros formatos. A compressão consiste na eliminação de dados redundantes nos arquivos. No caso de imagens, é possível fazer a compressão de forma que a retirada de informações não prejudique a qualidade (*lossless* - sem perda), assim como é possível utilizar níveis maiores de compressão que causam perdas visíveis (*lossy* - com perda). Neste formato, quanto maior o nível de compressão, menor será o tamanho do arquivo, porém pior será a qualidade da imagem.

2.2.3 – Imagens Padrão PNG

O *Portable Network Graphics* é um formato que suporta compressão sem perdas, embora, possa ser também com perdas. Possui um tamanho maior que o formato JPG. Suporta milhões de cores e não apenas as 256 cores convencionais. Possui, como característica, o canal alpha que permite a transparência da imagem, ou seja, a ausência de opacidade. Assim, é possível sobrepor uma imagem sobre a outra.

2.2.4 – Imagens Padrão TIFF

O *Tagged Image File Format* onsiste em um formato muito utilizado em aplicações profissionais, como imagens para finalidades médicas ou industriais. O formato *TIFF* oferece grande quantidade de cores e excelente qualidade de imagem, o que aumenta consideravelmente o tamanho dos seus arquivos, embora seja possível amenizar este aspecto com compressão sem perda de informações. O formato *TIFF* suporta o uso de *camadas*, isto é, pode-se utilizar versões diferenciadas da imagem a ser trabalhada em um único arquivo.

2.2.5 - E-Learning

A aprendizagem que utiliza computadores para aprimorar o estudo e aprendizagem é denominada de *e-learning*. O *e-learning* e a aprendizagem combinada também são amplamente investigados na interpretação de imagens médicas (44% de todos os

artigos). A aprendizagem combinada ou *blended learning* refere-se a uma mesclagem de atividades de aprendizagem *online* com as tradicionais baseadas em palestras (SPANJERS *et al.*, 2015). Os ambientes de *e-learning* e *blended learning* geralmente oferecem aos participantes a oportunidade de trabalhar com casos de pacientes ou fornecer informações de conteúdo de maneira interativa.

O *e-learning*, ou aprendizagem eletrônica, é uma forma popular de promover a aprendizagem ativa: permite que grandes grupos de alunos se envolvam na aprendizagem em um momento e local conveniente para eles, tem o potencial de ser adaptado às necessidades dos alunos e permite projetos instrucionais que não podem ser implementado em outros formatos (COOK *et al*., 2008). Certamente, o *e-learning* é amplamente considerado mais eficaz ou não inferior às formas tradicionais de ensino, tanto na educação médica em geral (COOK *et al.,* 2008), quanto na interpretação de imagens médicas (ZAFAR *et al.,* 2014).

O potencial do e-learning nem sempre se traduz em melhorias significativas nos resultados educacionais. Por esta razão, o *e-learning* precisa ser justificado por sua eficácia e relevância (MOREIRA *et al*., 2015).

MOREIRA ainda afirma que embora alguns autores acreditem que não há evidências de que os alunos aprendam mais com o *e-learning* do que com o aprendizado tradicional, reconhece-se que eles podem aprender de forma mais eficaz. O *e-learning* combinado com o aprendizado tradicional, ou seja, *blended learning*, é considerado a melhor forma de obter maior ganho de conhecimento (MOREIRA *et al.,* 2015).

2.2.6 – *Deep Learning*

A inteligência artificial é uma técnica que simula o aprendizado do cérebro humano. É dividida em aprendizado de máquina ou *machine learning* onde existe uma subárea denominada de aprendizado profundo ou *deep learning*. Esta última técnica utilizada de redes neurais artificiais para realizar tarefas como reconhecimento visual, reconhecimento de fala e processamento de linguagem natural. No caso deste projeto, o foco será utilizar o aprendizado profundo para realizar a leitura de imagens médicas para informar se tal imagem possui ou não uma determinada patologia. Essa informação é feita por um modelo de inteligência artificial treinado para prever se tal imagem possui alta ou baixa porcentagem de chance de ter ou não alguma patologia.

O Aprendizado de Máquina (AM) é subárea da Inteligência Artificial que compreende um corpo de conhecimento de modelos, métodos e técnicas que melhoram o seu desempenho a partir da experiência (Marsland, 2017). Para tanto, utiliza-se de teoria estatística na elaboração destes modelos e métodos, pois a sua principal tarefa consiste na elaboração de inferências a partir de amostras. Além da Estatística, a Ciência da Computação também possui um papel relevante no Aprendizado de Máquina, pois é necessário construir algoritmos eficientes para diversas tarefas, tais como para lidar com um grande volume de dados, para realizar o treinamento, para inferência, etc. (Alpaydin, 2010).

2.3 COMPUTAÇÃO EM NUVEM

O projeto final da plataforma desenvolvida neste trabalho será hospedada na nuvem com a finalidade de usufruir das inovações e facilidades que esta tecnologia oferece. Assim, este tópico faz uma reflexão sobre as características deste novo paradigma na área da tecnologia da informação.

Nos últimos anos, a computação em nuvem emergiu como um modelo de computação dominante em infraestruturas de TI, permitindo acesso flexível, onipresente, *on demand* e econômico a um amplo *pool* de recursos compartilhados (BARROSO *et al*., 2019).

A Computação em Nuvem tem sido responsável por uma das maiores revoluções ocorridas nos últimos anos na área de Tecnologia da Informação. Os impactos dessa transformação têm crescido, na medida em que a nuvem oferece maior diversidade de serviços, com mais segurança, melhores recursos e custos cada vez mais baixos. É uma indústria que definitivamente muda o modo de trabalho na área de TI e que, embora recente, proporciona resultados consolidados, fazendo com que sua adoção seja uma opção segura.

A computação em nuvem é dividida em três grupos de serviços principais:

- **IaaS – *Infraestructure as a Service*:**

A infraestrutura como serviço (IaaS), segundo a *Amazon Web Service* – AWS[9], é um modelo de negócios que fornece infraestrutura de TI, como recursos de computação, armazenamento e rede, com pagamento conforme o uso pela Internet. Você pode usar o IaaS para solicitar e conFigurar os recursos necessários para executar suas aplicações e sistemas de TI. Ou seja, é um serviço que de infraestrutura que funciona como um *data center* virtual. Um fornecedor deste serviço faz locação de suas máquinas, infraestrutura de rede e sistema de banco de dados a um cliente que paga pelo seu tempo de utilização.

- **SaaS - Software as a Service: Software como serviço.**

O Software como serviço (SaaS) segundo a *Amazon Web Service* – AWS[10] é um modelo de negócio e entrega de software que permite que as organizações ofereçam sua solução em uma abordagem centrada no serviço de baixo atrito. Ou seja, da mesma forma que a infraestrutura, o software a ser utilizado na nuvem é oferecido como uma espécie de assinatura. Não é necessário adquirir licenças do software ou se preocupar com atualizações para novas versões. O cliente paga pelo tempo de uso do software. O fornecedor do software obtém sua receita com o número de vendas de assinaturas que cresce com popularização do software na rede. O cliente poderá acessar de qualquer local onde existe o acesso à *Internet*. *Google Docs, Microsoft Office 365* e *Facebook* são exemplos de SaaS.

- **PaaS – Plataform as Service: Plataforma como serviço.**

Segundo a *Amazon Web Service – AWS*[11], com a Plataforma como um serviço, as empresas não precisam mais gerenciar a infraestrutura subjacente (geralmente, hardware e sistemas operacionais), permitindo que o desenvolvedor se concentre na implantação e no gerenciamento das suas aplicações.
Ou seja, este serviço fornece todos os recursos e ambientes para que o usuário possa desenvolver suas aplicações e disponibilizá-las a seus clientes. São oferecidos tipos

[9] https://aws.amazon.com/pt/what-is/iaas/
[10] https://aws.amazon.com/pt/solutions/saas/
[11] https://aws.amazon.com/pt/types-of-cloud-computing/

específicos de serviços como sistemas operacionais, banco de dados, serviços de mensagens, serviços de armazenamento de dados e etc.

2.3.1 Características da Computação em Nuvem

A tecnologia de computação em nuvem permite a integração de várias outras tecnologias distintas de forma clara a quem a utiliza. Assim, numa única tecnologia é possível obter recursos de tecnologias como virtualização de hardware, tecnologias de *Internet* como *Internet* 2.0, serviços web, automação e gerenciamento de manutenção de *Data Centers* e computação distribuída como computação utilitária, computação em grid e em cluster (BUYYA *et al.*, 2011).

A virtualização de hardware é a capacidade de criar um computador virtual no próprio computador pessoal do usuário onde é possível instalar qualquer sistema operacional mesmo que seja diferente do utilizado na máquina do usuário (ODUN-AYO, 2017).

Em termos de conceituação básica, a Virtualização pode ser vista como a utilização de recursos computacionais para imitar outros recursos computacionais ou um computador inteiro.

Além disso, trata-se de uma tecnologia com inúmeras vantagens tanto para usuários como para fornecedores de serviços. Por exemplo, (SINGH, 2018) traz alguns dos principais benefícios como:

- Possibilidade de execução de múltiplos sistemas operacionais em um mesmo hardware físico;
- Melhoria no gerenciamento de energia;
- Melhoraria na utilização de recursos;
- Possibilidade de balanceamento de carga;
- Manutenção;
- Aumento na disponibilidade dos sistemas;
- Isolamento.

O sistema de automação e gerenciamento em nuvem tem a importante função de gerenciar data centers, por meio de softwares, que controlam recursos de processamento, de rede e de armazenamento. Este tipo de sistema traz, com ele,

infraestrutura e aplicativos em múltiplos hipervisores (processo que cria e executa máquinas virtuais) em nuvens, dos tipos privada e pública.

Além disso, oferece o que as ferramentas tradicionais utilizadas em gerenciamentos não suportam. Com maior velocidade e agilidade, a automação em nuvem melhora a eficiência, o controle, a economia de custos e a manutenção da unificação do gerenciamento.

Segundo Jones (2023) os principais provedores de nuvem pública são a *Amazon* com sua plataforma *Amazon Web Services (AWS)*, a *Microsoft* com sua nuvem *Azure* e o Google**,** com a *Google Cloud*, respectivamente os três maiores fornecedores desse mercado.

2.3.2 Outras Características da Computação em Nuvem

2.3.2.1 Custo

O custo de uma infraestrutura na nuvem é na maioria das vezes menor do que o custo de uma infraestrutura convencional, denominada "*on premise*", em que se compra máquinas para uma empresa. Se o sistema não precisa funcionar fora do horário comercial. Basta programar o desligamento das máquinas e deixar de pagar por elas nesse período.

Se o volume de acessos está baixo, pode-se diminuir os recursos computacionais alocados sob demanda de modo a diminuir o custo da infraestrutura provisionada. Esse modelo dinâmico de alocação e liberação de recursos é denominado de elasticidade e de mesmo modo é tarifado na modalidade pagamento pelo uso, uma vez que só se paga pelo que é efetivamente utilizado.

É possível programar serviços de monitoramento na nuvem para que seja emitido um alarme quando a taxa de serviço cobrada por utilização de recursos chegue a um limite pré-estabelecido de um determinado valor. Por exemplo, seja um valor de dez dólares provisionado para taxas de serviço. Quando se atinge 80% deste valor, é enviada uma notificação, em geral via e-mail ou sms, informando que o limite programado está próximo de ser atingido.

2.3.2.2 Agilidade

Provedores de infraestrutura convencionais, podem demorar um longo tempo, para entregar novas máquinas, discos ou qualquer outro recurso para seus clientes adquiridos por necessidade. Isso pode acontecer independentemente de a infraestrutura ser própria, instalada em um data center local, ou terceirizada, sendo executada em um provedor de hospedagem. Na Computação em Nuvem, a alocação, ou seja, o processo de diminuição de recursos existentes ou aumento destes, de novos recursos demora apenas alguns minutos. Basta escolher a máquina desejada, seu sistema operacional e parametrizar alguns dados de conFiguração para que a nova máquina esteja no ar.

2.3.2.3 Flexibilidade

Caso uma máquina esteja ociosa, basta desligar. Caso seja necessária uma máquina de maior processamento, basta aumentar sua capacidade de processamento. Se necessitar de um disco com maior capacidade, basta definir um novo tamanho para este equipamento. Caso seja necessário provisionar um aumento de memória dinâmica, basta definir uma nova capacidade de memória a qualquer instante.

2.3.2.4 Alta Disponibilidade

Para que um ambiente computacional convencional garanta alta disponibilidade é necessário duplicá-lo, criando um ambiente de contingência que é acionado em caso de falha do principal. Essa duplicação de recursos pode implicar em desperdícios, uma vez que o ambiente de contingência fica ocioso a maior parte do tempo em condições normais. Mesmo não estando em operação, a infraestrutura de contingência demandou investimentos e gera despesas de depreciação, ocupando espaço, requerendo segurança e supervisão, ou seja, há geração de custos mesmo sem a infraestrutura estar no ar. Somente quando algo falha é que a infraestrutura adicional passa a ser utilizada.

Na Computação em Nuvem, a garantia de alta disponibilidade é mais acessível. O ambiente de contingência pode ser previamente conFigurado, mas mantido em formato reduzido e de baixo custo. Quando necessário, esse ambiente pode ser aumentado em poucos minutos, assumindo uma conFiguração semelhante ao do ambiente principal. A alta disponibilidade na nuvem tem custos expressivamente

menores que outras soluções, dentro da empresa ou em provedores onde se paga o aluguel de máquinas.

2.3.2.5 Banco de Dados

Entre os serviços em nuvem oferecidos pode-se citar a alocação de recursos computacionais otimizados para o melhor desempenho do banco de dados alocado para qualquer sistema. Realiza-se tarefas fundamentais de gerenciamento como atualização do software, alteração de espaço para o banco de dados e backup automático dos dados.

Através deste serviço é possível utilizar banco de dados relacionais como, por exemplo, MySql, Oracle, Microsof SQL Server ou PostgreSQL, diretamente na arquitetura da nuvem.

2.3.2.6 Integração com Aplicações

A integração de aplicativos é um conjunto de serviços que permitem a comunicação entre componentes desacoplados dentro de micros serviços, sistemas distribuídos e aplicativos sem servidor. O programador não precisa refatorar toda a sua arquitetura para se beneficiar. Dissociar aplicativos em qualquer escala pode reduzir o impacto das alterações, facilitando a atualização e agilizando o lançamento de novos recursos.

A tecnologia de nuvem disponibiliza uma ampla gama de serviços gerenciados de integração de aplicações que transferem as responsabilidades operacionais para a nuvem, a fim de que o programador possa se concentrar no desenvolvimento de seu sistema e na inovação. Com a escalabilidade automática, o profissional não precisa mais provisionar, corrigir e gerenciar servidores.

2.3.2.7 Segurança

Uma das principais preocupações com o método de armazenamento em Nuvem é a questão da segurança, importante para a proteção de ataques, violações e vazamentos quanto aos ataques de hackers e roubo de dados confidenciais. Para essa segurança existem recursos como a redundância do armazenamento de dados, que estão em diferentes localidades, em especial locais seguros de

incêndios, desastres naturais, etc., para melhor gerenciamento de risco e maior segurança, o uso da criptografia, que não é usado apenas na transmissão, mas também no armazenamento dos dados, codifica as informações de maneira que só o receptor e o emissor podem decifra-las mantendo a confidencialidade dos seus dados localizados nos Data Centers responsáveis pelo acesso dessas informações. Para isso é importante que estes ofereçam registros de auditoria onde é possível extrair as informações de quem, quando, o que acessou e de qual equipamento. Os backups em nuvem são feitos de forma automatizada e não necessitam de arquivos ocupando memória física das máquinas dos clientes, a facilidade é justamente pelo fato de serem salvos no servidor e assim se manterem acessíveis e disponíveis sempre, diferentemente se fosse guardado fisicamente. No caso de falhas, as cópias de segurança, são realizadas de acordo com a demanda empresarial, sendo diária, semanal, mensal, anual, ou programada com horário específico, tudo depende do volume de transformação das informações. Apesar dessa ligação, o servidor não é o único responsável pela segurança, é necessário implementar barreiras como antivírus, ferramentas para monitoramento de uso e procedimentos para maior proteção por parte da empresa e instruir seus funcionários/usuários quanto ao cuidado com anexos maliciosos, com senhas de autenticação e *login* em páginas não confiáveis (NOVO, 2021).

2.3.2.8 Problemas sobre Segurança em Nuvem

Nas redes de computadores, a segurança da informação é fundamental para manter as informações íntegras e confidenciais. As redes não podem ser simplesmente classificadas como seguras ou não seguras porque o termo não é absoluto quando o assunto são as ameaças nas redes de computadores (COMER, 2001).

O trabalho realizado por Davis (2014) e replicado por Cobb (2015) apresenta uma pesquisa com 1029 profissionais de segurança e tecnologia do negócio em março de 2013, 536 em abril de 2014 e 435 em abril de 2015 relacionando os maiores desafios desses profissionais com a segurança de redes e informações. Após analisar o trabalho de Cobb e Davis as seguintes indicações representam os maiores desafios de segurança de TI (PEREIRA, 2016):

- Gerenciamento do sistema de segurança das redes;
- Aplicação de políticas de segurança;

- Avaliação de riscos presentes nos sistemas de computação;
- Obtendo do preço adequado para os sistemas;
- Prevenção contra a violação de dados de invasores externos;
- Conscientização do usuário quanto à utilização do sistema;
- Controle de acesso do usuário aos sistemas e dados;
- Regulamentação e padronização dos requisitos do sistema;
- Obtenção de recursos e experiência profissional;
- Impedir o roubo de dados.

Adicionalmente, o trabalho realizado por Cobb (2015), permite constatar que 58% dos especialistas em Tecnologia da informação consideram o uso de dispositivos infectados na rede da corporação como uma situação preocupante, seguido por 49% com a preocupação dos usuários sendo vítimas de *phishing* ou outros *scams* (são fraudes na *Internet* que visa adquirir credenciais de um usuário por engano), e por último com a perda de dispositivos que portam informações sigilosas (PEREIRA, 2016).

2.4 ESCOLHA DA TECNOLOGIA DE COMPUTAÇÃO EM NUVEM

Cada serviço de computação em nuvem contém seu preço pré-determinado. Existem ferramentas como calculadoras fornecidas pelo próprio serviço de nuvem para auxiliar o usuário ou empresa a prever os cálculos dos serviços utilizados.

O foco deste trabalho não é entrar no contexto de comparação de preços entre serviços de computação em nuvem. Existem sites especializados como o Kinsta, empresa norte americana de hospedagem de sites desenvolveu uma pesquisa de comparação de preços entre as duas maiores empresas fornecedoras de serviços de nuvem do mundo, *Amazon* e *Microsoft*, e publicou o resultado no *blog* da empresa[12]. O foco do trabalho foi pesquisar sobre os serviços gratuitos oferecidos por duas dos maiores serviços de computação em nuvem; AWS e Microsoft.

[12] https://kinsta.com/pt/blog/aws-vs-azure/

2.4.1 Planos Gratuitos

O plano gratuito é ideal para analisar os serviços da infraestrutura da nuvem sem que seja necessário assumir um compromisso financeiro. Tanto *AWS* como *Azure* oferecem seus principais serviços de nuvem, oferecendo uma quantidade predefinida de recursos durante um determinado período de tempo estipulado para testar os serviços. Porém, ambos os provedores de nuvens oferecem também serviços "sempre gratuitos" ideais para quem precisa por poucos requisitos de uso da nuvem e não estiver preocupado com a interrupção das operações que serão demonstradas a seguir.

2.4.1.1 AWS Free Tier

Esta modalidade oferece acesso gratuito a 85 diferentes produtos serviços de nuvem através de computação, armazenamento, banco de dados, IoT, I.A. e muitas outras categorias.

O *AWS Free Tier*[13] é dividido em três tipos:

- **12 meses gratuitos:** Disponível gratuitamente durante os primeiros 12 meses a partir de sua inscrição inicial no AWS.
- **Ensaios:** Grátis por um curto prazo após a ativação de um determinado serviço.

Ao explorar o *AWS Free Tier* pela primeira vez, é recomendado inspecionar as opções de cálculo e armazenamento da *AWS* incluídas gratuitamente por 12 meses após a inscrição. Estes são os serviços que formarão a base de sua implantação da nuvem:

Cálculo: Acesso ao *EC2* da *Amazon* por 750 horas por mês com uma VM micro instância t2. ou t3.

- **Armazenagem**: Armazenamento padrão *Amazon S3* de 5 GB por mês com 20.000 operações de leitura e 2.000 operações de escrita.

De acordo com a Amazon (AMAZON, 2023), este serviço, por ser gratuito, possui várias restrições. Portanto, recomendável verificar o serviço[14] de "Perguntas Frequentes sobre o nível gratuito da AWS" para saber mais sobre informações chave

[13] https://aws.amazon.com/pt/free/
[14] https://aws.amazon.com/pt/free/free-tier-faqs/

de como se transferir de serviço gratuito para pago, restrições regionais e outras características relevantes.

2.4.1.2 Conta Azure Free

Segundo a *Microsoft* (MICROSOFT, 2023), a criação de uma conta *Azure* Gratuita[15] permitirá o acesso gratuito a 54 produtos e serviços *Azure* na nuvem através de computação, armazenamento, banco de dados, segurança, IA e outras categorias. A conta gratuita *Azure* oferece dois tipos de acesso:

- **12 meses gratuitos**: Acesso a 25 produtos em nuvem por apenas 12 meses

Além de seu acesso gratuito, o cliente receberá 200 dólares de crédito para gastar durante os primeiros 30 dias após a inscrição.
Se testar a plataforma de nuvem *Azure* pela primeira vez, sugere-se testar os serviços de computação e armazenamento do *Azure*, que são gratuitos durante os primeiros 12 meses:

- **Cálculo**: Acesso *Azure* por 750 horas por mês com uma instância de nível padrão B1S com um sistema operacional Linux ou Windows.
- **Armazenagem**: *Azure Blob* de 5 GB por mês com 20.000 leituras 10.000 operações de escrita.

Como na AWS, é importante certificar-se de explorar o serviço de “Perguntas Frequentes sobre o nível gratuito da *Microsoft Azure*” (https://azure.microsoft.com/en-us/free/free-account-faq/), pois existem várias restrições e considerações das quais é necessário estar ciente.
O plano *AWS Free Tier* gratuito por 12 meses foi o escolhido para hospedar este projeto.

2.5 ARQUITETURA DA NUVEM

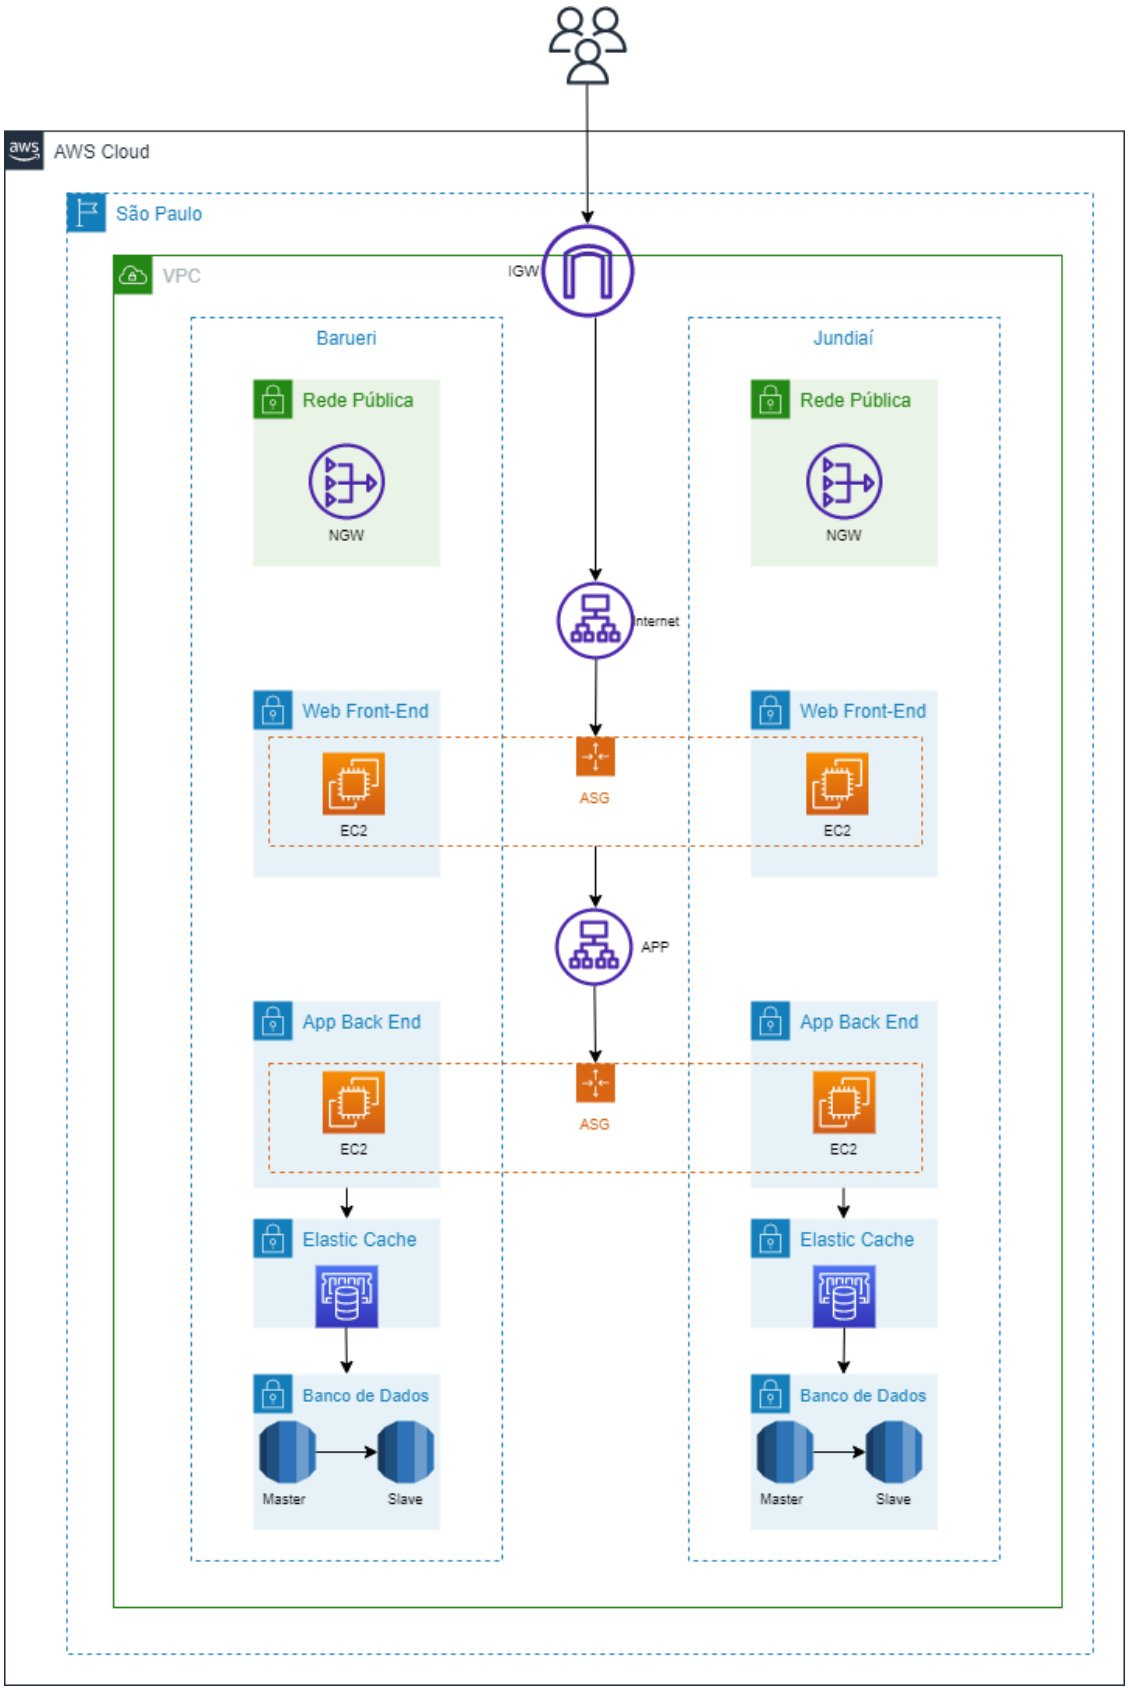
[15] https://azure.microsoft.com/en-us/free/

Esta arquitetura foi elaborada seguindo as melhores práticas do *AWS Well-Architected Framework*, cujo objetivo é baseado em seis pilares:

1. Excelência operacional
2. Segurança
3. Confiabilidade
4. Eficiência de performance
5. Otimização de custos
6. Sustentabilidade

A Figura 18 exibe esta arquitetura:

Figura 18 - Arquitetura da Nuvem



A *AWS* possui um framework denominado *Well Architeted Framework* que é um *design pattern* de arquiteturas desenvolvidos por arquitetos de soluções da própria

empresa que indicam as características mínimas que a arquitetura deverá ter para a hospedagem de uma aplicação na nuvem e isto é válido para qualquer provedor de nuvem que possa utilizar. Este framework indica a presença de componentes demonstrados:

1 - Inicialmente, tem-se a camada de acesso à nuvem através de usuários que acessam o provedor de nuvem, no caso deste exemplo, a AWS.

2 - A aplicação a ser acessada estará hospedada na região de São Paulo no Brasil. Esta região possui três zonas de disponibilidade ou *Data Centers* instalados nas cidades de Guarulhos, Jundiaí e Campinas. Na Figura 18, foram utilizadas duas zonas de disponibilidade, ou seja, Guarulhos e Jundiaí. Foram escolhidas duas zonas de disponibilidade porque em caso de falha de uma a outra entra imediatamente em operação.

3 - O usuário acessa a *VPC* ou *Virtual Private Cloud* que é a rede e todos os recursos fornecidos pelo provedor de nuvem. A *VPC* abrange todas as zonas de disponibilidade da região de São Paulo.

4 – O *IGW* ou *Internet Gateway* é o componente que permite a comunicação entre os usuários e recursos privados de rede da *VPC* via *Internet*.

5 – A Rede Pública fornece o endereço IP para troca de informações com o *Internet Gateway*.

6 – Do *Internet* Gateway, o fluxo de dados chega ao *Application Load Balancer* ou balanceador de cargas cuja função é distribuir o tráfego entre duas instâncias de virtualização *EC2* ou *Elastic Cloud Compute*.

7 - O *EC2* são computadores virtuais com processadores, sistemas Operacionais e todos os recursos de hardware. Estas instâncias, instaladas em rede privadas, hospedam a camada da aplicação de *Front End*.

8 – Entre as duas instâncias de *EC2*, existe um componente ASG ou *Auto Scalling* que monitora a escalabilidade do número de acessos da aplicação que ajusta automaticamente a capacidade de desempenho para mais ou para menos mantendo o tráfego constante e previsível pelo menor custo possível.

9 – Um segundo *Load Balancer* otimiza o tráfego entre as instâncias de *Back End* da aplicação.

10 – Foram conFigurados dois servidores de *Back End EC2* onde fica a camada da aplicação que faz o acesso ao banco de dados e um componente *Auto Scalling* para monitorar a escalabilidade e alta disponibilidade da aplicação.

11 – O *ElasticCache* é um servidor de cache instalado para armazenamento de dados utilizados com mais frequência para otimizar e efetuar a recuperação de dados com maior agilidade.
12 – Por fim, foram conFiguradas duas instâncias de banco de dados, um denominado de *master* e outra de *slave* que trabalham de forma síncrona. Se a instância principal *master* apresentar alguma falha, a *slave* entra em operação. O *backup* de dados é realizado de maneira automática.

2.6 REDES NEURAIS ARTIFICIAIS

Um dos módulos do sistema será desenvolvido para realizar triagem de imagens médicas no auxílio do estudante de medicina para apontar possíveis patologias em imagens que podem ser observados na diferença entre padrões de pixels de imagens normais e anormais. A diferença destes padrões mostram nas imagens onde existem patologias ou não. Dessa maneira o estudante, com repetição e treinamento, poderá aprender a discernir patologias e adquirir conhecimentos em sua formação. Assim, é relevante o estudo de tecnologias como redes neurais que serão utilizadas para desenvolver este projeto.
De acordo com Mendes (MENDES, 2021), uma rede neural é um mecanismo de aprendizado de máquina poderoso que simula basicamente o aprendizado do cérebro humano. O cérebro recebe o estímulo do mundo exterior, faz o processamento e gera o resultado.
Mendes (MENDES, 2021), afirma que é necessário o estudo das redes neurais artificiais para compreender o *Deep Learning* ou *Deep Neural Netwoks* que significa “Redes Neurais Profundas”, entre elas, está a *CNN – Convolutional Neural Network* ou Rede Neural Convolucional, utilizada para desenvolvimento de modelos de inteligência artificial no estudo de imagens.
Rede Neural Convolucional é uma classe de métodos de aprendizado profundo que se tornou dominante em várias tarefas de visão computacional e está atraindo interesse em uma variedade de domínios, incluindo a radiologia. É composta de vários blocos de construção, como camadas de convolução, camadas de pool e camadas totalmente conectadas, e é projetada para aprender hierarquias espaciais de recursos

de forma automática e adaptativa por meio de um algoritmo de retropropagação (YAMASHITA, 2018).

Segundo Mendes (MENDES, 2021), elas são usadas, por exemplo, para classificar imagens, ou seja, identificar o reconhecimento de rostos, indivíduos, placas de rua, tumores, animais, objetos do mundo real e outros aspectos de dados visuais. Podem agrupar imagens por similaridade como pesquisar por fotografias e realizar o reconhecimento de objetos em cenas fotográficas.

No uso da medicina as CNN's podem ser treinadas para identificar padrões e texturas de imagens como raios X, tomografias, ressonâncias, etc, para auxiliar profissionais qualificados como médicos e radiologistas a identificarem patologias com maior rapidez.

Estes profissionais não podem ser substituídos por um modelo de inteligência artificial porque não existem modelos com grau de eficiência de 100%. O desenvolvimento de um modelo depende não somente de algoritmos, mas, de interferência de profissional qualificado para realizar inferências de dados e modificar parâmetros e hiper-parâmetros nos algoritmos de inteligência artificial a fim de conseguir uma taxa de acurácia o mais eficiente possível, principalmente, quando o assunto é medicina onde se trata de vidas humanas.

As CNN's possuem a habilidade de aprender a partir de dados submetidos a ela com ou sem supervisão.

Os modelos supervisionados são aqueles que recebem entrada e saída de dados, armazenados em arquivo chamado de *dataset* ou planilha. Dados de entrada são aqueles que coletam valores históricos de um determinado evento já acontecido e os dados de saída são valores históricos resultados da conclusão ou totalização a respeito dos dados de entrada. Por exemplo, uma planilha de dados com valores da glicemia de pacientes num determinado período de tempo possui como resultado a glicemia glicada resultante destes valores. Os modelos supervisionados estabelecem a classificação do paciente, ou seja, ou ele é diabético ou não. Os dados históricos são a base do aprendizado de uma rede neural porque é através destes dados que ela será treinada para reconhecer tais valores. Ela irá gerar novos dados de saída decorrentes do seu treinamento para comparar estes novos dados aos dados de saída originais fornecidos pela planilha e calculará o erro existente da diferença entre os valores que ela gerou com os valores de totalização da planilha. A partir deste cálculo, seus pesos sinápticos serão ajustados em função do cálculo deste erro. Este processo

irá se repetir várias vezes durante o treinamento da rede neural até o momento em que se chegue a um resultado satisfatório com erro mínimo. Assim, é possível desenvolver um modelo para prever se um paciente poderá desenvolver ou não diabetes.

Os modelos não supervisionados não há classificação de dados como ocorre no modelo supervisionado. Os dados de entrada são apresentados ao algoritmo de inteligência artificial e este os classifica de acordo com as similaridades encontradas entre estes dados; não há dados de saída. Por exemplo, se fossem apresentadas radiografias de raios X de pulmões sem identificá-los, o algoritmo iria tentar classifica-los de acordo com seu tamanho, textura, padrões de cores, formato, estruturas anatômicas, ou seja, iria detectar características em comum entre conjunto de dados, neste caso, radiografias de pulmão. Caso fosse apresentado a ele o raios X de um outro órgão qualquer, ele não reconheceria tal radiografia.

As redes neurais artificiais são uma tentativa de simular o processamento do cérebro humano. Assim, foi necessário utilizar a matemática para desenvolver um neurônio artificial.

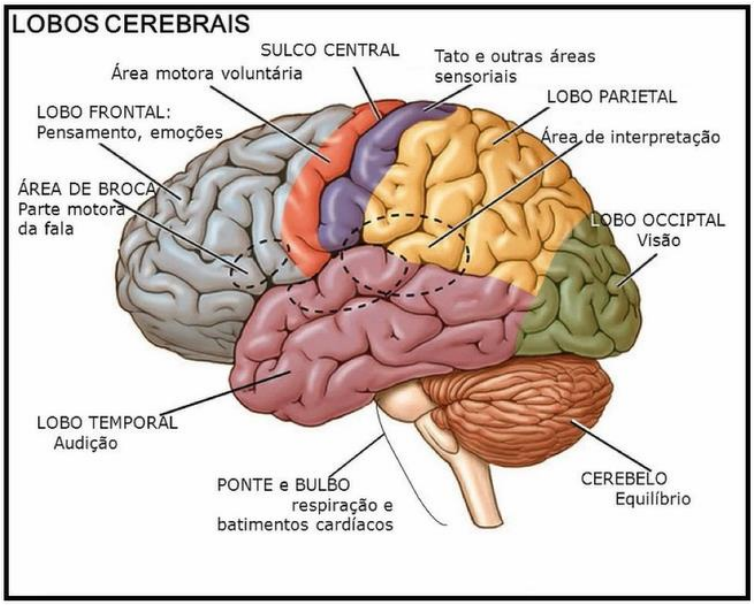
Antes de detalhar tais técnicas é relevante apresentar conceitos fundamentais para tais estudos.

2.6.1 O Cérebro Humano

O cérebro humano é o órgão mais perfeito e complexo conhecido em toda existência humana. É capaz de processar grande quantidade de informações em tempo mínimo. Nele o comportamento inteligente é uma propriedade que emerge de um grande número de unidades simples; os neurônios. Eles ligam e desligam em milissegundos enquanto o *hardware* atual, como um computador, pode realizar a mesma tarefa em nano segundos. Porém, o cérebro realiza tarefas cognitivas complexas como memória, visão e reconhecimento de voz em décimos de segundos. As unidades principais do cérebro são os neurônios e é por meio deles que as informações são transmitidas e processadas. Os neurônios ou células nervosas, existem em números de cerca de 100 bilhões. O cérebro, conforme ilustração da Figura 19, possui a capacidade de reconhecer um rosto familiar dentro de uma multidão em apenas

milésimos de segundo e alguns dos enigmas de seu funcionamento ainda não foram respondidos permanecendo ocultos até os dias atuais.

Figura 19 - Cérebro Humano



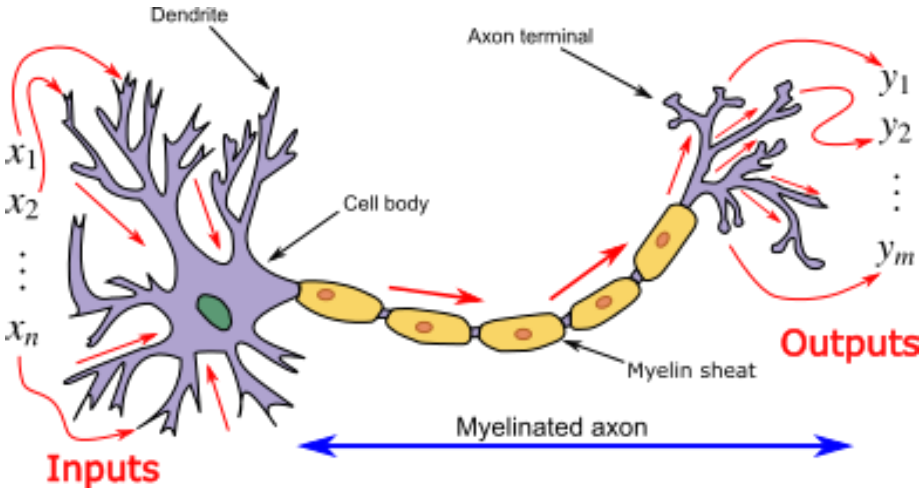
Autor: Gurgel, M. B. c2008

O neurônio é a unidade básica do cérebro. Uma célula especializada na transmissão de informações, pois nelas estão introduzidas propriedades de excitabilidade e condução de mensagens nervosas. Um neurônio consiste de um corpo celular, soma, onde ocorre o processo de decisão, do qual emana uma fibra maior; o axônio que é uma ramificação mais extensa, e um número de fibras em forma de ramificações, os dendritos.

Em termos gerais as entradas de dados são realizadas nos dendritos e o corpo celular, o qual combina e integra os sinais de entrada e emite um sinal de saída que ocorre nas extremidades dos axônios onde estão os nervos terminais, pelos quais é realizada a transmissão das informações para outros neurônios. Essa transmissão é conhecida como sinapse.

A informação transmitida pelos neurônios são impulsos elétricos que é a mensagem que os neurônios transmitem uns aos outros, ou seja, é a propagação de um estímulo percorrido ao longo dos neurônios que pode ser qualquer sinal captado pelos receptores nervosos. O estímulo resulta na capacidade dos neurônios se excitarem através da ação de um estímulo. A Figura 20 exibe um esquema de um neurônio.

Figura 20 - Esquema simplificado de um Neurônio

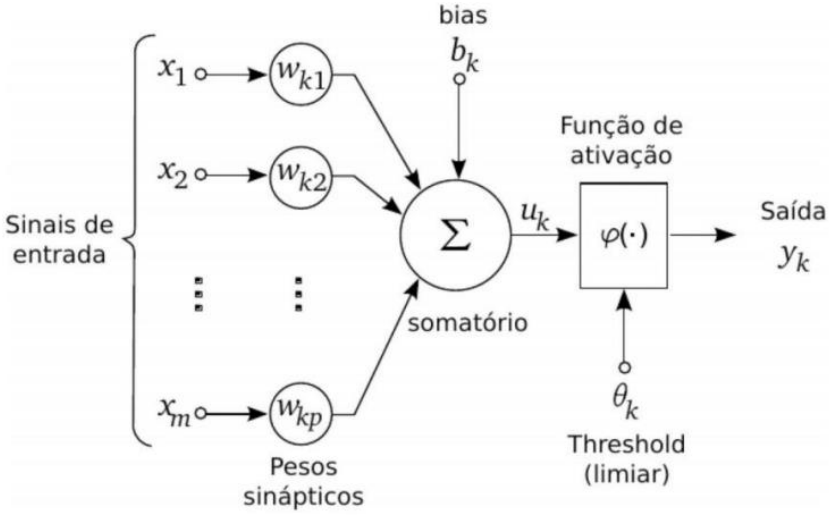


Fonte: OPENSTAX. Neurônios e Células Gliais, c2022

2.6.2 O Neurônio Matemático

Em 1943, os pesquisadores Walter Pitts e Warren McCulloch, propuseram um modelo de neurônio matemático o qual simulava o funcionamento do neurônio biológico que implementa de forma simplificada seus componentes e o mecanismo de funcionamento de um neurônio biológico.

Figura 21 - Representação Simplificada Neurônio Matemático



Fonte: BARCELOS (2018), *apud HAYKIN 2001*

Neste modelo de neurônio matemático, os impulsos elétricos provenientes de outros neurônios são representados pelos chamados sinais de entrada (a letra **x** na Figura 21, que nada mais são do que os dados que alimentam seu modelo de rede neural artificial). Entre os vários estímulos recebidos, alguns excitarão mais e outros menos. A medida do estímulo de excitação do neurônio é representada através dos pesos sinápticos. Quanto maior o valor do peso, mais excitatório é o estímulo. Os pesos sinápticos são representados por **wkn** na Figura anterior, onde **k** representa o índice do neurônio em questão e **n** se refere ao terminal de entrada da sinapse ao qual o peso sináptico se refere (MENDES, D. *et al.,* 2021).

A soma ou corpo da célula é representada por uma composição de dois módulos; o primeiro é uma junção aditiva, somatório dos estímulos (sinais de entrada) multiplicado pelo seu fator excitatório (pesos sinápticos), e posteriormente uma função de ativação, que definirá com base nas entradas e pesos sinápticos, qual será a saída do neurônio. O axônio é aqui representado pela saída (**yk**) obtida pela aplicação da função de ativação. Assim como no modelo biológico, o estímulo pode ser excitatório ou inibitório, representado pelo peso sináptico positivo ou negativo respectivamente (MENDES, D. *et al.,* 2021).

O neurônio matemático recebe um ou mais sinais de entrada e retorna um único sinal de saída, que pode ser distribuído como sinal de saída da rede, ou como sinal de entrada para um ou vários outros neurônios da camada posterior (que formam a rede neural artificial). Os dendritos e axônios são representados matematicamente apenas pelas sinapses, e a intensidade da ligação é representada por uma grandeza denominada peso sináptico, simbolizada pela letra **w**. Quando as entradas x são apresentadas ao neurônio, elas são multiplicadas pelos pesos sinápticos correspondentes, gerando as entradas ponderadas, ou seja, x1 que multiplica w1, x2 que multiplica w2, etc. Isso descreve uma das bases matemáticas do funcionamento de uma rede neural artificial, a multiplicação de matrizes, conforme ilustra a Figura 22:

Figura 22 - Multiplicação de Matrizes entre Sinais de Entrada (x) e Pesos Sinápticos (w) (Versão Simplificada)

$$\boldsymbol{X}\boldsymbol{w} = \boldsymbol{y}$$

$$\begin{bmatrix} 1 & x_{11} & \dots & x_{1d} \\ 1 & x_{21} & \dots & x_{2d} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & \dots & x_{nd} \end{bmatrix} \times \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_d \end{bmatrix} = \begin{bmatrix} y_0 \\ y_1 \\ \vdots \\ y_n \end{bmatrix}$$

Fonte: DeepLearning Book. O Neurônio Biológico e Matemático, c2022.

O neurônio, assim, totaliza todos os produtos gerando um único resultado. A esta função se denomina função de combinação. Este valor é então apresentado a uma função de ativação ou função de transferência, que tem, entre outras, a finalidade de evitar o acréscimo progressivo dos valores de saída ao longo das camadas da rede, visto que tais funções possuem valores máximos e mínimos contidos em intervalos determinados.

Um neurônio é disparado no momento em que a soma dos impulsos que ele recebe ultrapassa o seu limiar de excitação chamado de *threshold*. O corpo do neurônio, por sua vez, é emulado por um mecanismo que faz a soma dos valores ***xi*** e ***wi*** recebidos pelo neurônio (soma ponderada) e decide se o neurônio deve ou não disparar (saída igual a 1 se o resultado é positivo ou 0 se negativo) comparando a soma obtida ao limiar ou *threshold* do neurônio. A ativação do neurônio é obtida através da aplicação da função de ativação, que ativa a saída (se for 1) ou não (se for 0).

O modelo do neurônio matemático também pode incluir uma polarização ou *bias* de entrada. Esta variável é incluída ao somatório da função de ativação, com o intuito de aumentar o grau de liberdade desta função e, consequentemente, a capacidade de aproximação da rede. O valor do *bias* é ajustado da mesma forma que os pesos sinápticos. O *bias* possibilita que um neurônio apresente saída não nula ainda que todas as suas entradas sejam nulas. Por exemplo, caso não houvesse o *bias* e todas as entradas de um neurônio fossem nulas, então o valor da função de ativação seria nulo (MENDES, D. 2021).

2.6.3 Redes Neurais Convolucionais

O cérebro humano dificilmente aprende um “novo conceito” no primeiro contato que tem com este “novo conceito”. É necessário que o cérebro seja exposto várias vezes a este novo conceito para que aconteça o aprendizado. Assim, a repetição leva ao aprendizado. O treinamento de qualquer rede neural segue este mesmo preceito. O algoritmo de rede neural é exposto a um conjunto de dados e submetido a um treinamento que se repete em vários ciclos utilizando estes dados até que algum aprendizado aconteça. Ou seja, é uma reprodução do aprendizado do cérebro humano.

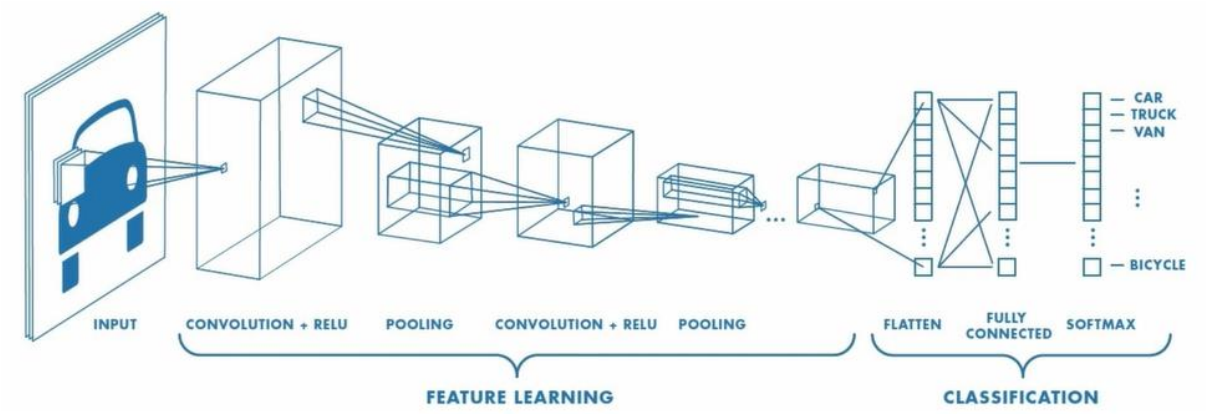
Redes Neurais Convolucionais é o mesmo que redes neurais profundas usadas principalmente para classificar imagens, agrupar imagens por similaridade, e realizar o reconhecimento de objetos em cenas.

Em 2012 numa competição denominada *ImageNet Large Scale Visual Recognition Challenge* – ILSVRC, promovida pelo site ImageNet (https://www.image-net.org) o pesquisador ucraniano Alex Krizhevsky (2012) apresentou uma arquitetura de rede neural convolucional profunda para classificar 1,3 milhões de imagens em 1000 classes diferentes. Possuía 60 milhões de parâmetros e 500.000 neurônios. A partir deste evento pesquisadores em todo mundo despertaram seus estudos impulsionando avanços em áreas como visão computacional, acarretando aplicações como carros autônomos, robótica, *drones*, segurança, diagnósticos médicos e tratamentos para deficientes visuais.

As redes neurais convolucionais não se limitam ao reconhecimento de imagens e podem ser utilizadas, também, em reconhecimento de caracteres ópticos (OCR) para digitalização de textos e possibilitar o processamento de linguagem natural em documentos analógicos e manuscritos onde as imagens são símbolos a serem transcritos. Podem ser aplicados em reconhecimento de sons quando representado visualmente como espectrograma e a representar graficamente dados com redes neurais de grafos.

A arquitetura de uma CNN é um modelo matemático composto por três tipos de camadas: convolução, *pooling* (agrupamento) e camada totalmente conectada. Enquanto as camadas de convolução e *pooling* extraem recursos das imagens, a camada totalmente conectada realiza o mapeamento dos recursos extraídos e realiza a classificação dos dados que saíram do processamento da rede.

Figura 23 - Esquema de Funcionamento de Uma Rede Neural



Fonte: Medium. Understanding of Convolutional Neural Network (CNN) — Deep Learning. c2020

O fluxo de dados na Figura 23 acontece sempre da esquerda para direita. Quando chegam ao final da rede neural no lado direito, os dados são recalculados e enviados novamente ao início no lado esquerdo se transformando num ciclo e reiniciando o processo novamente até o momento que ocorra o aprendizado onde será interrompido.

O primeiro passo é a entrada de dados onde a imagem é submetida ao algoritmo. Em seguida, é resgatada uma região da imagem para análise através de neurônios artificiais. Esta análise acontece na convolução que é uma operação matemática de multiplicação de matrizes. É acionado o mecanismo da função de ativação, no exemplo da Figura 23, a função *Relu* que torna os valores no formato linear para evitar problemas como o *overfitting*.

O *overfitting* é um problema que deve ser evitado e existem técnicas que podem ser utilizadas para preveni-lo. Ele pode ocorrer em decorrência do modelo aprender apenas determinados padrões e detalhes de um grupo de imagens tornando-o "viciado". Caso um novo conjunto de imagens que não foi treinado seja submetido ao modelo, corre-se o risco de ter sua acurácia prejudicada.

Em seguida, é realizada a operação de *pooling* que resgata os valores relevantes dos pixels da imagem e redimensiona o tamanho da matriz de pixels para um tamanho menor sem perder a qualidade do que foi aprendido nas etapas anteriores. Estas operações são repetidas em vários ciclos nas muitas camadas internas da rede neural chamada de camadas ocultas. É nesta fase que ocorre o aprendizado de recursos da imagem.

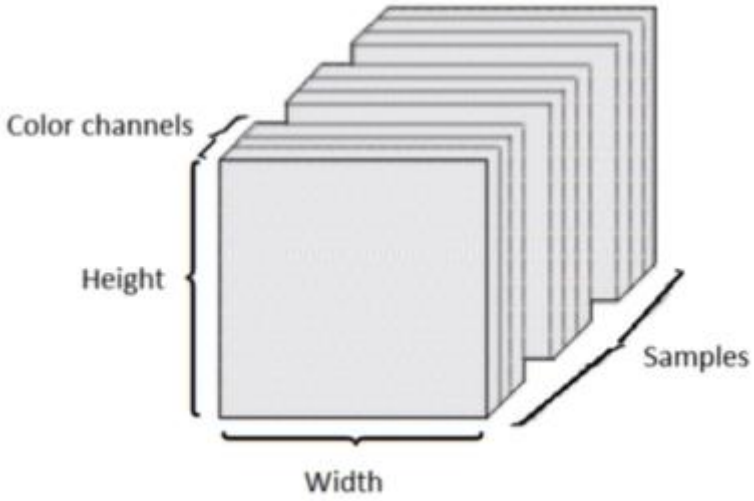
O resultado deste aprendizado é apresentado à fase de classificação, no lado direito da Figura 23, onde os pixels da imagem detectada deverão ser comparados aos pixels da imagem original. Se não forem iguais é porque ocorreram erros. Estes deverão ser calculados através de uma subtração dos valores dos pixels originais pelos valores dos pixels detectados ao final das operações realizadas na rede neural. Em caso de erro, é calculada a derivada do gradiente cuja função será estabelecer uma matriz de novos valores de pesos. Esta matriz deverá ser submetida ao algoritmo *backpropagation* que retornará ao início da primeira fase da rede neural à esquerda da Figura 23 para que os cálculos sejam efetuados novamente reiniciando o ciclo. Isso acontece em sucessivas idas e vindas até que se obtenha uma classificação da imagem com porcentagem relevante onde se indica o reconhecimento na Figura.23, será detalhada cada etapa de funcionamento da rede neural.

2.6.3.1 Tensores

Para desenvolver um modelo de inteligência artificial são necessários conjuntos de dados históricos que irão alimentar este modelo. Estes dados são armazenados em banco de dados, planilhas, data-frames ou até mesmo em arquivos do tipo texto.
Quando se trabalha com imagens, os conjuntos de dados a serem submetidos a um modelo de rede neural são os pixels das imagens.
O tensor é uma estrutura de dados matemática utilizado para armazenar dados. As redes neurais convolucionais carregam e processam imagens como tensores. Estes tensores são matrizes matemáticas que podem variar de um a quatro dimensões. O tensor bidimensional é classificado como uma matriz que possui dois eixos, um na horizontal, a largura e outro na vertical, a altura, onde se armazenam valores numéricos. Uma imagem monocromática é uma matriz bidimensional que possui apenas um único canal de cor, mas, uma rede neural não pode receber para treinamento apenas uma única imagem porque não é suficiente para se obter o aprendizado. Então, quando se submete ao modelo de rede neural muitas imagens, o tensor passa se comportar com três dimensões, ou seja, a largura, a altura e quantidade de imagens. Assim, se comporta visualmente como uma Figura geométrica de um cubo. O tensor de quatro dimensões ocorre quando se submete uma grande quantidade de imagens coloridas ao modelo de rede neural, ou seja, além

das dimensões já citadas têm-se três canais de cores separados que ao se fundirem compõe as cores da imagem. Os canais de cores formam a quarta dimensão do tensor que podem ter um canal se for uma imagem em preto e branco ou três canais se forem imagens coloridas, ou seja, RGB (*Red, Green, Blue*). As imagens são, fisicamente, bidimensionais que serão representadas ao modelo de rede neural como estruturas quadridimensionais. A Figura 24 ilustra a estrutura de quatro dimensões das imagens.

Figura 24 - Estrutura de Quatro Dimensões



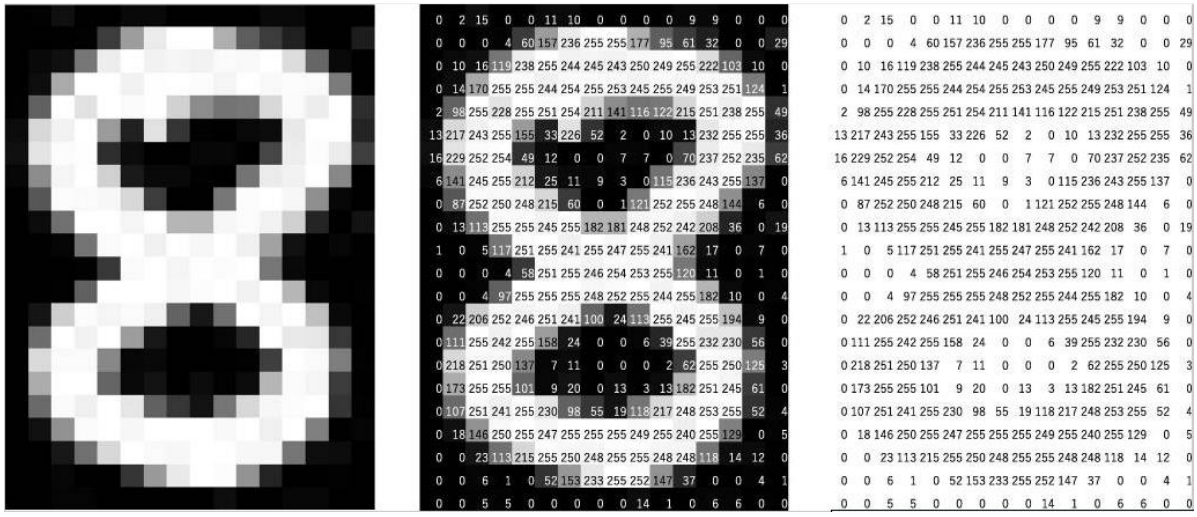
Fonte: Manning. c2024

A estrutura aninhada exibe a largura (*width*) da imagem, a altura (*height*), o número de canais de cores (*color channels*) e a quantidade de amostras (*sample*) de imagens.

2.6.3.2 A Convolução

A convolução é uma operação matemática responsável pela leitura e o aprendizado dos detalhes de uma imagem. É a operação matemática que detecta um detalhe da imagem. Cada imagem a ser processada é carregada na memória do computador onde será submetida ao algoritmo da CNN. O algoritmo interpreta uma imagem digital no formato bidimensional (largura e altura), ou seja, realizando a leitura de cada pixel como valores numéricos de uma matriz de números conforme ilustração da Figura 25:

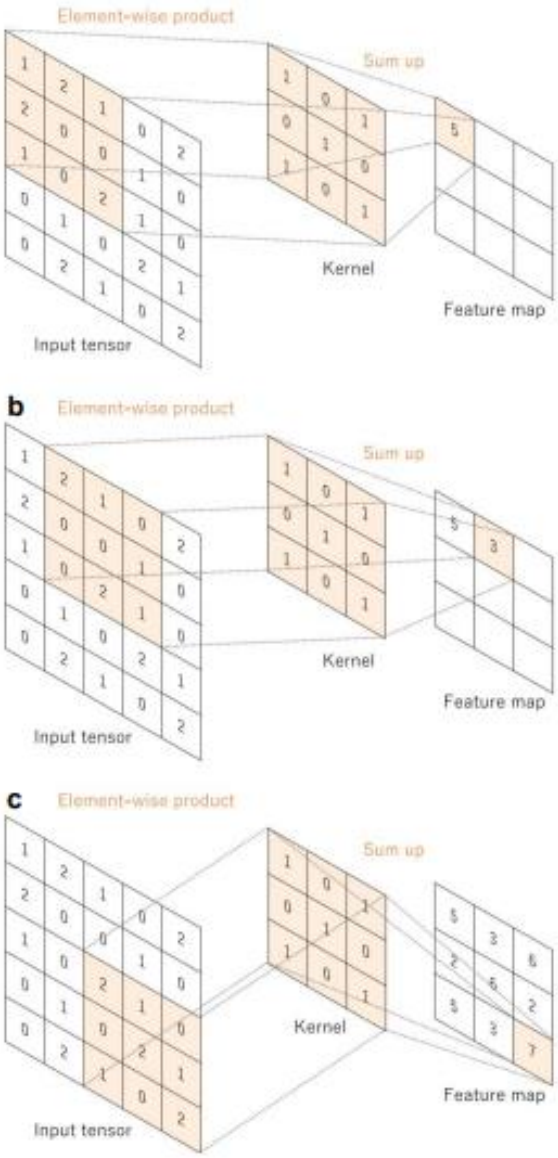
Figura 25 - Leitura dos Pixels da Imagem de um Número



Fonte: YAMASHITA, 2018.

O algoritmo cria, também, uma pequena matriz de parâmetros ou pesos denominada *kernel* ou filtro. Os parâmetros deste *kernel* são números fornecidos aleatoriamente uma única vez pelo algoritmo no início do seu funcionamento e ficam armazenados nesta matriz cujas dimensões de linhas e colunas poderão ser 7x7, 5x5 ou 3x3. Este *kernel* é aplicado a cada região da imagem, chamada de tensor, iniciando assim o processo de convolução. Para obter o valor final, cada valor em cada célula da matriz do tensor na imagem original é multiplicado por sua respectiva posição na matriz do *kernel*. Em seguida às multiplicações, soma-se todos os valores para se obter um único valor de saída a ser armazenado em outra matriz denominada mapa de atributos (*Feature map*). A Figura 26 ilustra o funcionamento deste mecanismo.

Figura 26 - Convolução



Fonte: YAMASHITA, 2018.

Ao final são obtidos todos os valores que são armazenados na matriz mapa de atributos. Os valores deste mapa é o aprendizado obtido neste tensor ou região ou da imagem.

2.6.3.3 A Função de Ativação

Na etapa seguinte, o mapa de atributos é submetido a uma função de ativação e a uma função de agrupamento (*pooling*), antes de passá-lo a uma nova convolução

numa próxima camada de neurônios da rede para que outros recursos da imagem sejam detectados.

A função de ativação é utilizada para manter a linearidade da rede neural porque garante um treinamento estável ao modelo de inteligência artificial que será criado. É um resultado preciso, pois, facilita as operações matemáticas e reduz o tempo total de processamento computacional. Numa matriz de mapa de atributos a função de ativação converte valores negativos em 0 (zero) e valores positivos em 1 (um). Existem várias funções de ativação que podem ser utilizadas neste processo como *Sigmoid*, *Relu*, *Tanh*, *Leaky*, etc.

A função *Relu* ou Unidade Linear Retificada é uma das mais utilizadas. Ela evita que valores negativos sejam registrados nos mapas de atributos e sigam para uma próxima etapa de uma nova convolução. Estes mecanismos evitam problemas em etapas seguintes como o cálculo do gradiente da derivada utilizado para calcular novos valores para a matriz de pesos, o *kernel*.

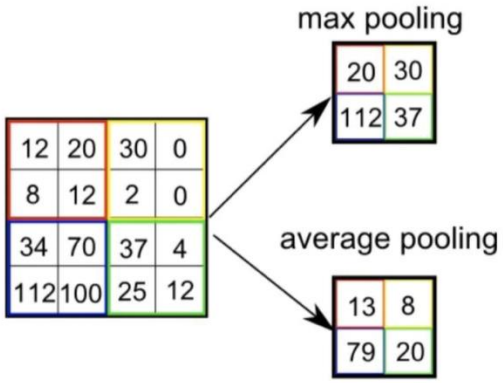
2.6.3.4 O Pooling

O *pooling* é uma técnica que reduz a dimensionalidade do mapa de atributos sem perder qualidade de algo que foi aprendido pela rede neural. O mapa de atributos é uma matriz de grandes dimensões que dispende de custo computacional para executá-lo. Um determinado ponto da imagem que está em análise pode conter áreas irrelevantes onde não existem pixels relevantes para o aprendizado da rede. O *pooling* é uma técnica que retira pontos sem relevância da matriz do mapa de atributos mantendo aquilo que foi aprendido.

Existem duas técnicas de *pooling*; ou seja, o *max pooling* e o *average pooling*. O *max pooling* é a técnica mais utilizada porque resgata valores maiores porque representam maior importância daquela região da imagem. O modelo não aprende o que é uma imagem e sim os valores numéricos de seus pixels através de operações matemáticas de matrizes.

A Figura 27 ilustra o exemplo de um *kernel* de 2x2 passando por um mapa de atributos 4x4 e mostra como as duas técnicas trabalham. O *max pooling* resgata o maior valor em cada quadrante da matriz e o *average pooling* a média dos valores. O *pooling* reduz as dimensões da matriz de atributos como pode ser observado.

Figura 27 - Pooling



Fonte: Data Science Academy. Deep Learning Book. Camadas de Pooling em Redes Neurais Convolucionais. c2022.

A função de ativação e o *pooling*, são técnicas matemáticas que visam reduzir a dimensão da matriz de mapa de atributos sem perder a qualidade das informações contidas nela. Ao converter os valores da convolução numa matriz de zeros e uns pela função de ativação, o *max pooling* resgata os maiores valores.

2.6.3.5 A Camada Totalmente Conectada e a Função Softmax

Nesta etapa será realizada a classificação da imagem. Ela é denominada de Camada “Totalmente conectada” porque seus neurônios estão conectados a todos os neurônios das camadas anteriores a ela e posteriores.

Nela, a camada “totalmente conectada”, também chamada de “camada densa”, recebe os resultados dos aprendizados em forma de pesos (valores). Estes resultados chegam em uma matriz bidimensional para ser convertido num vetor, ou matriz unidimensional, através de uma operação chamada “*flatten*” ou achatamento, onde se encontram os detalhes da imagem que foram reconhecidos. Nesta camada, os neurônios têm uma conexão completa com todas as ativações das camadas anteriores. Em seus neurônios matemáticos ocorrem operações de multiplicação de matrizes que serão efetuadas para que, em seguida, tenham seus resultados submetidos a uma função de ativação denominada *softmax*. Esta função resgata o resultados vindos da camada Totalmente Conectada e os converte em probabilidades. Assim, o algoritmo informará a porcentagem da imagem ser um objeto ou outro.

2.5.3.6 Treinamento do Modelo e Backpropagation

A rede neural dificilmente aprende algo quando é percorrida apenas uma única vez. São necessários vários percursos ou ciclos pela rede neural cujo fluxo vai do seu início ao fim e retorna ao início novamente. Estes percursos são, também, chamados de passadas ou épocas cuja repetição aconteça como consequência do aprendizado. Ao final do percurso da rede neural é feita a classificação da imagem.

No início do aprendizado poucos detalhes são aprendidos e o modelo de rede neural não tem conhecimento para realizar nenhuma classificação. Assim, são comparados os resultados do aprendizado com os valores dos pixels da imagem original. Se o aprendizado ainda não se completou, significa que a rede neural deve ser submetida a novo treinamento. Antes disso, será calculado o erro ocorrido em virtude da comparação dos valores aprendidos e os valores originais da imagem através de uma função denominada função de erro ou *loss function*.

O aprendizado é adquirido a partir dos erros cometidos. Assim, é aplicada a derivada do gradiente para calcular a taxa a ser aplicada para corrigir o erro da rede neural. Essa taxa é calculada a partir da função de erro. Portanto, torna-se possível direcionar a mudança dos pesos ou valores do *kernel*. Assim, será determinado o aumento ou diminuição dos valores iniciais contidos no *kernel* onde se estabelece a convolução da rede. Novos valores são estabelecidos para o *kernel* e o algoritmo de retropropagação (*backpropagation*) é acionado para que a rede neural retorne ao seu início para iniciar um novo percurso de aprendizagem com novos cálculos através dos valores do *kernel* atualizados. Essa operação de percurso será realizada várias vezes para que a taxa de erro seja minimizada. Quanto menor o erro calculado maior será o aprendizado da rede neural.

Função de cálculo do erro (Equação 1):

$$E_{\text{total}} = \sum \frac{1}{2}(target - output)^2 \qquad (1)$$

Onde:

- *target* é o valor original dos pixels da imagem entregues no início do treinamento da rede neural.
- *output* é o valor de saída dos pixels obtidos ao final do percurso percorrido do início ao fim da rede neural.

O valor da subtração é submetido à potência de 2 para se evitar valores negativos. Cálculo da mudança de peso ou taxa de aprendizado (Equação 2):

$$\omega = \omega_i - \eta\frac{dl}{dw} \qquad (2)$$

Onde:

ω = *weight* (peso)

ω_i = initial weight (peso inicial)

η = taxa de aprendizado

A taxa de aprendizado (*learning rate*) é um parâmetro escolhido pelo profissional em ciência de dados. Normalmente essa taxa varia de 0,1 a 0,001, que pode ser positivo ou negativo, dependendo do gradiente. Uma alta taxa de aprendizado significa que são tomadas medidas maiores nas atualizações de peso e, portanto, pode levar menos tempo para o modelo convergir para um conjunto ideal de pesos. No entanto, uma taxa de aprendizado muito alta pode resultar em saltos muito grandes e pouco precisos para atingir o ponto ideal. Uma baixa taxa de aprendizado refina as atualizações de pesos e tendem a otimizar o modelo com maior precisão. Em contrapartida, o custo computacional será maior e o treinamento da rede mais lento.

O processo de percorrer o fluxo da rede neural, o cálculo do erro, o processo para retroagir o fluxo ao início do percurso e atualização de parâmetros (pesos) é uma iteração de treinamento. O programa repetirá esse processo para um número fixo de iterações para cada conjunto de imagens de treinamento, geralmente chamado de lote, neste caso, um lote possui 10 imagens. Depois de concluir a atualização do parâmetro no último exemplo de treinamento, espera-se que a rede seja treinada o suficiente para que os pesos das camadas sejam ajustados corretamente.

2.6.3.7 – Métricas de Avaliação de Modelos

As métricas são técnicas utilizadas para avaliar a eficiência de um modelo de inteligência artificial em realizar previsões de probabilidades a respeito do estudo ao qual foi submetido. Normalmente utiliza-se um conjunto de métricas de avaliação para ajudar a concluir sobre o grau de eficiência do modelo. Neste projeto serão utilizadas as métricas de acurácia, matriz confusão, *precision*, *recall*, *f-score* e curva ROC.

2.6.3.7.1 – Acurácia

A acurácia ou exatidão (Equação 3) é uma métrica utilizada para avaliar modelos de classificação. O modelo de classificação é booleano, ou seja, disponibiliza um único resultado; verdadeiro ou falso. A acurácia calcula a frequência de acerto em previsões referente ao total de dados de uma amostra, ou seja, é a proporção de casos que foram corretamente previstos, sejam eles verdadeiro positivo ou verdadeiro negativo.

$$acurácia = \frac{TP+TN}{TP+FP+TN+FN} \qquad (3)$$

$$acurácia = \frac{Total\ de\ Acertos}{Total\ da\ Amostra}$$

2.6.3.7.2 – Matriz de Confusão

É uma Tabela que mostra as frequências de classificação para cada classe do modelo de inteligência artificial. Indica os erros e os acertos de um modelo de I.A.

- Verdadeiro positivo (*True Positive* — TP): ocorre quando no conjunto de dados, a classe que está sendo analisada foi prevista corretamente. Por exemplo, quando um paciente está doente e o modelo previu corretamente que ele está doente.
- Falso positivo (*False Positive* — FP): ocorre quando no conjunto de dados, a classe que está sendo analisada foi prevista incorretamente. Exemplo: o paciente não está doente, mas o modelo prevê que ele está doente.
- Falso verdadeiro (*True Negative* — TN): ocorre quando no conjunto de dados, a classe que está sendo analisada foi prevista corretamente. Exemplo: o paciente não estava doente, e o modelo previu corretamente que ele não está doente.
- Falso negativo (False Negative — FN): ocorre quando no conjunto de dados a classe que está sendo analisada foi prevista incorretamente. Por exemplo, quando o paciente está doente e o modelo previu incorretamente que ele não está doente.

2.6.3.7.3 – Precisão (Precision)

A precisão (Equação 4) mede a porcentagem de predições positivas que foram encontradas corretamente, ou seja, é definida pela razão entre a quantidade de exemplos classificados corretamente como positivos (TP) e o total (TP + FP) de exemplos classificados como positivos:

$$precision = \frac{TP}{TP+FP} \quad (4)$$

2.6.3.7.4 – Revocação (Recall)

Também conhecido como sensibilidade (*sensitivity*) (Equação 5) é a porcentagem de valores positivos classificados corretamente, ou seja, sensibilidade é a capacidade de o teste detectar corretamente resultados positivos.

$$recall = \frac{TP}{TP+FN} \quad (5)$$

2.6.3.7.5 – Especificidade

É a capacidade do modelo em detectar resultados negativos, ou seja, prevê as observações negativas como verdadeiro negativo e falso positivo *(Equação 6)*, ou seja, é a capacidade de o teste detectar corretamente resultados negativos.

$$especificidade = \frac{VN}{VN+FP} \quad (6)$$

2.6.3.7.6 – F1-score

É a média harmônica entre *recall* e *precision* (Equação 7).

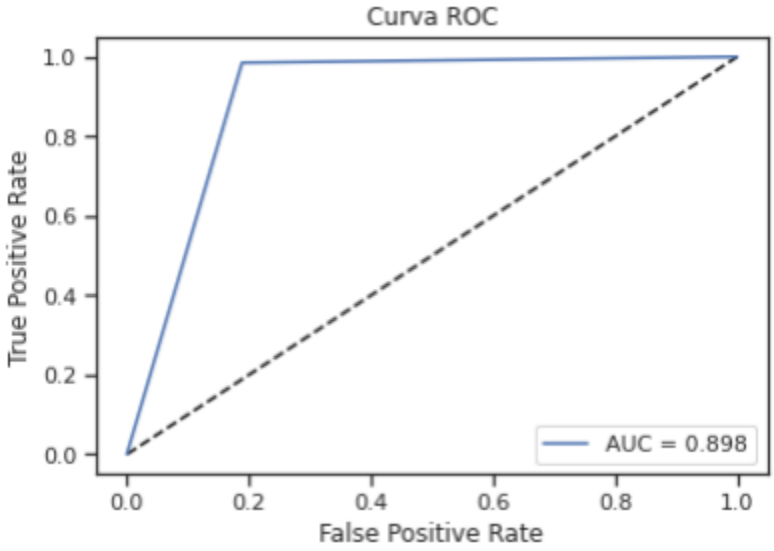
$$f1 = 2 * \frac{precision*recall}{precision+recall} \quad (7)$$

2.6.3.7.7 – Curva ROC - Receiver Operating Characteristics

A curva *ROC* mostra o desempenho do classificador, exibindo a taxa de verdadeiros positivos (recall) à medida que a taxa de falsos positivos modifica.

No eixo X (horizontal), temos a taxa de falsos positivos (o oposto da especificidade). No eixo Y (vertical), temos a taxa de verdadeiros positivos (a sensibilidade). Quanto maiores os valores de sensibilidade e de especificidade (mais

próximos de 100%), maior a acurácia do teste. A curva ROC ilustra como varia a sensibilidade e a especificidade do teste. Ela ajuda a definir o valor de corte ideal, para as finalidades do exame.



2.6.3.7.8 – AUC - Area Under the Curve

A *Area Under the Curve* é um número de 0 a 1 que mostra como está a performance do modelo ao utilizar como base para o cálculo a Taxa de Falso Positivo e a Taxa de Verdadeiro Positivo. O número *AUC*, quanto mais próximo de 1, melhor.

2.7 CONSIDERAÇÕES SOBRE EXAMES DO CREMESP

O exame que o CREMESP – Conselho Regional de Medicina de São Paulo aplicava aos egressos dos cursos de medicina no estado de São Paulo foi uma das inspirações para fundamentar a criação deste projeto. A ideia seria alimentar a base de dados deste sistema com questões formuladas para este exame desenvolvidas a cargo da Fundação Carlos Chagas. Por questões de direitos autorais não foi possível a cessão destas provas para alimentar a base de dados do sistema. A seguir será apresentado um resumo do relatório destes exames aplicados entre os anos de 2005 a 2017.

Segundo LUNA (LUNA *et al.,* 2018) a partir dos anos 2000, o Brasil viu surgir uma grande expansão do ensino médico no país e pouco estruturada. No ano de 2018 o país contava com 317 cursos, sendo que 218 novos cursos foram abertos nos últimos 20 anos. Assim o Brasil tornou-se o segundo maior país em número de escolas de medicina no mundo, perdendo apenas para a Índia que possui 399 cursos para uma

população aproximada de 1,2 bilhão de habitantes, mas, superior a países como Estados Unidos e China.

O aumento do número de cursos elevou substancialmente o número de profissionais de medicina, mas, este crescimento não foi acompanhado pela ampliação dos hospitais-escolas para a prática do aprendizado adquirido fundamental para a formação do estudante de medicina. Acrescenta-se a este problema a carência de vagas nas residências médicas cruciais para a formação profissional.

O estado de São Paulo concentra um quinto da população do Brasil também possui um quinto das escolas de medicina do país. São aproximadamente 140 mil médicos em atividade o que representa próximo de um terço dos 450 mil médicos atuantes no território nacional. Este panorama é consequência da capacidade do estado em atrair profissionais de medicina formados em outros estados para participar de programas de residência em instituições de credibilidade ou para atuar na sua rede de saúde.

A deterioração do ensino em instituições com estruturas e condições inadequadas, sem infraestrutura diagnóstica e terapêutica, de profissionais com baixa remuneração docente e a consequente não reprovação de estudantes em disciplinas do curso considerados insuficientes acarretou na inserção de profissionais despreparados, sem habilidades, e sem experiência para o bom exercício da profissão.

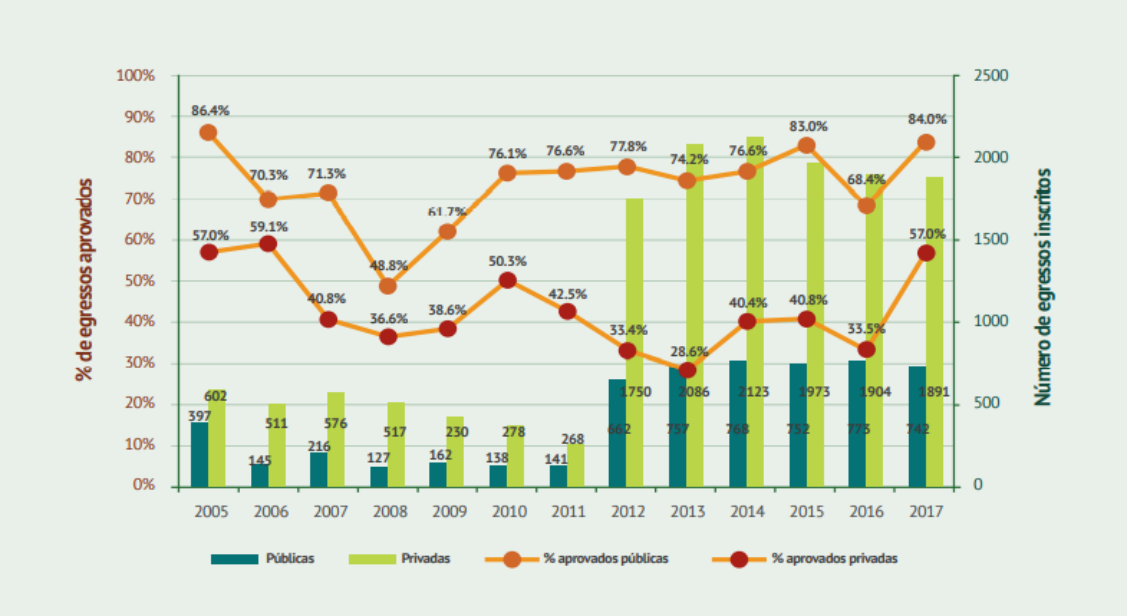
Assim, no ano de 2005 o Conselho Regional de Medicina do Estado de São Paulo – CREMESP, criou um exame facultativo a ser aplicado anualmente aos egressos em Medicina das instituições do estado com o objetivo de aferir a qualidade da formação destes novos profissionais, preservando o sigilo de participantes e instituições. No entanto, a reprovação do exame não impedia o profissional de exercer suas atividades como médico.

O exame, aplicado entre o período de 2005 a 2017, retratou resultados alarmantes resultando na constatação do desconhecimento básico nas situações do dia a dia do atendimento médico.

Nas 13 edições do Exame do CREMESP, realizadas de 2005 a 2017, participaram 20.978 candidatos e 50,1% deles foram aprovados. Ou seja, somente 10.680 acertaram 60,0% ou mais das 120 questões da prova. O Exame considera o mínimo de 72 acertos para que o candidato esteja em condições de bem exercer a profissão. Trata-se do conhecimento essencial esperado para um graduado em Medicina.

Quando se comparam os candidatos de todas as edições do Exame pela natureza administrativa de suas escolas médicas, vê-se que 76,8% dos que fizeram cursos públicos foram aprovados contra 40,6% daqueles formados em faculdades privadas.
A partir de 2012 o exame tornou-se obrigatório ao egresso. No período de 2005 a 2011, estudantes de escolas renomadas como USP e UNIFESP se recusaram a prestar o exame e outras instituições renomadas tiveram participações muito pequenas. Apesar da obrigatoriedade do exame, a reprovação não impedia ao egresso de realizar suas atividades médicas. O Gráfico 1 mostra a evolução do número de participantes dos egressos das escolas de medicina públicas e privadas, o percentual de aprovação e o número de inscritos no certame:

Gráfico 1 - Número de Candidatos e médias de acertos de 2005 a 2017 por Tipo de Administração de Escolas Médicas



Fonte: LUNA; CASSENOTE, 2018, p. 47

Ao se comparar candidatos de todas as edições do Exame pela natureza administrativa de suas escolas médicas, vê-se que 76,8% dos que fizeram cursos públicos foram aprovados contra 40,6% daqueles formados em faculdades privadas.
A partir de 2012, quando o exame se tornou obrigatório, o número de participantes por ano subiu de uma média de 650 para cerca de 2.900. Na primeira fase do exame (até 2011) o percentual de aprovação foi de 55.9% e, nesses seis últimos anos, o número de aprovados caiu para 49,5%, em média. Dos 16.590 formandos, que

prestaram exame nesse período, 8.220 foram considerados aprovados e 8.370, insuficientes.

Surpreende a queda significativa nos dois grupos, quando se compara 2016 com o ano anterior: entre os candidatos de escolas públicas foram aprovados 68%, em 2016, contra 83% no ano anterior. Entre aqueles de cursos privados, passaram 33,5% em 2016, contra 40,8% no ano anterior. Os resultados dos últimos seis anos chamam a atenção, especialmente, para o fraco desempenho das escolas médicas privadas.

Nesse período, apenas um terço dos formandos nesses cursos se mostrou apto a exercer a profissão (38,9% de aprovados).

As 120 questões de múltipla escolha que compõem o Exame do CREMESP são divididas em nove áreas, que formam a base do conhecimento da Medicina. Cada uma das áreas recebe determinado número de questões, refletindo suas cargas horárias e suas prioridades no currículo e na prática médica. Desta forma, nos exames dos últimos anos, três disciplinas tiveram 22 questões cada uma: Clínica Médica, Clínica Cirúrgica e Pediatria, somando 66 do total de 120. Para as áreas de Ginecologia e Obstetrícia foram feitas 11 perguntas cada uma das especialidades. Para Ciências Básicas foram 14; Saúde Pública/ Epidemiologia, nove; Saúde Mental, cinco; e na área de Bioética/Ética foram apresentadas quatro questões.

Nos 13 anos de exame do CREMESP onde foram avaliados um total de 20.978 egressos de escolas paulistas, o rendimento observado em pelo menos 4 áreas (Ciências Básicas, Pediatria, Saúde Pública e Epidemiologia e Clínica Médica) foi baixo, de acordo com as médias e desvios padrões obtidos conforme ilustrados na Tabela 3:

Tabela 3 - Média e Desvio Padrão do Exame do CREMESP de 2005 a 2018

Área	Média	Desvio Padrão
Bioética	64,3	(25,9)
Saúde Mental	63,6	(20,7)
Obtetrícia	61,6	(18,4)
Ginecologia	61,6	(20,7)
Clínica Cirúrgica	60,0	(14,8)
Ciências Básicas	59,4	(19,0)
Pediatria	58,1	(16,9)
Saúde Pública e Epidemiologia	55,9	(22,1)
Clínica Médica	55,1	(18,0)

Fonte: LUNA; CASSENOTE, 2018, p. 52

No exame de 2017, a área de Saúde Mental teve a maior porcentagem de questões respondidas corretamente: 72,3% das perguntas receberam respostas certas superando o mínimo. Em segundo lugar, Ginecologia e Obstetrícia bem como Pediatria com 67,0%, 64,1% e 67,7% de acertos; Clínica Médica e Clínica Cirúrgica com 63,1% e 59,4%; Bioética, 58,1%. Na área de Saúde Pública-Epidemiologia e Ciências Básicas, a média de acertos ficou em 63,0% e 52.2%.

No Exame do CREMESP de 2018, muitos dos recém-formados demonstraram não saber interpretar exames para diagnosticar e administrar a conduta terapêutica adequada em casos médicos básicos e problemas de saúde frequentes, alguns exemplos de questões com altos índices de erro, conforme o Quadro 2:

Quadro 2 - Média e Desvio Padrão do Exame do CREMESP de 2005 a 2018

Relatório do Exame do CREMESP 2018	
Quantidade (%)	**Questões com Alto Índice de Erros**
86	Erraram a abordagem inicial para atendimento a paciente vítima de acidente de trânsito;
69	Não souberam as diretrizes para aferição da pressão arterial;
68	Não acertaram a conduta para paciente com infarto no miocárdio;
65	Erraram o Quadro laboratorial do diabetes mellitus descompensado;
59	Não informaram corretamente o período de transmissão da gripe;
44	Não souberam identificar o agente causador e um dos principais transmissores da Doença de Chagas;

Fonte: LUNA; CASSENOTE, 2018

Em países como, por exemplo, Alemanha, Arábia Saudita, Austrália, Canadá, Índia, Indonésia, Nepal, aplicam exames obrigatórios para o início da prática médica. Nos Estados Unidos, a licença para o exercício da Medicina somente é alcançada após o graduado se submeter a distintas etapas de avaliação de conhecimentos conceitual, clínico e de princípios aplicadas junto a um programa federal. Enquanto no Brasil ainda se luta pela exigência de um exame de conhecimento, na Inglaterra os médicos já em atividade passam por avaliações anuais para continuarem a exercer a profissão.

No capítulo 3 Materiais e Métodos, serão abordados temas como o estudo dos recursos e módulos oferecidos pelo sistema, softwares e etapas utilizadas no seu desenvolvimento e os testes de avaliação ao qual o projeto será submetido.

3 MATERIAIS E MÉTODOS

Este capítulo descreve a estrutura que compõe o sistema e seus recursos. Detalha-se cada funcionalidade contida no sistema, tecnologias utilizadas na sua concepção, descrição de requisitos funcionais e não funcionais, protótipos de interfaces e testes de avaliação para aferição do sistema.

3.1 ANÁLISE DE RECURSOS DA PLATAFORMA

Com fundamento nas literaturas revisadas até o momento, foi elaborado um sistema computacional via web para corresponder a um procedimento de interação com o usuário remoto a fim de fornecer ao estudante e seu tutor elementos para estabelecer a relação de ensino / aprendizagem na área de imagens médicas.
A metodologia de desenvolvimento implementada nesta pesquisa foi segmentada em etapas seguindo os seguintes critérios:

a) Revisão bibliográfica de semelhantes trabalhos produzidos e o mecanismo de desdobramento de aptidões e perícias no esclarecimento e interpretação e de imagens médicas;
b) Análise de tecnologias para determinar qual melhor se adequa ao desenvolvimento do projeto;
c) Exposição de uma estrutura de questionários, estudos de casos e artigos científicos a serem incluídos na plataforma para eventuais estudos;
d) Desenvolvimento, implementação e testes do sistema;
e) Disponibilização do sistema aos usuários para avaliação em sala de aula para realização de possíveis ajustes para aperfeiçoamento do sistema;

O Quadro 3 apresenta o comparativo entre aos recursos propostos para o Sistema e os recursos existentes em sistemas que mais se assemelham ao proposto. Neste Quadro o símbolo ✓ significa a presença de uma funcionalidade enquanto **x** significa a ausência.

Quadro 3 - Recursos do Sistema

Recursos do Sistema patologIA	**Radiopaedia**	**Dr. Tis**	**Epacs**
Visualizador de Imagens	✓	✓	✓
Criação de Questionários	✓	x	x
Interação com Questionários	✓	✓	x
Pontuação de Questionários	✓	x	x
Mudança de Nível do questionário quanto ao grau de dificuldade com aproveitamento mínimo determinado	✓	x	x
Demarcação em Imagens	x	x	x
Estudo de Casos Propostos	✓	x	x
Relatório de Notas por estudante	x	x	x
Predição de Patologias em Imagens	✓	✓	✓
Vídeos para estudos	x	x	x
Fórum	x	x	x
Integração com Nuvem	✓	✓	✓
Gratuita	✓	x	✓ *

* Parcialmente gratuita
✓ Significa a presença de uma funcionalidade enquanto **X** significa a ausência.

As plataformas pesquisadas existentes no mercado e semelhantes à plataforma proposta, apesar de excelentes, não possuem módulos de interatividade com estudantes porque não foram desenvolvidas para essa finalidade. A plataforma proposta foi desenvolvida com o objetivo de auxiliar o estudante no seu aprendizado de intepretação de imagens, afinal, a alta porcentagem de egressos que não sabem interpretar imagens médicas segundo o exame do CREMESP é preocupante.

3.2 ESTRUTURA DA PLATAFORMA

O sistema necessita ser intuitivo e de fácil assimilação por professor e estudantes numa sala de aula para atingir seu objetivo principal; o aprendizado na interpretação de imagens médicas. Uma de suas principais características é prover a responsividade da interface para que se ajuste à tela de qualquer dispositivo a ser utilizado como computadores desktop, notebooks, tablets ou aparelhos celulares.
As técnicas de aprendizagem desenvolvidas no sistema para o auxílio do ensino-aprendizagem foram as seguintes:

Questionários

O questionário é uma técnica com alta eficiência no processo de ensino aprendizagem e seu uso corriqueiro em sala de aula contribui com o aprendizado dos alunos e desenvolvimento de suas habilidades na matéria ministrada (DUNLOSKY *et al*., 2013).

Estudo de Casos

O estudo de caso é definido como uma estratégia de investigação, abordando as suas características e problemáticas, visando facilitar sua utilização por parte dos investigadores que queiram construir conhecimento e inovar no âmbito da educação (MEIRINHOS *et al*., 2016).

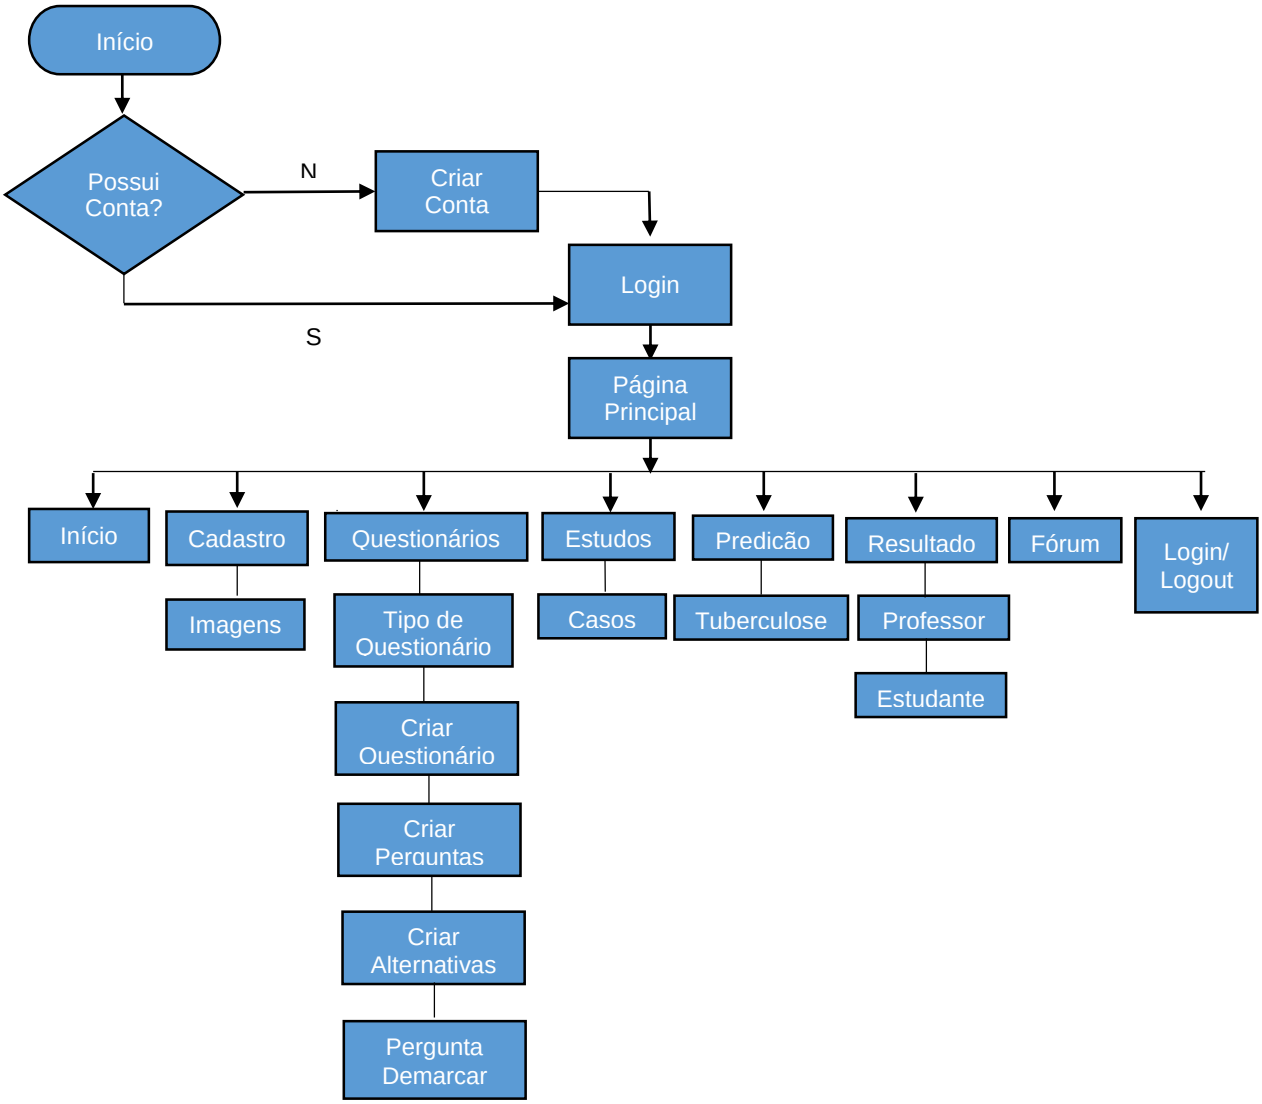
Fórum

O fórum no Ambiente Virtual de Aprendizagem (AVA) é um instrumento de mediação na Educação a Distância e tem o objetivo de atender às demandas contemporâneas dessa modalidade de ensino, promovendo autonomia e protagonismo dos estudantes. Segundo Junqueira *apud* Zwicker (2018), o fórum é um recurso de comunicação tipicamente assíncrona que deve estabelecer laços afetivos entre os participantes, promovendo um alinhamento na construção coletiva do conhecimento, um espaço onde se permite discussões reflexivas do conteúdo curricular (ZWICKER *et al.*, 2021).

Predição

A inteligência artificial é uma disciplina que inclui um amplo espectro de funcionalidades, entre as quais se destaca a análise de imagens digitais. Particularmente esta área, teve um desenvolvimento exponencial na última década fomentada pelos avanços da aprendizagem profunda. Inovações que tiveram impacto direto na imagem, onde um dos principais substratos é a análise de imagens para fins de diagnóstico. Os principais objetivos da inteligência artificial vão desde o auxílio ao radiologista, otimização de imagens, reconhecimento de estruturas, segmentação de lesões, até a transcrição de laudos. Todos eles compartilham um amplo potencial de impacto na especialidade e, portanto, na medicina, onde o papel da radiologia é cada vez mais preponderante (AGUIRRE *et al.*, 2021). A Figura 28 ilustra a disposição dos recursos e o fluxo de dados do sistema:40

Figura 28 - Fluxo da Estrutura do Sistema



3.3 SOFTWARES UTILIZADOS NO DESENVOLVIMENTO DO PROJETO

O desenvolvimento de uma plataforma *web* acarreta no uso de vários softwares especializados em cada área proposta pela engenharia de software. Neste projeto foram utilizadas as seguintes tecnologias:

Draw.io

Este software livre de código aberto é um editor Gráfico disponível *online* ou para download que permite desenvolver Gráficos, fluxogramas, diagramas de atividades, caso de usos, diagrama de classes, diagrama de modelagem de entidades e relacionamentos para banco de dados, diagrama de bloco e vários outros.

Balsamiq

Esta é uma ferramenta comercial que possibilita a prototipação de interfaces do sistema e disponível para testes e uso pelo período de 14 dias.

Mobirise

Este é um software gratuito para *web design*. Disponibiliza recursos para criação de páginas HTML5 integrado à biblioteca bootstrap e fornece recursos como responsividade para que a interface se adapte a qualquer dispositivo computacional.

HTML

Linguagem de marcação de hipertexto *open source* que utiliza a marcação para identificar textos, imagens, vídeos, áudios e outros elementos presentes numa interface para sistema web. O hipertexto são "*links*" ou vínculos que interligam páginas entre si dentro de um único *site* ou entre *sites*. O site é o local onde o sistema está hospedado.

CSS

Esta é uma linguagem de estilo open source ou Folha de Estilo em Cascata utilizada para formatar e apresentar um documento escrito em HTML. O CSS conFigura os elementos da interface para que sejam apresentados na tela de um *site*.

Javascript

O ***Javascript*** é uma linguagem de programação *open source* que atua em conjunto com o ***HTML***. Tem como função adicionar comportamento interativo nas páginas de um site e permite a interação de um usuário com as funcionalidades disponibilizadas nas páginas de um site. Assim, é definida como "*front-end*" porque trabalha diretamente com o navegador presente no dispositivo do usuário que executa as funcionalidades desenvolvidas nesta linguagem.

Canvas

O ***Canvas*** é um elemento do **HTML5** destinado a criar um espaço onde é possível desenhar elementos específicos como linhas, formas geométricas e imagens através de scripts, normalmente utilizado em conjunto com o ***Javascript***.

Django

O ***Django*** é um framework para desenvolvimento de aplicações web de código aberto escrito em *python*, gratuito, multiplataforma e de alto nível. Fornece recursos para

autenticação de usuários, rotas, *object relational mapper* (ORM) e *migrations*. O ORM é uma tecnologia que faz o mapeamento de objetos com atributos das Tabelas de banco de dados para gerar comandos SQL para manipular dados em um banco de dados. A tecnologia de *migrations* faz a leitura das classes destes objetos para gerar as linhas e colunas das Tabelas do banco de dados automaticamente. É seguro, escalável, versátil e portável.

MySql

O MySql é um gerenciador de banco de dados *open source* gerenciado pela licença *GPL – General Public License*, ou seja, é um software aberto, mas, não gratuito. Isto quer dizer que se um software for produzido sob a licença GPL o MySql não requer licença paga. Se o software for comercializado, a licença deverá ser adquirida. É um software consistente, confiável, performático e de fácil utilização.

Visual Studio Code

É um editor de código multiplataforma gratuito e *open source* desenvolvido pela *Microsoft*, compatível com mais de 30 linguagens de programação. É uma ferramenta leve com grande quantidade de recursos que auxiliam no processo de desenvolvimento ágil de software.

PyCharm

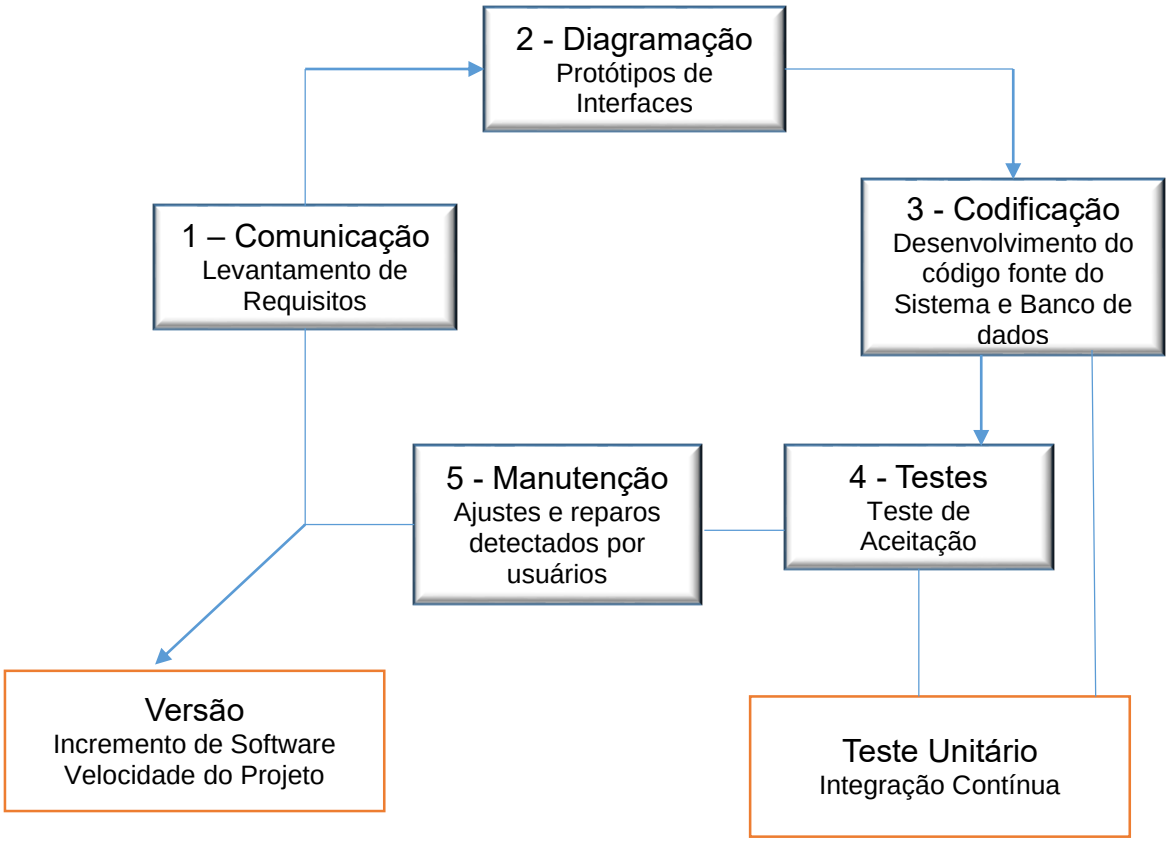
O *Pycharm* é uma IDE que possui funções internas do *python* para que o programador possa ter maior produtividade de desenvolvimento de código *python*. É ideal para construir projetos em *Django* porque cria automaticamente a infraestrutura de pastas e arquivos necessários para desenvolver projetos neste *framework*. Está disponível para vários sistemas operacionais como *Windows*, *MacOs* e *Linux*. Possui uma versão gratuita denominada “*Community Edtion*” e, também, as versões pagas.

3.4 DESENVOLVIMENTO DO SISTEMA

Visto que o sistema proposto foi desenvolvido por um desenvolvedor e seguindo os fundamentos da engenharia de *software* (PRESSMAN, 2006). Este modelo se inicia com a especificação dos requisitos que especificam as atividades efetuadas para chegar ao objetivo do software. Tais requisitos prolongam-se ao

planejamento, modelagem, desenvolvimento e implantação, finalizando na manutenção progressiva do software para atingir sua maturação. Assim, o sistema foi desenvolvido nas seguintes fases conforme ilustra a Figura 29.

Figura 29 - Fases de Desenvolvimento do Sistema



3.4.1 Etapa 1 - Fases da Estrutura para Desenvolvimento de Sistemas

Levantamento de requisitos

Requisitos são as funcionalidades que o sistema deverá ter. Sommerville (2003) propõe um processo genérico de levantamento e análise que contém as seguintes atividades:

- **Compreensão do domínio:** Os analistas devem desenvolver sua compreensão do domínio da aplicação;

- **Coleta de requisitos:** É o processo de interagir com as partes interessadas do sistema para descobrir seus requisitos. A compreensão do domínio se desenvolve mais durante essa atividade;
- **Classificação:** Essa atividade considera o conjunto não estruturado dos requisitos e os organiza em grupos coerentes;
- **Resolução de conflitos:** Quando múltiplos partes interessadas estão envolvidos, os requisitos apresentarão conflitos. Essa atividade tem por objetivo solucionar esses conflitos;
- **Definição das prioridades:** Em qualquer conjunto de requisitos, alguns serão mais importantes do que outros. Esse estágio envolve interação com os partes interessadas para a definição dos requisitos mais importantes;
- **Verificação de requisitos:** Os requisitos são verificados para descobrir se estão completos e consistentes e se estão em concordância com o que as partes interessadas desejam do sistema.

Projeto do sistema

Segundo Pressman (PRESSMAN, 2006), a prototipagem auxilia o engenheiro de software e o cliente a entenderem melhor o que deve ser construído. Eles definem os objetivos gerais do sistema, identificam necessidades conhecidas e delineiam áreas que necessitam de mais definições. A prototipagem gera um projeto rápido que concentra os aspectos visíveis do software para o cliente, como por exemplo, o layout da interface humana ou os formatos de entrada e saída de dados na tela.

Codificação do sistema

É a fase de programação ou implementação do código escrito numa linguagem programação adequada à tecnologia do sistema que está se pretendendo construir e, ao final, o produto é materializado.

Testes

Segundo Pressman (PRESSMAN, 2006) Teste é um processo de execução de um programa com a finalidade de encontrar uma erro.

O desenvolvimento de um software é constituído em várias fases de testes que são executados durante sua concepção.

- ***Teste Unitário:*** É uma técnica utilizada para verificar a qualidade do código desenvolvido para o sistema com a finalidade de reduzir falhas e erros operacionais no intuito de encontrar defeitos em pequenas unidades de código.
- ***Teste de Integração:*** Possui o objetivo de testar módulos completos atuando em conjunto de forma simultânea onde se fornece o resultado esperado.
- ***Teste de Segurança:*** Verifica se os dados e o sistema são acessados de forma segura pelo autor das ações a fim de evitar a interceptação no tráfego de informações e obtenção de dados sensíveis.
- ***Teste de Usabilidade:*** Avalia o grau de satisfação do usuário na utilização da interface do sistema. O usuário deverá ter boa condução e controle de navegação da interface, consistência, padronização de elementos e cores, legibilidade e feedback em resposta às suas ações.
- ***Teste de aceitação:*** Verifica se os requisitos do sistema foram desenvolvidos de maneira a satisfazer as necessidades do usuário.
- ***Manutenção:*** É a fase de maturação do software que visa o aperfeiçoamento da tecnologia do sistema. Assim, o sistema passa em constantes fases de ajustes e correções de problemas encontrados durante sua utilização. Adaptações podem ser realizadas devido a uma nova regra de negócio alterada depois que o sistema estava finalizado. Adequações a novas leis, regras contábeis e tributárias são alguns exemplos de ajustes ao qual um sistema poderá sofrer. Novas funcionalidades poderão ser agregadas conforme a dinâmica e demanda de usuários.

3.4.2 Organização do Sistema

O sistema foi concebido para fornecer acesso a quatro tipos de usuários: professor, estudante, visitante e administrador. Cada usuário é tratado no sistema para que seja direcionado aos módulos específicos de sua categoria. A autenticação se dará por meio da informação do seu e-mail, senha e a categoria ao qual pertence. Neste sistema, a transferência desses dados até o servidor é realizada por conexão segura

através do protocolo HTTPS, ou, *HiperText Transfer Protocol Secure*. Este protocolo cria uma criptografia da transmissão de dados no processo de comunicação entre o usuário e o servidor onde o sistema está hospedado.

- **Professor:** O professor é o responsável pela disciplina que leciona. Portanto deverá ser o responsável pela disponibilização de materiais didáticos a serem visualizados por estudantes ao qual irão interagir. Para que o professor não tenha dificuldades, a interface deverá ser fácil e intuitiva de ser manipulada dispensando treinamento de uso do sistema. Ele será responsável por inserir casos clínicos, artigos, criar questionários para os estudantes responderem, realizar demarcações em imagens para enfatizar algum tipo de estudo e terá acesso às predições de imagens fornecidas pelo sistema. Deverá solicitar ao administrador o seu cadastro no sistema.
- **Estudante:** O estudante não terá acesso às áreas destinadas à criação de atividades pelo professor. Poderá acessar materiais didáticos postados pelo professor, interagir com questionários, realizar marcações em imagens conforme instruções fornecidas pelo professor e terá acesso às predições de imagens fornecidas pelo sistema. Poderá criar seu próprio cadastro para ter acesso ao sistema.
- **Visitante:** O visitante é um usuário que não é um estudante regular, mas, poderá se cadastrar para utilizar o sistema. Poderá se interagir com as mesmas credenciais do estudante, mas, não terá suas iterações salvas no banco de dados do sistema.
- **Administrador:** Profissional encarregado da gerência e manutenção do sistema. É o único que possui acesso irrestrito a todos os módulos. Caso necessário, poderá realizar ajustes e correções necessárias ao bom funcionamento do sistema. A Figura 30 exibe a barra de menus do sistema:

Figura 30 - Descrição da Barra de Menus



- **PatologIA**: Título do plataforma.
- **Início**: Página principal do projeto.
- **Cadastro**: Registro de imagens na plataforma. O estudante não possui acesso a este recurso.
- **Questionários**: Este menu fornece acesso para criação dos tipos de questionários, perguntas, alternativas de questões de múltipla escolha a serem respondidas por estudantes e demarcação de regiões de imagens a serem estudadas.
    - **Professor**: Responsável por criar os questionários. Poderá alterar, excluir e visualizar questionários. É possível vincular imagens aos questionários que serão alvo de estudo pelo aluno.
    - **Estudante**: Poderá interagir com os questionários elaborados pelo professor conforme sua demanda e com imagens vinculadas a estes.
- **Casos**: Estudo de casos clínicos postados pelo professor que poderão acessados pelos estudantes. Operações como inclusão, exclusão e visualização da documentação dos casos.
- **Predição**: Interação com modelos de inteligência artificial em imagens médicas na previsão de patologias em órgãos ou regiões do corpo humano.
- **Fórum**: O Fórum é um canal de discussão que visa aproximar professor e estudantes onde são criados diálogos para debater temas sugeridos pelo professor a respeito de sua disciplina ou ao curso em foco.
- ***Login***: Aciona a tela de *login* para autenticação no sistema. Será solicitado ao usuário seu e-mail, senha e categoria. Será oferecida a operação ao usuário para se cadastrar. Sem esta operação as funcionalidades dos menus estarão desabilitadas.

3.4.3 Requisitos do Sistema

A engenharia de requisitos fornece o mecanismo apropriado para entender o que o cliente deseja, analisando as necessidades, avaliando exequibilidade, negociando uma condição razoável especificando a solução de modo não ambíguo, validando a especificação e gerindo os requisitos à medida que são transformados em um sistema operacional (PRESSMAN, 2006 *apud* THAYER, 1997).

Requisitos Funcionais

Segundo Sommerville (SOMMERVILLE, 2011) Os requisitos funcionais de um sistema descrevem o que ele deve fazer. Eles dependem do tipo de software a ser desenvolvido, de quem são seus possíveis usuários e da abordagem geral adotada pela organização ao escrever os requisitos. Quando expressos como requisitos de usuário, os requisitos funcionais são normalmente descritos de forma abstrata, para serem compreendidos pelos usuários do sistema.

Está ligado às funcionalidades do software, ou seja, como o software deve reagir às entradas específicas e como deverá se comportar em determinadas situações.

Estes requisitos são classificados por ordem de prioridade, ou seja, alta, média ou baixa.

O requisito de alta prioridade é fundamental para o sistema, sem o qual não pode ser considerado como completo, ou apto para produção. Um requisito com alta prioridade é uma funcionalidade que deverá constar, obrigatoriamente, no sistema. Os requisitos de média e baixa prioridade podem ser postergados para implementação posterior pois não prejudicam o bom funcionamento do sistema. O Quadro 4 demonstra os requisitos funcionais (RF) do sistema.

Quadro 4 - Requisitos Funcionais do Sistema

ID	Descrição	Prioridade
RF01	O professor poderá incluir, excluir e visualizar imagens.	Alta
RF02	O administrador poderá incluir, alterar, excluir e visualizar tipos de imagens.	Alta
RF03	O administrador poderá incluir, alterar, excluir e visualizar usuários.	Alta
RF04	O administrador poderá incluir, alterar, excluir e visualizar tipos de usuários.	Alta
RF05	O estudante poderá se cadastrar no sistema.	Alta
RF06	O usuário poderá se autenticar no sistema.	Alta
RF07	O sistema verificará dados de *login* e senha do usuário.	Alta
RF08	O sistema poderá enviar uma mensagem de erro ao usuário.	Alta
RF09	O professor poderá criar questionários com questões objetivas.	Alta
RF10	O professor poderá vincular imagens às questões do questionário onde poderá, com ferramentas, demarcar e manipular regiões da imagem.	Alta
RF11	O professor poderá carregar imagens e demarcar suas estruturas.	Alta
RF12	O professor e o estudante poderão interagir com modelos de inteligência artificial para pesquisar patologias em imagens.	Alta
RF13	O professor poderá abrir, interagir e fechar fóruns.	Média
RF14	O estudante poderá visualizar e responder questionários elaborados pelo professor.	Alta
RF15	O estudante poderá visualizar e marcar imagens conforme solicitação do professor.	Alta
RF16	O estudante poderá visualizar e baixar documentos de estudo de casos clínicos postados pelo professor.	Alta
RF17	O sistema irá gerar a pontuação conforme as respostas de cada estudante.	Alta
RF18	O sistema permitirá uma segunda chance ao estudante em caso de erro para responder uma questão, mas, retirará 50% dos pontos na segunda tentativa em caso de acerto.	Alta
RF19	O estudante poderá visualizar o resultado das suas respostas.	Alta
RF20	O estudante poderá visualizar e participar de fóruns.	Média

Requisitos Não Funcionais

Os requisitos não funcionais são restrições nos serviços e nas funções oferecidas pelo sistema e, por exemplo, podem incluir restrições de tempo, restrições no processo de desenvolvimento, e restrições impostas por normas (SOMMERVILLE, 2011).

Ao contrário das funcionalidades individuais do sistema, os requisitos não funcionais se aplicam ao sistema de maneira geral. Fatores como a confiabilidade, tempo de resposta às interações do usuário, facilidade de uso e de manutenção são alguns exemplos que podem afetar no desempenho e no uso de um sistema.
O Quadro 5 demonstra os requisitos não funcionais (RNF) do sistema.

Quadro 5 - Requisitos Não Funcionais do Sistema

ID	Descrição	Prioridade
RNF01	O sistema deverá ter resposta e atualização de tela com velocidade compatível.	Alta
RNF02	A interface deverá ser intuitiva, com linguagem simples e de fácil assimilação pelo usuário.	Alta
RNF03	A interface deverá ter padronização entre as várias páginas mantendo coerência de cores, fontes e disposição de informações.	Alta
RNF04	O sistema deverá ser executado pela maioria dos navegadores mais utilizados pelo mercado.	Alta
RNF05	O sistema deverá se ajustar ao tamanho de tela de vários dispositivos de uso como computadores, *notebooks*, *tablets* e celulares aos quais serão disponibilizados.	Alta
RNF06	O sistema deverá estar preparado para ser utilizado em sala de aula com acesso à *Internet*.	Média
RNF07	O sistema será hospedado em infraestrutura de nuvem	Alta

Regras de Negócios

Segundo Sujithra (SUJITHRA, 2012) é a descrição atômica, na qual não poderá ser subdividida em partes; e deve afirmar, ou influenciar ou controlar o comportamento dos negócios de uma organização. O Quadro 6 descreve tais regras:

Quadro 6 - Regras de Negócios

ID	Descrição	Prioridade
RN1	Os menus do sistema estarão bloqueados até que o usuário se autentique.	Alta
RN2	O cadastro de usuários à plataforma se dará através de cada usuário com relação ao seu tipo.	Alta
RN3	Usuários deverão se autenticar com o seu e-mail, senha e tipo cadastrado para acessar a plataforma.	Alta
RN4	O estudante poderá realizar testes de conhecimento em questionários da plataforma que terá sua pontuação salva em banco de dados.	
RN5	O usuário Convidado poderá utilizar a plataforma como visitantes, porém não terão seus dados e pontuação dos questionários salvas no banco de dados.	Alta
RN6	Os estudantes terão duas chances para responder a uma questão em caso de erro, mas, terão sua pontuação reduzida em 50% em caso de acerto na segunda chance. Em caso de acerto na primeira chance, a plataforma passará a exibir a próxima questão.	Alta
RN7	O estudante não terá acesso aos módulos de criação de questionários.	Alta
RN8	O estudante não terá acesso à postagem de imagens médicas.	
RN9	O professor fará o cadastro de imagens no repositório da plataforma.	Alta
RN10	O professor terá acesso ao módulo de criação de questionário, questões e suas alternativas.	Alta
RN11	O professor poderá desenvolver dois tipos de questionários. Um com questões objetivas e outro para demarcação em regiões de imagens.	Alta
RN12	O professor poderá editar, alterar, atualizar e excluir uma questão ou alternativas das questões.	Alta
RN13	O professor poderá modificar o status da alternativa para certo ou errado.	Alta
RN14	O professor terá acesso ao módulo de resultados e terá visão do desempenho dos estudantes.	Alta
RN15	O estudante terá acesso aos resultados do seu desempenho.	Alta
RN16	Professor e estudante terão acesso ao módulo de Predição.	Alta
RN17	O módulo de Predição informará a probabilidade em porcentagem de uma radiografia estar ou não com a patologia.	Alta
RN18	Professor e estudante terão acesso ao módulo Estudos de Casos.	Alta
RN19	Professor poderá postar arquivos de Estudos de Casos.	Alta
RN20	Professor e estudantes poderão acessar ao Fórum da plataforma.	Alta

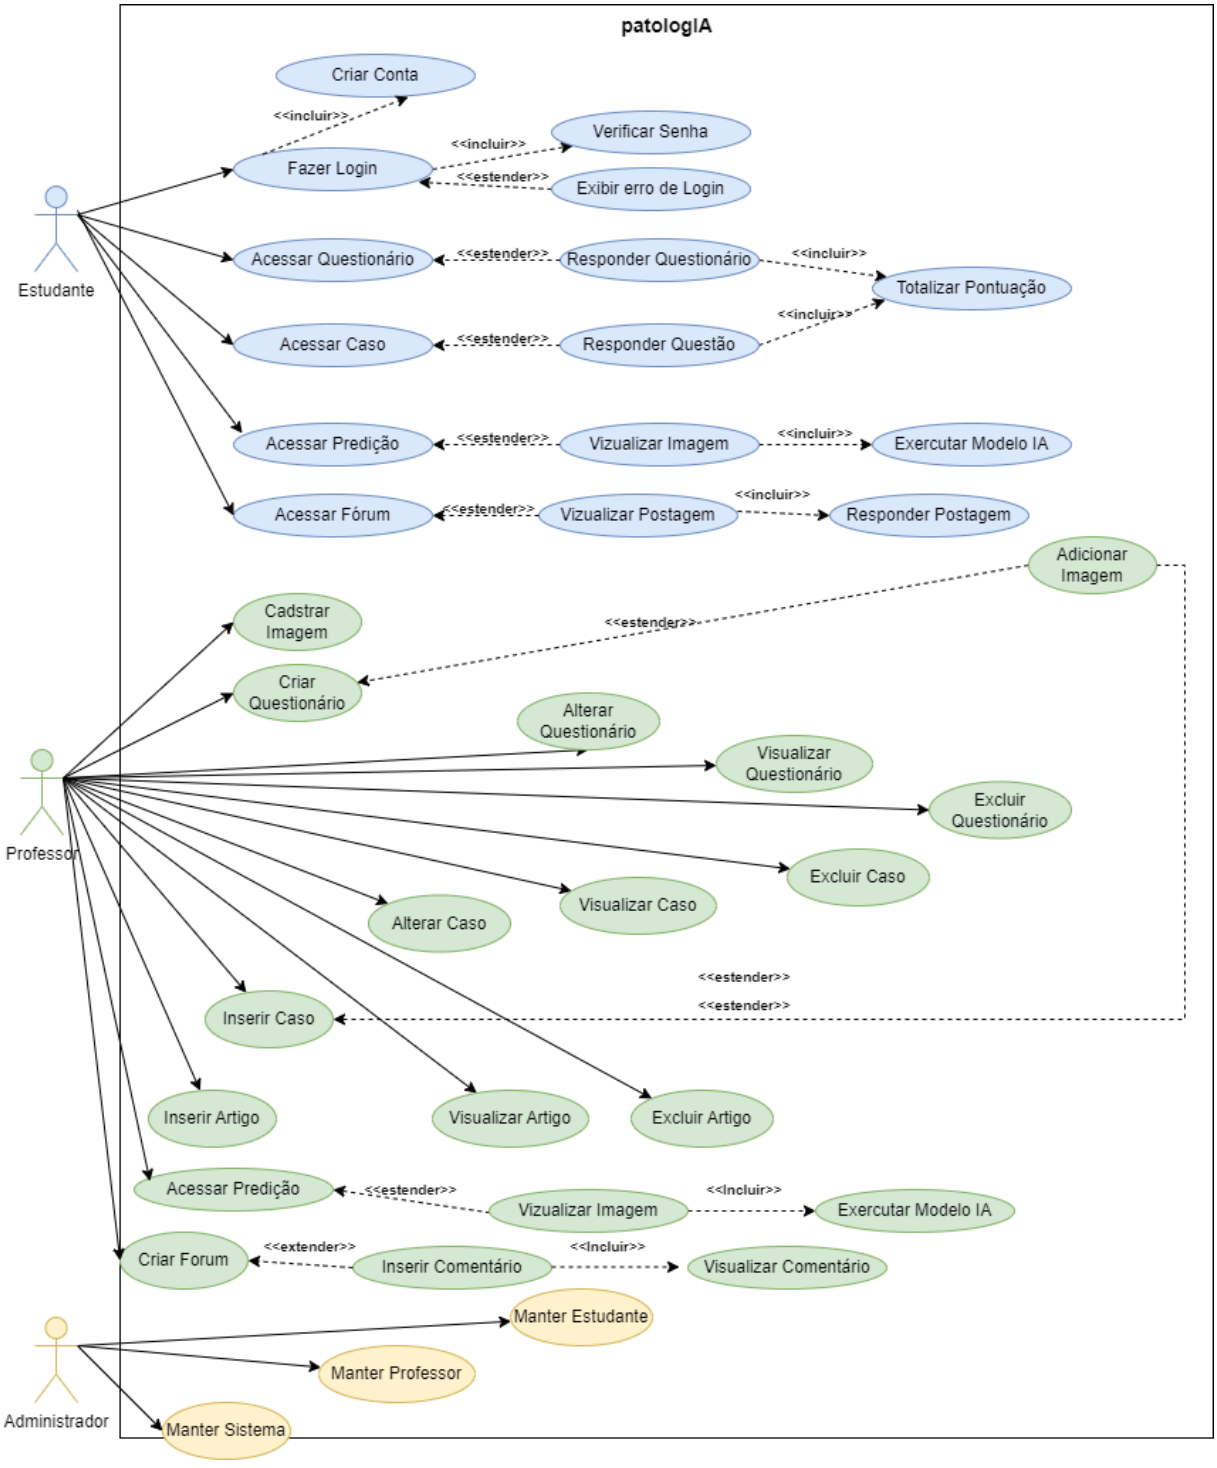
3.4.4 Diagrama de Caso de Uso

De maneira geral, processos de negócio envolvem relações entre organizações, entre organizações e seus clientes e fornecedores, entre colaboradores em uma organização e entre todas as demais entidades que precisam colaborar de alguma forma para que as organizações cumpram seus objetivos. Esse é o enfoque de negócio e, segundo esse enfoque, os casos de uso de negócio representam os processos realizados e os atores de casos de uso de negócio são todos os que participam deles. Eventualmente, um processo em uma organização é informatizado, parcial ou totalmente. As funcionalidades, demais características desse sistema e seus usuários dizem respeito ao enfoque de sistema. Segundo esse enfoque, os casos de uso de sistema representam as funcionalidades do sistema; os atores dos casos de uso de sistema são seus usuários (PEREIRA, 2011).
Este diagrama é derivado da especificação de requisitos cuja função é de documentar as funcionalidades sob a visão do usuário. Se compõem basicamente em quatro partes:

- **Cenário**: sequência de eventos derivados da interação do usuário com o sistema.
- **Ator**: um tipo de usuário do sistema.
- **Caso de uso**: tarefa ou operação realizada pelo ator.
- **Relacionamento**: é a ligação de um ator com um caso de uso.

A Figura 31 ilustra a sequência de iterações do usuário com o sistema. Nela tem-se a visão geral das iterações dos usuários com o aplicativo e demonstra o fluxo básico de funções que o aplicativo é capaz de executar.

Figura 31 - Diagrama de Casos de Usos



A Figura 31 mostra a Figura geométrica de um retângulo que representa o sistema a ser desenvolvido e no topo está o título do aplicativo. As funcionalidades do aplicativo são demonstradas dentro do retângulo. O que está fora do retângulo não acontece dentro do aplicativo, porque, são entidades distintas. Os atores são os usuários do sistema, ou seja, estudante, visitante, professor ou administrador.

Cada Figura geométrica no formato oval significa um caso de uso ou de ações que ocorrem dentro do sistema. Cada caso de uso é disposto de forma lógica segundo o sistema. Por isso o *login* é o primeiro estudo de caso a ser apresentado. Cada ator deverá se relacionar com pelo menos um caso de uso do sistema representado por uma linha sólida. Este tipo de relacionamento é denominado de associação que representa a comunicação entre entidades distintas, ou seja, entre um ser humano e uma funcionalidade de um programa de computador.

Além da associação, existem outros três tipos de relacionamentos; são eles, inclusão, extensão e generalização. O relacionamento de inclusão ocorre sempre dentro do aplicativo. Por exemplo, a funcionalidade “verificar senha” somente irá acontecer se o usuário tentar realizar a autenticação do *login* no sistema, ou seja, mostra a dependência entre um caso de uso básico como “fazer *login*” e um caso de uso incluído como “verificar senha”. A cada momento que um caso de uso básico for acionado, o caso de uso incluído será executado e isto completa o relacionamento entre os casos de uso. A linha de relacionamento, neste caso, é tracejada.

Outros relacionamentos de inclusão como “totalizar pontuação” somente ocorrerá se outro caso de uso básico como “responder questionário” for executado pelo estudante. O mesmo raciocínio ocorre entre os casos de uso “visualizar imagem” e “executar modelo de IA” e, também, “totalizar pontuação” que dependem de os casos de usos “responder questionário” e “responder questão” serem acionados para poderem acontecer.

O caso de uso estendido ocorrerá às vezes, mas nem sempre. Ele só ocorre depois que determinados critérios forem cumpridos. Por exemplo, O caso de uso estendido “verificar erro de *login*” somente ocorrerá se houver falha de autenticação do *login*. Outros exemplos ocorrem no diagrama como “responder questionário” e “responder questão”, “visualizar imagem”, também, são estendidos porque poderão ocorrer ou não.

3.4.5 Diagrama de Atividades

Diagramas de atividades são diagramas que ilustram como o sistema se comporta depois que suas ações são executadas para concluir uma atividade ou processo.

A figura 32 ilustra o comportamento das atividades da elaboração dos questionários de múltipla escolha e de demarcação de imagens pelo professor e a interação dessas atividades com o estudante:

Figura 32 – Diagrama de Atividades – Elaborar Questionários



3.4.6 Diagramas de Sequências

O diagrama de sequência mostra a sequência de eventos cujas mensagens são transmitidas entre objetos durante uma interação. É baseado no diagrama de casos de uso onde, normalmente, há um diagrama de sequência para cada caso de uso.
O *Django* trabalha com a arquitetura MTV, ou seja, *Model, Template, View*, onde *model.py* é o arquivo onde são desenvolvidas as classes do sistema. O *Template* são os arquivos *HTML* que exibem os dados na tela do usuário, ou seja, o *Front End* do sistema. O arquivo *view.py* é o local onde são desenvolvidos os métodos de regras de negócios do sistema. É semelhante à arquitetura MVC – *Model, View, Controler*, mas com nomenclaturas diferentes o que pode causar confusão porque no sistema MTV do *Django*, a *view* funciona como o *controler* do MVC e o template do MTV é o mesmo que a *view* do MVC. Já o Model significa o mesmo para as duas arquiteturas. Os diagramas de sequência foram elaborador conforme a arquitetura MTV do *Django*.

Figura 33 - Diagrama de Sequência – Elaborar Questionário de Múltipla Escolha

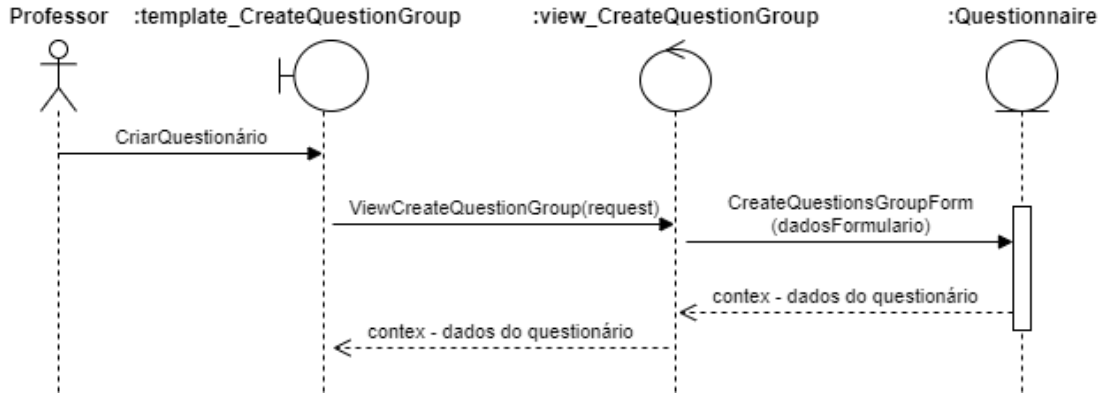


Figura 34 - Diagrama de Sequência – Elaborar Questões de Múltipla Escolha

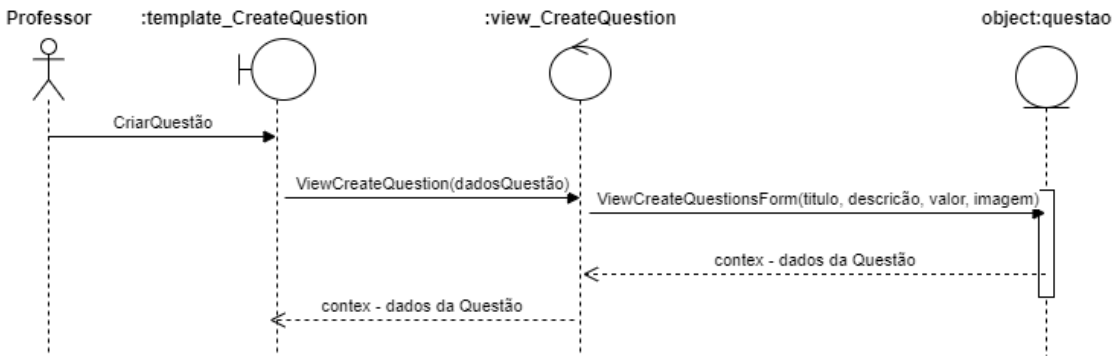


Figura 35 - Diagrama de Sequência – Elaborar Alterantivas de Múltipla Escolha

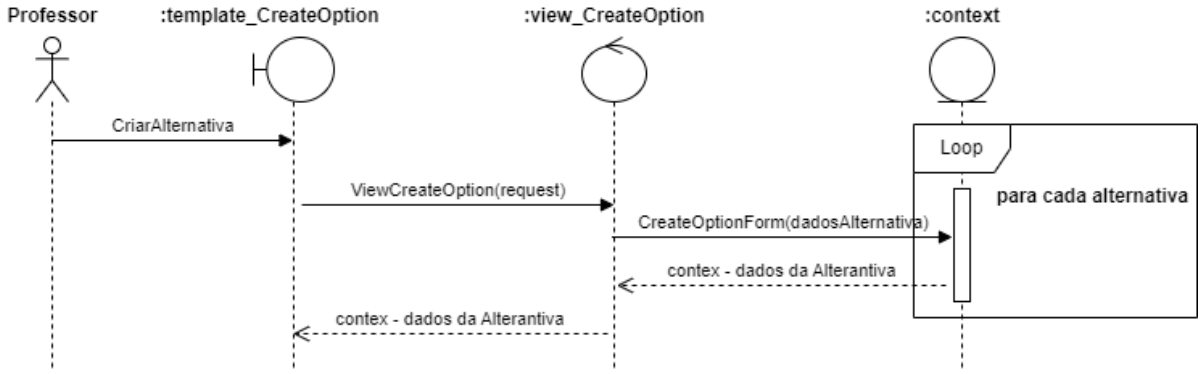


Figura 36 - Diagrama de Sequência – Questionário de Demarcação de Imagem Professor

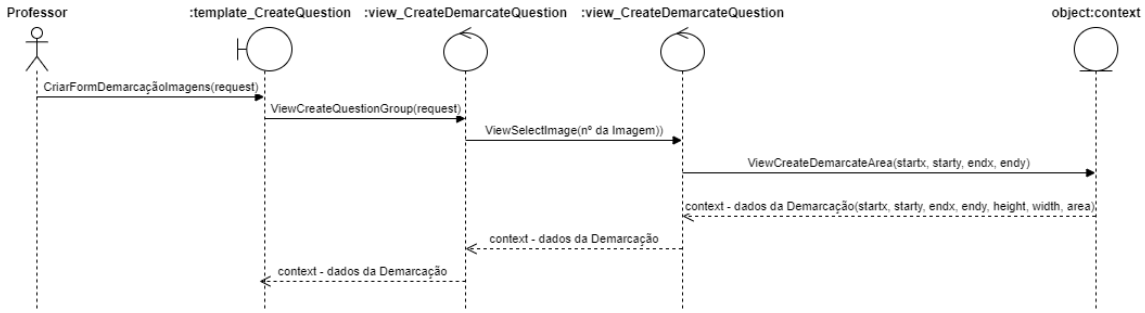
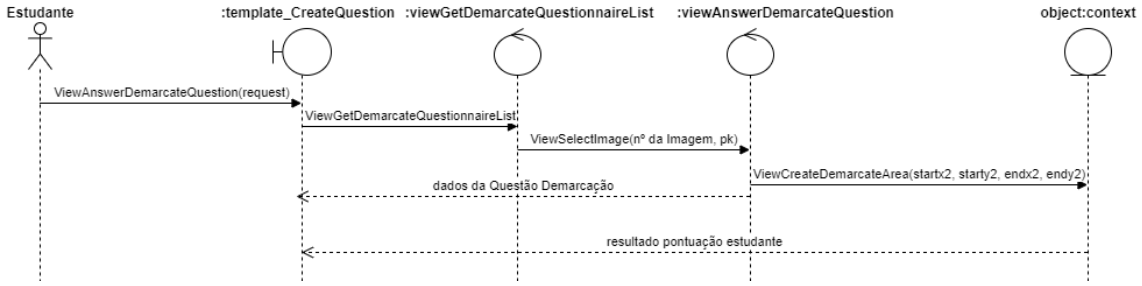


Figura 37 - Diagrama de Sequência – Questionário de Demarcação de Imagem Estudante



3.4.7 Etapa 2 - Protótipos de Interfaces

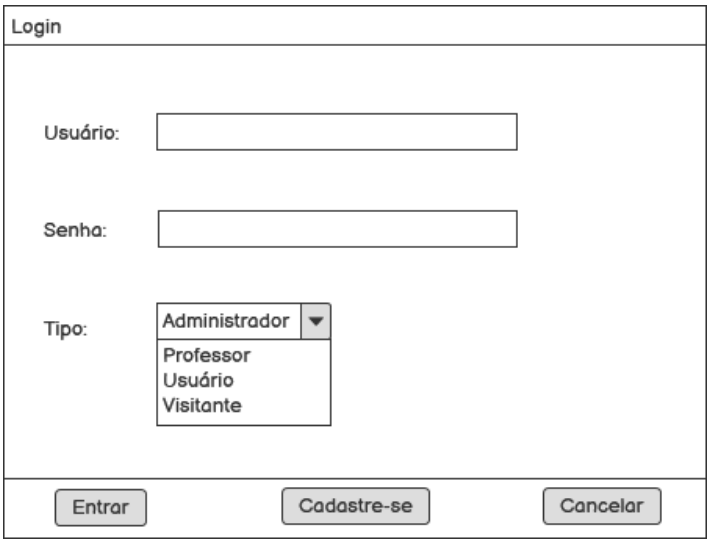
Um protótipo é uma simulação da navegação e das funcionalidades de um site, composto normalmente por *wireframes* clicáveis ou layouts. É uma forma rápida de validar e testar um produto antes de desenvolvê-lo do começo ao fim (TEIXEIRA, 2014).

Um projeto de prototipagem visa representar os aspectos do sistema que estarão visíveis ao usuário como o *layout* da interface, os formatos e disposição dos componentes de entrada, manipulação e saída de dados na interface.

O protótipo serve como mecanismo para identificar requisitos de software.

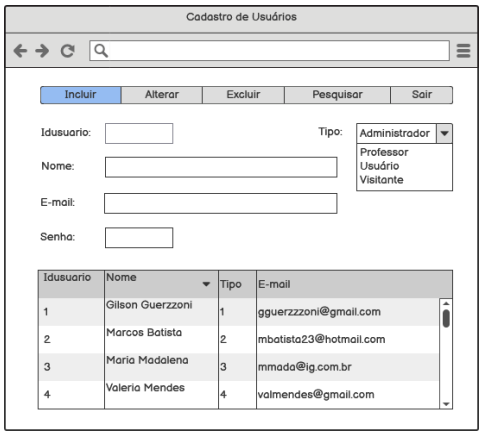
A Figura 38 exibe um protótipo para a tela de *login* do sistema. Nela o usuário poderá se autenticar no sistema conforme o tipo de sua categoria se estiver cadastrado no sistema, senão, terá a o pção para cadastrar-se.

Figura 38 – Protótipo Login



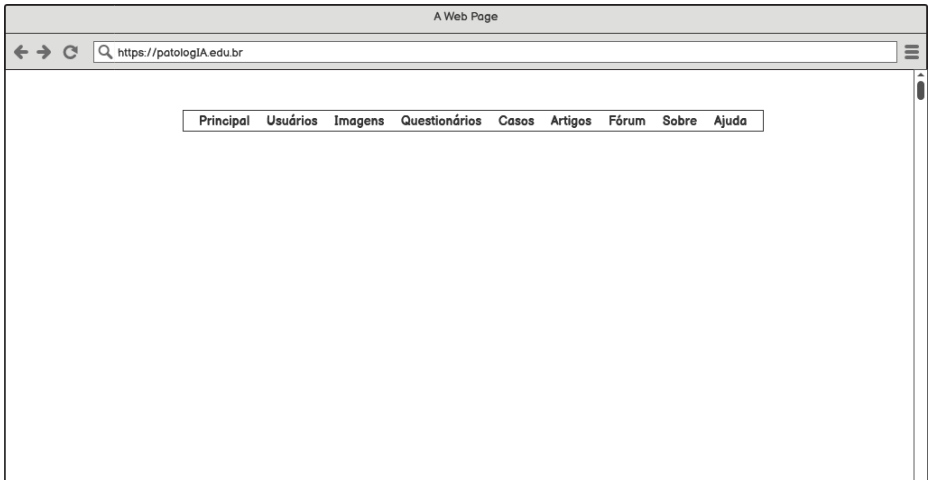
A Figura 39 mostra a tela de cadastro do usuário no sistema para que possa se autenticar posteriormente. Apenas as opções de usuário estudante ou visitante estarão disponíveis neste cadastro. Professores deverão solicitar ao administrador sua inclusão no sistema.

Figura 39 – Protótipo Cadastro de Usuários



A Figura 40 exibe a página principal ou o ponto de partida do sistema exibindo o menu de opões das funcionalidades.

Figura 40 - Protótipo Menu Principal



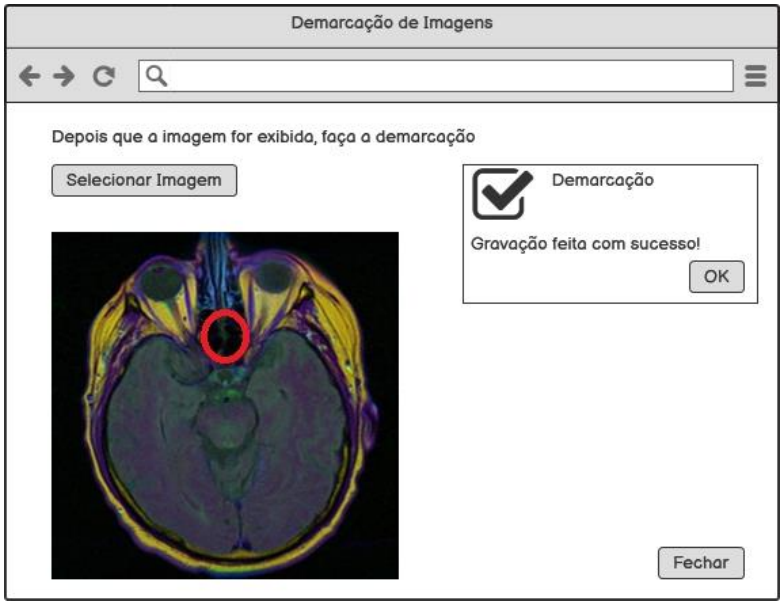
A Figura 41 mostra a tela de cadastro de imagens. Cada imagem ficará hospedada num repositório criado para este fim. O que este cadastro faz é atribuir um número de identificação para cada imagem no banco de dados e armazenar a rota do repositório onde a imagem se encontra. É possível determinar a data do cadastro e a classificação do grau de dificuldade da interpretação da imagem.

Figura 41 - Protótipo Cadastro de Imagens



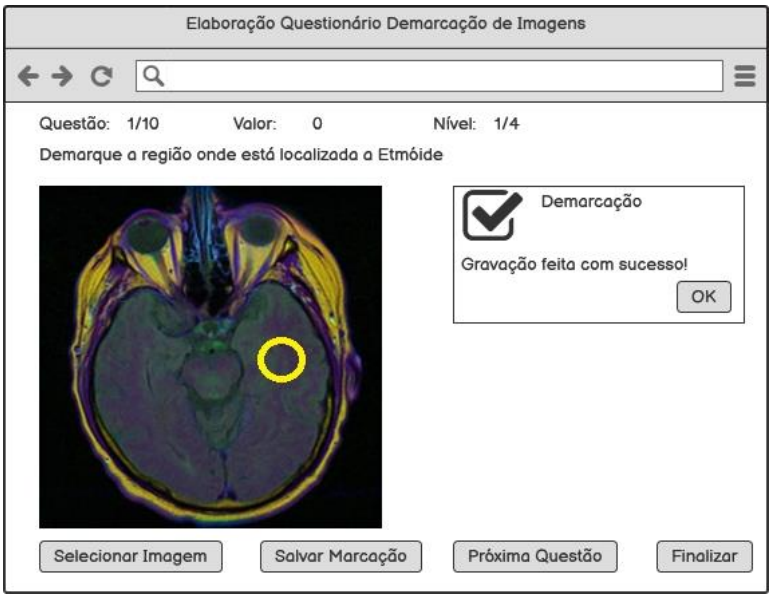
A Figura 42 mostra a demarcação em vermelho de uma região da imagem feita pelo professor para fins didáticos. Ele poderá, por exemplo, demarcar uma região da imagem e perguntar ao estudante onde fica esta região do cérebro, neste caso a “Etmóide”. Esta demarcação não será exibida ao estudante.

Figura 42 - Protótipo Demarcação de Imagens



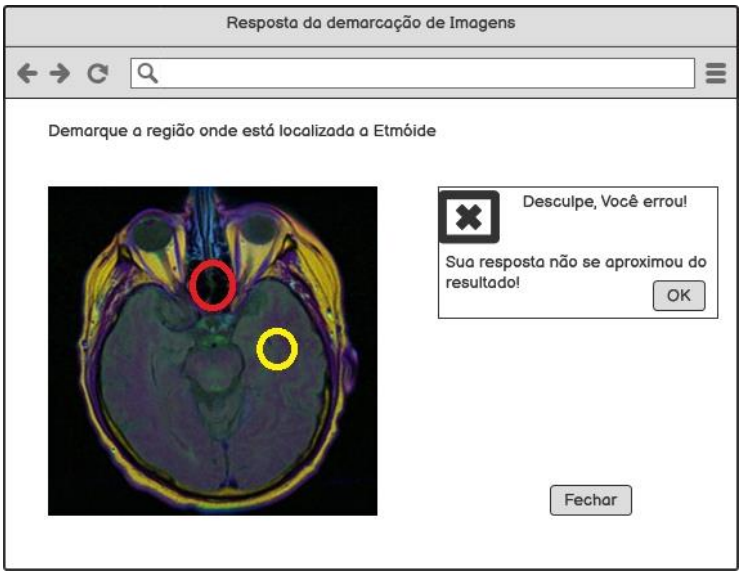
A Figura **Erro! Fonte de referência não encontrada.**43 ilustra um exemplo de emarcação feita pelo estudante em resposta ao que foi solicitado pelo professor.

Figura 43 - Protótipo Questionário Demarcação de Imagens



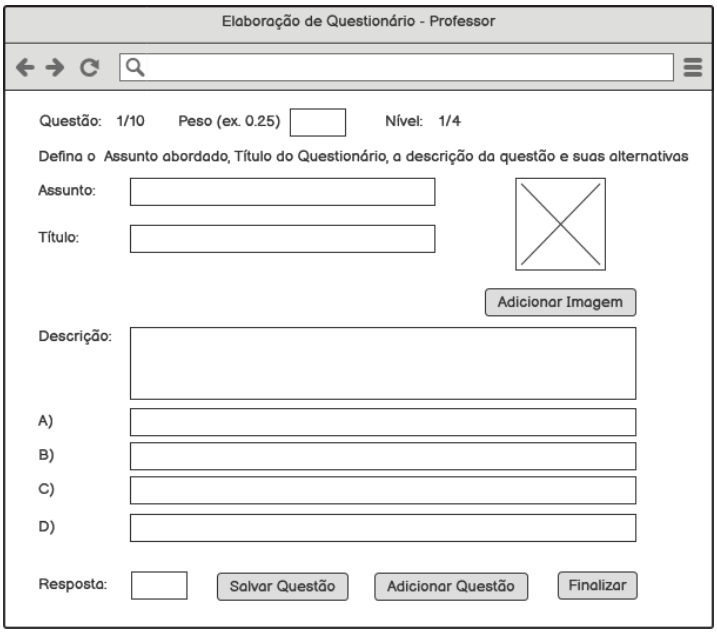
A Figura 44 exibe as demarcações feitas pelo professor e o estudante e as compara fornecendo a resposta da questão ao estudante.

Figura 44 - Protótipo Demarcação Feita por Professor e Estudante



A Figura 45 mostra o formulário de criação de um questionário pelo professor com os campos que deverão ser preenchidos.

Figura 45 - Protótipo Elaboração de Questionário



Uma vez apresentada ao estudante, a interface permite que seja escolhida uma das alternativas de resposta de acordo com a preferência do usuário, em função das informações exibidas na questão. Imediatamente após a confirmação de escolha da resposta, a interface promove a mudança da cor de fundo do texto referente à alternativa escolhida, ou seja, verde, caso correta, ou vermelha, caso incorreta, conforme as Figura 46 e Figura 47.

Figura 46 – Protótipo Resposta de Alternativa Correta

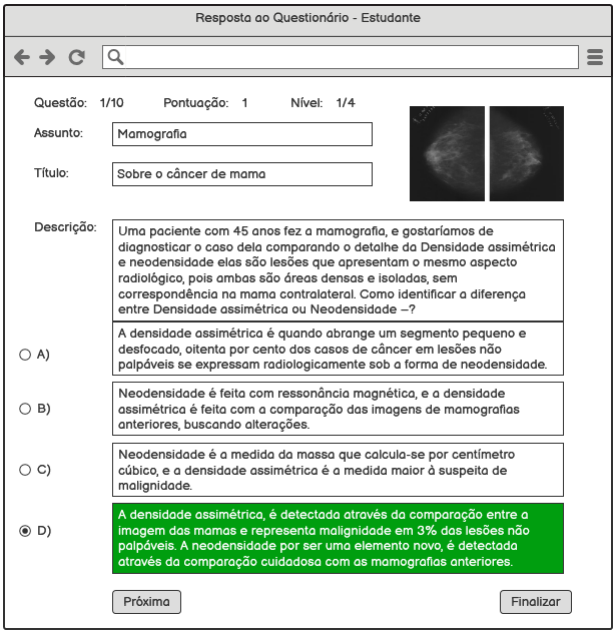
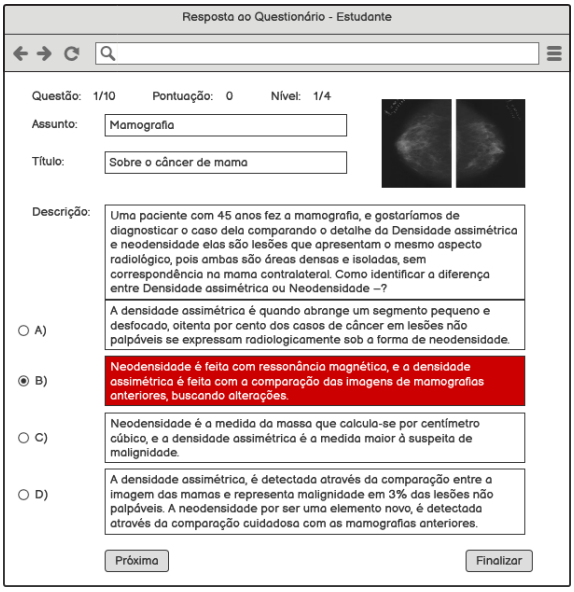


Figura 47 - Protótipo Resposta de Alternativa Errada



3.4.8 Etapa 3 - Banco de Dados

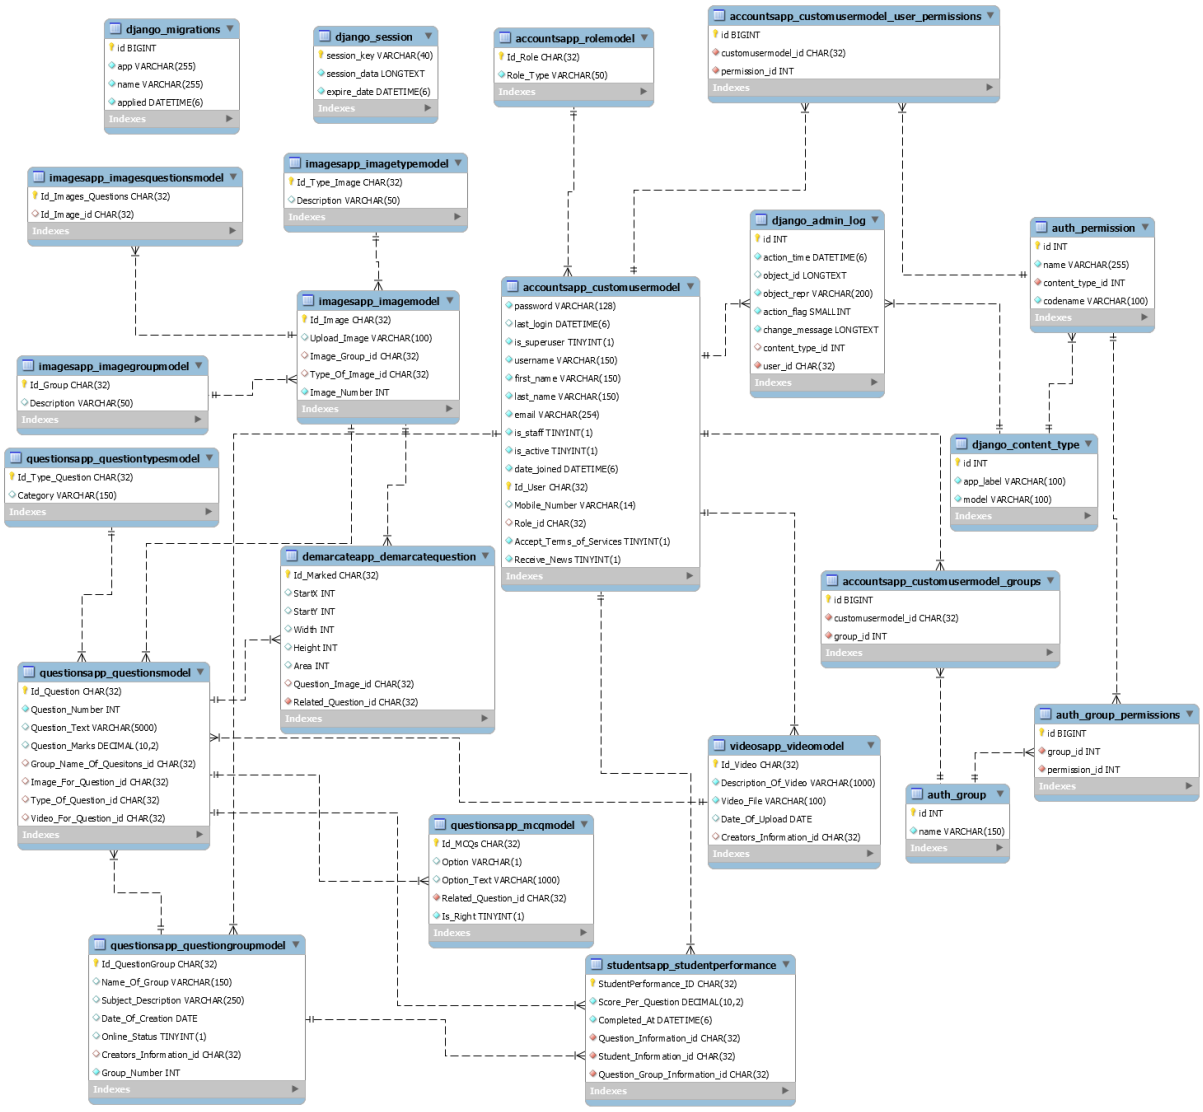
O gerenciador de banco de dados utilizado neste projeto é o MySql versão 8.0. É um projeto *open source* mantido pela Oracle e possui como características a rapidez, robustez, a escalabilidade horizontal que permite a replicação de dados e multiplataforma. Utiliza a linguagem de consulta estruturada SQL – Structure Query Language utilizada para manipulação e consulta de dados. Por ser desenvolvido em linguagem C/C++, fornece conexão com várias linguagens de programação independente do sistema operacional. Possui uma interface de interação denominada *MySql* Workbench que possibilita a criação de entidades, relacionamentos e modelagem de forma rápida e fácil.

O *MySql* é um banco de dados relacional utilizado para armazenamento de informações. É constituído por elementos básicos como campos, colunas, linhas ou tuplas e Tabelas. Campos são locais reservados para inserção de dados. As colunas se relacionam com as linhas formando uma Tabela. Enquanto as colunas armazenam registros de um determinado campo; as linhas são registros que armazenam dados de várias colunas. As Tabelas são coleções de colunas, linhas e campos e um banco de dados relacional é uma coleção de Tabelas.

Suas Tabelas podem armazenar volumes de dados equivalentes a *terabytes* em tamanho. É capaz de realizar milhões de transações por minuto. O *MySql* aceita até 30 conexões simultâneas em ambiente de hospedagem de sites, e até 2.000 conexões simultâneas em ambiente de nuvem. No exemplo de acesso a um site que se conecta ao banco de dados, o acesso acontece apenas se duas ou mais conexões ao banco se iniciarem exatamente no mesmo instante. Depois de carregada a página, a conexão se encerra.

A Figura 48 ilustra o diagrama de modelagem das entidades e seus relacionamentos da base de dados denominada **pathologia** produzida para o sistema.

Figura 48 - Diagrama de Entidades e Relacionamentos



3.4.8.1 Descrição das Tabelas do Banco de Dados

O framework *django* contém vários aplicativos que são instalados juntos com ele. Segundo a documentação do *django*, estes aplicativos geram automaticamente ao menos uma Tabela no banco de dados. Das vinte Tabelas do banco de dados, sete foram geradas por aplicativos que constam no framework *django*. São elas:

- ***auth_group***: Tabela gerada pelo aplicativo *django.contrib.auth*. Armazena grupos ou funções para usuários em uma estrutura muitos para muitos. Por padrão, cada usuário está em seu próprio grupo, mas um usuário pode estar em vários grupos e cada grupo pode conter vários usuários. Um grupo é identificado por uma função e uma descrição. Relaciona-se com as Tabelas *auth_group_permissions* e *accountsapp_customusermodel_groups*.
- ***auth_group_permissions:*** Vincula grupos e permissões. Uma permissão é identificada por um nome e, opcionalmente, por uma Tabela e um registro. Por exemplo, membros de um determinado grupo podem ter permissões de "atualização" em um registro específico de uma Tabela específica. Tabela gerada pelo aplicativo *django.contrib.auth* instalado com o *django*, responsável pelo controle de permissões de autenticação de grupos de usuários do sistema. Relaciona-se com as Tabelas *accountsapp_customusermodel* (cadastro de usuários) e *auth_permission* (Tabela de permissão de autenticações).
- ***auth_permission:*** Tabela gerada pelo aplicativo *django.contrib.auth*, responsável pelo controle de permissões de usuários do sistema. Relaciona-se com as Tabelas *django_content_type*, contêm informações de permissionamento.

- ***django_session:*** Tabela gerada pelo aplicativo *django.contrib.sessions*. Sessões são o mecanismo usado pelo *Django* (e muitos outros na Internet) para monitorar o "estado" entre o site e um navegador web em particular. Sessões permitem que você armazene dados arbitrários por navegador web, e têm esse dado disponível no site sempre que o navegador conectar. Dados de itens individuais associados com a sessão são referenciados por uma "chave", que é usada para armazenar e recuperar os dados[16].

[16] https://developer.mozilla.org/pt-BR/docs/Learn/Server-side/Django/Sessions

- ***django_migrations:*** Possui informações sobre as migrações efetuadas no banco de dados. Para criar uma Tabela pelo ***django***, cria-se uma classe com os campos e suas características no arquivo ***models.py***. A migração é operação que vincula os campos de uma classe com o banco de dados. A migração executa a classe e a converte em Tabela do banco de dados.

- ***django_admin_log:*** Tabela gerada pelo aplicativo *django.contrib.admin*. Contêm informações de auditoria do painel de administrador do sistema. Relaciona-se com as Tabelas *django_content_type* e *accountsapp_customusermodel*.
- ***django_content_type:*** Contêm informações sobre o conteúdo interno do sistema, permite a catalogação de tal conteúdo e a gestão de permissões sobre os mesmos.

- ***accountsapp_customusermodel_groups*:** Tabela que interliga grupos de usuários e usuários. Relaciona-se com as Tabelas *accountsapp_customusermodel* (cadastro de usuários), *auth_group* (autenticação de grupos de usuários).
- ***accountsapp_customusermodel*:** É a Tabela responsável por armazenar os dados informados no formulário de cadastro de contas do usuário. É a Tabela com o maior número de campos da plataforma. Relaciona-se com sete outras Tabelas como, *accountsapp_rolemodel, accountsapp_customusermodel_user_permissions*, *questionsapp_questionsmodel*, *django_admin_log*, *accountsapp_customusermodel_groups, studentsapp_studentperformance* e *videosapp_videomodel*.
- **questionsapp_questiontypesmodel:** Tabela responsável por armazenar os dois tipos de questionários que a plataforma oferece: múltipla escolha e demarcação de imagens. Relaciona-se com a Tabela *questionsapp_questionsmodel.*
- ***questionsapp_questionsmodel***: Tabela responsável por armazenar dados das questões como número, descrição e valor da questão. Comporta chaves estrangeiras de outras Tabelas como *id's* do tipo de questionário, imagens, tipo

de questão e vídeo. Possui campos como número da questão, descrição, valor da questão e permite vincular uma imagem à questão.

- ***questionsapp_questiongroupmodel***: Esta Tabela armazena dados a respeito da criação de questionários. Existem dois tipos; múltipla escolha e demarcação de imagens, o qual o professor deverá escolher um deles. Outros campos como descrição do questionário, data da criação, status que controla de o questionário está aberto ou fechado para uso.
- ***accountsapp_rolemodel:*** Tabela responsável por armazenar os tipos de usuários da plataforma. Relaciona-se com a Tabela *accountsapp_customusermodel.*
- ***questionsapp_mcqmodel:*** Tabela responsável em armazenar dados das alternativas das questões de múltipla escolha e registrar a opção correta da questão. Relaciona-se com as Tabelas *imagesapp_imagemodel, questionsapp_questiontypesmodel*, *questionsapp_mcqmodel*, *demarcateapp_demarcatequestion*, *questionsapp_questiongroupmodel* e *studentsapp_studentperformance*.
- ***imagesapp_imagegroupmodel:*** Tabela que armazena os tipos de especialidades de imagens médicas. Relaciona-se com a Tabela *imagesapp_imagemodel*.
- ***imagesapp_imagemodel:*** Tabela responsável pelo armazenamento do cadastro de imagens na plataforma. Relaciona-se com as Tabelas *imagesapp_imagetypemodel*, *imagesapp_imagesquestionsmodel*, *imagesapp_imagegroupmodel* e *demarcateapp_demarcatequestion*.
- ***imagesapp_imagetypemodel:*** Tabela responsável em armazenar os tipos de imagens de radiologia digital como raios X, ressonância, tomografia, etc.
- ***imagesapp_imagesquestionsmodel***: Tabela que vincula imagens às questões de um questionário.
- ***demarcateapp_demarcatequestion*:** Tabela responsável por armazenar coordenadas de pontos, largura, altura e área da demarcação de regiões da imagem feita por professores.
- ***studentsapp_studentperformance*:** Tabela responsável por armazenar o ID do estudante, a pontuação obtida por ele e a data do resultado da iteração.

Relaciona-se com as Tabelas *accountsapp_customusermodel, questionsapp_questionsmodel* e *questionsapp_questiongroupmodel*.

3.4.9 Etapa 4 – Acesso à Plataforma

Será fornecida a URL para que qualquer usuário possa acessar através do seu navegador de *Internet* por qualquer dispositivo disponível. Para tal, é necessário que se tenha acesso à *Internet*.

3.4.10 Etapa 5 – Metodologia de Validação e Verificação da Plataforma

O projeto foi submetido ao protocolo de pesquisa envolvendo seres humanos para análise do Comitê de Ética em Pesquisa da Universidade de Mogi das Cruzes.
O projeto foi constituído com a finalidade de atender à Norma Operacional 001/2013 do Conselho Nacional de Saúde - Ministério da Saúde, bem como à resolução 466/12 e 510/16 do CNS vigente neste momento e outras específicas para projetos de genética humana ou estudos com população vulnerável.
Este projeto teve o Parecer Consubstanciado do CEP aprovado sob o número CAAE 65495922.7.0000.5497 e Número do Parecer 5.863.020.

3.5 TESTES DE AVALIAÇÃO

Este teste é de caráter exploratório onde o foco é o estudo subjetivo do que será analisado, neste caso, um sistema informatizado por um ator, ou seja, o usuário. Assim, buscar-se-á entender o comportamento do usuário diante de um sistema computacional. Diante das características expostas, conclui-se que a pesquisa qualitativa e exploratória se enquadra neste perfil.
A pesquisa qualitativa baseia-se na observação ou exploração do foco em estudos, neste caso, no ambiente de interação entre o sistema utilizado e do entendimento das várias perspectivas dos potenciais usuários do sistema.

A Norma ISO 25010 que substituiu a norma ISO 9126, categoriza os atributos de qualidade de software em sete características (funcionalidade, confiabilidade, usabilidade, eficiência, manutenção e portabilidade).

Funcionalidade: é definida como “o conjunto de funções que satisfaz as necessidades explícitas e implícitas para a finalidade a que se destina o produto.” é composta pelas seguintes subcategorias:

- Adequação: Propõe-se a fazer o que é apropriado?
- Acurácia: Gera resultados corretos ou conforme acordados?
- Interoperabilidade: É capaz de interagir com os sistemas especificados?
- Segurança de acesso: Evita acesso não autorizado, acidental ou deliberado a programas de dados?
- Conformidade: Está de acordo com normas e convenções previstas em leis e descrições similares?

Confiabilidade: é uma medida obtida pela avaliação da precisão resultante da execução de cada função de um programa. É definida como “o desempenho que se mantém ao longo do tempo e em condições estabelecidas.” A Confiabilidade é composta pelas seguintes subcategorias:

- Maturidade: Com que frequência apresenta falhas?
- Tolerância a falhas: Ocorrendo falhas, como ele reage?
- Recuperabilidade: É capaz de recuperar dados após uma falha?

Usabilidade: é o grau de facilidade de utilização do software pelo usuário. Verifica-se o esforço para aprender, operar, preparar a entrada e interpretar a saída (resultados do processamento) de um programa. É composta pelas seguintes subcategorias:

- Inteligibilidade: É fácil entender os conceitos utilizados? Representa a facilidade com que o usuário pode compreender as suas funcionalidades e avaliar se o mesmo pode ser usado para satisfazer as suas necessidades específicas.
- Apreensibilidade: É fácil apreender a usar? Identifica a facilidade de aprendizado do sistema para os seus potenciais usuários.
- Operacionalidade: É fácil de operar e controlar a operação? É como o produto facilita a operação por parte do usuário, incluindo a maneira como ele tolera erros de operação.

Eficiência: é avaliada através da quantidade de recursos de computação e de código exigida para que um programa execute sua função. É composta pelas seguintes subcategorias:

- Comportamento em relação aos recursos: Quanto de recurso utiliza?
- Comportamento em relação ao tempo: Qual é o tempo de resposta e de processamento?

Segurança: é o aspecto relacionado com a capacidade do software de impedir o uso do programa ou acesso aos dados por pessoas não autorizadas. É composta das seguintes subcategorias: confidencialidade, integridade, não repúdio, responsabilização e autenticação. Sendo também conhecidos como CID, os três principais critérios de Segurança da Informação: Confidencialidade, Integridade e Disponibilidade.

Manutenibilidade: é mensurada verificando-se o grau de esforço exigido para localizar, melhorias e reparo de erros e facilidade de modificação do software. Suas subcategorias são:

- Analisabilidade: identifica a facilidade em se diagnosticar eventuais problemas e identificar as causas das deficiências ou falhas.
- Modificabilidade: caracteriza a facilidade com que o comportamento do software pode ser modificado.
- Estabilidade: avalia a capacidade do software de evitar efeitos colaterais decorrentes de modificações introduzidas.
- Testabilidade: representa a capacidade de se testar o sistema modificado, tanto quanto as novas funcionalidades quanto as não afetadas diretamente pela modificação.
- Conformidade: com relação a requisitos funcionais e de desempenho que foram explicitamente declarados, a padrões de desenvolvimento claramente documentados, e a características implícitas que são esperadas de todo software.

Portabilidade: é o esforço necessário para transferir o programa de um ambiente de hardware e/ou sistema operacional para outro. Deve-se considerar todos os fatores de adaptação, tais como diferentes condições de infraestrutura (sistemas operacionais, versões de bancos de dados, etc.), diferentes tipos e recursos de hardware tal como aproveitar um número maior de processadores ou memória.

Suas subcategorias são:

- Adaptabilidade: representando a capacidade do software de se adaptar a diferentes ambientes sem a necessidade de ações adicionais (conFigurações).
- Capacidade para ser instalado: identifica a facilidade com que se pode instalar o sistema em um novo ambiente;
- Coexistência: mede o quão facilmente um software convive com outros instalados no mesmo ambiente;
- Capacidade para substituir: representa a capacidade que o sistema tem de substituir outro sistema especificado, em um contexto de uso e ambiente específicos. Este atributo interage tanto com adaptabilidade quanto com a capacidade para ser instalado.

Compatibilidade: é o grau em que um produto, sistema ou componente pode trocar informações com outros produtos, sistemas ou componentes, e/ou realizar as suas funções necessárias, ao compartilhar o mesmo ambiente de hardware ou software. Suas subcategorias são: coexistência e interoperabilidade.

Ainda segundo a Norma ISO 9126 é praticamente impossível medir todas as sub características para todas as partes de um produto de software de grande porte. Da mesma forma, em geral não é prático medir qualidade em uso para todos os possíveis cenários de uso.

Baseado no trabalho de Silva (SILVA, 2018), três testes serão realizados nesta pesquisa: usabilidade, funcionalidade e aprendizado.

3.5.1 Usabilidade

(NIELSEN, 1994) define usabilidade como o grau de satisfação e eficiência que um usuário de um determinado sistema computacional pode atingir, em função dos objetivos específicos do trabalho, num dado ambiente. A usabilidade é um conceito o qual se refere à qualidade da interação de sistemas com os usuários e depende de vários aspectos. Alguns destes princípios são:

- Facilidade de aprendizado do sistema - é o tempo e o esforço necessários para os usuários atingirem um determinado nível de desempenho;

- Facilidade de uso - avalia o esforço físico e cognitivo do usuário durante o processo de interação;
- Satisfação do usuário - que avalia se o usuário gosta e sente prazer em trabalhar com este sistema;
- Flexibilidade - que avalia a possibilidade do usuário utilizar o sistema de maneira inteligente e criativa, realizando um maior número de tarefas com as mesmas funções e comandos do sistema, ou seja, o sistema deve prover mais de uma maneira de realizar uma mesma tarefa.
- Produtividade - se o sistema permite ao usuário ser mais produtivo do que seria se não utilizasse o sistema.

Critérios de Avaliação de Usabilidade

As avaliações são desenvolvidas com a utilização de três avaliadores profissionais da área de informática. Sua finalidade é medir a consistência da interface do sistema, estrutura do layout, o acesso às funcionalidades do sistema para, enfim, determinar o grau de satisfação do usuário na utilização da interface do sistema (NIELSEN, 1994). Para medir a usabilidade de um sistema (BROOKE, 1986), propôs a escala SUS (*System Usabilidade Scale*) que atribui um grau de usabilidade a um sistema. Essa escala foca na efetividade, eficiência e satisfação do usuário na utilização da interface. São apresentados dez quesitos a serem respondidos por avaliadores. A medida da usabilidade é obtida a partir da resposta de 10 quesitos respondidos utilizando a escala SUS, de cinco valores. Para a compilação dos cálculos da medição, (BROOKE, 1986) propôs um cálculo obtido em duas fases. Para as respostas das questões ímpares, subtrai-se de 1 da pontuação que o usuário respondeu e nas questões pares, subtrai-se 5 à resposta do usuário. Ao final, soma-se todos os valores obtidos das 10 questões e multiplica-se por 2,5. Em seguida é calculada a média final de onde se obtém a pontuação SUS. O resultado estará sempre no intervalo de 0 a 100.
O questionário é composto por 10 perguntas padrões conforme descrição no apêndice A.
Ainda, segundo (BROOKE, 1986) um aplicativo para ser considerado de boa usabilidade, deverá obter média final mínima de 68 pontos, conforme descrição no apêndice A.

3.5.2 Teste de Funcionalidade

Este teste, também chamado de teste *caixa-preta*, é baseado nos requisitos funcionais do sistema e será aplicado a estudantes de professores ou profissionais de imagens médicas após a utilização do sistema. Esta técnica não está preocupada com o comportamento interno do sistema durante a execução do teste, mas sim com a saída gerada após a entrada dos dados especificados. Este teste está focado a responder se o sistema funciona ou não de maneira adequada segundo suas próprias funcionalidades e, neste caso, deverá responder o quanto o sistema auxilia naquilo que se propõe, ou seja, o ensino e aprendizagem de interpretação de imagens médicas.

Os participantes do teste de funcionalidade receberão um roteiro de tarefas (Apêndice C) a serem executadas que exploram as funcionalidades da plataforma. Depois dessa interação, será aplicado o teste a cinco professores ou profissionais de imagens médicas e aos estudantes. Foram desenvolvidos dois questionários com 10 questões relativas ao uso das funcionalidades da plataforma, baseados no trabalho de Silva (SILVA, 2018), um para professores e outro para estudantes do grupo GE. Os dois questionários são necessários porque existem diferenças de funcionalidades da plataforma para cada um deles (Apêndice B). Cada questão estará vinculada a uma resposta baseada na escala Likert (LIKERT, 1932) de 5 valores dispostos conforme descreve o Quadro 7:

Quadro 7 - Escala Likert

Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
○	○	○	○	○
1	2	3	4	5

Fonte: LIKERT, 1932

O Teste de funcionalidade baseado na escala Likert, permite o teste quantitativo das respostas. No caso desta escala, quanto mais as questões se aproximam do valor 5, maior a funcionalidade. Para realizar o teste dos resultados foi utilizada a moda obtida em cada questão respondida por cada usuário, ou seja, professores e estudantes.

3.5.3 – Teste de Aprendizado

Para avaliar um software da área educacional é necessário levar em consideração não apenas critérios técnicos da área de engenharia de software e interação homem-computador, mas também em critérios vinculados às características educacionais oriundos da área ao qual se pretende ensinar.
O teste de aprendizado consta do uso da plataforma tanto pelo professor quanto o aluno. O professor utilizará a plataforma para irá elaborar um questionário de 10 questões para que os estudantes possam responder.
Foi programado um período de um mês que ocorrerão no ano 2023 a professores e alunos para utilização da plataforma utilizando laboratórios de informática nas dependências da Universidade de Mogi das Cruzes para poder treinar e rever o conteúdo postado na plataforma. Ao final deste período de uso e treinamento os estudantes passarão por um teste de conhecimentos e habilidades sobre o conteúdo ministrado pelo professor no transcorrer da disciplina de imagenologia durante este período.

3.5.4 – Local e Realização da Pesquisa

A pesquisa será realizada no laboratório de informática nas dependências da Universidade de Mogi das Cruzes situada à Av. Dr. Cândido Xavier de Almeida e Souza, 200 Mogi das Cruzes – SP, porém o aluno também poderá fazer a opção de respondê-lo on-line.

3.5.5 – Amostragens

Serão necessários três universos de amostras, cada um com suas particularidades: São elas:

Amostragem para Teste de Usabilidade

Para o teste de usabilidade foram convidados vinte e dois avaliadores profissionais da área de informática que responderão o Apêndice A. De acordo com a

Resolução 510 de 07 de abril de 2016, por se tratar de opinião de especialistas não há a necessidade de passá-los pelo Comitê de ética.

Amostragem para Teste de Funcionalidade

Este teste, também chamado de teste caixa-preta, é baseado nos requisitos funcionais da plataforma e será aplicado a estudantes, professores ou profissionais de imagens médicas após a utilização da plataforma. Esta técnica não está preocupada com o comportamento interno da plataforma durante a execução do teste, mas sim com a saída gerada após a entrada dos dados especificados. Este teste está focado a responder se a plataforma funciona ou não de maneira adequada segundo suas próprias funcionalidades e, neste caso, deverá responder o quanto a plataforma auxilia naquilo que se propõe, ou seja, o ensino e aprendizagem de interpretação de imagens médicas (Apêndice B).

Amostragem para Teste de Aprendizado

Para o teste de aprendizado, serão convidados a participar como voluntários desta pesquisa uma amostra de 104 estudantes regularmente matriculados no curso de medicina da Universidade de Mogi das Cruzes e que já tenham cursado ao menos o sexto período. Embora o número de matriculados seja maior que este universo, é factível que haja recusas e desistências na participação. Os estudantes serão divididos em dois grupos de indivíduos de forma aleatória, sendo:

- **GC (Grupo Controle - Sem utilizar a plataforma patologIA):** O professor apresentará o conteúdo de sua aula de maneira convencional de acordo com seus princípios.
- **GE (Grupo Experimental - que utilizou a plataforma patologIA):** O professor apresentará o conteúdo de maneira convencional e em seguida apresentará a plataforma aos estudantes.

O convite foi feito ao estudante selecionado de maneira aleatória para o Grupo Experimental.

Os participantes do teste de aprendizado receberão um roteiro de tarefas (Apêndice B) a serem executadas que exploram as funcionalidades do sistema.

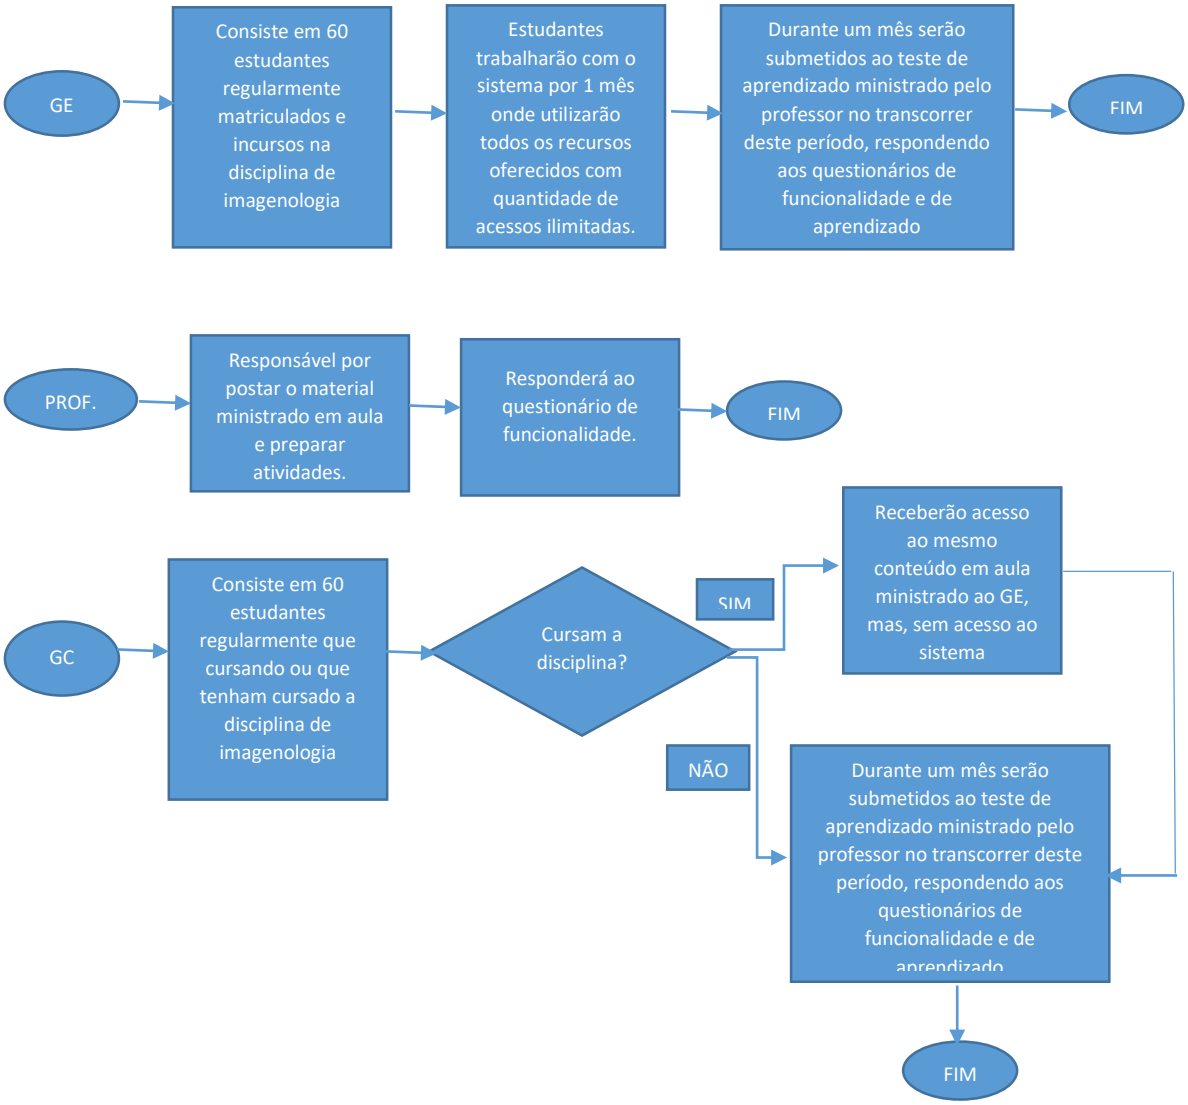
Ao final deste período, o professor deverá responder ao questionário de funcionalidade do sistema e os estudantes de ambos os grupos ao teste de aprendizado fundamentado no conteúdo da disciplina ministrada pelo professor e medirá o conhecimento em análise e interpretação de imagens adquirido no transcorrer da disciplina. O teste deverá ter 10 questões e será criado pelo professor da disciplina cuja pontuação será determinada por ele utilizando o próprio sistema.

Em seguida, receberão um questionário (Apêndice B) com 10 perguntas objetivas a serem respondidas a fim de apurar a funcionalidade utilizando o sistema.

Ao final será calculada a média aritmética, moda e desvio padrão dos dois grupos de estudantes e dos professores a fim de comparar o desempenho alcançado por cada grupo e apurar se houve aprimoramento de conhecimentos em virtude do uso do sistema.

A Figura 49 exibe o fluxograma com a sugestão de estruturação dos grupos e das tarefas a serem efetivadas:

Figura 49 - Fluxograma de Testes



No Capítulo 4 serão abordados temas que produziram resultados sobre o sistema como o funcionamento das interfaces, o sistema de funcionamento do questionário proposto ao estudante e como se dará a sua interação com ele, os formulários de demarcação de imagens por professor e alunos e, por fim, o desenvolvimento de um modelo de inteligência artificial para detecção de tuberculose e como o usuário deverá utilizá-lo.

4 – RESULTADOS

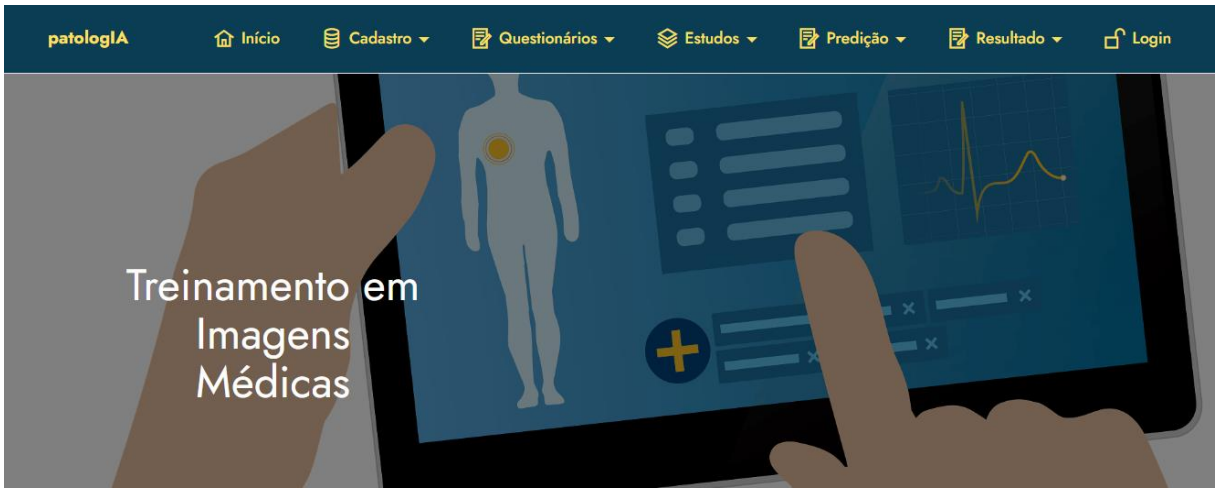
Este capítulo descreve os resultados obtidos pelo sistema. Descreve as funcionalidades das interfaces, o desenvolvimento e as técnicas utilizadas para o desenvolvimento de um modelo de inteligência artificial para detecção de diagnóstico

de tuberculose que constará do módulo de triagem de imagens, identificado na interface como “Predição”.

4.1 IMPLEMENTAÇÃO DAS INTERFACES

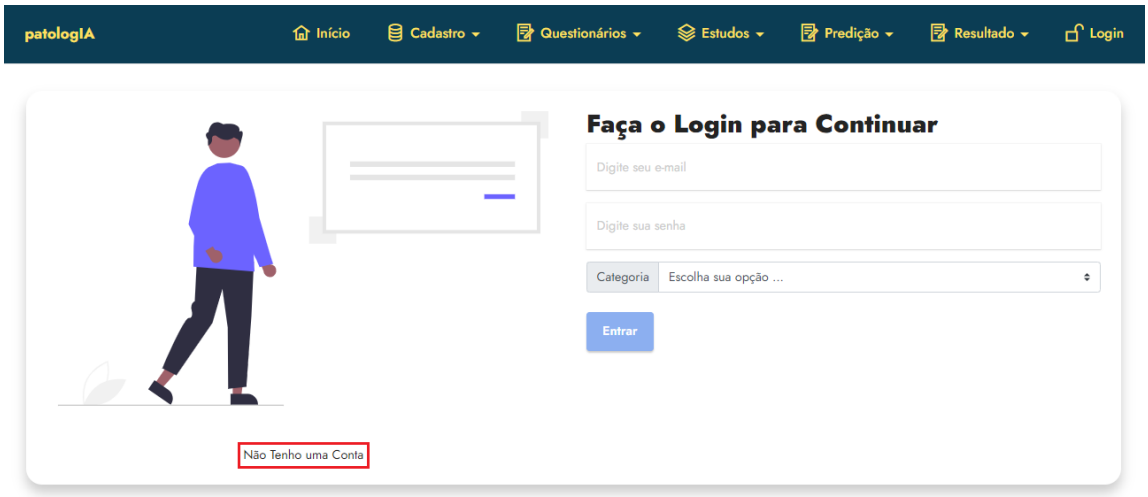
A partir da elaboração das interfaces, foram desenvolvidas as telas que irão integrar o protótipo do sistema. A Figura 50 ilustra a tela principal com o menu de opções, conforme o projeto de Figura 40. Essa interface estará com os menus bloqueados ao usuário enquanto este não se autenticar na plataforma, com exceção do menu *Login*.

Figura 50 - Interface da Tela Principal



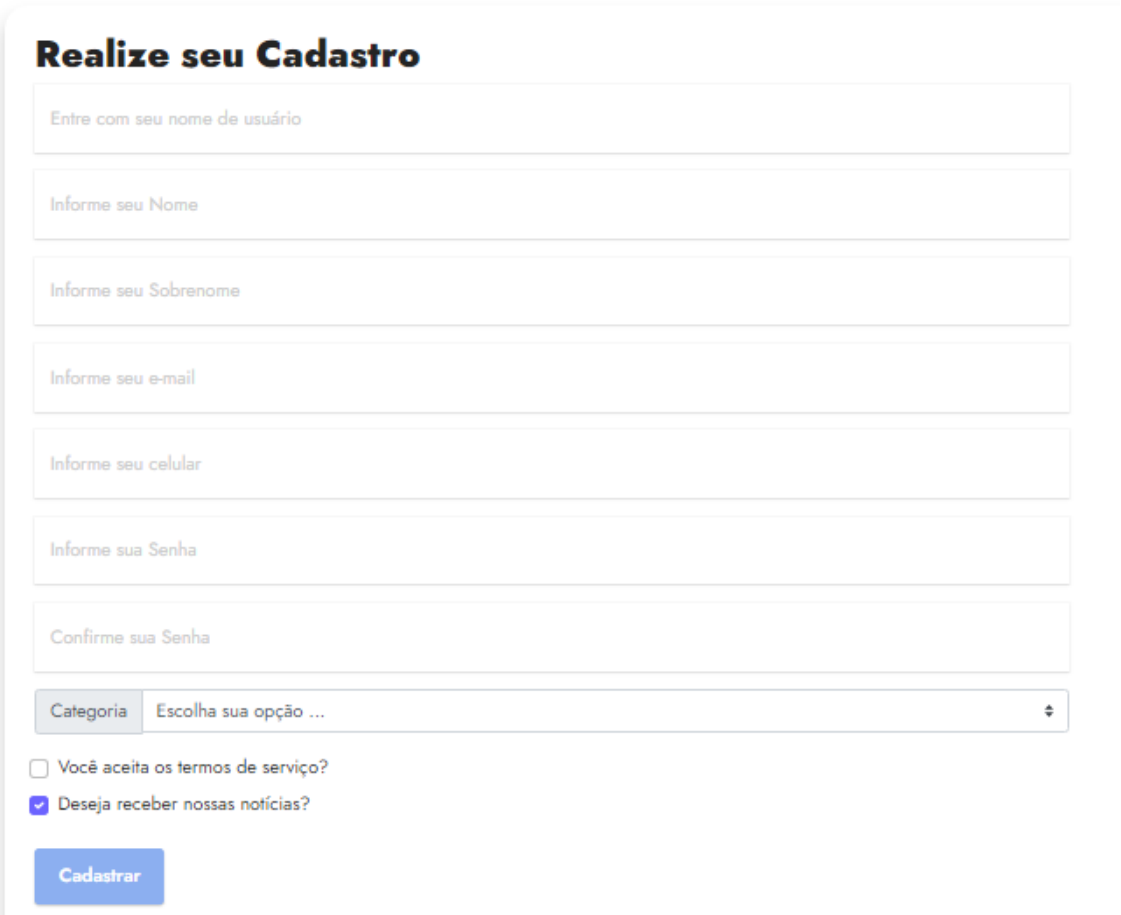
A tela de *Login* foi projetada para oferecer a opção ao usuário de se cadastrar como estudante, professor ou convidado. O usuário deverá preencher o formulário com seu e-mail, senha e selecionar sua categoria. Caso não esteja cadastrado na plataforma, poderá acionar a opção “Não tenho uma conta” para efetuar seu registro, conforme Figura 51.

Figura 51 - Interface da tela de Login



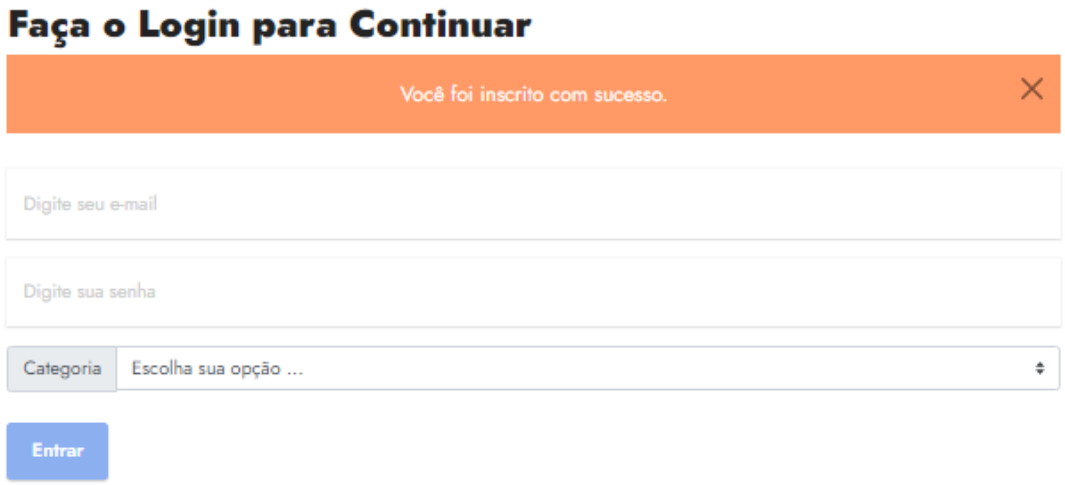
A Figura 52 exibe o formulário de cadastro dos dados do usuário visando sua autenticação à plataforma.

Figura 52 - Interface de Cadastro do Usuário



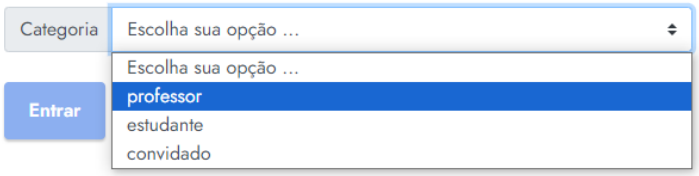
Após preencher os dados, o usuário recebe uma mensagem da plataforma onde é informado sobre o sucesso da operação de cadastro conforme ilustra a Figura 53.

Figura 53 - Mensagem de Sucesso do Cadastro do Usuário



Assim, o usuário é conduzido a preencher seus dados conforme sua inscrição cadastral. Ao selecionar o componente de escolha da categoria, o usuário visualizará a seguinte lista de opções, onde poderá escolher entre professor, estudante ou convidado conforme a Figura 54.

Figura 54 - Lista de Opções para Categoria de Usuário



Ao clicar sobre o botão “Entrar” o usuário irá acessar a plataforma que informará sobre o sucesso do acesso ou não. As funcionalidades dos menus serão desbloqueadas conforme o contexto da categoria do usuário. O professor terá acesso a todas as funcionalidades da plataforma. O estudante e o convidado terão acesso restrito às respostas aos questionários elaborados pelo professor. O estudante terá sua pontuação e respostas dos questionários registradas no banco de dados. O convidado

terá acesso à sua pontuação, mas esta não será registrada no banco. A Figura 55 mostra a mensagem de sucesso na autenticação do usuário à plataforma.

Figura 55 - Mensagem de Sucesso na Autenticação da Plataforma



A Figura 56 mostra a interface de cadastro de um arquivo de imagem pelo professor autenticado. Um número de identificação é gerado automaticamente pelo sistema. O usuário é conduzido a escolher um arquivo de imagem ao acionar o botão "*browse*". A rota do repositório onde está o arquivo, deverá ser armazenada no banco de dados. A imagem será exibida do lado esquerdo da tela, em substituição à Figura existente nesta posição. Define-se a data do cadastro e, a seguir, são apresentados três componentes onde será selecionada uma opção em cada para determinar o tipo, nível e especialidade da imagem.

Figura 56 - Cadastro de Imagens



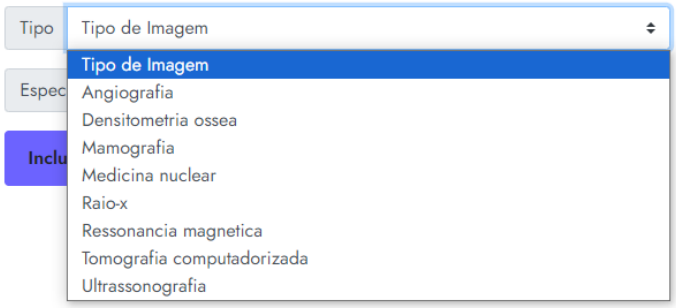
A Figura 57 mostra a escolha de um arquivo de imagem a ser cadastrada no sistema:

Figura 57 - Cadastro de Imagens



A Figura 58 mostra as opções de classificação para tipo de imagem que poderão ser incluídas. Existe outra interface para se cadastrar os tipos de imagens que serão apresentados neste componente, conforme projeto de interface da Figura 41.

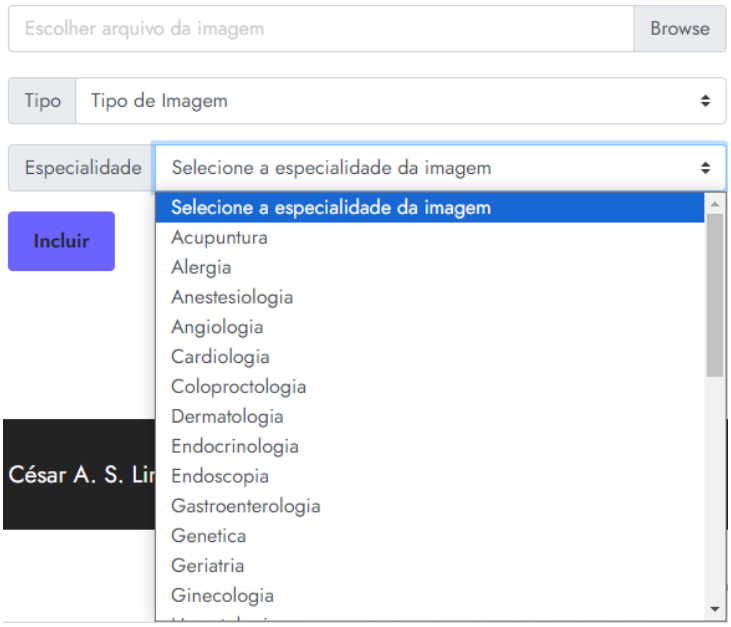
Figura 58 - Lista de Tipos de Imagens



A plataforma exibe os tipos de arquivos da imagem a ser estudada. Os arquivos são classificados em DCM (DICOM - *Digital Imaging and Comunications in Medicine*), PNG (*Portable Network Graphic*), TIF (*Tag Image File Format*), JPG (*Joint Photographic Experts Group*).

A Figura 59 permite vincular a imagem à especialidade ao qual ela pertence.

Figura 59 - Especialidade da Imagem

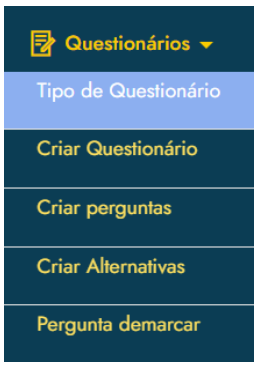


4.1.1 – Elaboração de Questionário de Múltipla Escolha

A elaboração de um questionário pelo professor é uma operação que exigirá sua iteração com três interfaces em sequência, uma após outra.

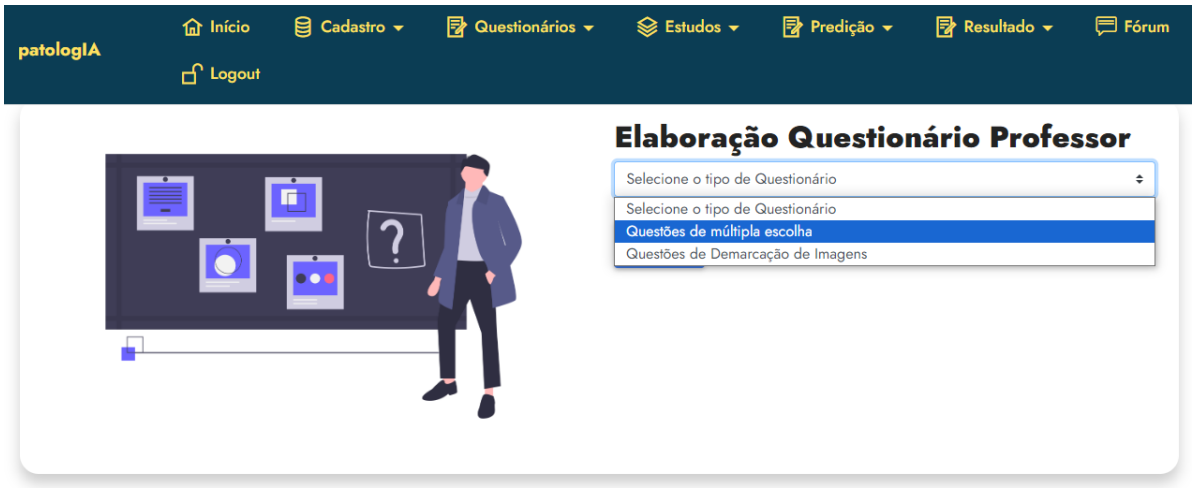
A primeira interface, exibida na figura 50, é acessada através do menu Questionários → Tipo de Questionário demonstrado na Figura 60.

Figura 60 - Menu da Escolha do Tipo de Questionário



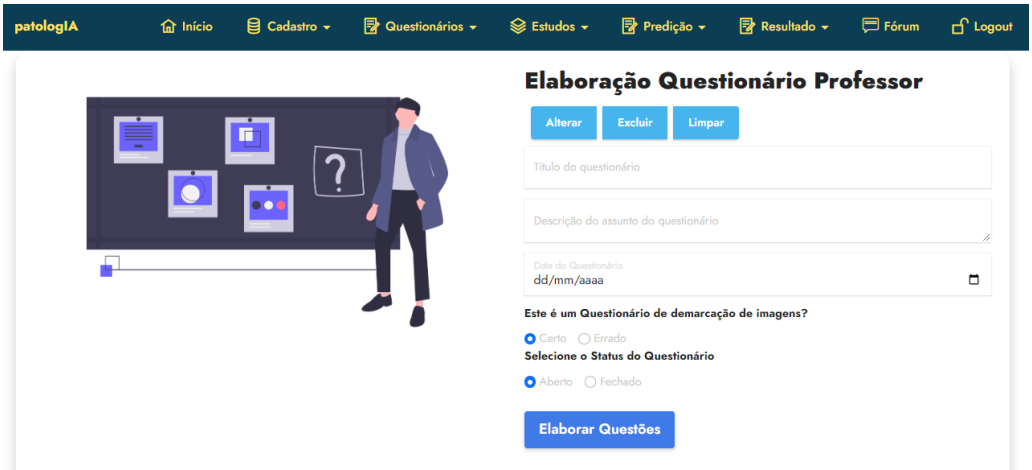
A Figura 61 solicita ao usuário que escolha um dos dois tipos de questionários a ser elaborado pela plataforma, ou seja, “Questões de Múltipla Escolha” ou “Questões de demarcação de Imagens”.

Figura 61 - Selecionando o Tipo de Questionário



Caso a escolha seja o tipo “Questões de Múltipla Escolha”, a interface irá solicitar dados como o título do questionário e a descrição ou assunto que será tratado no questionário e sua data de criação. Em seguida, o usuário deverá responder a pergunta se “Este é um Questionário de demarcação de imagem” e selecionar a opção “Errado” para este caso. Por fim, deverá selecionar a opção para determinar o status do questionário que poderá estar aberto aos estudantes ou fechado quando o prazo determinado pelo professor se expirar, conforme Figura 62.

Figura 62 - Elaboração do Questionário pelo Professor



A segunda interface, exibida na figura 63, consiste na de elaboração de uma questão que irá compor o questionário. Nela, o usuário deverá selecionar o componente tipo *DropDown* para selecionar o título do questionário o qual a questão deverá ser

vinculada. A descrição da questão será ser seu enunciado a ser respondido pelo estudante. O professor poderá determinar o valor da questão no questionário e poderá escolher o número da imagem ou não para ilustrar o enunciado da questão. O usuário poderá conferir o número da imagem ao clicar na frase “Clique aqui para ver a referência”.

Figura 63 - Elaboração da Questão



O usuário poderá conferir o número da imagem desejada ao clicar na frase “Clique aqui para ver a referência”, demonstrada na Figura 64:

Figura 64 - Listagem de Imagens Cadastradas na Plataforma



A terceira, exibida na figura 65, é a interface de elaboração das alternativas da questão. Nela existe um componente do tipo *DropDown* onde o usuário deverá

selecionar a descrição da questão elaborada na interface da Figura 62. Em seguida deverá informar a descrição e a identificação (A, B, C, D, E, etc) da alternativa. Por fim, a deverá selecionar o status da alternativa para determinar se ela é a resposta certa ou errada.

Figura 65 - Interface de Elaboração de Alternativas



As questões formuladas para este exemplo foram retiradas da prova do concurso público do CREMESP para o cargo de médico da instituição aplicado no ano de 2009, elaborada pela Fundação Carlos Chagas, entidade responsável pela elaboração das provas aplicadas pelo CREMESP aos estudantes dos cursos de medicina do estado de São Paulo. Este exame e seu gabarito oficial está disponível no sítio eletrônico pci concursos[17] cujo acesso deu-se em 25/05/2021.

O questionário a ser respondido por um usuário autenticado como estudante é constituído de um título, o número da questão a ser respondida e o número de questões existentes no questionário, o enunciado da questão, a imagem a ser estudada e as alternativas elaboradas como respostas. Neste exemplo, cada questão correta recebe o valor 10 como pontuação. A figura 66 mostra a questão 1 deste questionário, conforme projetado na figura 45:

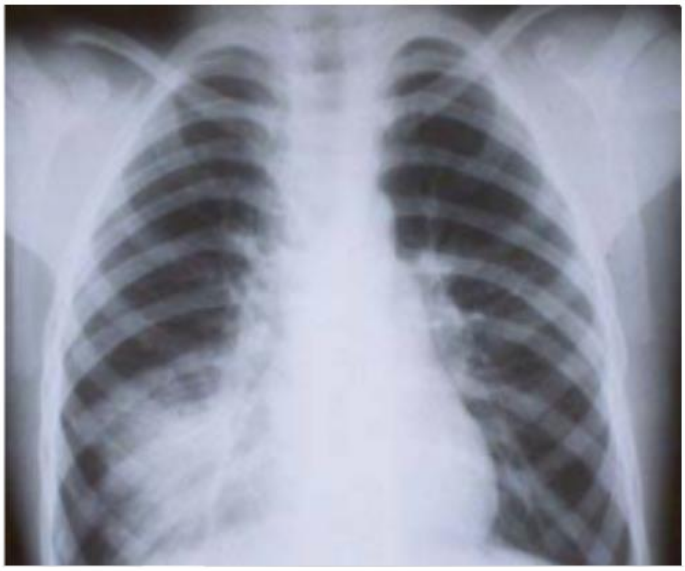
[17] https://www.pciconcursos.com.br/provas/download/medico-cremesp-sp-fcc-2009

Figura 66 - Questão 0/2 a ser Respondido pelo Estudante

Concurso Público para Médico

Questão 0/2

Pontuação 0

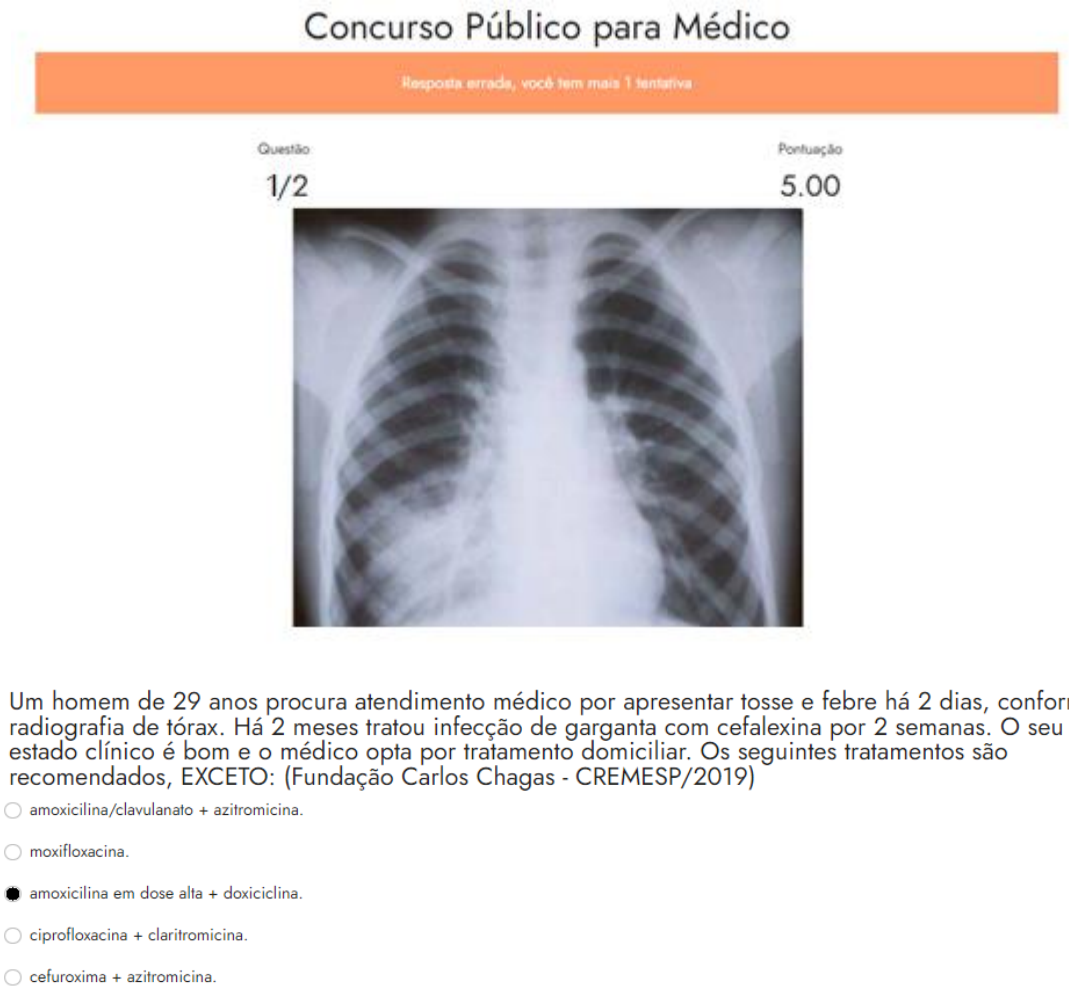


Um homem de 29 anos procura atendimento médico por apresentar tosse e febre há 2 dias, conforme radiografia de tórax. Há 2 meses tratou infecção de garganta com cefalexina por 2 semanas. O seu estado clínico é bom e o médico opta por tratamento domiciliar. Os seguintes tratamentos são recomendados, EXCETO: (Fundação Carlos Chagas - CREMESP/2019)

- amoxicilina/clavulanato + azitromicina.
- moxifloxacina.
- amoxicilina em dose alta + doxiciclina.
- ciprofloxacina + claritromicina.
- cefuroxima + azitromicina.

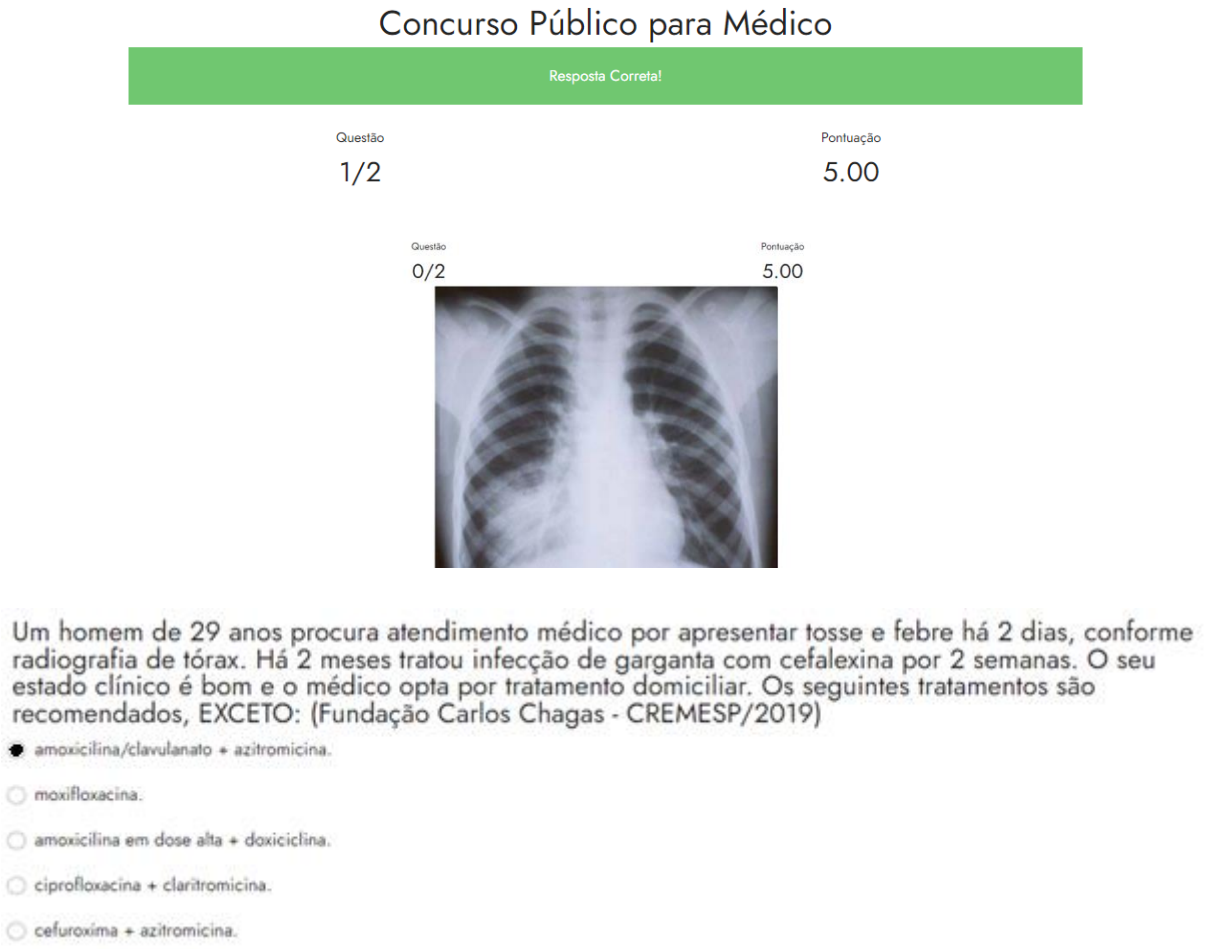
A resposta correta seria a alternativa “A”. Caso o estudante responda uma alternativa diferente, a plataforma permite ao estudante uma segunda chance para responder, mas, penalizando-o em 50% de perda na pontuação em caso de acerto na nova chance conforme ilustra a Figura 67:

Figura 67 - Resposta do Estudante com erro ao Questionário



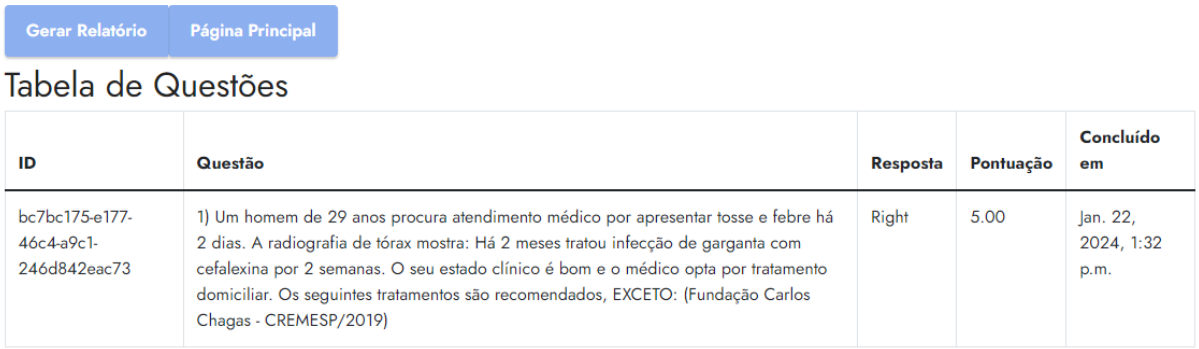
Em caso de acerto o questionário passa à próxima questão com a pontuação atualizada conforme como mostra a Figura 68, conforme projetado na Figura 46:

Figura 68 - Resposta do Estudante com acerto ao Questionário



No exemplo acima, a resposta correta seria a alternativa “A”. Se o estudante acertar essa resposta na segunda tentativa, recebe um desconto de 50% em sua pontuação. Ao terminar de interagir com o questionário, o estudante deverá acionar o Menu Resultados para tomar ciência de sua pontuação conforme ilustra a figura 69:

Figura 69 - Resultado da Pontuação do Estudante

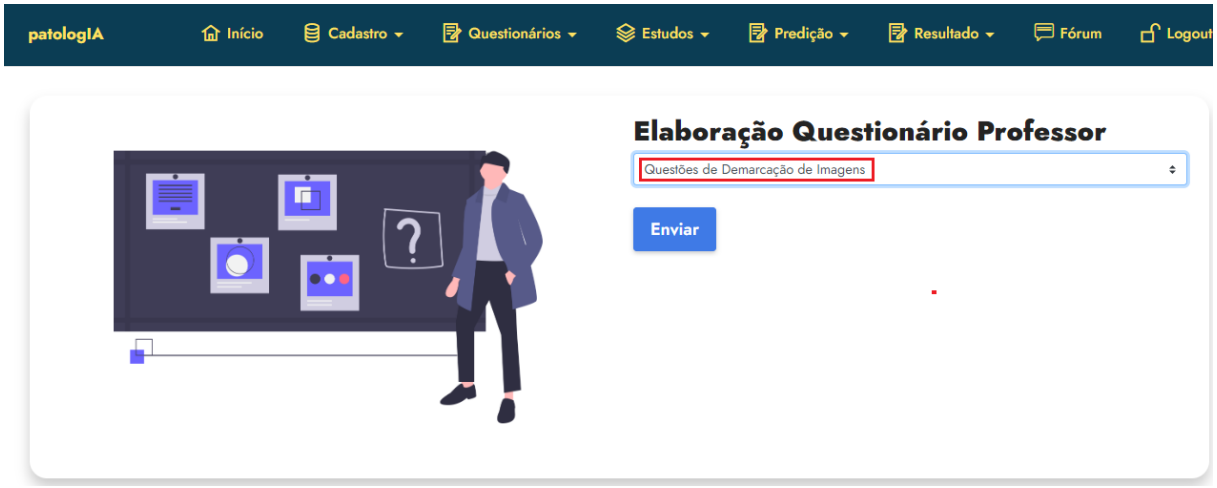


Ao clicar no botão “**Gerar Relatório**”, a plataforma permite exportar este relatório para uma planilha do Excel em arquivo .xls. Ainda na figura 69 é possível observar que o número ID é criptografado por questões de segurança.

4.1.2 – Elaboração do Questionário de Demarcação de Imagens

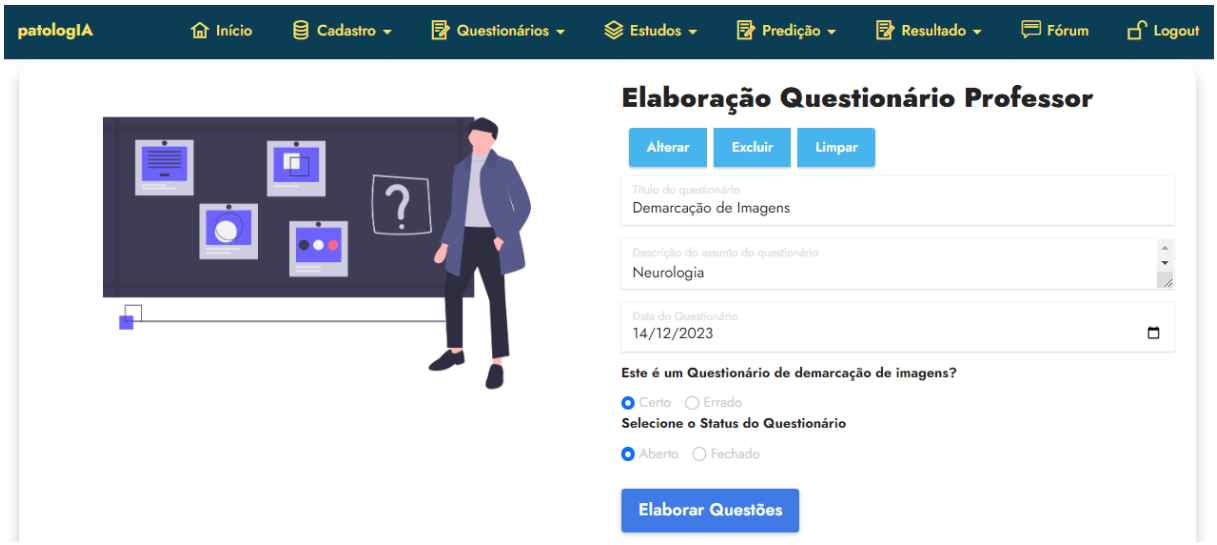
Este é outro tipo de questionário oferecido pela plataforma. Permite ao professor demarcar áreas de interesse de imagens médicas para finalidade de estudos. Após carregar a imagem desejada o professor demarca a área de interesse a ser estudada. Ao encerrar esta operação, a imagem será disponibilizada para teste ao estudante.
A dinâmica para se criar um questionário de demarcação de imagens é parecida com a do questionário de múltipla escolha.
No Menu Questionário, o usuário deverá selecionar o item “Tipo de Questionário” e, em seguida, selecionar “Questões de Demarcação de Imagens” e clicar no botão “Enviar” conforme ilustra a Figura 70:

Figura 70 - Selecionando o Tipo de Questionário para Demarcação de Imagens



Em seguida, o usuário deverá preencher os dados do formulário para elaboração do questionário de demarcação de imagens conforme ilustra a Figura 71.

Figura 71 - Elaboração do Questionário de Demarcação de Imagens



Ao clicar no botão “Elaborar Questões” o usuário será transportado à próxima interface onde deverá preencher os dados referentes à questão do questionário conforme ilustra a Figura 72:

Figura 72 - Elaboração das Questões de Demarcação de Imagens



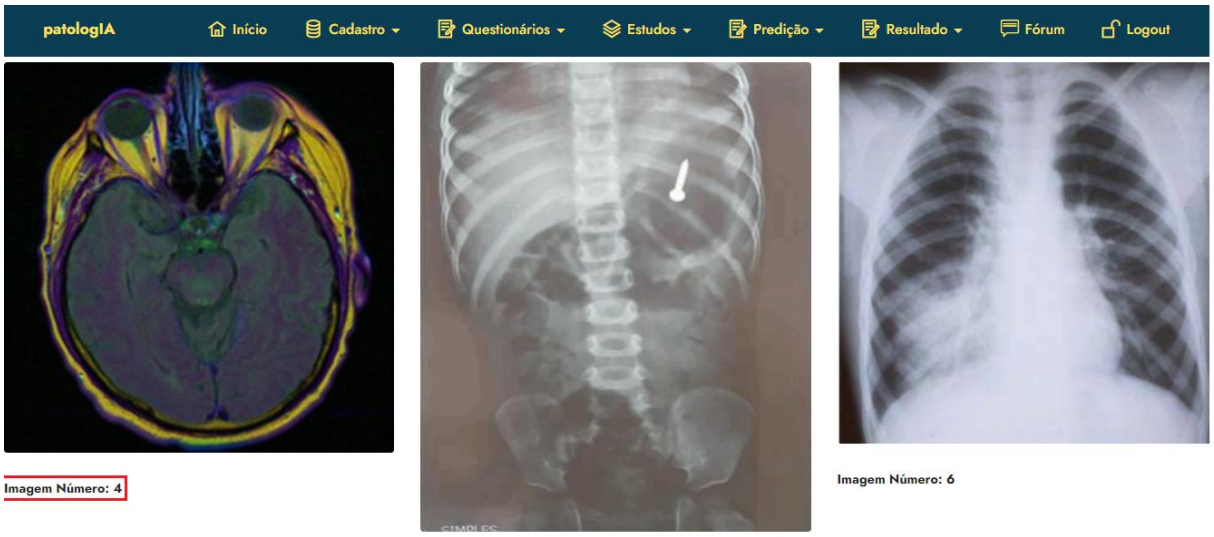
Ao clicar no botão “Selecione a Imagem” o usuário é solicitado a informar o número da imagem a ser carregada na questão. Caso queira consultar o número da imagem, basta clicar no link “Clique aqui para ver a referência” conforme mostra a Figura 73:

Figura 73 - Consultando o Número de Referência da Imagem



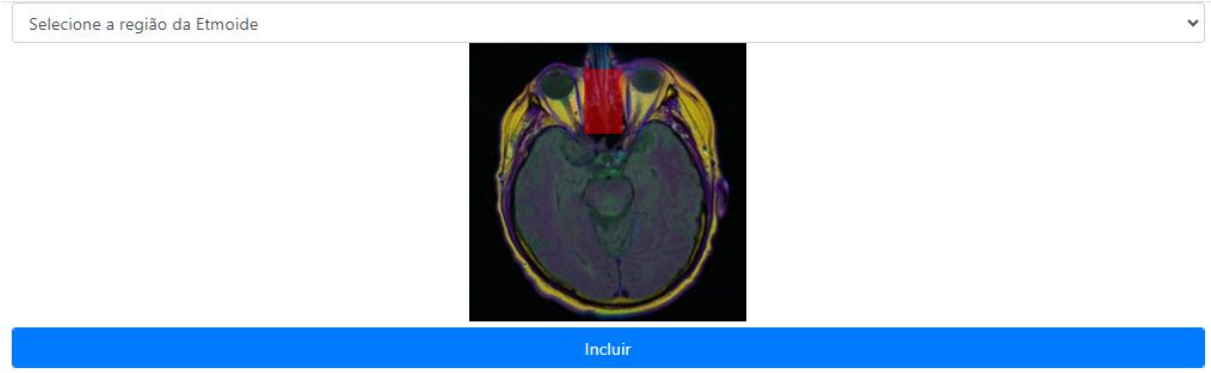
Neste exemplo a imagem escolhida será a de número 4 conforme a lustração do Figura 74:

Figura 74 - Consultando o Número de Referência da Imagem



Ao clicar no botão “Criar Demarcação” da Figura 73, o usuário será transportado à nova interface onde deverá selecionar o texto da questão elaborada e realizar a demarcação desejada utilizando o mouse para demarcar a região desejada. Ao final deverá clicar no botão “Incluir” para finalizar a operação, conforme ilustração da Figura 75:

Figura 75 - Demarcação da Imagem Utilizando o Mouse

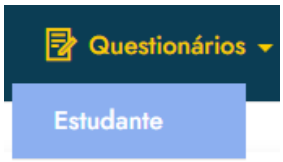


A partir deste instante, a questão de demarcação de imagem estará disponível para teste ao estudante.

4.1.3 – A Interação do Estudante com o Questionário de Demarcação de Imagens

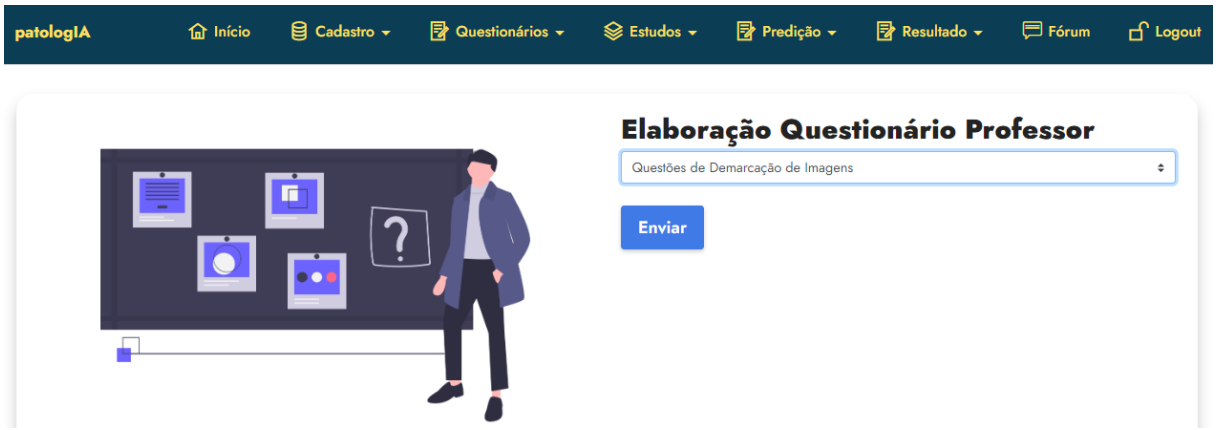
O estudante deverá se autenticar na plataforma e acionar o Menu Questionários e, em seguida, em “Estudante”, conforme ilustra a Figura 76:

Figura 76 - Menu Questionário Acionado por um Estudante



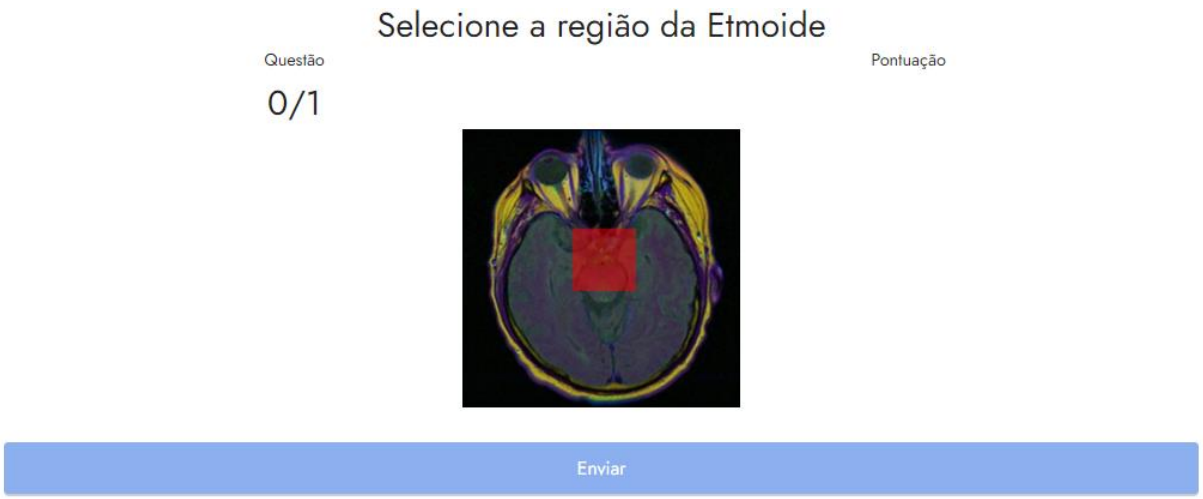
Em seguida, o usuário estudante deverá selecionar o tipo de questionário de “Demarcação de Imagens” e clicar no botão “Enviar”, conforme ilustra a Figura 77:

Figura 77 - Selecionando o Tipo de Questionário de Demarcação de Imagens



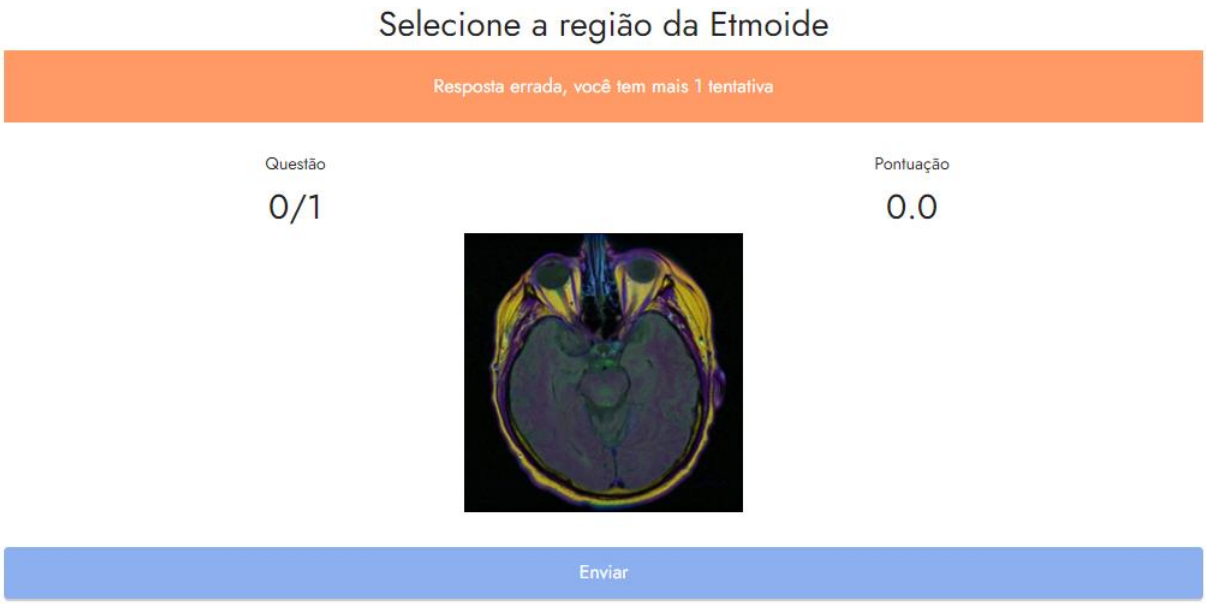
O estudante será transportado à interface da questão elaborada pelo professor. Neste exemplo, ela faz a demarcação de uma região errada conforme mostra a ilustração da Figura 78:

Figura 78 - Realizando a Demarcação na Região Errada da Imagem



Para concluir a tarefa o estudante deverá acionar o botão **Enviar**. Como a demarcação foi feita em região errada da imagem, a plataforma irá informar sobre o acontecido conforme ilustra a Figura 79:

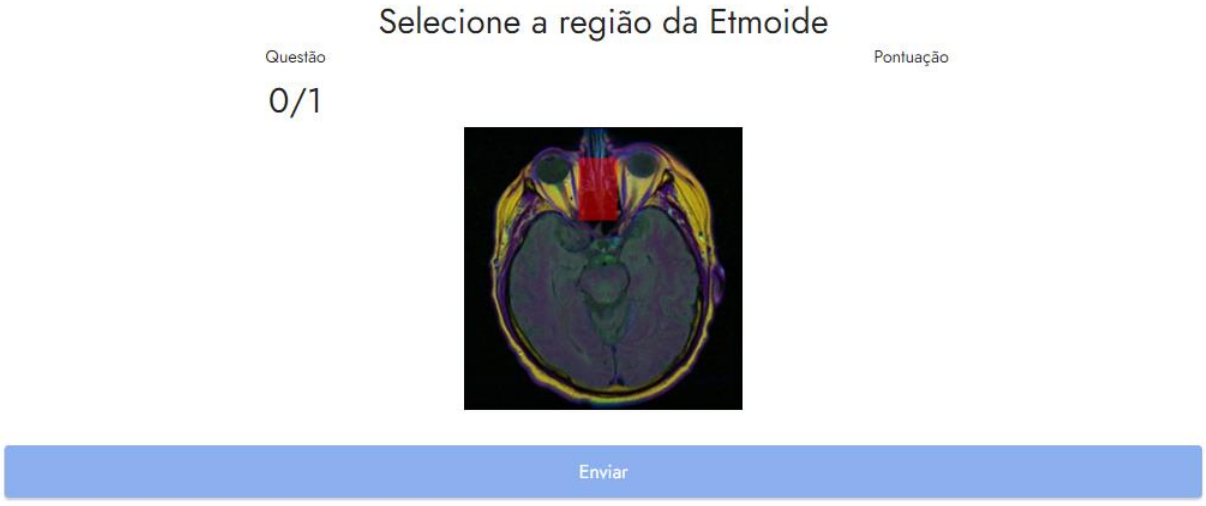
Figura 79 - Resposta da Plataforma à Demarcação Errada na Imagem



A plataforma permite mais uma chance para que o estudante repita sua resposta.

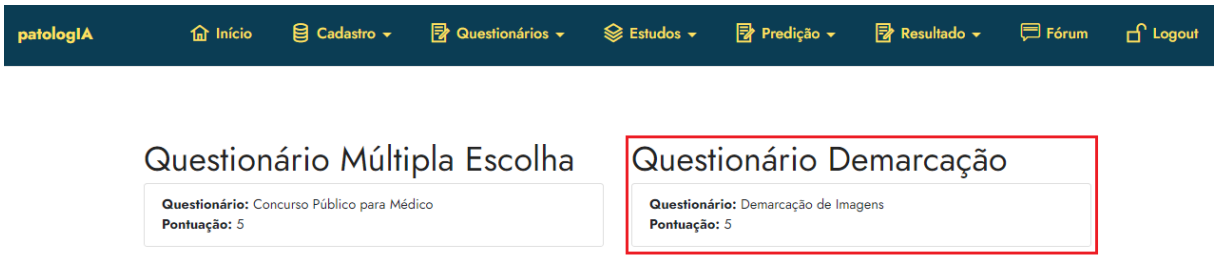
Na Figura 80, o estudante realiza a demarcação de forma correta na imagem. A plataforma permite que o estudante cometa um erro de 10% com relação às coordenadas definidas pelo professor que ainda será considerada correta.

Figura 80 - Resposta da Plataforma à Demarcação Correta na Imagem



Neste exemplo, como o estudante obteve sucesso na segunda tentativa, a plataforma encerra o procedimento e o estudante deve consultar a pontuação no Menu Resultados, conforme ilustra a Figura 81:

Figura 81 - Resultado do Questionário de Demarcação de Imagens



4.1.3.1 – Mecanismo de Captura de Coordenadas de Demarcação de Imagens

Para realizar essa tarefa foram utilizadas tecnologias de ***FrontEnd*** como a linguagem ***JavaScript*** em conjunto com a ferramenta ***Canvas*** da linguagem ***HTML5*** e de ***BackEnd*** através da linguagem de programação ***Django***.

No ***FrontEnd***, o primeiro passo foi criar uma função ***JavaScript*** para carregar uma imagem na tela. Esta função contém atributos que detectam a largura e a altura da imagem original.

O segundo passo foi utilizar o método ***addEventListner()*** do ***Canvas*** onde é passado como parâmetro o evento ***mousedown*** cuja função é resgatar as coordenadas dos pontos **x** e **y** onde o botão do ***mouse*** é pressionado sobre a imagem.

Em seguida, utiliza-se novamente, o método ***addEventListner()*** do ***Canvas*** onde é passado como parâmetro o evento ***mousemove*** que verifica se o movimento do mouse está dentro dos limites da imagem e permite desenhar uma Figura geométrica para demarcar a área desejada da imagem utilizando a movimentação de arrasto do mouse simultaneamente com o botão pressionado onde, também, é possível obter a largura e altura deste retângulo. Neste caso, foi desenvolvido um retângulo na cor vermelha.

Por último, o método ***addEventListner()*** do ***Canvas*** onde é passado como parâmetro o evento ***mouseup*** foi utilizado para resgatar os pontos x e y das coordenadas finais do retângulo bem como sua largura e altura no momento em que o botão do mouse é solto.

Este procedimento de demarcação é utilizado tanto pelo professor no momento de formular o questionário, quanto ao estudante em resposta ao questionário criado pelo professor.

Os dados são transportados do sistema *Frontend* para o *backend* através de um método de envio da dados denominado *POST* que é configurado no *django* através do arquivo *views.py*. Neste arquivo existem métodos que recebem os dados da demarcação da imagem feita pelo professor e registrada no banco de dados.

Existe outro método que recebe os dados da demarcação da imagem feita pelo estudante para ser confrontada aos dados do professor armazenados no banco. Os dados da demarcação do professor como as coordenadas iniciais x e y, largura e altura e as coordenadas finais x e y da área do retângulo são recuperados e comparados aos mesmos dados de demarcação do estudante. Existe uma função da linguagem de programação *python*, denominada ***range(start, stop, step)***, que é utilizada para verificar os pontos das coordenadas iniciais e finais tanto para o eixo X como para o eixo Y, e calcular o comprimento de largura e altura do retângulo.

Os parâmetros *start, end e step* são responsáveis para receber os valores das coordenadas do eixo X como *startX*, *endX*, *stepX*, onde, *startX* é o ponto inicial da demarcação no eixo X, *endX* é o ponto final da demarcação no eixo X e *stepX* é a contagem de pixels de um em um existentes entre os pontos startX e endX para determinar o comprimento da largura do retângulo. Em seguida o mesmo processo é feito para as coordenadas do eixo Y para determinar a altura do retângulo.

Esta mesma função ***range()*** foi utilizada para calcular os dados das coordenadas de demarcação do estudante para serem comparadas à dos professores.

Tomando como referência as coordenadas X e Y do professor, foi concedido ao estudante uma taxa de erro em sua demarcação de até 10% para mais ou para menos em suas coordenadas de demarcação X e Y. Dentro do código do sistema este mecanismo foi denominado de intervalo positivo e intervalo negativo. Às coordenadas de X e Y são adicionadas um fator de 10% ou subtraídas neste mesmo fator. Por exemplo, se o valor de X do professor é 100 adicionaremos uma taxa de erro de 10%, salvando-o como uma margem de erro positiva. Em seguida, o mesmo é feito no lado negativo subtraindo e salvando-o como uma margem de erro negativa. Assim, as coordenadas do estudante poderão estar 10% acima de 100 *pixels* ou 10% abaixo de 100 *pixels* que serão consideradas corretas. O mesmo cálculo é efetuado para o eixo de Y. Este mecanismo utilizou-se da função *range()* para estabelecer os cálculos.

4.1.4 – Cadastro de Estudo De Casos

A figura 82 mostra como estudos de casos poderão ser disponibilizados para que os estudantes possam acompanhar seu conteúdo na plataforma enquanto o professor faz sua exposição sobre o assunto. Da mesma forma o professor poderá desenvolver um questionário sobre o caso em estudo para que o estudante possa interagir com o assunto em discussão. Ao clicar sobre o nome do arquivo o usuário poderá acessar seu conteúdo para leitura em uma nova aba do navegador.

Figura 82 - Cadastro de Estudo de Casos



A figura 83 mostra a predição através um modelo de inteligência artificial treinado para analisar imagens de pulmão para detectar tuberculose. Nesta imagem, o modelo informa a possibilidade de 94,5% estar doente e 5,5% de estar saudável.

Figura 83 - Predição para Detecção de Tuberculose



4.2 DESENVOLVIMENTO DE UM MODELO DE I.A. PARA PREDIÇÃO DE TUBERCULOSE

Esta fase do projeto, consta do treinamento de um modelo de inteligência artificial com imagens de pulmões saudáveis e com tuberculose para que o modelo seja capaz de realizar a detecção de patologia em novas imagens.

Segundo a Organização Mundial da Saúde, A tuberculose é uma grande ameaça à saúde global. O advento de novas técnicas poderosas de hardware e software desencadeou tentativas de desenvolver sistemas de diagnóstico auxiliados por computador para detecção de tuberculose. No entanto, o progresso no campo foi prejudicado pela falta de radiografias publicamente disponíveis para treinamento de algoritmos de aprendizado de máquina para sistemas de diagnóstico auxiliados por computador. Em um esforço para fornecer dados de treinamento suficientes para a comunidade de pesquisa, permitindo testes de referência, a Biblioteca Nacional de Medicina dos EUA disponibilizou publicamente dois conjuntos de dados de radiografias de tórax póstero-anteriores (PA): o conjunto MC e o conjunto Shenzhen (JAEGER, 2014).

Os dados de conjunto de imagens para este estudo foram obtidos através do site *NIH – National Library of Medicine*[18] que estão disponíveis para comunidades de pesquisa. Os dados da radiografia de tórax usados para apoiar os achados deste estudo estão disponíveis com o autor correspondente mediante solicitação (YILIN *et al.*, 2020).

Tanto o conjunto de dados Montgomery quanto *Shenzhen* podem ser solicitados através do contato na seguinte página da web: http://archive.nlm.nih.gov/repos/chestImages.php.

> Pedimos que os solicitantes não compartilhem os conjuntos de dados fora de seus grupos de pesquisa e organização, mas incentivamos que novas solicitações sejam encaminhadas diretamente para nós. Além disso, solicitamos que as publicações resultantes do uso desses dados atribuam a fonte (*National Library of Medicine, National Institutes of Health, Bethesda, MD, EUA*) e citem as seguintes publicações, que usaram os dados para experimentos de classificação e segmentação pulmonar (JAEGER, 2014, p.233)

Será utilizada uma arquitetura clássica de rede neural convolucional inspirada na arquitetura *Visual Geometry Group* de 16 camadas convolucionais ou VGG-16 que é um modelo de rede neural convolucional proposto por K. Simonyan e A. Zisserman da Universidade de Oxford.

> Neste trabalho investigamos o efeito da profundidade da rede convolucional em sua precisão no cenário de reconhecimento de imagem em larga escala. Nossa principal contribuição é uma avaliação completa de redes de profundidade crescente usando uma arquitetura com filtros de convolução muito pequenos (3 × 3), o que mostra que uma melhoria significativa nas conFigurações da técnica anterior pode ser alcançada empurrando a profundidade para 16 ou19 em número de camadas. Essas descobertas foram a base da submissão do *ImageNet Challenge* 2014, onde nossa equipe garantiu o primeiro e o segundo lugares nas faixas de localização e classificação, respectivamente. Mostramos também que nossas representações generalizam bem para outros conjuntos de dados, onde alcançam resultados de última geração. Disponibilizamos publicamente nossos dois modelos ConvNet de melhor desempenho para facilitar mais pesquisas sobre o uso de representações visuais profundas em visão computacional. (SIMONYAN *et al,*, 2015, p. 1).

[18] https://lhncbc.nlm.nih.gov/search-results.html?query=pub9931

4.2.1 Conjunto de Raios X de Tórax do Condado de Montgomery (Mc)

O conjunto de dados MC foi coletado em colaboração com o Departamento de Saúde e Serviços Humanos, Condado de Montgomery, Maryland, EUA. O conjunto contém 138 radiografias de tórax frontal do programa de rastreamento de tuberculose do condado de Montgomery, dos quais 80 são casos normais e 58 são casos com manifestações de tuberculose, correspondendo a aproximadamente 585 MB. Os raios X foram capturados com uma máquina de raios X estacionária Eureka (CR) e são fornecidos no formato *Portable Network Graphics* (PNG) como imagens de nível de cinza de 12 bits. O tamanho das imagens de raios X é de 4.892 × 4.020 pixels.
Os nomes dos arquivos de imagem são codificados em MCUCXR _####_X.png, onde #### representa um identificador numérico não sequencial de 4 dígitos e X é 0 para um raios X normal ou 1 para um Raios X anormal.

4.2.2 Conjunto de Raios X de Tórax do Condado de Shenzhen

O conjunto de dados de *Shenzhen* foi coletado em colaboração com o *Shenzhen* No.3 *People's Hospital, Guangdong Medical College, Shenzhen*, China. As radiografias de tórax são provenientes de ambulatórios e foram captadas como parte da rotina diária do hospital em um período de 1 mês, principalmente em setembro de 2012, usando um sistema *Philips DR Digital Diagnost*. O conjunto contém 662 radiografias de tórax frontais, sendo 326 casos normais e 336 casos com manifestações de tuberculose, incluindo radiografias pediátricas, correspondendo a aproximadamente 3.5 GB. As radiografias são fornecidas no formato PNG. Seu tamanho pode variar, mas é de aproximadamente 3K × 3K pixels (JAEGER, 2014).
Todos os nomes de arquivo de imagem seguem o mesmo modelo: CHNCXR_####_X.png, onde #### representa um identificador numérico de 4 dígitos e X é 0 para raios X de pulmões saudáveis ou 1 para um raios X de pulmões doentes. A leitura clínica de cada raios X é salva em um arquivo de texto seguindo o mesmo formato, exceto que a terminação “.png” é substituída por “.txt”. Cada leitura contém a idade do paciente, sexo e anormalidade observada no pulmão, se houver.

4.2.3 Compreensão dos Dados das Imagens

Observa-se que os dados do Hospital de Shenzhen possui um número superior de imagens em relação ao de Montgomery. São utilizados dois tipos de conjuntos de dados porque foram gerados por duas equipes de pessoas diferentes e em locais distantes um do outro. Este procedimento é importante para que o modelo a ser desenvolvido possa resultar num modelo o mais genérico possível, evitando que o modelo aprenda um só padrão caso seja submetido ao treinamento de apenas um único conjunto de dados.

Salienta-se que um modelo de inteligência artificial é um sistema especialista. Isto significa que é um sistema para um único objetivo ou detectar um único problema.

Para detectar mais de um problema seria necessária uma quantidade de imagens bastante superior o que acarretaria num custo computacional muito maior pois seria necessário equipamento com quantidade maior de memória, maior número de núcleos de CPU's e GPU's para acelerar o processo. Um número muito grande de dados pode acarretar num tempo de processamento com duração de vários dias ou semanas.

O desenvolvimento de algoritmos para análise de imagens médicas exige que seja extraído um conjunto de descritores representativos das regiões das imagens. Essa tarefa envolve um alto nível de abstração e continua sendo um desafio para os pesquisadores da área. Métodos matemáticos, estatísticos e computacionais que visam extrair informações específicas de imagens vêm sendo adaptados para essa função, mas tais algoritmos costumam ser bastante específicos para cada tarefa de análise de imagens (DA SILVA, 2019).

4.2.4 Linguagem de Programação e Pacotes

O *python* versão 3.7.6 foi a linguagem de programação utilizada para o desenvolvimento deste modelo de I.A. Junto a ele, foram necessárias as instalações para utilização dos seguintes pacotes com suas respectivas versões conforme descreve o Quadro 8:

Quadro 8 - Relação de Pacotes Utilizados

Pacote	Versão	Função
nvidia-smi		Biblioteca de reconhecimento de GPU's para para aceleração do processamento de imagens.
numpy	1.18.1	Biblioteca de código aberto destinada a realizar operações em matrizes multidimensionais. Possui funções para trabalhar com computação numérica. Seu principal objetivo é o vetor n-dimensional, ou ndarray. Um vetor n-dimensional também é conhecido pelo nome de tensor.
pandas	1.0.3	Biblioteca para análise e manipulação de dados.
matplotlib	3.1.3	Biblioteca *Python*, utilizada para visualização de dados e plotagem gráfica que interage com a biblioteca *numpy*.
tensorflow	2.3.1	Framework de ferramentas, bibliotecas e recursos que permite aos pesquisadores e aos desenvolvedores criar e implantar aplicativos com tecnologia de *Machine Learning*.
sklearn	0.22.1	Biblioteca de aprendizado de máquina de código aberto para a linguagem de programação *python*. Inclui algoritmos de classificação, regressão e agrupamento incluindo máquinas de vetores de suporte, florestas aleatórias, gradient boosting, k-means e DBSCAN. É projetada para interagir com as bibliotecas *Python* numéricas e científicas *NumPy* e *SciPy*.
imageio	2.6.1	Biblioteca *python* multiplataforma que fornece uma interface para ler e gravar dados de imagem, incluindo imagens animadas, dados volumétricos e formatos científicos.
skimage	0.16.2	Biblioteca *python* para processamento de imagem que interage com matrizes da biblioteca *numpy*.
cv2 (OpenCv)	4.2.0.34	Biblioteca de código aberto para a visão computacional, processamento de imagem, interpolação de imagens e aprendizagem de máquina.
keras	2.4.3	Biblioteca aberta de *Deep Learning* implementada utilizando *TensorFlow* para diversas linguagens/plataformas, como *Python* e *R*, com foco na sua facilidade de utilização. Ela permite modelar e treinar modelos de redes neurais com poucas linhas de código.

Cada versão dos pacotes mencionados são compatíveis com a linguagem python versão 3.7.6. Não somente a linguagem de programação, mas, as bibliotecas sofrem constantes atualizações o que influencia em implementações desenvolvidas a partir de uma versão mais antiga. Em vários casos, funções disponibilizadas por atualizações de bibliotecas são modificadas o que altera a quantidade de parâmetros e sua sintaxe acarretando estudos de reaprendizado para reescrever seu código.

Uma possível solução para amenizar este tipo de problema seria a adoção de utilização de containers.

A virtualização baseada em contêineres tem seu foco no isolamento entre processos. Para isso, a conteinerização apoia-se nos recursos do núcleo do sistema e não busca abstrair o hardware do hospedeiro. Um contêiner possibilita a virtualização de um aplicação implementando a gestão de tarefas, escalonamento e multiplexação de recursos (PANIZZON, 2019)

Containers são tecnologias que permitem empacotar e isolar aplicações com todo o ambiente de execução delas, ou seja, com todos os arquivos necessários para executá-las. Dessa forma, fica mais fácil migrá-las de um ambiente para outro (desenvolvimento, teste, produção etc.) sem perder funcionalidades. Os containers também são uma parte importante da segurança da TI.

Para exemplificar, pode-se imaginar um navio cargueiro a carregar diversos containers. Caso um dos recipientes seja danificado, os demais não são afetados. Afinal, são isolados, protegidos e estão carregando seus próprios produtos.

Transportando este conceito à área de desenvolvimento de sistemas, cada container possui uma única funcionalidade, sendo responsável por resolver um único problema. Caso um deles sofra um dano, o funcionamento do sistema não para e a função afetada é redirecionada a um novo container.

4.2.5 Arquitetura de Hardware

Modelos de inteligência artificial grandes e complexos devem ser treinados em equipamentos providos de GPU's – *Grafical Processive Unit* ou Unidade de Processamento Gráfico, também chamada de placa de vídeo, e não apenas que contenha CPU – *Central Processive Unit*. Isto é válido porque uma CPU possui quatro núcleos (*cores*) de processamento enquanto uma GPU possui entre três mil a cinco

mil núcleos. Assim, é possível paralelizar operações matemáticas de renderização de imagens como multiplicação de matrizes para cálculo de convolução para execução nos núcleos da GPU do equipamento. Estes núcleos são bem menores que os núcleos da CPU, mas, são em maiores quantidades. Assim, uma placa de vídeo projetada para executar *games* de alta resolução e com alta performance, pode ser utilizada para outra finalidade; o treinamento de modelos de *Deep Learning*. A partir desta descoberta, as pesquisas utilizando inteligência artificial tiveram um aumento significativo em todo o mundo. Um modelo que leva o tempo aproximado de 10 minutos para completar seu treinamento numa CPU levaria 5 segundos aproximadamente para ser treinado numa GPU, observando-se todas as suas características.

Enfim, ressalta-se que nem toda GPU está capacitada para realizar operações de paralelismo para treinamento de modelos de I.A. Para que esta operação seja possível, é necessário que o atributo denominado "*compute capability*" ou capacidade de computação seja superior a 3.5. Caso esta característica seja comprovada, significa que tal GPU suporta a plataforma CUDA que permite trabalhar com GPU's via programação. As bibliotecas *tensorflow* e *keras* são as tecnologias responsáveis por executar tais operações, automaticamente, na GPU. Caso a GPU da máquina tiver a capacidade de computação inferior a 3.5 ou não possuir GPU, as operações serão realizadas na CPU do equipamento, tornando-se mais lentas.

A plataforma CUDA - Compute Unified Device Architecture, é uma API – *Application Programming Interface* desenvolvida pela NVIDIA, empresa fabricante de processadores Gráficos para *games*. API's são rotinas de programação que facilitam a comunicação e troca de informações entre sistemas. CUDA é uma plataforma de bibliotecas desenvolvidas para proporcionar alto desempenho em processamento de dados utilizando computação paralela fornecido por uma placa de vídeo.

Assim, para desenvolver este modelo proposto, foi utilizado um cluster de processamento de dados baseado em ***GPU***, gentilmente cedido pelo Sr. Daniel Mendes, da *Data Science Academy*, proporcionando as seguintes conFigurações:

- *CPU*: Intel Core i7;
- *Clock Speed*: 3.0 GHZ;
- Memória *RAM*: 128 GB;
- Disco: 1 TB SSD e *Storage* 30 TB HDD;

- *GPU* 0: Titan X 12 GB GDDR5, *compute capability* 6.1;
- *GPU* 1: Geforce GTX 1080 Ti 11 GB, *compute capability* 6.1;
- *GPU* 2: Titan RTX 24 GB, *compute capability* 7.5;
- Linux Ubuntu 18.04.4 LTS (GNU/Linux 4.15.0-72-generic).

4.2.6 – Carregando o Repositório de Imagens

É necessário separar os dois conjuntos de imagens para treinamento para que o sistema em *python* possa ler e carregar cada uma delas. Foram criados dois repositórios para as imagens. Um para as 139 imagens do hospital *Montgomery* e outro para as 663 imagens do hospital de *Shenzhen*. O Quadro 9, demonstra alguns arquivos destas imagens:

Quadro 9 - Arquivos de Imagens

Imagens *Shenzhen*	Imagens *Montgomery*
image_id	image_id
0 CHNCXR_0501_1.png	0 MCUCXR_0289_1.png
1 CHNCXR_0223_0.png	1 MCUCXR_0243_1.png
2 CHNCXR_0051_0.png	2 MCUCXR_0196_1.png
3 CHNCXR_0179_0.png	3 MCUCXR_0070_0.png
4 CHNCXR_0621_1.png	4 MCUCXR_0079_0.png

Observa-se no Quadro 9 que o nome de cada arquivo se encerra com valor 0 ou 1. Arquivos que se encerram com o valor 0 significa que o pulmão está negativo ou saudável e com valor 1 significa que está positivo ou a patologia está presente. Assim, pode-se concluir que este modelo de I.A. é classificado como supervisionado.

4.2.7 – Extraindo a Variável Target

A variável denominada *target* é aquela que será alvo do estudo. Ela armazenará o valor 0 ou 1. A finalidade desta operação será criar uma nova coluna no *dataframe* para indicar a imagem que está com indicativo de pulmão normal ou com diagnóstico

de tuberculose, afinal, nenhuma pessoa teria obrigação de saber o que significam as nomenclaturas 0 e 1 na demonstração destes dados. Assim, será possível, também, determinar a quantidade de imagens de pulmões saudáveis e doentes.

O

10 exibe os cinco primeiros arquivos de cada *dataframe* com suas respectivas classificações na coluna *target*:

Quadro 10 - Arquivos de Imagens acrescidos da coluna target

Imagens *Shenzhen*

	image_id	target
0	CHNCXR_0501_1.png	Tuberculose
1	CHNCXR_0223_0.png	Normal
2	CHNCXR_0051_0.png	Normal
3	CHNCXR_0179_0.png	Normal
4	CHNCXR_0621_1.png	Tuberculose

Imagens *Montgomery*

	image_id	target
0	MCUCXR_0289_1.png	Tuberculose
1	MCUCXR_0243_1.png	Tuberculose
2	MCUCXR_0196_1.png	Tuberculose
3	MCUCXR_0070_0.png	Normal
4	MCUCXR_0079_0.png	Normal

Assim, é possível descobrir que existem 336 imagens com pulmões normais e 336 anormais para os dados fornecidos por *Shenzhen*. Para *Montgomery*, são 80 normais e 58 com pulmões doentes.

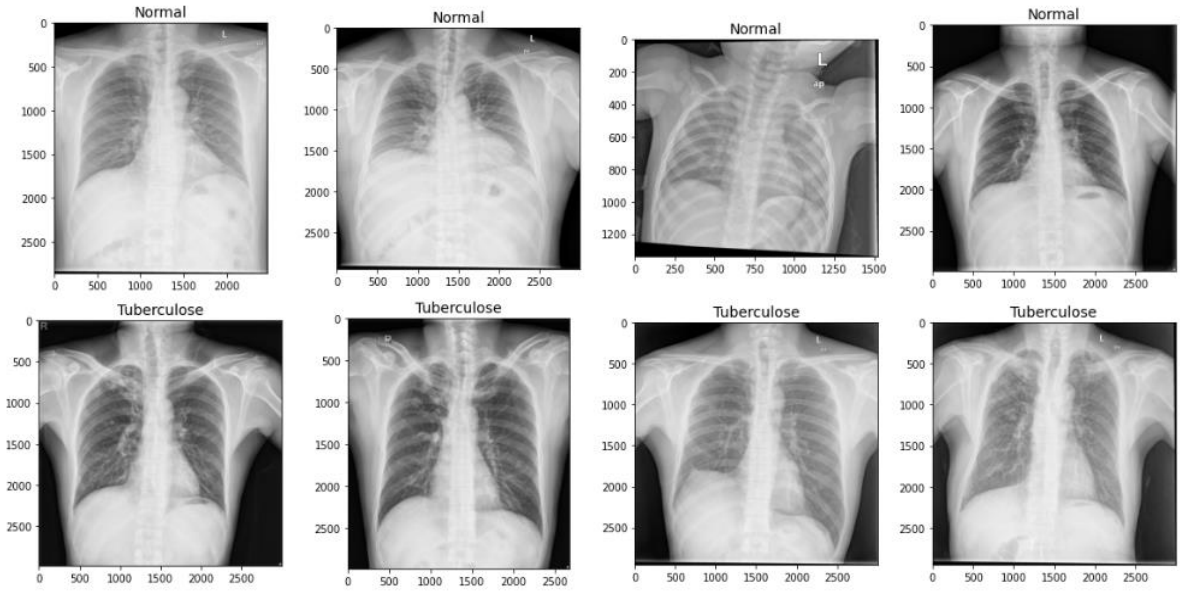
A quantidade de imagens normais e anormais são importantes porque possuem valores próximos o que facilita o balanceamento de classes. Se tivessem quantidades desproporcionais, teriam que ser realizadas operações para equalizar estes números. Se, por exemplo, a quantidade de imagens de pulmões normais fosse muito superior aos doentes, o modelo de I.A. poderia aprender mais sobre pulmões normais do que sobre os doentes. Assim, o modelo desenvolvido poderia ter baixa acurácia para pulmões doentes. Uma das possíveis soluções para corrigir este problema é a geração de imagens sintéticas (*dataset augmentation*) para aumentar o número de imagens para o grupo de pulmões doentes.

4.2.8 – Visualização de Imagens

As imagens são exibidas antes do modelo ser construído. Foi desenvolvida uma função que utiliza quatro parâmetros como a coluna “*target*” que define o número

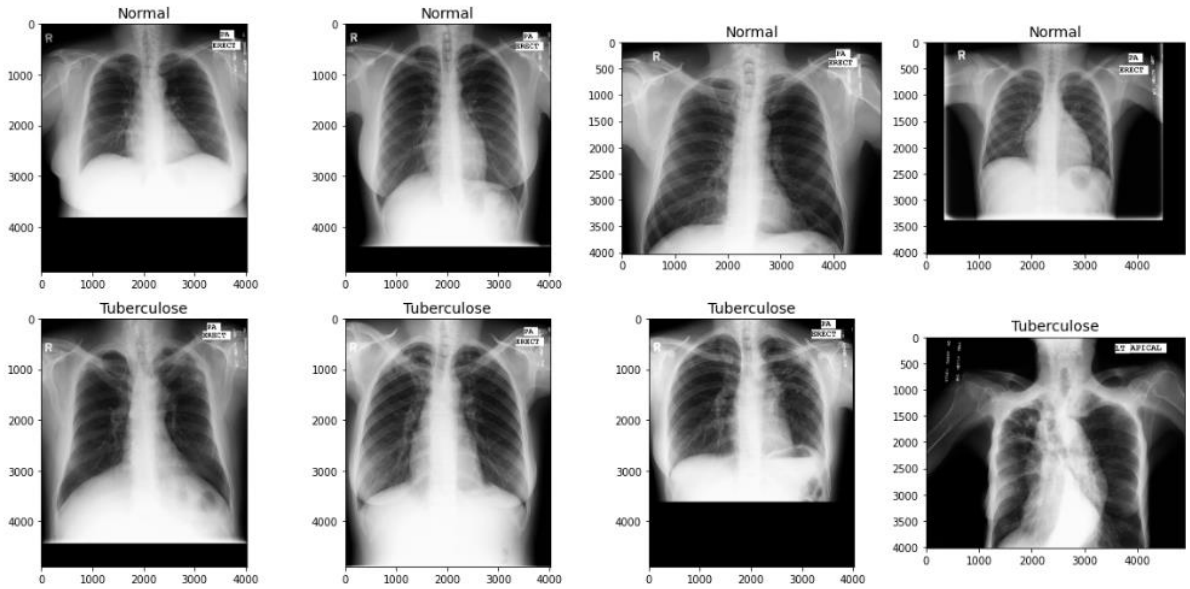
categoria das imagens que neste caso são duas (*Shenzhen* ou *Montgomery*), o número de colunas de imagens a serem exibidas em cada linha, neste caso, quatro colunas, o nome do *dataframe* correspondente à imagem e o repositório onde as imagens estão armazenadas em disco. Serão exibidas oito imagens, ou seja, quatro imagens de duas categorias (normal ou tuberculose) por *dataframe* com seu respectivo hospital. Os Quadros 11 e 12 exibem estas imagens:

Quadro 11 - Imagens do Hospital de Shenzhen



Na área médica, técnicas de reconhecimento de padrões desenvolvidas pela ciência da computação são utilizadas para reconhecimento de tumores, quantificação de deformidades em estruturas anatômicas, visualização de contornos, análises morfométricas e para auxílio ao diagnóstico, entre outras funções (DA SILVA, 2019).

Quadro 12 - Imagens do Hospital de Montgomery



Observa-se a diferença de padrões das imagens catalogadas nos dois hospitais. O hospital de *Shenzhen* mantém um formato padrão das imagens. *Montgomery* fornece imagens com diferentes tamanhos e resoluções. Isto faz que o modelo aprenda padrões diferentes para se tornar mais genérico e menos especialista.

4.2.9 Ajustando e Organizando Imagens de Raios X

É necessário organizar e ajustar as imagens separadamente para cada *dataset* que foi coletado do hospital de *Shenzen* e de *Montgomery*. A preparação dos dados é feita separadamente para que, ao final, seja feita a concatenação das imagens antes da criação do modelo. As imagens não podem ser entregues ao modelo da maneira como estão porque não foram extraídos os metadados das imagens. O *dataframe* de *Shenzhen* possui apenas duas colunas, ou seja, o nome dos arquivos de cada imagem e a coluna *target* que é classificação das imagens. Precisa-se extrair os metadados das imagens para inclui-los ao *dataset*. Metadados são características que descrevem um determinado dado. Neste caso, o dado é a imagem e os metadados são as características da imagem que devem ser obtidas.

Em imagens, metadados são características como os números máximo e mínimo de pixels, as dimensões das imagens como largura e altura e número de canais de cores. É imprescindível obter estes dados para incluí-los aos *dataframes* de *Shenzhen* e *Montgomery*. Estes metadados irão alimentar o *dataframe* que deverá ser fornecido para criar o modelo de I.A. Será necessário redimensionar todas as imagens para formatá-las no mesmo padrão.

Num projeto como este a preparação dos dados consomem aproximadamente até 70% do tempo de desenvolvimento.

Após o ajuste de metadados, os *dataframes* de cada grupo de imagens exibem as informações descritas nos Quadros 13 e 14:

Quadro 13 - Metadados Extraídos das Imagens do Hospital de Shenzhen

	image_id	target	largura	altura	canais	maior_valor_pixel	menor_valor_pixel
0	CHNCXR_0501_1.png	Tuberculose	2906	2408	3	255	0
1	CHNCXR_0223_0.png	Normal	2939	3000	3	255	0
2	CHNCXR_0051_0.png	Normal	2935	2985	3	255	0
3	CHNCXR_0179_0.png	Normal	2941	3000	3	255	0
4	CHNCXR_0621_1.png	Tuberculose	2630	2584	3	255	0

Quadro 14 - Metadados Extraídos das Imagens do Hospital de Montgomery

	image_id	target	largura	altura	canais	maior_valor_pixel	menor_valor_pixel
0	MCUCXR_0289_1.png	Tuberculose	4892	4020	3	255	0
1	MCUCXR_0243_1.png	Tuberculose	4020	4892	3	255	0
2	MCUCXR_0196_1.png	Tuberculose	4892	4020	3	255	0
3	MCUCXR_0070_0.png	Normal	4892	4020	3	255	0
4	MCUCXR_0079_0.png	Normal	4020	4892	3	255	0

4.2.10 Redimensionamento e Padronização de Imagens

Ao observar as larguras e alturas das imagens de *Shenzen* e *Montgomery* nos Quadros 13 e 14, observa-se grandes diferenças de dimensões entre elas.
As imagens, portanto, deverão estar padronizadas numa mesma escala antes de serem submetidas ao modelo de aprendizagem. Se a padronização não fosse realizada, acarretaria vários problemas na geração do modelo. Todas as imagens devem estar no mesmo formato. Então, as imagens serão formatadas com as mesmas dimensões de largura, altura e mesma quantidade de pixels antes de se submeter o modelo ao treinamento.

4.2.10.1 Mantendo a Qualidade das Imagens ao Redimensiona-las

A tarefa de redimensionamento poderia acarretar perdas de qualidade, mas, com a utilização de técnicas eficazes é possível realizar esta operação sem descaracterizar as imagens para este experimento. Para implementar tal operação, foi aplicada a técnica de interpolação inter área que reorganiza os pixels para redimensionar imagens e manter o mesmo padrão de qualidade. A técnica de interpolação visa expandir ou contrair o pixel da imagem.
Existem à disposição várias opções de técnicas de redimensionamento como a interpolação linear, interpolação cúbica, interpolação do vizinho mais próximo ou interpolação adaptativa que são técnicas diferentes para realizar a organização dos pixels. Cada técnica possui suas características e a escolha de uma delas dependerá do tipo de problema o qual se deseja resolver.

4.2.10.2 Interpolação de Imagens

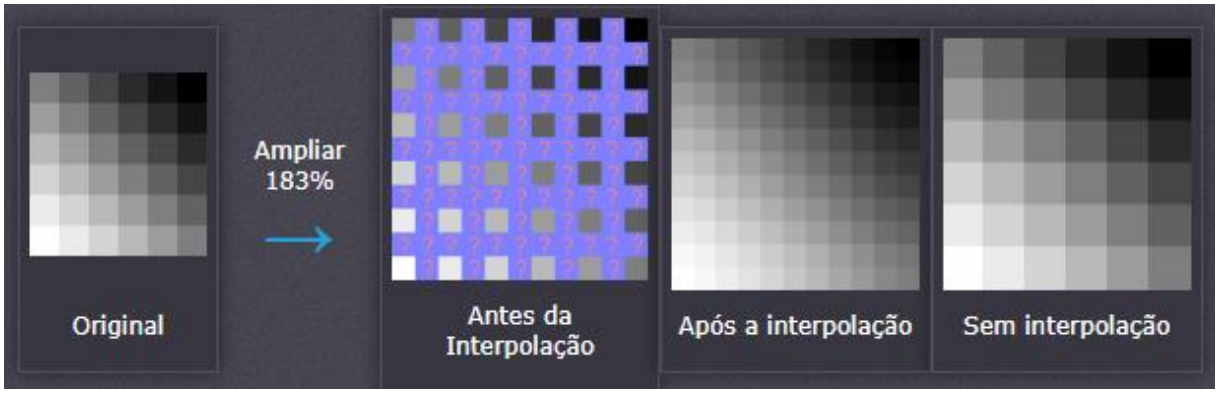
A interpolação é um método de estimativa. Isto acontece sempre quando se redimensiona uma imagem. Esta operação ocorre quando se deseja aumentar ou diminuir o total de pixels. A medida que a imagem é ampliada, os pixels aumentam, mas aumenta também a distância entre eles, e o que o software de interpolação faz é preencher esses espaços criando pixels novos a partir dos “pixels vizinhos”. Contudo

se isso for feito de forma errada ou brusca haverá distorção na imagem. Da mesma forma, caso ocorra uma diminuição muito grande numa imagem a distância entre os pixels diminui, o que faz com que os pixels se sobreponham causando um borrão na imagem.

4.2.10.3 Exemplo de Interpolação de Imagens

O exemplo a seguir ilustra o mecanismo de interpolação de imagem pelo pixel do vizinho mais próximo.
Na figura 84, à esquerda é exibida a imagem original e o objetivo seria ampliá-la em 183%. Neste processo, a área onde se estabelecerá a imagem é aumentada nas proporções desejadas. Os pixels originais da imagem são copiados para a segunda grade de pixels. Nos locais onde há uma interrogação na cor lilás, será calculada a estimativa baseada no pixel mais próximo deste local e preenche a lacuna com o mesmo valor do pixel mais próximo a ele. Após a interpolação, observa-se uma imagem cujo padrão se equivale à original. Ao aumentar a imagem sem aplicar a interpolação, poderá ocorrer distorção da imagem, como na última imagem à direita.

Figura 84 - Interpolação Pelo Vizinho mais Próximo



Fonte: Cambrigde in Colour, c2005-2020

4.2.10.4 Testes de Interpolação de Imagens

Foi realizado um teste de interpolação em uma imagem de pulmão do repositório de *Shenzhen* com a finalidade de submetê-la a testes de interpolação a fim de verificar a

se a perda de qualidade poderia influenciar no aprendizado do modelo de I.A. Apesar da perda de qualidade após o redimensionamento a imagem deverá manter detalhes fundamentais para permitir o aprendizado do modelo.

Ao observar os detalhes de largura e altura das imagens de *Shenzhen* no Quadro 13, conclui-se que a resolução da imagem é superior a 2.000 x 2.000 pixels.

Uma das tecnologias mais utilizadas para redimensionamento e interpolação é a biblioteca para visão computacional *OpenCV*, utilizada neste experimento.

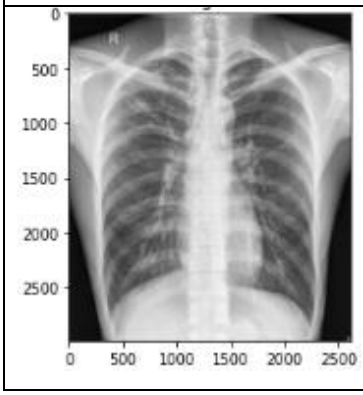
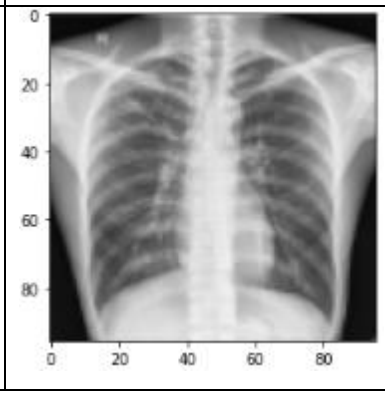
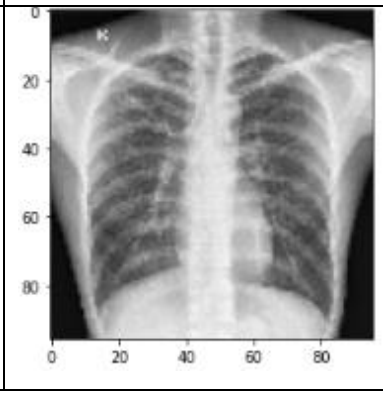
Segundo Backes (BACKES *et al.*, 2016) pode-se definir visão computacional como a área de estudo que tenta repassar para máquinas a incrível capacidade de visão.

Assim, pode-se afirmar que é um ramo da inteligência artificial que estuda o processamento de imagens, fornecendo capacidade aos computadores para interpretar informações visualmente, ou seja, é a maneira pela qual um computador enxerga.

Neste experimento, uma imagem original de aproximadamente 2500 x 2500 pixels foi redimensionada para 96 x 96 pixels. Para a arquitetura de hardware definida no tópico 4.2.5 deste capítulo, descobriu-se através de testes que a resolução máxima das imagens seria de 320 x 320 pixels. Acima desta resolução, existem as limitações físicas de memória e processamento do computador. Assim, o modelo deveria ser submetido a supercomputadores com alta capacidade de processamento ou em arquitetura de *clusters*.

O Quadro 15 exibe a mesma imagem submetida a duas técnicas de interpolação: inter-área (vizinho mais próximo) e linear utilizando o método *resize* da biblioteca *openCV*.

Quadro 15 - Redimensionamento por Interpolação

Original	Resize 1 (inter-area)	Resize 2 (linear)
2500 x 2500 pixels	96 x 96 pixels	96 x 96 pixels
		

A escolha da técnica depende da qualidade original das imagens. Em muitas ocasiões o modelo de I.A. não tem uma boa performance por falta de tratamento adequado nas imagens. Sempre haverá perdas, mas, desde que sejam poucos significativas para que o modelo possa aprender com eficiência.

Conclui-se que para este exemplo de imagem o redimensionamento para 96 x 96 pixels não afeta o aprendizado do modelo porque a compressão das imagens não afetou as estruturas dos pixels das imagens que identificam a tuberculose. Isto não significa que estas dimensões sejam sempre um padrão a ser determinado. Em outras imagens e outros tipos de problemas pode ser necessário ampliar ou reduzir as resoluções.

O próximo passo será redimensionar todas as imagens para serem submetidas ao modelo de I.A. e separá-las em treino e validação. Cerca de 85% das imagens serão destinadas para treinamento do modelo e 15% para validação. As imagens para validação possuem a função de validar o modelo durante seu treinamento. As imagens dos dois *datasets* (*Shenzhen* e *Montgomery*) serão armazenadas em repositórios diferentes, ou seja, um repositório para cada *dataset*. Em seguida, serão agrupadas as imagens dos dois *datasets* para seja aplicado a técnica de redimensionamento e interpolação de todas as imagens uma única vez.

4.2.11 Separação dos Dados para Treino e Validação

Esta etapa consiste na preparação dos dados das imagens visando o processo de treinamento do modelo de I.A.

1. Concatenar os *datasets* de imagens. Será necessário trabalhar com os *datasets* concatenados em vez de individualmente. Isto porque algumas técnicas serão aplicadas a todas as imagens e o modelo precisa aprender características de todas elas. Depois de concatenado, é criado um *dataframe* único que totalizará 800 imagens dos dois hospitais. Os *datasets* são concatenados e armazenados num vetor do tipo lista do *python*, onde os nomes dos arquivos das imagens poderão ser consultados na memória da máquina.
2. Embaralhar as imagens para manter a aleatoriedade dos dados de entrada através de uma função denominada *shuffle*. Isto evita que o modelo aprenda um determinado padrão e fique 'viciado' conforme suas particularidades. Assim evita-se o *overfitting*.
3. Separar as imagens por classes (Normal / Tuberculose). Esta classificação será utilizada para treinar o modelo supervisionado. O tipo Normal será conFigurado como **0** e Tuberculose como **1**, demonstrado na coluna "*labels*" do Quadro 16. No momento de treinar o modelo deve-se utilizar valores numéricos e não strings.

Quadro 16 - Criação da Coluna labels no Dataframe Concatenado

	image_id	target	largura	altura	canais	maior_valor_pixel	menor_valor_pixel	labels
323	CHNCXR_0295_0.png	Normal	2482	2344	3	255	0	0
409	CHNCXR_0662_1.png	Tuberculose	2988	2619	3	255	0	1
287	CHNCXR_0613_1.png	Tuberculose	2672	2546	3	255	0	1
248	CHNCXR_0300_0.png	Normal	2951	3000	3	255	0	0
124	CHNCXR_0646_1.png	Tuberculose	2929	3001	3	255	0	1

4. Divisão dos dados em treino e validação/teste. As imagens de treino não são as mesmas das imagens de teste/validação. Num conjunto de imagens 85% delas são separadas para treino e 15% para validação e teste. As imagens de validação não podem, então, estar no conjunto de dados de treino. Depois que o modelo for treinado com as imagens separadas e estiver com uma versão pronta, aplica-se as outras imagens do conjunto de dados para teste/validação a fim de verificar o grau de aprendizado e prever o diagnóstico de outras imagens. A validação das imagens é feita durante o treinamento do modelo porque assim consegue-se controlar o treinamento. Se a validação estiver com a performance ruim, pode-se

inserir uma regra para mudar o hiperparâmetro correspondente durante o treinamento em vez de esperar sua conclusão completamente. Não é necessário esperar a conclusão do treinamento para agir e tomar outra decisão. Assim, é possível tornar o processo mais assertivo. Esta é a função principal do *dataset* de validação. O Quadro 17 descreve a divisão dos dados de treino e validação/testes.

Quadro 17 - Divisão dos Dados de Treino e Teste/Validação

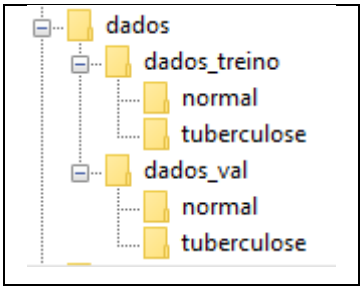
Dados de Treino (85%)	Dados de Teste/Validação (15%)
680 Imagens	120 Imagens

5. Aplicar as técnicas de processamento de imagens (como redimensionamento) em treino e validação/teste de forma separada porque não se deve aplicar técnicas que influenciam no modelo a todo seu conjunto de dados de uma única vez porque ao realizar este procedimento corre-se o risco de trazer o mesmo padrão para todas as imagens. Isto é ruim para o modelo porque pode acarretar *overfitting*. Então, o processo de validação irá seguir o padrão das imagens de treino e não do conjunto de dados como um todo. Este procedimento é utilizado para qualquer aprendizado de máquina e não é exclusivo deste estudo.

4.2.12 Pré Processamento de Imagens

Esta operação consiste em dois objetivos. O primeiro é separar as 800 imagens aleatoriamente em diretórios para treino e validação. Criou-se um diretório principal denominado **dados** e dois subdiretórios denominados **dados_treino**, onde serão armazenadas 85% ou 680 imagens para treino e **dados_val**, onde serão armazenadas 15% ou 120 imagens para validação. Em cada um destes subdiretórios foram criados outros dois subdiretórios; normal e tuberculose onde as imagens serão classificadas, conforme ilustra a figura 85:

Figura 85 - Diretórios de Treino e Validação



Cria-se um vetor tipo lista que armazena o nome de todos os arquivos das imagens e da coluna "*target*" do *dataframe*. É possível realizar a busca de cada arquivo nos diretórios e subdiretórios onde as imagens encontram-se armazenadas. Elas serão copiadas do seu diretório original, onde estão armazenadas sem classificação, para o subdiretório conforme sua classificação do tipo normal ou tuberculose para treino ou validação. Isto é feito via rotina de programação.

O segundo objetivo, será a tarefa de redimensionamento de todas as imagens. As imagens de Shenzhen possuem largura e altura de aproximadamente 2000 x 2000 pixels e Montgomery de 4000 x 4000 pixels. É necessário enquadrá-las nas mesma escala antes de submetê-las ao modelo para treinamento.

Ao final, foram obtidas 345 imagens de pulmões normais e 335 de pulmões com tuberculose para treino. Para validação, 61 imagens de pulmões normais e 59 de pulmões doentes.

4.2.13 AUMENTO DO CONJUNTO DE DADOS - DATASET AUGMENTATION

Neste estudo foram obtidas, aproximadamente, 700 imagens de dois hospitais para treinamento de um modelo, e mesmo assim este número é considerado baixo para submissão a um modelo de *Deep Learning*. Para resolver este problema e aumentar a quantidade mínima de imagens e se obter uma acurácia aceitável, foi aplicado uma operação denominada "*flip*" ou giro para criar imagens sintéticas. A partir de uma imagem original cria-se de três a cinco copias desta imagem, aplicando um giro de, por exemplo, 15º graus a cada imagem, gerando novas imagens. As imagens são iguais às originais, porém, com uma leve modificação no formato. Essa técnica é chamada de *Dataset Augmentation* e é amplamente usada em Inteligência Artificial para suprir a carência de dados em volume suficiente. Poderia se aplicar o giro, para

direita ou esquerda, de 45°, 90º, 180º, etc ou qualquer modificação que se deseja realizar, exceto, criar uma cópia idêntica da imagem original sem realizar o *flip*.

Neste caso, serão criadas imagens sintéticas, que serão armazenadas em pastas juntamente com as imagens originais para que posteriormente sejam alimentadas pelos geradores de *batches* (lotes) o que acelera o processo de treinamento.

Assim, o objetivo é aumentar para cerca de 2 mil imagens para treino no total, sendo definido o limite de 1000 imagens normais e 1000 com tuberculose criadas via programação. Esta operação requer as imagens originais separadas em dois diretórios para esta finalidade. Porém, não é necessário criar imagens sintéticas para validação porque estas imagens não são submetidas a treino. Posteriormente, serão submetidas ao modelo como imagens novas para que ele exerça sua previsão.

Existem duas classes de imagens, ou seja, normal e tuberculose. A proporção de geração de imagens deve ser a mesma para ambas as classes. A quantidade de imagens originais normais e com tuberculose é de 345 normais e 335 com tuberculose, ou seja, têm-se um conjunto de dados balanceados. Caso existisse grande disparidade entre elas, seria necessário implementar outra operação para balanceá-las.

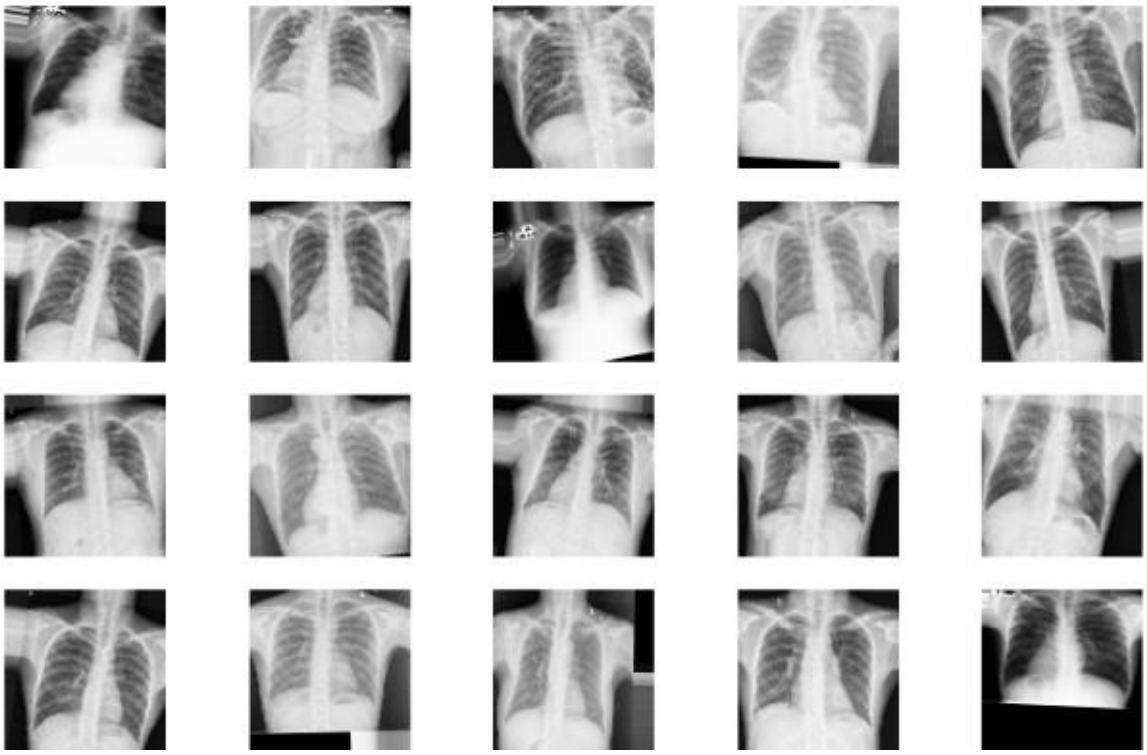
Foi definida a criação de imagens sintéticas para atingir o total de mil imagens normais e mil com tuberculose.

Utiliza-se o método *imageDataGenerator* da biblioteca *keras* para conFigurar parâmetros, como por exemplo, o ângulo de rotação das imagens que será de 10º, a fração do deslocamento horizontal de largura da imagem e o deslocamento vertical da altura da imagem numa fração de 0,1 e aplica-se o método *flow_from_directory* responsável por gerar as imagens sintéticas. O parâmetro *horizontal_flip* conFigurado como “*True*” indica que o giro das imagens será no sentido do plano horizontal das imagens. Para evitar a sobrecarga de memória num eventual carregamento de todas as imagens de uma só vez, o que inviabilizaria o processamento conFigura-se parâmetro *batch_size* para carregar o número máximo de 50 imagens por vez na memória do computador. O último parâmetro denominado *fill_mode* foi conFigurado como “*nearest*”. Isto significa que será realizada interpolação pelo pixel do vizinho mais próximo em caso de ampliação ou redução da imagem.

Após aplicar esta técnica o conjunto de dados totalizou entre imagens originais e sintéticas o valor de 1035 imagens normais e 1005 imagens com tuberculose.

O Quadro 18 exibe algumas imagens sintéticas após este procedimento:

Quadro 18 - Imagens Sintéticas com Giro de 10º

Imagens Sintéticas


4.2.14 DESENVOLVIMENTO DO MODELO

O desenvolvimento do modelo consiste na execução de etapas as quais, em termos gerais, pode-se destacar a criação de três objetos, ou seja, um para treino, um para validação e outro para teste. A função deles será coletar as imagens em seus respectivos diretórios dispostos conforme a Figura 79 para dados de treino e dados de validação. Nesta etapa foram definidas a quantidade de 10 imagens em lote que serão carregadas à memória para treino e outras 10 para validação e teste. Utilizou-se as mesmas imagens de validação para teste.

No Quadro 17 é possível observar que existem imagens maiores e outras menores. Então é necessário normalizar todas as imagens em uma só escala padrão. Para calcular a nova escala utiliza-se o método *ImageDataGenerator*(*rescale* = 1.0/255) da biblioteca *keras*. Esta escala leva em consideração o número de cores monocromáticas para imagens de raios X. Usa-se o método *flow_from_directory* do *keras* para resgatar o diretório das imagens, o tamanho de cada uma, neste caso 96

x 96 pixels, a quantidade de imagens a serem carregas na memória para não a sobrecarregar, neste caso, um grupo de 10 imagens e o modo de classificação que contém duas categorias; normal e tuberculose. Estes procedimentos são utilizados para os objetos de treino, validação e teste.

No Quadro 19, foram definidos os hiperparâmetros que, em redes neurais, controlam o processo de treinamento. Cada um deles pode ser conFigurado de forma manual e são determinantes na melhora ou piora da eficiência do modelo criado.

Quadro 19 - Hiperparâmetros

Valores dos Hiperparâmetros do Modelo	
Tamanho do *kernel* (filtro)	kernel_size = (3,3)
Tamanho do *pooling*	pool_size = (2,2)
Número de neurônios da primeira camada	num_neurons_1 = 32
Número de neurônios da segunda camada	num_neurons_2 = 64
Número de neurônios da terceira camada	num_neurons_3 = 128
Taxa de *dropout* nas camadas de convolução	*dropout_conv* = 0.3
Taxa de *dropout* na camada densa	*dropout_dense* = 0.3
Taxa de aprendizado	taxa_aprendizado = 0.0001
Número de épocas de treinamento	num_epochs = 300

Não existe um critério único para definir o número de neurônios em cada camada. Neste caso, os valores definidos foram de 1/3 (um terço) da resolução de pixels das imagens. A resolução é de 96 x 96 pixels, então, um terço de 96 é 32. Isto não é regra e sim um experimento de tentativas e erros. À medida que se avança às camadas intermediárias e mais profundas da rede neural, aumenta-se o número de neurônios duplicando-se os valores para as próximas camadas, conforme ilustra o Quadro 18.

O número de épocas de treinamento foi definido como 300, pois em testes foi verificado que a acurácia do modelo não se altera com valores acima deste número para este modelo.

Definição da arquitetura do modelo, em termos gerais, é onde são definidas as camadas, a função de ativação a ser utilizada, o tamanho do filtro ou *kernel size* que

é uma matriz quadrada 3 x 3, a camada de *dropout* que é um algoritmo de prevenção ao *overfitting* e como será realizada a saída de dados.

Segundo Srivastava (SRIVASTAVA *et al.*, 2014), *dropout* é uma técnica que aborda dois tipos de soluções: evita o *overfitting* e fornece uma maneira de combinar de forma exponencial outras topologias de redes neurais diferentes de forma eficaz. O termo "*dropout*" se refere ao desativar alguns neurônios em modelos de redes neurais. Ao desativar esses neurônios, o intuito é removê-los temporariamente da rede, juntamente com todas as suas conexões de entradas e saídas. A escolha de quais neurônios serão desativados é aleatória.

Arquitetura da Rede Neural

A arquitetura é a quantidade e a composição de camadas que serão desenvolvidas para o modelo. Foram desenvolvidas três camadas ocultas, cada uma com três operações de convolução.

A convolução é a operação que extrai os recursos das imagens. Para isto, foi criado um objeto da biblioteca “*sequential*” do pacote *keras* e utilizado o método *Conv2D*.

Esta biblioteca permite a adição de várias camadas ocultas à arquitetura da rede neural e o método *conv2D* realiza o cálculo de convolução entre as matrizes de pixels da imagem e os pesos do *kernel* onde se armazena os pesos referentes ao aprendizado adquirido pela rede.

Em seguida, adiciona-se em cada camada oculta através do método *MaxPooling2D* para calcular a redução de dimensionalidade para uma matriz 2 x 2. Em seguida, adiciona-se o método *Dropout* para desativar em 30% do número de neurônios da rede a fim de evitar o aprendizado viciado ou *overfitting*. Aqui encerra-se o aprendizado profundo. A partir dos próximos passos, a rede trabalha com algoritmos de *machine learning*.

Segundo Santos, (SANTOS *et al.*, 2019, apud Erickson *et al.*, 2017) uma das áreas mais estudadas em inteligência artificial e na classificação de imagens médicas é o aprendizado de máquina (do inglês *machine learning*). Esta técnica permite a identificação de padrões com base em casos e experimentos anteriores, assim como ocorre com a inteligência humana.

O primeiro algoritmo de *machine learning* aplicado nesta rede é o método "*Flatten*". O primeiro objetivo dele é converter a matriz de saída bidimensional em um vetor unidimensional. O segundo é a aplicação da função de ativação para camada densa denominado "*Relu*" para manter a estabilidade da rede. Por fim aplica-se a função de ativação "*Softmax*" que realiza a classificação das imagens em normal ou tuberculose.

Arquitetura do Modelo

A seguir são apresentados os passos criados em linguagem *python* para criação do modelo. O valor de cada hiperparâmetro está definido acima no Quadro 18.

Cria-se o objeto "*model*" que permite a criação de camadas ocultas:

model = Sequential()

Adiciona-se a primeira camada oculta com 3 operações de convolução. O parâmetro *input_shape* possui três dimensões porque será alimentado por uma imagem por vez durante o treinamento. Cada época carregará 10 imagens. Ao final, serão 300 épocas. Os parâmetros recebem as resoluções das imagens para o qual foram redimensionadas. *IMAGE_HEIGHT=96, IMAGE_WIDTH=96.* Aplica-se o *MaxPooling* para redimensionar a matriz e *dropout* para evitar *overfitting*.

```
model.add(Conv2D(num_neurons_1, kernel_size, activation = 'relu', input_shape = (IMAGE_HEIGHT, IMAGE_WIDTH, 3)))
model.add(Conv2D(num_neurons_1, kernel_size, activation = 'relu'))
model.add(Conv2D(num_neurons_1, kernel_size, activation = 'relu'))
model.add(MaxPooling2D(pool_size = pool_size))
model.add(Dropout(dropout_conv))
```

Adiciona-se a segunda camada oculta com 3 operações de convolução.

```
model.add(Conv2D(num_neurons_2, kernel_size, activation = 'relu'))
model.add(Conv2D(num_neurons_2, kernel_size, activation = 'relu'))
model.add(Conv2D(num_neurons_2, kernel_size, activation = 'relu'))
model.add(MaxPooling2D(pool_size = pool_size))
model.add(Dropout(dropout_conv))
```

Adiciona-se a terceira camada oculta com 3 operações de convolução

model.add(Conv2D(num_neurons_3, kernel_size, activation = 'relu'))

model.add(Conv2D(num_neurons_3, kernel_size, activation = 'relu'))

model.add(Conv2D(num_neurons_3, kernel_size, activation = 'relu'))

model.add(MaxPooling2D(pool_size = pool_size))

model.add(Dropout(dropout_conv))

Adiciona-se a camada para converter matriz em vetor.

model.add(Flatten())

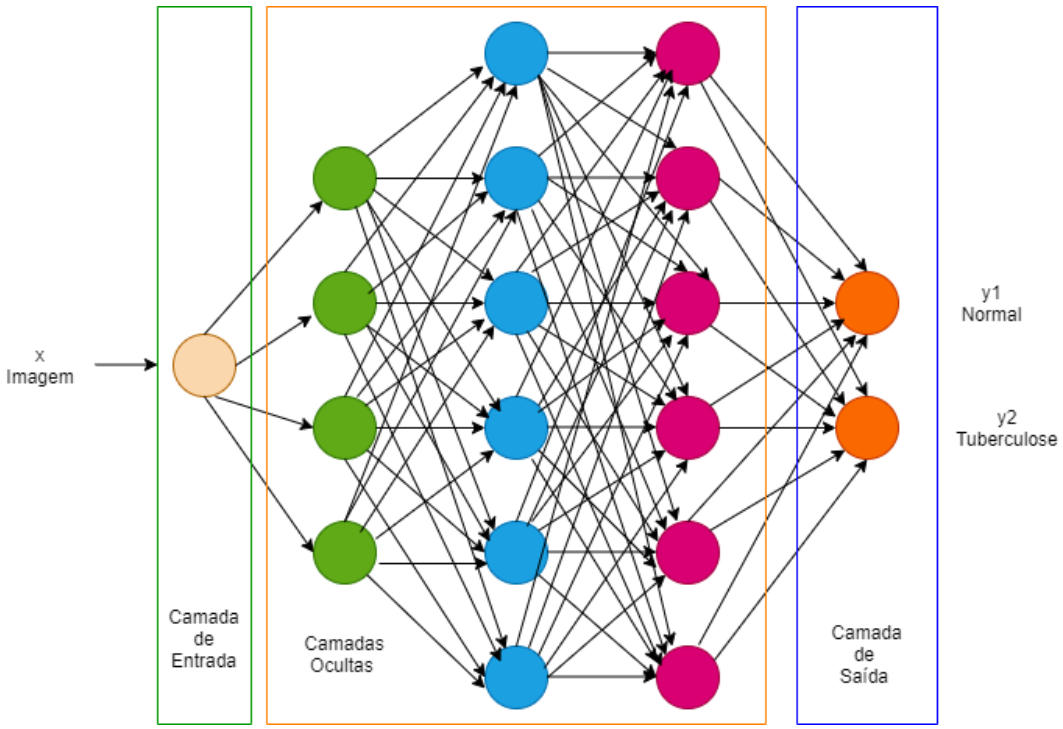
Adiciona-se à camada densa com *dropout*.

model.add(Dense(256, activation = "relu"))

model.add(Dropout(dropout_dense))

Adiciona-se a camada de saída de dados para duas classificações das imagens, normal ou tuberculose. E a função *softmax* calcula probabilidades. *model.add(Dense(2, activation = "softmax"))*. A Figura 86 ilustra de maneira simplificada o funcionamento de uma rede neural:

Figura 86 - Esquema Simplificado da Rede Neural



Definição da compilação do modelo.

A compilação do modelo é o aprendizado da rede neural a partir do erro. Quando o algoritmo do modelo de treinamento se inicia, são atribuídos pesos aleatórios na matriz *kernel_size*. Nesta matriz ficam armazenados os valores ou pesos referentes ao aprendizado da rede neural. Ao final da primeira execução do algoritmo, quase nada terá sido aprendido. Então, é calculado o valor da acurácia do modelo após a primeira execução pelos valores de entrada atribuídos aleatoriamente ao *kernel_size*. O resultado da acurácia é um valor em porcentagem que será comparado aos valores reais da imagem. Aplica-se a função "*binary_crossentropy*" para calcular a diferença entre estes valores. Esta diferença é o erro do modelo.

Para se aprender com o erro, aplica-se o algoritmo responsável pela otimização da rede neural, que no caso deste exemplo, será a função "*Adam*". A esta função é passado como parâmetro a taxa de aprendizado definido no Quadro 18. Esta função indicará se os valores dos pesos da matriz *kernel_size* deverão ser aumentados ou diminuídos a partir da taxa de aprendizado. Com essa taxa, é possível controlar a magnitude do aprendizado. O cálculo do aumento ou diminuição dos valores dos pesos é feito a partir da derivada do gradiente. Isto é feito acrescentando à taxa de aprendizado o aumento ou a diminuição calculado pela derivada do gradiente.

Utiliza-se a acurácia como métrica durante o aprendizado. Amostras de pesos não serão consideradas para este modelo porque não são necessárias, neste caso.

Compilação do modelo em *python*:

```
model.compile(Adam(taxa_aprendizado),
        loss = 'binary_crossentropy',
        metrics = ['accuracy'],
        sample_weight_mode = None)
```

Assim, o algoritmo retorna ao início com novos valores dos pesos atualizados para a *kernel_size* e um novo treinamento se inicia com uma nova imagem. Isto é feito sucessivamente até que se encontre o valor ideal dos pesos. Neste exemplo, foram utilizadas 300 épocas. Isto pode ser alterado para mais ou menos a fim de que um modelo possa conseguir maior acurácia. Se a quantidade de épocas for aumentada e

a acurácia permanecer a mesma da quantidade anterior, significa que o modelo encontrou sua estabilidade.

O número de 300 épocas foi elaborado de maneira empírica. Foram inseridos dois *call backs* para o controle do número de épocas caso a estabilização do modelo ocorressem antes de atingir este valor. Em nenhum dos treinamentos foi necessário aumentar o número de épocas.

Definição do diretório onde o modelo será salvo e o nome do modelo.

Este item define o nome do modelo e o caminho do diretório (path) onde ele será salvo. É normal criar vários modelos alterando-se os hiperparâmetros para se conseguir uma melhor acurácia. A cada mudança de um hiperparâmetro salva-se o modelo com um nome diferente para não ocorrer sobreposição de arquivos.

Definição da lista de *callbacks* que são algoritmos fornecidos pela biblioteca *Keras*, a serem executados durante a geração do modelo. Neste caso, foram criados dois *callbacks: ModelCheckpoint* que salva a melhor performance do modelo de tempos em tempos durante a compilação. Cria-se um ponto de restauração do modelo caso ocorra algum imprevisto e aplica-se o método *ReduceLROnPlateau* que permite estimular o modelo em caso de interrupção de aprendizagem.

Treinamento do modelo

O treinamento resume-se à uma linha de código acionada pelo método "*fit*" que faz o ajuste do modelo aos dados do objeto *model*. O resultado será armazenado no objeto *history*.

Os parâmetros do método *fit* fornecido pela biblioteca *sklearn* são:
gen_treino é o objeto que contém o diretório e carrega as imagens para o treinamento.
Steps_per_epoch é o parâmetro que determina o término de uma época e o início da próxima época. É um argumento para a função de ajuste do modelo. *Steps_per_epoch* é o quociente do total de amostras de treinamento por tamanho de lote escolhido. Neste caso, a quantidade de imagens de treino pelo tamanho do lote de imagens, ou seja, passos_treino = 680/10.
validation_data é o parâmetro que recebe de *gen_val* o diretório e carrega as imagens de validação.

validation_steps é o parâmetro que recebe o número de passos de validação que é o quociente do total de amostras de validação por tamanho de lote escolhido. Neste caso, a quantidade de imagens de validação pelo tamanho do lote de imagens, ou seja, passos_treino = 120/10.

epochs é o número de épocas ou número de vezes que o algoritmo será executado. Cada época carrega apenas uma imagem por vez. Ao final de 10 imagens, muda-se para a próxima época, ou seja, para completar uma época, o algoritmo faz a análise de 10 imagens uma por uma de cada vez.

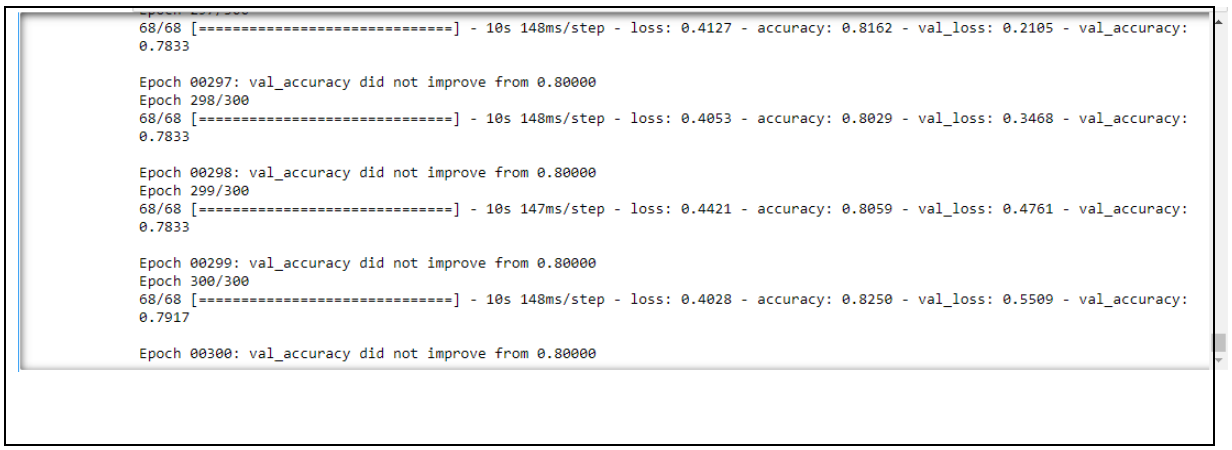
Verbose = 1 permite a visualização da execução do treinamento conforme a Figura 81.

callbacks é o parâmetro que recebe um vetor do tipo lista de *call-backs*, neste caso, *ModelCheckpoint* e *ReduceLROnPlateau*.

```
history = model.fit(gen_treino,
                    steps_per_epoch = passos_treino,
                    validation_data = gen_val,
                    validation_steps = passos_val,
                    epochs = num_epochs,
                    verbose = 1,
                    callbacks = callbacks_list)
```

A Figura 87 mostra a execução parcial final do treinamento do modelo:

Figura 87 - Execução do Treinamento



Ao final do treinamento, depois de 300 épocas o grau de eficiência se estabeleceu em 80%. Esta taxa significa que foram submetidas imagens de validação que não participaram do treinamento e em 80% houve acertos. Na última época, pode ser verificado que a porcentagem de acurácia para treino foi 82,5% e a de validação 79,1%. Se a acurácia final foi próxima à do treinamento, significa que o modelo está generalizável. Isto significa que o modelo não aprendeu os detalhes das imagens de treino o que poderia acarretar *overfitting*, porém, aprendeu a concepção matemática das imagens, conforme a Figura 81.

É possível atingir uma performance melhor do que a conseguida neste modelo. Algumas possíveis tentativas seria a modificação de hiperparâmetros como:

a) Aumentar a resolução das imagens para 128 x 128;
b) Aumentar o número de épocas;
c) Aumentar a quantidade de camadas ocultas;
d) Modificação da taxa de aprendizagem inicial;
e) Ampliação do tamanho do filtro ou *kernel_size*;
f) Ampliação do grau “patience” no call-back *ReduceLROnPlateau*;
g) Ampliar a quantidade de imagens sintéticas.

Para cada modificação, deve-se gerar um novo modelo e, ao final, compará-los entre si para determinar o melhor. Porém, nada garante que alguma destas modificações poderão melhorar a acurácia do modelo.

4.2.15 Avaliação da Performance do Modelo

A métrica de avaliação escolhida para este modelo é a acurácia porque as classes analisadas, normal e tuberculose, estão equilibradas. O total de imagens originais e sintéticas são de 1035 imagens de pulmões normais e 1005 de pulmões com tuberculose na etapa de treino. Para teste e validação, existem 61 imagens normais e 59 com tuberculose. Por isto, pode ser considerada a mais adequada a este contexto. Existem várias métricas de avaliação além da acurácia ou *acuracy* como a *precision*, *recall*, *f1score*, etc. A métrica da acurácia deve ser evitada quando as classes alvo da análise estiverem desbalanceadas. Mas, podem ser aplicadas técnicas para balanceamento.

Para realizar esta avaliação, carrega-se o modelo que foi salvo em seu diretório e extrai-se dele a maior acurácia durante os testes de validação. Neste a maior acurácia foi 0,8000. Este índice se estabilizou em 80% a partir da época número 68 e não mais progrediu. Ao acionar o método *model.summary() do python*, observou-se que foram treinados 1.661.186 parâmetros.

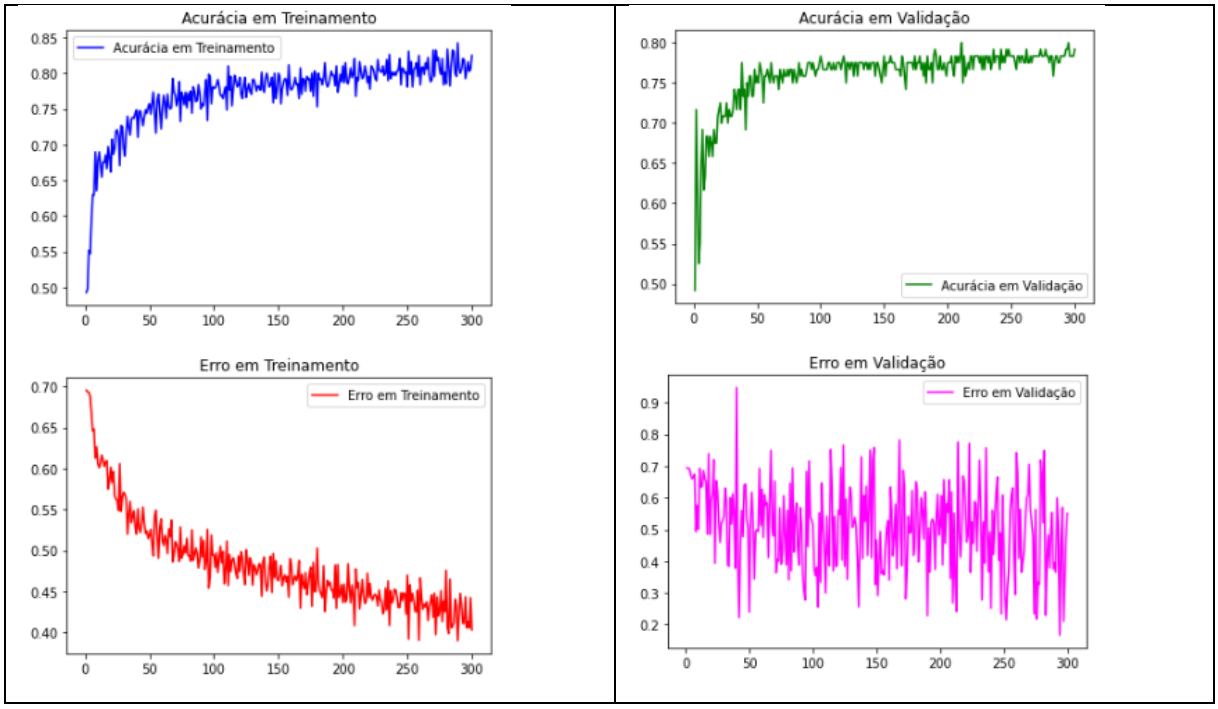
Para melhor compreensão, são apresentados dois Gráficos. O primeiro exibe a curva para acurácia de treinamento. O segundo exibe a curva de erro do treinamento. Percebe-se que em treinamento à medida que o erro diminui, a acurácia aumenta. Observa-se que no início do treinamento o aprendizado é muito baixo. Em seguida, rapidamente, dá um salto de aumento no aprendizado. Em concomitância o erro diminui, aproximadamente, na mesma proporção. Também, é possível observar vários picos na imagem do Gráfico. Estes picos representam pontos onde não houve nenhum ou pouco aprendizado. Isto acontece porque a imagem a ser analisada poderia estar ofuscada, ou com um giro muito grande, ou com algum tipo de interferência que impedia o reconhecimento de parte da imagem, ou outros fatores.

Em teste de validação, os Gráficos são parecidos com o de treinamento, ou seja, há um aumento de aprendizado e diminuição do erro. Porém, a curva de erro em validação apresenta um comportamento irregular. Isto pode ter acontecido em virtude da redução de valores dos parâmetros da taxa de aprendizado para se evitar o *overfitting*. Embora o modelo apresente bom aprendizado global quanto à acurácia, quando submetido a novas imagens, característica do teste de validação, a performance se mostra irregular. O ideal seria tentar obter uma curva de erro mais linear, porque não é interessante que o modelo cometa erros com frequência.

O Gráfico 2 ilustra o comportamento do algoritmo durante seu aprendizado. Na acurácia, o eixo vertical do Gráfico representa a medição da taxa de crescimento do aprendizado do algoritmo. No erro, o eixo vertical representa a taxa da quantidade de erros decrescentes cometidos no aprendizado do algoritmo.

O eixo horizontal de ambos os Gráficos representa a quantidade de épocas ou o número de vezes que o algoritmo é executado.

Gráfico 2 - Acurácia e Erro em Treino e Validação 1ª Versão



4.2.16 Avaliação da Performance do Modelo Utilizando Matriz Confusão

A matriz de confusão é um recurso visual utilizado para avaliar a performance do modelo em análise de classificação. É um tabela que mostra as frequências de classificação para cada classe do modelo que possui duas dimensões cujo objetivo é mostrar o verdadeiro e o previsto. Não é uma medida de desempenho. No entanto a maioria das métricas a utilizam para analisar dados de avaliação.

Essa matriz é gerada a partir dos resultados de um algoritmo de classificação. Os erros e os acertos são contabilizados e somados para que tais somas sejam dispostas em uma matriz.

A matriz confusão é dividia em quatro amostras. Cada análise possui um rótulo correspondente ao seu quadrante conforme ilustra o Quadro 20:

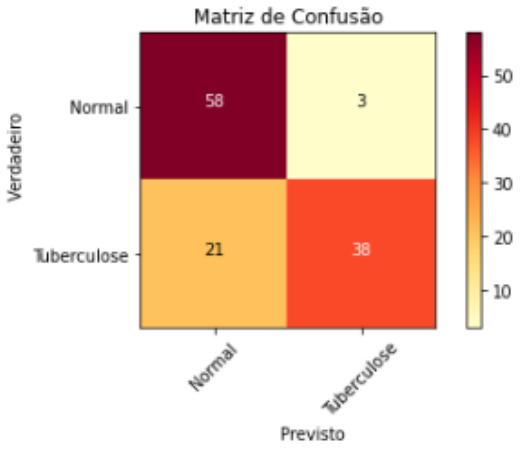
Quadro 20 - Matriz Confusão Amostras

Verdadeiro	Normal	Tuberculose
	Verdadeiro Positivo 1	Falso Positivo 2
	Falso Negativo 3	Verdadeiro Negativo 4
	Previsto	

Verdadeiro Positivo: A imagem de raios X possui diagnóstico normal e o modelo previu um diagnóstico de que a imagem é normal confirmando o diagnóstico real.
Falso Positivo: A imagem de raios X possui diagnóstico normal e o modelo previu um diagnóstico de que a imagem é de diagnóstico de tuberculose, não confirmando o diagnóstico.
Falso Negativo: A imagem de raios X possui diagnóstico de tuberculose e o modelo previu um diagnóstico de que a imagem é normal, não confirmando o diagnóstico.
Verdadeiro Negativo: A imagem de raios X possui diagnóstico tuberculose e o modelo previu a imagem com diagnóstico de tuberculose, confirmando o diagnóstico real.

As análises foram feitas sob as imagens originais de teste e validação. Existem 61 imagens normais e 59 com diagnóstico de tuberculose. A Figura 88 faz um resumo visual dessa análise.

Figura 88 - Matriz Confusão



Segundo Mendes (MENDES, 2021), não é aconselhável definir apenas a métrica da acurácia como resultado do modelo porque é uma métrica global.

Na matriz de confusão a diagonal principal referentes aos quadrantes de números 1 e 4 correspondem aos acertos aferidos pelo modelo.

A diagonal secundária referentes aos quadrantes de números 2 e 3 correspondem aos erros cometidos pelo modelo.

De início pode-se concluir que o modelo mais acertou do que errou.

No 1º quadrante da matriz conclui-se que em 58 imagens cujo raios X era verdadeiramente normal, o modelo previu acertadamente como normal.

No 4º quadrante conclui-se que em 38 imagens cujo raios X era verdadeiramente diagnóstico de tuberculose, o modelo previu acertadamente como tuberculose.

No 2º quadrante conclui-se que em 3 imagens cujo raios X era verdadeiramente normal, o modelo previu equivocadamente como diagnóstico de tuberculose, ou seja, em 3 pessoas que não possuíam doença alguma o modelo previu que estariam doentes.

No 3º quadrante conclui-se que em 21 imagens cujo raios X era verdadeiramente diagnóstico de tuberculose, o modelo previu equivocadamente como normal, ou seja, 21 pessoas que estavam doentes, foram previstas como normais.

Este modelo possui boa acurácia global de 80%, mas, se suas classes são verificadas individualmente, conclui-se que são necessários ajustes para tentar baixar a quantidade de erros ocorridos no 3º quadrante, cujo erro é considerado grave.

Algumas estratégias para criar novas versões deste modelo seria aumentar o número de camadas ocultas, a quantidade de imagens sintéticas ou aumentar a resolução das imagens para tentar conseguir algo mais estável. A seguir serão demonstradas algumas novas versões com tentativas de melhorar a acurácia do modelo.

4.2.18 Segunda Versão do Modelo

Na segunda versão do modelo foram alteradas as resoluções de 96 x 96 para 128 x 128. Para isto, é necessário alterar o número de neurônios da primeira, segunda e terceira camadas. Utilizou-se o mesmo critério para redimensionar o número de neurônios utilizado no modelo anterior. Aumentou-se na ordem de um terço do valor da resolução de 128 para 42 na primeira camada oculta. Para cada camada oculta

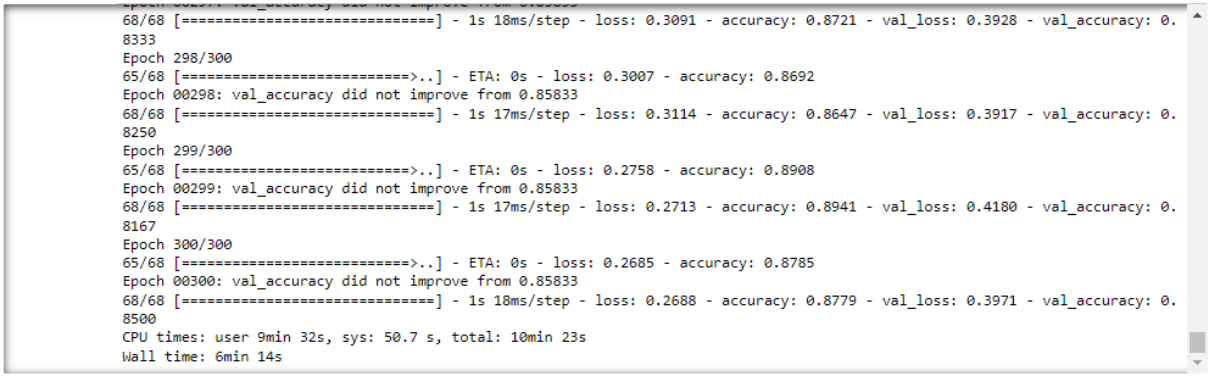
dobra-se o valor anterior. Apenas este parâmetro foi alterado. Todos os outros, inclusive o número de imagens sintéticas permaneceram os mesmos. O Quadro 21 descreve essas modificações.

Quadro 21 - Hiperparâmetros para Imagens com Resolução 128 x 128

Valores dos Hiperparâmetros do Modelo	
Tamanho do *kernel* (filtro)	*kernel_size* = (3,3)
Tamanho do *pooling*	*pool_size* = (2,2)
Número de neurônios da primeira camada	num_neurons_1 = 42
Número de neurônios da segunda camada	num_neurons_2 = 84
Número de neurônios da terceira camada	num_neurons_3 = 168
Taxa de *dropout* nas camadas de convolução	*dropout_conv* = 0.3
Taxa de *dropout* na camada densa	*dropout_dense* = 0.3
Taxa de aprendizado	taxa_aprendizado = 0.0001
Número de épocas de treinamento	num_epochs = 300

A Figura 89 mostra a execução parcial final do treinamento do modelo:

Figura 89 - Execução do Treinamento da 2ª Versão



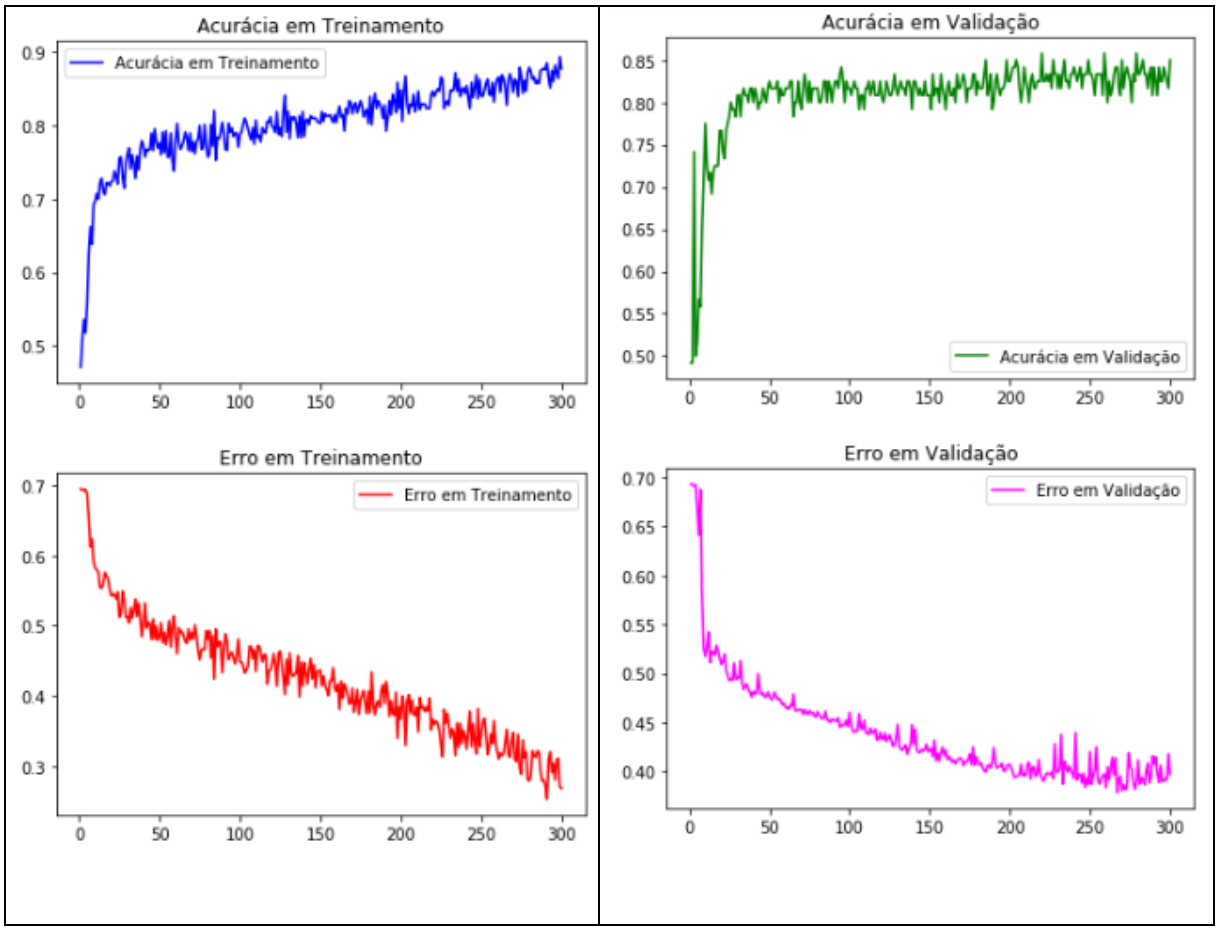
A acurácia desta segunda versão modelo apurou um grau de eficiência na ordem de 85,8%. Na última época, pode ser verificado que a porcentagem de acurácia para treino foi 87,8% e a de validação 85% como pode ser visto na Figura 83. A acurácia de estabilizou em 85,8% a partir da época número 221.

Se a acurácia final está próxima à do treinamento, significa que o modelo permanece generalizável. Ao acionar o método *model.summary()* do *python*, observou-se que foram treinados 5.129.138 parâmetros na *rede neural*.

4.2.19 Avaliação da Performance da 2ª Versão Modelo

Neste caso observa-se que o Gráfico de erro de validação que destoava dos demais por sua irregularidade manteve-se em consonância de linearidade se comparado aos outros. À medida que o aprendizado ocorre, a quantidade de erros diminui tanto em treinamento quanto em validação conforme ilustra o Gráfico 3:

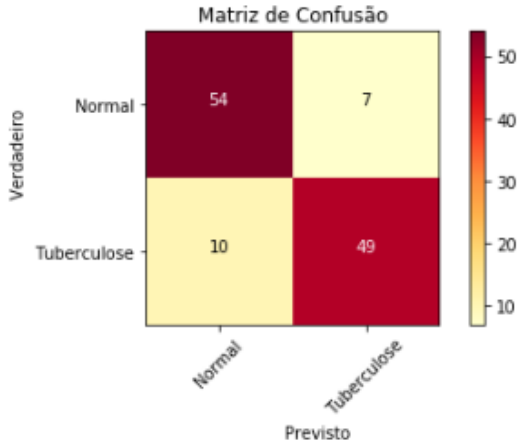
Gráfico 3 - Acurácia e Erro em Treino e Validação 2ª Versão



4.2.20 Avaliação da Segunda Versão do Modelo Utilizando Matriz Confusão

Nas amostras da matriz confusão é possível observar o descréscimo no terceiro quadrante que obtem-se o número de erros na previsão de pessoas doentes classificadas como normais conforme ilustração na Figura 90:

Figura 90 - Matriz Confusão da 2ª Versão



No 1º quadrante da matriz conclui-se que em 54 imagens cujo raios X era verdadeiramente normal, o modelo previu acertadamente como normal.
No 4º quadrante conclui-se que em 49 imagens cujos raios X era verdadeiramente diagnóstico de tuberculose, o modelo previu acertadamente como tuberculose.
No 2º quadrante conclui-se que em 3 imagens cujo raios X era verdadeiramente normal, o modelo previu equivocadamente como diagnóstico de tuberculose, ou seja, em 7 pessoas que não possuíam doença alguma o modelo previu que estariam doentes.
No 3º quadrante conclui-se que em 10 imagens cujos raios X eram verdadeiramente diagnóstico de tuberculose, o modelo previu equivocadamente como normal, ou seja, 10 pessoas que estavam doentes, foram previstas como normais.
Uma nova versão será construída aumentando-se o número de camadas ocultas da rede neural.

4.2.21 Terceira Versão do Modelo

Na terceira versão do modelo manteve-se a resolução de imagens em 128 x 128. Alterou-se o número de camadas ocultas de três para quatro. Assim, o número de

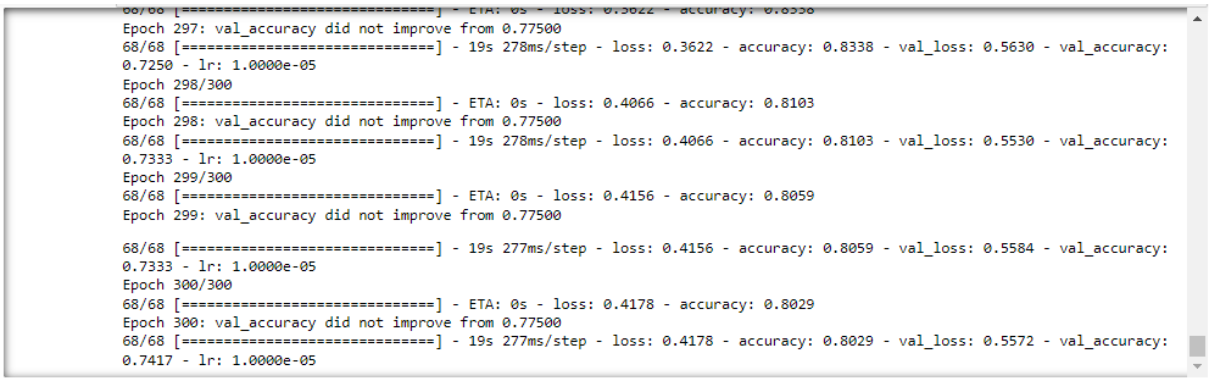
neurônios da quarta camada foi definido em 256. Apenas este parâmetro foi alterado, conforme descreve o Quadro 22.

Quadro 22 - Hiperparâmetros para Imagens com Adição da 4ª Camada Oculta

Valores dos Hiperparâmetros do Modelo	
Tamanho do *kernel* (filtro)	*kernel_size* = (3,3)
Tamanho do *pooling*	*pool_size* = (2,2)
Número de neurônios da primeira camada	num_neurons_1 = 42
Número de neurônios da segunda camada	num_neurons_2 = 84
Número de neurônios da terceira camada	num_neurons_3 = 168
Número de neurônios da quarta camada	num_neurons_4 = 256
Taxa de *dropout* nas camadas de convolução	*dropout_conv* = 0.3
Taxa de *dropout* na camada densa	*dropout_dense* = 0.3
Taxa de aprendizado	taxa_aprendizado = 0.0001
Número de épocas de treinamento	*num_epochs* = 300

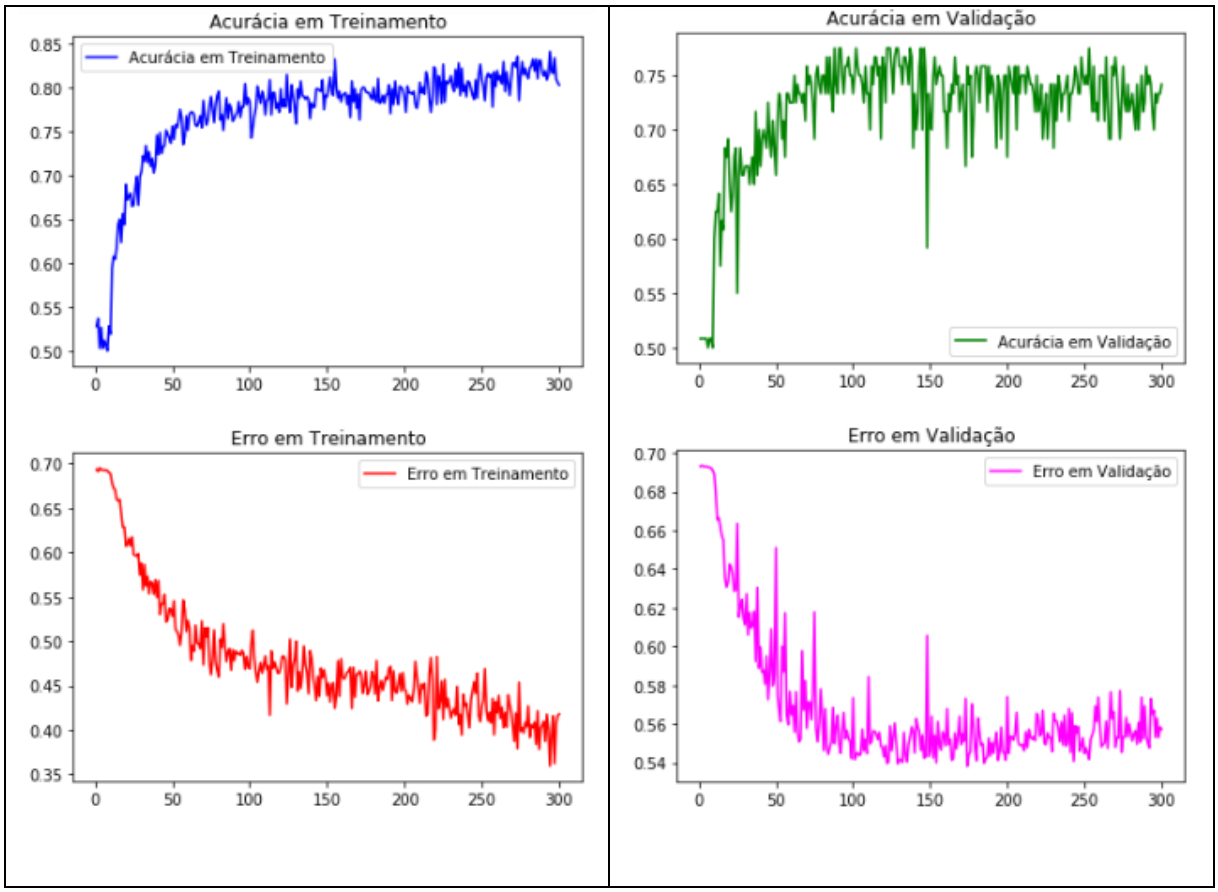
A Figura 91 ilustra a execução parcial final do treinamento do modelo:

Figura 91 - Execução do Treinamento da 3ª Versão



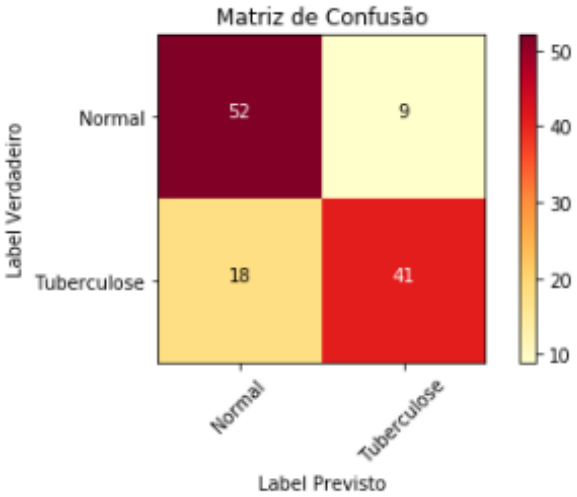
A acurácia da terceira versão modelo apurou um grau de eficiência na ordem de 77,5%. Na última época, pode ser verificado que a porcentagem de acurácia para treino foi 80,2% e a de validação 74,1% como pode ser visto na Figura 85. A partir da época de número 89, o modelo estabilizou a acurácia em 77,5% e não conseguiu estabelecer aprendizado depois desta época. Ao acionar o método *model.summary()* do objeto *model python*, observou-se que foram treinados 2.219.010 parâmetros. O Gráfico 4 ilustra o desempenho do algoritmo para a terceira versão:

Gráfico 4 - Acurácia e Erro em Treino e Validação 3ª Versão



Observa-se que os Gráficos desta versão não possuem a mesma linearidade da segunda versão. Os picos irregulares dos Gráficos de validação estão acentuados tanto para acurácia quanto para erros. Os dados de treinamento revelam-se bons, mas, quando submetidos a validação há baixa quantidade de acertos. Esta é uma situação que pode ocorrer em decorrência de *overfitting,* conforme ilustra a Figura 92.

Figura 92 - Matriz Confusão da 3ª Versão



No 1º quadrante da matriz conclui-se que em 52 imagens cujo raios X eram verdadeiramente normal, o modelo previu acertadamente como normal.

No 4º quadrante conclui-se que em 41 imagens cujos raios X era verdadeiramente diagnóstico de tuberculose, o modelo previu acertadamente como tuberculose.

No 2º quadrante conclui-se que em 9 imagens cujos raios X eram verdadeiramente normal, o modelo previu equivocadamente como tuberculose, ou seja, em 9 pessoas que não possuíam doença alguma o modelo previu que estariam doentes.

No 3º quadrante conclui-se que em 18 imagens cujos raios X eram verdadeiramente diagnóstico de tuberculose, o modelo previu equivocadamente como normal, ou seja, 18 pessoas que estavam doentes, foram previstas como normais.

A terceira versão, embora tenha mais camadas de aprendizado, teve aprendizado inferior ao da segunda versão. Possivelmente isto aconteceu em virtude da degradação do gradiente por causa da inserção de mais camadas.

Conclui-se que destas versões, a segunda é a mais confiável.

4.3 - TRANSFERÊNCIA DE APRENDIZAGEM PARA CATEGORIZAÇÃO DE PATOLOGIAS

Transferência de Aprendizado é uma técnica de Aprendizado de Máquina em que um modelo é treinado e desenvolvido para uma tarefa para ser reutilizado em uma segunda tarefa relacionada. Refere-se à situação em que o que foi aprendido em um ambiente é explorado para melhorar otimização em outra configuração (HUSSAIN *et*

al., 2018 *apud* Gao 2018). A Transferência de Aprendizado é geralmente aplicada quando há um novo conjunto de dados menor que o conjunto de dados original usado para treinar o modelo pré-treinado (HUSSAIN *et al*., 2018 *apud* Larsen-Freeman 2013). Assim, o uso de um modelo pré-treinado reduz significativamente o tempo necessário para engenharia de recursos e treinamento porque aproveita os pesos aprendidos do modelo já treinado para ser utilizado em outro modelo.

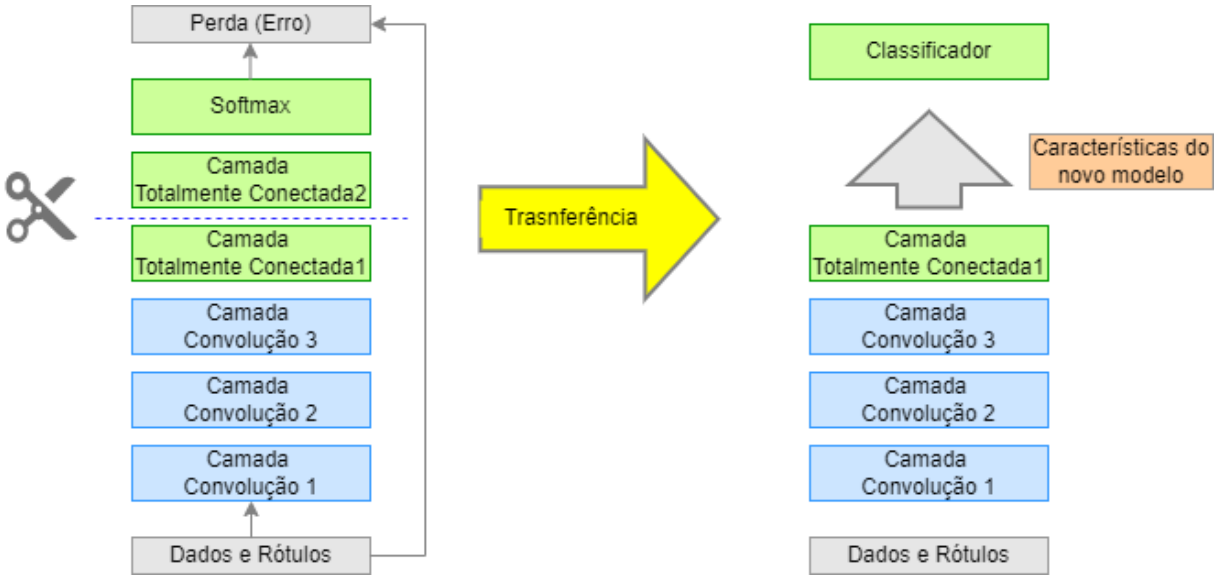
A primeira etapa do aprendizado é selecionar um modelo de origem com um grande conjunto de dados que será utilizado para o treinamento. Muitas instituições de pesquisas lançam esses modelos e conjuntos de dados como projetos de código aberto. Assim, não é necessário criar um modelo próprio.

A próxima etapa é decidir quais camadas do modelo pré-treinado será reutilizada em uma nova rede. Normalmente, as camadas mais profundas são reutilizadas, pois tendem a ser mais gerais, enquanto as camadas superiores da rede são ajustadas a um problema específico a ser resolvido.

Assim, o modelo pré-treinado é usado apenas como extrator de características; os recursos extraídos são inseridos em uma nova rede que executará a tarefa de classificação (APOSTOLOPOULOS *et al*., 2020), no caso desse trabalho, pulmões normais ou com Covid-19.

Na prática mantêm-se as camadas iniciais do conjunto de dados original porque normalmente são modelos genéricos, ou seja, praticamente iguais e retira-se dela as camadas finais substituindo-as pelas camadas finais do novo conjunto de dados, mas, aproveitando-se os pesos já treinados das camadas iniciais da rede neural do modelo pré-treinado. A Figura 93, lustra esta descrição:

Figura 93 - Transferência de Aprendizado



Fonte: LIMA *et al.*, 2023

4.3.1 - Trabalhos Relacionados à Transferência de Aprendizado

Narin *et al.,* (2020) utilizaram cinco diferentes modelos baseados em Redes Neurais Convolucionais, sendo eles, *ResNet50*, *InceptionV3*, *InceptionResNetV2, ResNet50 e ResNet101*. Estes modelos foram propostos para a detecção em imagens de raios X de pacientes infectados por coronavírus. Neste estudo, InceptionV3 e Inception-ResNetV2 alcançaram, respectivamente, 97% e 87% de acurácia. ResNet50 apresentou o melhor desempenho, obtendo 98% de acurácia. Foram processadas imagens de radiografia de tórax de 341 pacientes com COVID-19 os quais foram obtidas do repositório *GitHub* de código aberto compartilhado pelo Dr. Joseph Cohen, (COHEN *et al.,* 2020). As imagens foram divididas em 80% para treino, 10% para validação e 10% para teste. O método de aumento de dados foi usado com fator de escala = 1./255, faixa de cisalhamento = 0,1, faixa de zoom = 0,1 e inversão horizontal habilitada no conjunto de dados de treinamento. Todas as imagens foram redimensionadas para 224 x 224 pixels de tamanho nos conjuntos de dados.

Já Abbas (Abbas *et al*., 2020) utilizaram a arquitetura ResNet, obtendo 95,12 de acurácia. Apresentaram soluções robustas para a classificação de casos de COVID-19, com a capacidade de lidar com irregularidade de dados e com um número limitado de imagens de treinamento. Foram utilizadas 80 amostras de imagens de pulmão

normal e 105 de imagens obtidas de pacientes com Covid-19 fornecidas pela da Sociedade Japonesa de Tecnologia Radiológica. Utilizaram diferentes técnicas de aumento de dados para gerar mais amostras, incluindo rotacionar para cima/baixo e direita/esquerda, translação e rotação usando cinco ângulos aleatórios diferentes. Este processo resultou num em um total de 1764 amostras. O conjunto de dados foi então dividido em dois grupos: 70% para treinamento do modelo e 30% para avaliação do desempenho da classificação.

Em seus estudos (Kassania *et al.,* 2020) realizaram a comparação de extração das características de entrada de dados brutos, precisos e robustos baseada em Deep Learning, para a classificação automática de imagens de pacientes com COVID-19. Como componentes do aprendizado escolheram utilizar os modelos MobileNet, DenseNet121, Xception, ResNet, InceptionV3, InceptionResNetV2, VGGNet, NASNet entre um conjunto de sub arquiteturas de Redes Neurais Convolucionais profundas. Os recursos extraídos foram fornecidos a vários classificadores de Aprendizado de Máquina para classificar os assuntos como um caso de COVID-19 ou um caso de controle.

Neste caso, o extrator de recursos DenseNet121 com classificador de árvore de ensacamento, alcançou o melhor desempenho, com precisão de classificação de 99%.

4.3.2 - Metodologia Aplicada a Transferência de Aprendizado

Neste estudo foram desenvolvidos três *scripts* de programação utilizando linguagem *python* na versão 3.8.8 utilizando três modelos de inteligência artificial para detecção de Covid19 em imagens de raios X de pulmões, utilizando transferência de aprendizagem por modelos disponibilizados pela biblioteca *tensorflow*. Outras bibliotecas como *sklearn*, *matplotlib*, *numpy* e *keras* também foram utilizadas. Estes modelos são extremamente de alta precisão na aplicação do aprendizado para o diagnóstico de imagens da doença por coronavírus, denominada Covid19.

Assim, utilizando as técnicas segundo Narin *et al.,* (2020), foram escolhidos três dos cinco modelos preditivos de melhor performance conforme as métricas de Acurácia, Precisão, Recall e F1-Score, utilizando a linguagem *python* para o *framework tensorflow* versão 2.3.1 e a biblioteca *Keras* versão 2.11.0. Foram utilizados os

modelos *InceptionResNetV2*, *InceptionV3* e *ResNet50*, todos pré-treinados sob o conjunto de dados *ImageNet*.

O *ImageNet* é um conjunto de dados de domínio público pré-treinado que abrange 1.000 classes de objetos e contém 1.281.167 imagens de treinamento, 50.000 imagens de validação e 100.000 imagens de teste (Russakovsky *et al*., 2015).

Foram utilizados os pesos do conjunto de dados *imagenet* para pré-treinamento dos modelos de onde se aproveitam os pesos das camadas genéricas para que o treinamento não se inicie do zero, e assim, acelerando o seu processo de treinamento.

4.4 - DESCRIÇÃO DOS MODELOS PRÉ-TREINADOS UTILIZADOS

4.1 - RESNET50

O modelo de rede neural residual *ResNet* é uma versão aprimorada da CNN – Convolutional Neural Network. O *ResNet* adiciona atalhos entre camadas para resolver um problema, evitando distorção que ocorre à medida que a rede se torna mais profunda e complexa. Além disso, blocos gargalos são usados para tornar o treinamento mais rápido no modelo *ResNet* (WU *et al*., 2019).

4.2 - INCEPTIONV3

InceptionV3 é um tipo de modelo de rede neural convolucional. Ele consiste em várias etapas de convolução e agrupamento máximo de informação. No último estágio, ele contém uma camada de rede neural totalmente conectada (AHN *et al*., 2018).

4.3 - INCEPTIONRESNETV2

A *ResNet* é uma rede neural profunda que possui como característica evitar a degradação dos gradientes centrais da rede em decorrência da inserção indiscriminada de camadas na tentativa de melhorar o aprendizado GLOROT (2010). Percebeu-se que havia saturação da métrica da acurácia e, por conseguinte, a degradação do gradiente por isso desenvolveu-se as *ResNet's* introduzindo o bloco de aprendizado residual (HE *et al.,* 2015).

4.4 - BANCO DE IMAGENS

O banco de imagens para Covid19 utilizado neste estudo foi disponibilizado gratuitamente para uso de pesquisadores conforme termos descritos pelo BIMCV – *Medical Imaging Databank of The Valencia Region*, da cidade de Valência – Espanha. O banco de imagens é composto de 10192 imagens de pulmões normais, 3616 imagens de pulmões com Covid19 e 1095 imagens de pulmões com pneumonia. Foram separadas em 80% imagens para treino, 10% para validação e 10% para testes utilizando o conjunto de imagens de pulmões Normais e com Covid19.

4.5 - HIPER-PARÂMETROS

O método de aumento de dados foi usado com fator de escala = 1./255, faixa de cisalhamento = 0,2, faixa de zoom = 0,3 e inversão horizontal habilitada e ângulo de rotação de 30º no conjunto de dados de treinamento. O algoritmo utilizado foi o *backprogation Adam* com taxa de aprendizagem mínima de 0.000001. Todas as imagens foram redimensionadas para 224 x 224 pixels de tamanho nos conjuntos de dados e executadas em 15 épocas ou ciclos de percursos do algoritmos da rede neural. Foram desenvolvidas duas funções do tipo call-back, sendo elas:
A) Uma interrompe a execução do treinamento depois de percorrer por duas vezes o fluxo do algoritmo pelo conjunto de dados caso não haja aprendizado na rede.
B) A outra diminui a taxa de aprendizado da rede depois de dois percursos caso não ocorra aprendizado deverá ser diminuída a taxa de aprendizado para que a rede retorne a aprender.

Os três modelos, ou seja, *ResNet50*, *InceptionV3* e *InceptionResNetV2* foram treinados utilizando os mesmos parâmetros e hiper parâmetros para se estabelecer a comparação da melhor acurácia. Além da acurácia e matriz confusão, utilizados em outros modelos neste projeto, outros critérios como, *precision*, *recall* e *f1-core* foram utilizados para determinar o melhor modelo treinado o qual irá se integrar à plataforma patologIA.

4.6 - BALANCEAMENTO DE CLASSES

O modelo desenvolvido é generalizável, ou seja, depois do treinamento com os dados de treino o modelo deve ser capaz de fazer previsões ou extrair padrões em novos conjuntos de imagens. Se houver desbalanceamento de classes no aprendizado o modelo irá aprender mais sobre as caraterísticas da classe majoritária do que da classe minoritária. Neste trabalho, há 10192 imagens normais correspondendo a 74% do total consideradas com diagnósticos de normalidade (Classe 1) e 3616 imagens de resultados de pacientes com diagnóstico de covid (Classe 0) ou 26% do total. A tarefa do modelo será aprender o relacionamento matemático da combinação de pixels de imagens classificadas como covid e da combinação de pixels classificadas como normais. O modelo deve aprender de forma igual as características dos dois tipos de imagem.

Uma das técnicas para resolver o problema de desproporção das imagens seria utilizar a técnica do *oversampling* da classe minoritária criando imagens sintéticas para aumentar o número de imagens de covid. Outra técnica seria utilizar o *undersampling* da classe majoritária para reduzir o número de imagens normais. Outra alternativa seria fornecer um peso para cada uma das classes para que o modelo pudesse realizar um balanceamento ponderado no aprendizado. Basicamente seria calculada a proporção da quantidade de imagens das classes e fornecer um peso a cada uma delas.

Foi proposto neste trabalho o desenvolvimento de um modelo para produzir o aprendizado com base na proporção de imagens. Assim, esta técnica estima o peso das classes majoritária (Normal) e minoritária (Covid) para o *dataset* desbalanceado.

O balanceamento ponderado será realizado apenas em imagens de treino cujo objetivo é de treinar o algoritmo do modelo porque as imagens para validação são utilizadas para avaliar o modelo durante o treinamento e as imagens de teste para validar a performance do modelo já treinado, apresentando a ele imagens que não foram submetidas ao treinamento para que se faça previsões. Utilizou-se o algoritmo de balanceamento ponderado segundo o método *compute_class_weight()* da biblioteca *sklearn* para realizar essa tarefa. Para Kabir (KABIR *et al*., 2022) como a distribuição de classes sobre o conjunto de dados é distorcida, utiliza-se a precisão ponderada ou balanceamento ponderado em função do número de imagens de cada classe (Normal ou Covid). O objetivo aqui foi atribuir pesos diferentes aos diferentes custos de erros de classificação enquanto calcula-se o custo total durante o

treinamento o qual é alcançado atribuindo pesos maiores às classes minoritárias e pesos menores às classes majoritárias (SHRIVASTAVA *et al*., 2022).

Os pesos estabelecidos pelo algoritmo do método *compute_class_weight* para cada classe foram 1.90 para classe 0 (Covid) minoritária e 0.677 para classe 1 (Normal) majoritária.

Antes de começar o treinamento congelou-se os pesos das camadas previamente treinadas do modelo tornando-os valores constantes, ou seja, imutáveis. Assim, evita-se que o treinamento se inicie novamente e perca o trabalho de transferência de aprendizado zerando seus pesos.

O aprendizado por transferência é um método no qual as informações do modelo pré-treinado são aplicadas a um grande conjunto de dados para resolver um problema semelhante em diferentes conjuntos de dados. Aqui, os pesos de todas as camadas são congelados, exceto os últimos da camada totalmente conectados como visto na Figura 87, ou seja, apenas os pesos das camadas descongeladas participam do treinamento, reduzindo a complexidade computacional produzindo desempenho adequado ao método (SHRIVASTAVA *et al*., 2022).

4.7 - ESQUEMA DE MÉTRICAS DA MATRIZ CONFUSÃO

Em relação à tarefa de classificação das CNNs, as métricas específicas foram registradas da seguinte forma na matriz confusão, conforme a Figura 94:

Figura 94 - Transferência de Aprendizado

	Normal	**Covid**
Verdadeiro	VP - Verdadeiro Positivo 1	FP - Falso Positivo 2
	FN - Falso Negativo 3	VN - Verdadeiro Negativo 4
	Previsto	

Fonte: LIMA *et al.*, 2023

(1º Quadrante - Verdadeiro Positivo, VP) casos de imagens corretamente identificados como Normal ou sem a presença do diagnóstico de doenças e o modelo previu como Normais;

(2º Quadrante - Falso Positivo, FP) casos de imagens classificadas incorretamente, ou seja, as imagens são classificadas com diagnóstico Normal, mas que foram classificadas como Covid-19 pelo modelo.

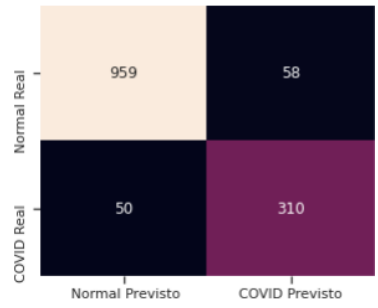
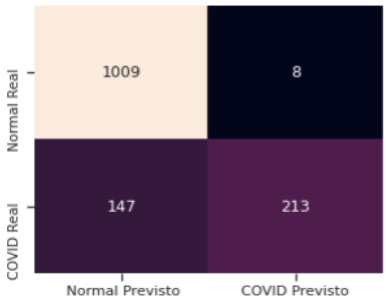
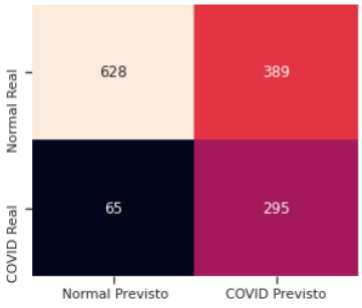
(3º Quadrante - Falso Negativo, FN) casos de imagens classificadas incorretamente, ou seja, as imagens deveriam ser classificadas com diagnóstico de COVID-19 e foram classificadas como Normais pelo modelo, esse erro é considerado o mais perigoso, pois o paciente que deveria ter o tratamento não tem o diagnóstico da doença;

(4º Quadrante - Verdadeiro Negativo, VN) casos de imagens corretamente identificados como Covid-19 e o modelo previu como Covid-19.

Observa-se, na Figura 88 que na diagonal principal encontram-se os acertos (VP e VN) e na secundária os erros (FN e FP).

A Figura 95 exibe o resultado do processamento em cada modelo testado:

Figura 95 - Matriz Confusão

<table>
<tr><td colspan="3">Modelos Treinados (Redes Neurais)</td></tr>
<tr><td>InceptionResNetV2</td><td>InceptionV3</td><td>ResNet50</td></tr>
<tr><td>
</td><td>
</td><td>
</td></tr>
</table>

Fonte: LIMA *et al.*, 2023

Segundo HARRISON (2020), acurácia é a porcentagem de classificações corretas.

Em virtude da acurácia ser um índice global, é necessário a criação da matriz confusão dos três modelos para apurar seus resultados. As imagens de teste (10% do total) possuem a quantidade de 1017 imagens de pulmões normais e 360 imagens de

pulmões com Covid-19. A Tabela 4 exibe o resumo dos resultados da Matriz Confusão de cada modelo.

Em virtude da acurácia ser um índice global, é necessário a criação da matriz confusão dos três modelos para apurar seus resultados. As imagens de teste (10% do total) possuem a quantidade de 1.017 imagens de pulmões normais e 360 imagens de pulmões com COVID-19. A Tabela 4 exibe o resumo dos resultados da Matriz Confusão de cada modelo.

Tabela 4 - Resultados da Matriz Confusão de cada Modelo

Resumo Matriz Confusão				
Rede	VP (un)	FP (un)	FN (un)	VN (un)
InceptionResNetV2	959	58	50	310
InceptionV3	1009	8	147	213
ResNet50	628	389	65	295

Fonte: LIMA *et al*., 2023, p. 13

Além da matriz confusão foram necessárias utilizar outras métricas obtidas junto ao pacote *sklearn (ou scikitlearn)*. A Figura 95 mostra as equações de cada métrica utilizada. A Acurácia (Equação 3), Precisão (*precision*) (Equação 4), Sensibilidade (Equação 5), Especificidade ou *recall,* (Equação 6) e *F1-Score* (Equação 7). As equações de número 2 a 5 complementares à acurácia.

Figura 96 - Métricas

Métricas - Equações

$$acurácia = \frac{VP + VN}{VP + FN + VN + FP}$$

$$precisão = \frac{\mathrm{VP}}{\mathrm{VP} + \mathrm{FP}}$$

$$sensibilidade = \frac{VP}{VP + FN}$$

$$especificidade = \frac{VN}{VN + FP}$$

$$f1 = 2 * \frac{precisão * sensibilidade}{precisão + sensibilidade}$$

Fonte: LIMA *et al.*, 2023

A Tabela 5 exibe o resultado das métricas em cada modelo calculadas com a utilização do algoritmo do método *classification_report* do *python*. Este método calcula as métricas de precisão (*precision*), sensibilidade (*recall*), F1-score e acurácia.

Tabela 5 - Métricas dos modelos de redes

Resultado das Métricas					
Rede	Imagem	Precisão	Sensibilidade	F1-Score	Acurácia %
InceptionResNetV2	Normal Covid	0,84 0,95	0,86 0,94	0,85 0,95	92,15
InceptionV3	Normal Covid	0,96 0,87	0,59 0,99	0,73 0,93	88,74
ResNet50	Normal Covid	0,43 0,91	0,82 0,62	0,57 0,73	67,02

Fonte: LIMA *et al.*, 2023

Análise dos Resultados dos Modelos Testados para Transferência de Aprendizado

Segundo SCUDILIO (2020) Recall ou Sensibilidade é a proporção dos Verdadeiros Positivos entre todas as observações que realmente são positivas no seu conjunto de dados, ou seja, entre todas as observações que são positivas quantas o modelo conseguiu identificar como positiva. Representa a capacidade de um modelo em prever a classe positiva. Assim, para todos os pacientes que realmente têm uma

patologia, o recall informa a quantidade de pacientes identificada corretamente como tendo uma doença patológica (MENDES, 2023).

Para SCUDILIO (2020) precisão é a métrica que traz a informação da quantidade de observações classificadas como positiva que realmente são positiva. Ou seja, entre todas as observações identificadas como positivas, quantas foram identificadas corretamente. Para a identificação do problema, essa seria a medida de pacientes que são identificados corretamente como tendo uma patologia entre todos os pacientes que realmente a possuem (MENDES, 2023). Segundo HARRISON (2020), é a capacidade de encontrar somente amostras relevantes, ou seja, não atribuir um rótulo positivo a um negativo.

F1-Score: Para HARRISON (2020), é a média harmônica entre precisão e recall para cada uma das classes, ou seja, visa aprimorar a precisão do modelo.

4.7.1 – Relatório InceptionResNetV2

No *InceptionResNetV2*, o modelo, na métrica *Recall*, consegue detectar a classe Normal em 86% dos casos e em 94% da classe de Covid.

A Precisão toma como base a porcentagem estabelecida no *Recall*. Isso quer dizer que em 94% das classificações como Covid, 95% das imagens de teste foram previstas corretamente. De 86% de imagens classificadas como Normais, 85% foram previstas como Normais.

A métrica *F1-Score* mostra um valor mais realista em relação à acurácia, ou seja, 85% para classe Normal e 95% para Covid.

Observou-se que os modelos InceptionV3 e ResNet50**,** neste exemplo, previram dez imagens como verdadeiro positivo com o rótulo (*label*) Normal e 5 imagens verdadeiro negativo onde os modelos previram as imagens com o rótulo Covid.

Já o modelo InceptionResNetV2 previu 9 imagens Normais como verdadeiro positivo e 5 imagens como verdadeiro negativo onde o modelo previu como Normal imagens com o rótulo de Covid, gerando a ocorrência de Falso Positivo.

4.7.2 – Relatório InceptionV3

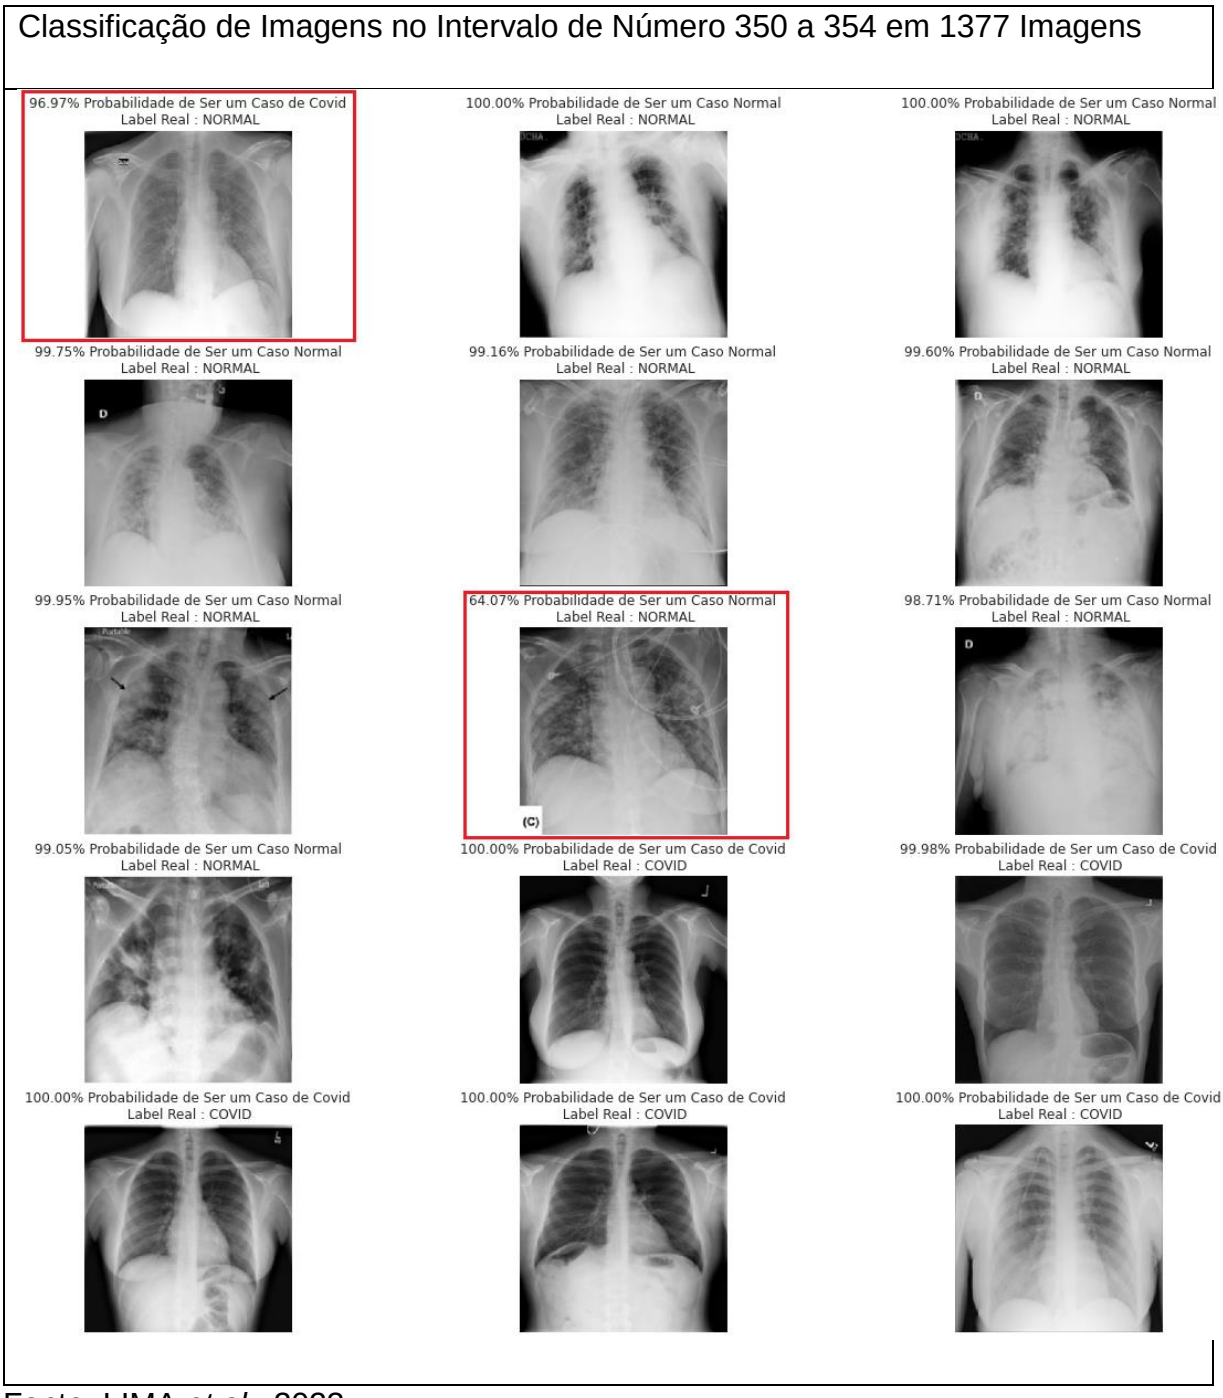
No *InceptionV3*, o modelo, na métrica *Recall,* consegue detectar a classe Normal em 59% dos casos e em 99% da classe de Covid.

A Precisão em 59% das classificações como Normal, 96% das imagens de teste foram previstas corretamente. De 99% de imagens classificadas como Covid, 87% foram previstas como Covid.
A métrica *F1-Score* mostra o valor de 73% para classe Normal e 93% para Covid.

4.7.3 – Relatório ResNet50

No *ResNet50*, o modelo, na métrica *Recall,* consegue detectar a classe Normal em 82% dos casos e em 62% da classe de Covid.
A Precisão em 62% das classificações como Covid, 91% das imagens de teste foram previstas corretamente. De 82% de imagens classificadas como Normais, 43% foram previstas como Normais.
A métrica *F1-Score* mostra o valor de 57% para classe Normal e 73% para Covid-19.
As Figuras 97, 98 e 99 exibem exemplos de 15 imagens selecionadas aleatoriamente, via programação, referentes ao intervalo de número 350 a 364 de 1377 imagens de teste.
Embora os três modelos tenham acertado a previsão destas 15 imagens, observa-se que as porcentagens de previsões são diferentes para cada modelo.
No *InceptionResNetV2*, com exceção de uma imagem com falso positivo e outra com porcentagem de 64,07% (ambas em destaque vermelho), as outras 13 das 15 imagens apresentam previsão na ordem de 98,71% a 100,00%.

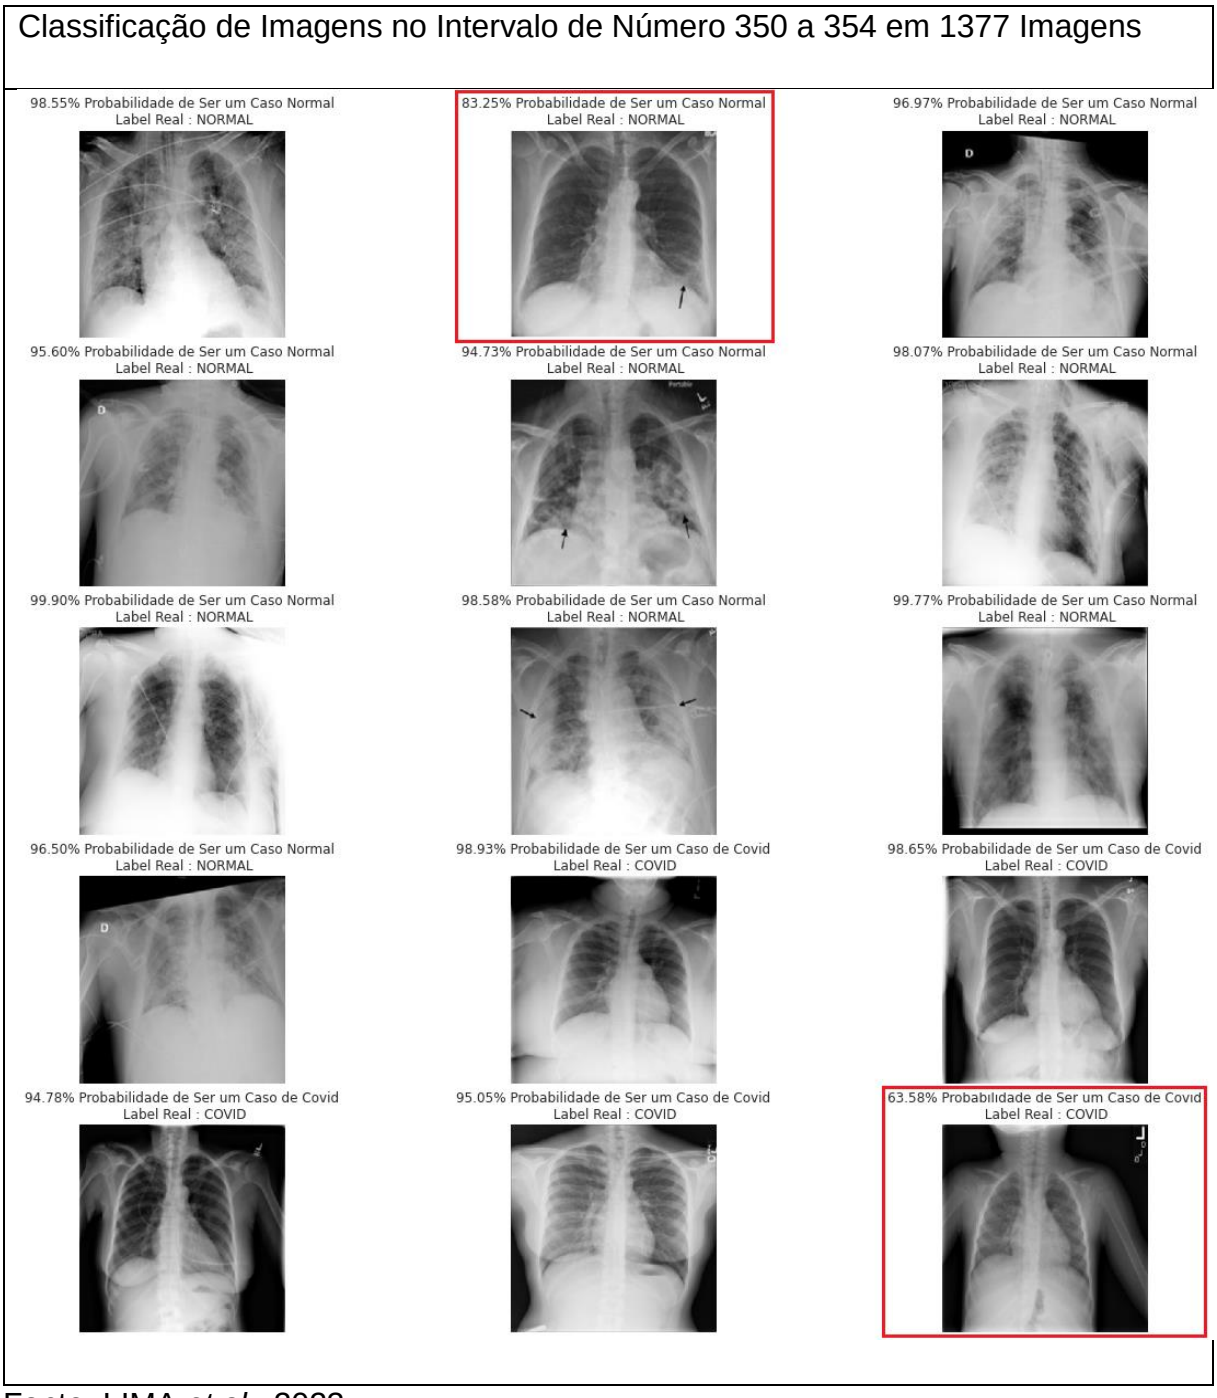
Figura 97 - InceptionResNetV2



Fonte: LIMA *et al.*, 2023

No *InceptionV3*, com exceção da segunda imagem com previsão de 83,25% e da última imagem cuja previsão foi de 63,58% (em destaque vermelho), as demais apresentaram previsão de 94,73% a 99,90%.

Figura 98 - InceptionV3

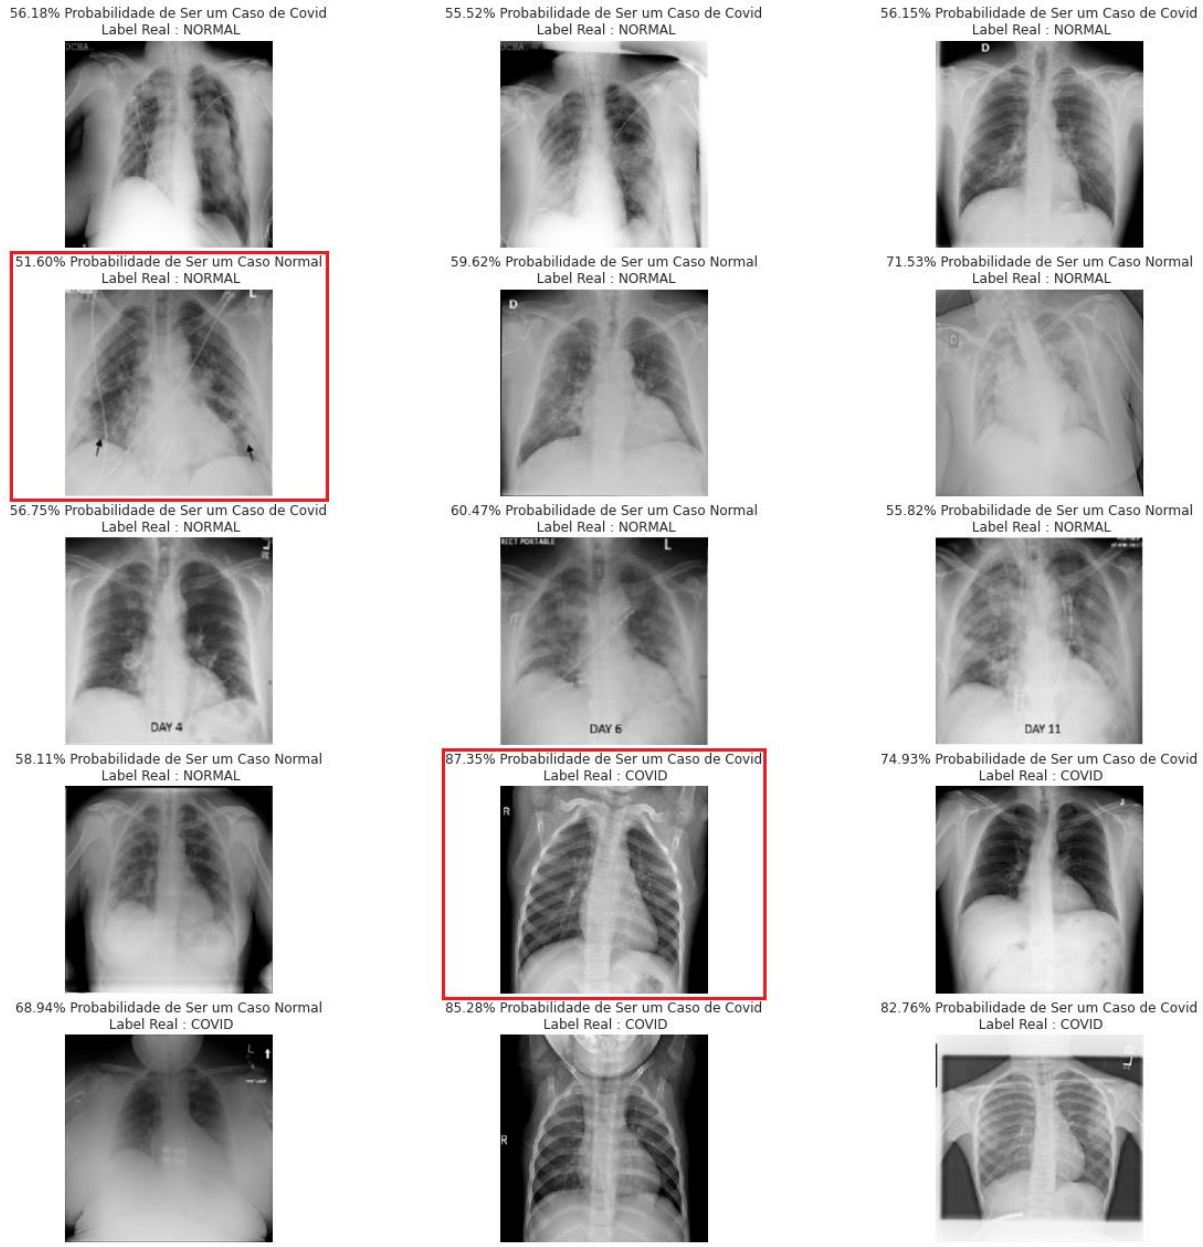


Fonte: LIMA *et al.*, 2023

No *ResNet50*, apenas 3 das 15 imagens tiveram previsão acima de 80%. As demais, variaram entre 51,6% a 74,93%, tornando-se o menos eficiente entre os três modelos estudados.

Figura 99 - ResNet50

Classificação de Imagens no Intervalo de Número 350 a 354 em 1377 Imagens



Fonte: LIMA *et al.*, 2023

Pode-se observar que o modelo *InceptionResNetV2* oferece melhor desempenho em todos os casos porque acarretou maior uniformidade dos resultados para este conjunto de imagens. Essa uniformidade pode ser verificada entre os valores aproximados das métricas de precisão, sensibilidade e F1-Score demonstrados na Tabela 5. O modelo mostrou-se estável ao final do último ciclo de aprendizado durante o treinamento porque acarretou acurácia de validação à taxa de 0,9090 (90%) e em

acurácia de treino à taxa de 0,9117 (91%). A proximidade entre as métricas significa a não ocorrência de *overfitting* durante o treinamento. Este estudo provém conhecimento sobre como os métodos de aprendizado por transferência profunda podem ser utilizados.

O capítulo 5 irá discutir os resultados obtidos sobre os propósitos disponibilizados pelo sistema.

CAPÍTULO 5 - DISCUSSÕES E RESULTADOS SOBRE A PLATAFORMA

Em contato mantido com a diretoria do CREMESP na cidade de São Paulo, foi solicitada a disponibilização de todos os exames aplicados aos profissionais de medicina recém-formados a partir do ano de 2005, quando aconteceu o primeiro certame até o último ocorrido em 2018 para fins acadêmicos. A intenção seria alimentar a base de dados do sistema com questões retiradas destes exames. No entanto, foi informado que o órgão responsável pela elaboração das provas seria a Fundação Carlos Chagas com quem deveria requerer tal solicitação. Esta entidade, no entanto, negou o fornecimento das questões dos exames em virtude de segurança e de direitos autorais.

O CREMESP declinou da aplicação dos exames a partir de 2019 depois que a justiça do estado de São Paulo determinou o fim da obrigatoriedade da realização do exame CREMESP, que condicionava o registro dos profissionais formados em Medicina no estado à participação no exame. O órgão foi obrigado a abster-se de publicar os resultados em seu sítio eletrônico e nos meios de comunicação da entidade e outros veículos de comunicação listas de classificação do desempenho dos estudantes egressos das instituições de ensino superior, nominando-as, salvo se autorizado pela própria instituição de ensino.

Os sistemas similares apresentados no item 2.1, apesar de excelentes projetos, não permitem aferir o desempenho do aprendizado do estudante por atribuição de pontuação por acerto de questões e não permite a demarcação de regiões na imagem por professor para o treinamento de estudantes.

O trabalho desenvolvido é apoiado na utilização de *softwares* e bibliotecas *open source*, face aos benefícios de auditoria e segurança intrínsecos ao modelo de distribuição adotado.

Entretanto, face à diversidade de bibliotecas voltadas à inteligência artificial na linguagem *python*, fornecidas por diferentes desenvolvedores, com diferentes periodicidades de versionamento e essenciais em diferentes fases do projeto, não são raros problemas relacionados a “sistemas quebrados” em função de incompatibilidades de versão entre bibliotecas.

O Container é uma tecnologia que pode ser aplicada ao controle de versões porque agrupam todas as dependências necessárias em um pacote. Eles são portáteis, rápidos, seguros, escaláveis e fáceis de gerenciar utilizando uma ferramenta para gerenciamento de contêineres como o *Kubernetes* ou o *Docker swarm*.

Assim, a migração para ambiente de nuvem, municiado por recursos de desenvolvimento em “notebooks” *Jupyter* como o *SageMaker* da AWS, gerenciado pelo provedor da solução, é uma alternativa nesse tipo de cenário, frente aos requisitos de estabilidade, compatibilidade e dados heterogêneos, necessárias em aplicações dinâmicas como a apresentada neste trabalho.

Fenômenos físicos presentes no processo de formação de imagens radiológicas e problemas encontrados nos sistemas públicos de saúde, tem impacto na qualidade dos exames produzidos.

Se a origem do problema, apesar de conhecida, é de difícil solução, é preciso que profissionais de saúde tenham ferramentas de treinamento e apoio ao diagnóstico capazes de lidar com estas dificuldades.

Na plataforma apresentada, é importante a participação de professores e médicos especialistas, de modo a conduzir e acompanhar os procedimentos de ensino-aprendizagem e fornecer diagnósticos assertivos para as imagens disponibilizadas aos alunos respectivamente.

A tecnologia de aprendizado profundo utilizada na plataforma baseia-se na contribuição desses profissionais no processo de treinamento da rede, passo necessário para a emissão de laudos de imagens obtidas em bases de dados públicas disponíveis na *Internet*, que posteriormente serão analisadas e validadas com a supervisão de um profissional de saúde qualificado.

Uma vez populado e devidamente validado, o sistema poderá então ser submetido a estudantes de medicina ao longo do curso, de modo a propiciar em sua formação a qualificação e capacitação necessárias para o domínio de suas habilidades com ênfase em tecnologias emergentes (LIMA *et al.,* 2021).

5.1 – COMPILAÇÃO DE DADOS ESTATÍSTICOS

Foram realizados três testes distintos para validar a plataforma; o de usabilidade, o de funcionalidade com estudantes e de funcionalidade com professores.

5.1.1 – Testes de Usabilidade

O teste de usabilidade foi realizado por 22 usuários especializados na área de informática que responderam o questionário do Anexo A. Segundo Nielsen (NIELSEN, 1994) o teste feito com 5 usuários pode encontrar ao menos 85% dos problemas de um produto.

O cálculo da usabilidade proposto por Brooke apurou um coeficiente de 58,97 (BROOKE, 1986). Em seus estudos, Brooke afirma que uma interface para ser considerada boa deve ter um coeficiente de 68 e razoável entre 50 e 67 conforme Gráfico 5. O coeficiente apurado mostra que a interface pode ser melhorada utilizando a técnica da avaliação heurística proposta por Nielsen que é simples e eficaz.

Cálculos da Usabilidade realizados segundo Brooke onde P1, P2, P3, etc, referem-se às respostas das perguntas do Apêndice A (BROOKE, 1986), conforme resultados na Tabela 6.

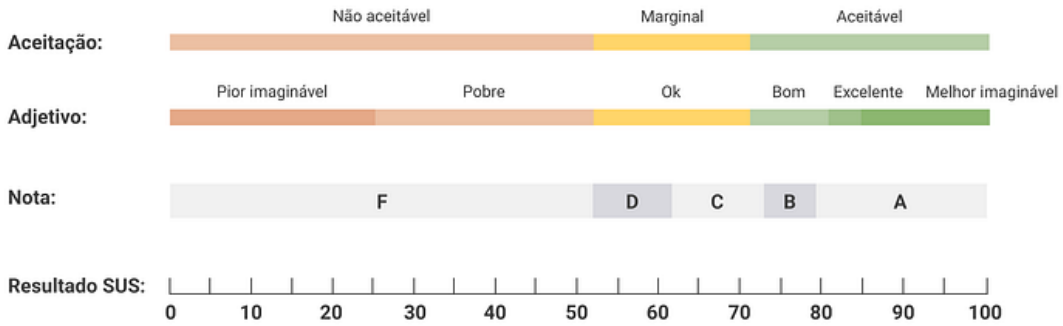
- Total Ímpar = (P1 + P3 + P5 + P7 + P9) – 5
- Total Par = 25 – (P2 + P4 + P6 + P8 + P10)
- Totais = (Total Ímpar + Total Par) * 2,5
- Média Geral = Soma Totais / 22

Tabela 6 - Cálculo da Usabilidade

Avaliador	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	Total Ímpar	Total Par	Totais	Média Geral
1	3	5	5	5	5	1	5	2	5	5	18	7	62,5	58,98
2	3	4	5	1	3	2	5	1	4	3	15	14	72,5	
3	5	5	5	1	2	3	5	1	5	1	17	14	77,5	
4	1	2	5	5	4	1	5	1	2	1	12	15	67,5	
5	4	1	4	1	3	2	4	3	4	1	14	17	77,5	
6	5	3	5	4	4	5	5	5	5	5	19	3	55,0	
7	3	2	3	3	2	5	4	4	2	1	9	10	47,5	
8	3	2	4	1	4	1	5	1	5	1	16	19	87,5	
9	5	1	4	2	5	1	4	1	5	1	18	19	92,5	
10	3	3	4	4	3	4	2	4	3	4	10	6	40,0	
11	5	4	3	1	3	1	4	3	3	1	13	15	70,0	
12	3	2	4	2	4	2	5	1	4	1	15	17	80,0	
13	1	5	2	3	1	3	2	5	1	3	2	6	20,0	
14	2	5	1	4	1	5	1	5	1	3	1	3	10,0	
15	2	2	4	1	2	4	4	2	3	2	10	14	60,0	
16	3	4	5	4	3	1	3	3	4	5	13	8	52,5	
17	1	2	2	4	3	1	5	2	4	2	10	14	60,0	
18	1	5	2	3	1	2	2	5	3	2	4	8	30,0	
19	2	4	2	4	3	3	3	2	2	4	7	8	37,5	
20	3	2	4	1	4	3	4	3	4	3	14	13	67,5	
21	3	4	3	3	2	3	4	4	3	2	10	9	47,5	
22	4	3	3	2	5	1	4	1	5	1	16	17	82,5	

O Gráfico 5 ilustra o desempenho da medida da usabilidade calculada para a plataforma.

Gráfico 5 - Medida de Usabilidade



Fonte: Medium. Guia: Como medir a usabilidade de produtos com System Usabilidade Scale (SUS). c2019

5.1.2 – Testes de Funcionalidades com Estudantes

O teste de funcionalidades constou da avaliação elaborada por um professor da disciplina de Imagenologia do curso de medicina da Universidade de Mogi das Cruzes. Foram convidados 104 estudantes de medicina que cursavam a disciplina e, gentilmente, se dispuseram a realizar o teste presencialmente em um dos laboratórios de informática da Universidade de Mogi das Cruzes.

Após a finalização do teste, cada estudante respondeu ao questionário de funcionalidades conforme descrito no Anexo B.

A compilação de dados estatísticos foram realizados através de testes não paramétricos *U de Mann-Whitney* onde foi utilizada a tabulação cruzada que permite medir a interação entre duas variáveis numa mesma pergunta. Estas variáveis são os grupos Controle e Experimental no qual os estudantes foram divididos.

Neste estudo, trabalhou-se com o intervalo de confiança de 95% e nível de significância de $\alpha = 0,05$. De acordo com a Tabela 6, o valor do nível de significância *(p)* está demonstrado na coluna denominada “Sinal Assintótico”. A pergunta número 1 foi a única que apresentou diferença estatisticamente significante $p = 0,035$, as demais não apresentaram diferença estatisticamente significante.

Lembrando que a pergunta de número 1 “Eu creio que essa plataforma poderia ser usada em cursos relacionados com interpretação de imagens médicas”, foi apurado o nível de significância de 0,035, ou seja, um valor inferior de 0,05. Isto significa que há diferença estatisticamente significativa entre os dois grupos.

Observando a Tabela 7 os estudantes que responderam o conceito 4 (Concordo) do Grupo Experimental representam 12% do total de 63 respostas. Já o Grupo Controle 0% respondeu o conceito 4 (Concordo). No Grupo Experimental 84% responderam a opção 5 (Concordo Totalmente) contra 97% do Grupo Controle que responderam a opção 5 (Concordo Totalmente) e apenas um estudante respondeu o conceito 3 (Indiferente). Embora o nível de significância tenha apresentado um resultado estatisticamente significante onde a hipótese nula se esperava que ambos os grupos respondessem de forma semelhante, onde as respostas seriam distribuídas entre os conceitos 4 (Concordo) e 5 (Concordo Totalmente), isto não aconteceu por causa da alta taxa de resposta do conceito 5 (Concordo Totalmente) do grupo Controle, mas, ambas respostas “Concordam” com a pergunta que foi feita. Tanto esta resposta quanto as respostas das outras nove perguntas, validam a plataforma.

Tabela 7 - Resultados do Teste U de Mann-Whitney (não paramétrico) entre os grupos GC e GE utilizando as perguntas do Anexo B

Perguntas	U de Mann-Whitney	Sinal assintótico*
1.Eu creio que essa plataforma poderia ser usada em cursos relacionados com interpretação de imagens médicas.	1.122,00	0,035**
2. Eu consegui testar meus conhecimentos sobre interpretação de imagens médicas.	1.302,50	0,866
3. Eu acredito que o uso da plataforma irá me ajudar a adquirir habilidades na interpretação de imagens médicas.	1.313,50	0,815
4. Eu melhoraria o conteúdo da plataforma adicionando mais abas para novas funcionalidades.	1.038,50	0,76
5. Eu acredito que as funcionalidades da plataforma são suficientes e adequadas para seu propósito.	1.423,00	0,332
6. Eu acredito que o menu Questionário está adequado as minhas necessidades.	1.370,00	0,541
7. Eu tive facilidade para encontrar o questionário a ser respondido.	1.326,50	0,797
8. Eu acredito que tive facilidades em responder as perguntas do questionário.	1.404,00	0,415
9. Eu entendi com facilidade a dinâmica da plataforma que oferecia uma segunda chance para responder a uma questão.	1.235,00	0,684
10. Eu acredito que o menu Resultados está adequado as minhas necessidades.	1.274,00	0,893

*Teste bilateral.
**Significância estatística.

A Tabela 8 contabiliza as respostas obtidas pelas respostas dos 104 estudantes.

Tabela 8 - Respostas das 10 perguntas com relação as repostas dos estudantes

		Respostas*					
Perguntas	**Grupos**	**1**	**2**	**3**	**4**	**5**	**Total**
1.Eu creio que essa plataforma poderia ser usada em cursos relacionados com interpretação de imagens médicas.	**GC**	0	0	1	0	40	41
	GE	0	0	2	8	53	63
2. Eu consegui testar meus conhecimentos sobre interpretação de imagens médicas.	**GC**	0	0	0	3	38	41
	GE	0	0	1	3	59	63
3. Eu acredito que o uso da plataforma irá me ajudar a adquirir habilidades na interpretação de imagens médicas.	**GC**	0	0	0	7	34	41
	GE	1	0	3	5	54	63
4. Eu melhoraria o conteúdo da plataforma adicionando mais abas para novas funcionalidades.	**GC**	2	2	7	8	22	41
	GE	5	2	19	15	22	63
5. Eu acredito que as funcionalidades da plataforma são suficientes e adequadas para seu propósito.	**GC**	0	0	9	12	20	41
	GE	0	2	8	16	37	63
6. Eu acredito que o menu Questionário está adequado as minhas necessidades.	**GC**	0	0	5	12	24	41
	GE	1	0	8	12	42	63
7. Eu tive facilidade para encontrar o questionário a ser respondido.	**GC**	0	1	9	9	22	41
	GE	1	5	5	17	35	63
8. Eu acredito que tive facilidades em responder as perguntas do questionário.	**GC**	0	1	6	17	17	41
	GE	0	2	9	19	33	63
9. Eu entendi com facilidade a dinâmica da plataforma que oferecia uma segunda chance para responder a uma questão.	**GC**	0	6	4	9	22	41
	GE	2	6	7	18	30	63
10. Eu acredito que o menu Resultados está adequado as minhas necessidades.	**GC**	0	0	7	8	26	41
	GE	1	1	8	14	39	63

Fonte:

*Não houve nenhuma resposta 0 (zero).

5.1.3 – Testes de Funcionalidades com Professores

Este último teste foi realizado por 4 professores com experiência na área de imagens médicas que avaliaram individualmente a plataforma conforme um roteiro de tarefas apresentado conforme descrito no Apêndice D. Após a interação com o sistema, os professores responderam a um questionário conforme descrito no Apêndice C. O resultado da compilação de dados está descrito na Tabela 8 onde os professores consideram a plataforma satisfatoriamente por atingir média aritmética geral de 4,61, conforme descreve a Tabela 9.

Tabela 9 - Respostas dos Professores com relação às Perguntas

		Respostas					
Perguntas	**Professores**	**1**	**2**	**3**	**4**	**5**	**Média**
1.Eu creio que essa plataforma poderia ser usada em cursos relacionados com interpretação de imagens médicas.	1					5	4,75
	2					5	
	3					5	
	4				4		
2. Eu consegui testar meus conhecimentos sobre interpretação de imagens médicas.	1					5	5,0
	2					5	
	3					5	
	4					5	
3. Eu acredito que o uso da plataforma irá me ajudar a adquirir habilidades na interpretação de imagens médicas.	1					5	4,75
	2					5	
	3					5	
	4					4	
4. Eu melhoraria o conteúdo da plataforma adicionando mais abas para novas funcionalidades.	1					5	5,0
	2					5	
	3					5	
	4					5	
5. Eu acredito que as funcionalidades da plataforma são suficientes e adequadas para seu propósito.	1					5	5,0
	2					5	
	3					5	
	4					5	
6. Eu acredito que o menu Questionário está adequado as minhas necessidades.	1				4		4,75
	2					5	
	3					5	
	4					5	
7. Eu tive facilidade para encontrar o questionário a ser respondido.	1				4		4,5
	2					5	
	3					5	
	4				4		
8. Eu acredito que tive facilidades em responder as perguntas do questionário.	1	1					3,5
	2				4		
	3					5	
	4				4		
9. Eu entendi com facilidade a dinâmica da plataforma que oferecia uma segunda chance para responder a uma questão.	1					5	4,25
	2					5	
	3			3			
	4				4		

6 – CONCLUSÃO

O objetivo deste trabalho foi responder a uma pergunta a qual questionava se estudantes poderiam aprender interpretação de imagens médicas com o auxílio de tecnologias digitais usando computador. De acordo com Horvat, mais estudos são necessários para explorar diferentes estratégias educacionais e seu impacto no conhecimento clínico dos principais conceitos radiológicos dos estudantes de medicina (HORVAT, 2023).

Pode-se considerar como importante o alto índice de participação estudantil durante os estudos tanto da parte de medicina quanto da parte de informática o que reflete o interesse destes estudantes em participar de pesquisas científicas e enfatiza a importância do aprendizado da interpretação de imagens médicas ao longo do curso de medicina, importância esta detectada nos exames aplicados pelo CRESMESP aos egressos dos cursos de medicina no estado de São Paulo.

A plataforma desenvolvida demonstrou ser útil na interação com os estudantes onde os testes estatísticos comprovam esta afirmação.

Professores que a utilizaram, também, comprovaram sua utilidade.

Em tempos de ebulição da inteligência artificial, pode-se afirmar que nada substitui o ser humano porque para se construir um modelo de I.A. é necessário a intervenção humana para configurar todos os parâmetros necessários para se chegar a um modelo eficaz que propicie boa acurácia.

Como trabalhos futuros, poderia melhorar a interface gráfica do sistema com a realização de avalições utilizando heurísticas com o objetivo de aumentar o grau de usabilidade da plataforma.

Também seria relevante a inserção de novos modelos de Inteligência Artificial já desenvolvidos como o de Covid-19.

Seria interessante inserir recursos de zoom para aumentar os detalhes de visualização das imagens médicas e submeter o sistema ao controle de virtualização sob containers.

Também, pode-se sugerir a utilização da plataforma por estudantes ao longo dos anos para maturar seu desenvolvimento e definir a inserção de novas funcionalidades e fornecer acesso aos egressos poderem utilizar a plataforma como capacitação continuada.

Ao colocar a plataforma em produção, aplicar testes aos alunos durante um certo tempo determinado para descobrir o quanto a plataforma auxilia no aprendizado.

Disponibilizar a plataforma para treinamento dos alunos dos cursos de medicina, odontologia, Biomedicina, fisioterapia e outros da área biológica que tenham relação com leitura e interpretação de imagens.

Poderia ser oferecido futuramente como apoio a diagnósticos, apesar de não ser regulamentado por algum órgão de registros. Isto aumentaria o número de recursos da plataforma, bem como, desenvolver um módulo com a finalidade de utilizar a plataforma para prontuários eletrônicos.

Oferecer o módulo de I.A. apenas ao professor para ajudá-lo a separar imagens para submeter diagnósticos aos estudantes, como também, oferecer a plataforma a profissionais de medicina a utilizar o sistema.

O desenvolvimento da plataforma foi realizado utilizando software livre de código aberto em todas as fases o que poderia estimular outros desenvolvedores a adicionar novas funcionalidades ao sistema.

Um assunto sensível seria dar responsabilidade no documento de termos de uso da aplicação a quem insere imagens na plataforma em virtude de direitos autorais e inserção de imagens não autorizadas ou atribuir a um administrador das imagens responsável por autorizar a inserção de imagens na plataforma a fim de evitar transtornos. Os termos de uso da plataforma estão descritos no Apêndice F.

Integrar frameworks de inteligência artificial à plataforma com algoritmos experimentados e que podem trazer maior credibilidade e aceitação. São algoritmos de I.A. já padronizados, aceitos e testados.

Utilização do ChapGPT de forma adequada para treinar a criação de relatórios clínicos. O ChatGPT está apto a desenvolver este tipo de tarefa. Também, possui a capacidade de criar questionários.

Poder-se-ia desenvolver um módulo específico para Recursos de Acessibilidade.

Poderia se levar em consideração a mudança das questões desenvolvidas na escala SUS para outras perguntas em função da má interpretação com relação ao entrevistado em virtude da confusão atribuídas a algumas dessas perguntas.

Desenvolvimento de um banco de imagens e banco de questões para facilitar o uso pelo professor.

REFERÊNCIAS

AGUIRRE, F. *et al*. Inteligência Artificial Aplicada À Imagem Médica. **Imaging Magazine**, [S.l.], v. 24, n. 2 p. 09-20, ago. 2021. Disponível em: https://sriuy.org.uy/ojs/index.php/Rdi/article/view/94. Acesso: 17 mar. 2023.

AHN, J.M.; KIM S.; AHN, K.S.; CHO, S.H.; LEE, K.B; KIM, U.S. A deep learning model for the detection of both advanced and early glaucoma using fundus photography. **PLoS UM**, v.13, n.11, e0207982, 2018. Disponível em: https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6258525/pdf/pone.0207982.pdf. Acesso em: 17 mar. 2023.

ALPAYDIN, E. **Introduction to Machine Learning**. 2nd. ed. Cambridge, MA: The MIT Press, 2010. 613 p.

AMAZON. **Perguntas frequentes sobre o nível gratuito da AWS.** 22 Mar 2023. Disponível em: https://aws.amazon.com/pt/free/free-tier-faqs. Acesso em: 22 mar. 2023.

AMORIN, P. H. J.; MORAES, T. F.; AZEVEDO, F. S.; SILVA, J. V. L. **Vesalius**: **Software Livre de Imagens Médicas**. In: XXXI Congresso da Sociedade Brasileira de Computação, 31., 2011, Campinas. **Anais** [...]. CSB, 2011. Disponível em: https://www2.sbc.org.br/csbc2011/anais/eventos/contents/WIM/WIM_Sessao_1_Artigo_4_Amorim.pdf. Acesso em: 18 mar.2021

ANSARI, A. N.; PATIL, S; NAVADA, A; PESHAVE, A; BOROLE, V. Online C/C++ compiler using cloud computing. *In:* **IEEE international conference on multimedia technology**. Hangzhou, China, 2011. Disponível em: https://ieeexplore.ieee.org/document/6002124. Acesso em: 18 mar.2021

APOSTOLOPOULOS, I. D.; MPESIANA, T. A. Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks. **Phys Eng Sci Med**., v.43, n.2, p.635-640, jun. 2020. Disponível em: doi10.1007/s13246-020-00865-4. Epub 2020 Apr 3. PMID: 32524445; PMCID: PMC7118364. Acesso em: 23 mar. 2021.

ASMAA, A.; MOHAMMED, M. A.; MOHAMED, M. G. **Classification of covid-19 in chest x-ray images using detrac deep convolutional neural network**. Preprint, submetido em 17 maio 2020. DOI: https://doi.org/10.48550/arXiv.2003.13815. Disponível em: https://arxiv.org/abs/2003.13815. Acesso em: 23 mar.2021.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR- ISO/IEC 9126-1**: Engenharia de software - Qualidade de produto - Parte 1: Modelo de qualidade. Rio de Janeiro: ABNT, 2003.

BACKES, A. R.; SÁ JUNIOR, J. J. M. **Introdução à Visão Computacional Usando Matlab**. 1. ed. Rio de Janeiro: Editora Alta Books, 2016. 288 p.

BARCELOS, A. F.; TOSHIMITSU, H. S. Modelo Matemático Neural Artificial Para Cálculo de Rendimento Metálico Teórico de um Laminador De Tiras A Frio. *In* **53°**

Seminário de Laminação – Processos e Produtos Laminados e Revestidos, 2016, Resende RJ: XV SEGET-AED.

BARROSO, L. A.; HÖLZLE, U; CLIDARAS J. **The datacenter as a computer**: an introduction to the design of warehouse-scale machines. 3rd. ed. Switzerland: Springer Nature Switzerland, c2022. *E-book*. (Synthesis Lectures on Computer Architecture
Lecture #46). Disponível em: https://doi.org/10.2200/S00516ED2V01Y201306CAC024. Acesso em 17 mar. 2021.

BROOKE, J. **SUS: A "quick and dirty" usability**. **Usability evaluation in industry**. United Kingdon: Taylor & Francis, 1996. 189 p.

BOUTIS, K. Dificuldade de Interpretação de Radiografias Normais Versus Anormais Usando Um Exemplo Pediátrico. **Canadian Medical Education Journal**, v. 7, n. 1, e68-e77, 2016. Disponível em: https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4830375/. Acesso em 09 mar. 2021.

BUYYA, R.; BROBERG, J.; GOSCINSKI, A. **Cloud Computing – Principles and Paradigms**; 1. Ed, New Jersey, U.S.: John Wiley & Sons, Inc. 2011. 664 p.

BYRA, M; STYCZYNSKI G.; SZMIGIELSKI, C.; KALINOWSKI, P.; MICHALOWSKI, L.; PALUSZKIEWICZ R.; *et al*. Transfer learning with deep convolutional neural network for liver steatosis assessment in ultrasound images. **Int J Comput Assist Radiol Surg**., v.13, n. 12, p.1895-1903, 2018. DOI: 10.1007/s11548-018-1843-2. Disponível em: https://link.springer.com/article/10.1007/s11548-018-1843-2. Acesso em 23 mar 2021

CAMBRIGDE IN COLOUR. **Digital Image Interpolation**. c2005-2020. Disponível em: https://www.cambridgeincolour.com/tutorials/image-interpolation.htm. Acesso em: 24 mar 2021

CANDEMIR, S.; JAEGER, S.; PALANIAPPAN, K.; MUSCO, J. P.; SINGH, R. K.; XUE, Z.; KARARGYRIS, A.; ANTANI, S.; THOMA, G.; MCDONALD, C. J. Automatic tuberculosis screening using chest radiographs. **IEEE Trans Med Imaging**, v. 33, n. 2, p. 233-245, 2004. Disponível em:10.1109/TMI.2013.2290491. PMID: 24239990. Acesso em: 24 mar 2021.

CARITA, C. E.; MATOS, A. L. M.; MARQUES, P. M. A. Ferramentas para Visualização de Imagens Médicas em Hospital Universitário. **Radiol. Bras.,** Ribeirão Preto, v. 37, n. 6, p. 437-440, 2004. Disponível em: https://doi.org/10.1590/S0100-39842004000600010. Acesso em: 25 mar. 2021.

CARRARE, A. P. G. D.; AMARAL, L. H.; MOURA, L. A. R. Imagens médicas digitais – preservação, ensino e pesquisa. **Arquivos Médicos dos Hospitais e da Faculdade de Ciências Médicas da Santa Casa de São Paulo**, São Paulo, v.53, n. 2, 2008. Disponível em: http://arquivosmedicos.fcmsantacasasp.edu.br/index.php/AMSCSP/article/view/394. Acesso em: 12 mar. 2021.

CHAGAS, E. T. O. Deep Learning e suas aplicações na atualidade. **Revista Científica Multidisciplinar Núcleo do Conhecimento**, São Paulo, ano 4, ed. 5, v.

04, p. 05-26, maio 2019. DOI: 10.32749/nucleodoconhecimento.com.br/administracao/deep-learning. Disponível em: https://www.nucleodoconhecimento.com.br/administracao/deep-learning. Acesso em: 12 mar. 2021.

CHANDRA, D. G.; BORAH M. D. Cost Benefit Analysis of Cloud Computing in Education. **2012 International Conference on Computing, Communication and Applications, Dindigul, India.** 2012, pp. 1-6, Disponível em https://doi.org/10.1109/ICCCA.2012.6179142. Acesso em 17 mar 2021.

CHOI, J. K.; KIM, K. B.; KIM, G. J. Image Selection Algorithm Proposal for Digital Radiography Training Simulator. **Wireless Pers Commun***,* v. 89, p.833-845, 2016. Disponível em: https://doi.org/10.1007/s11277-016-3247-3. Acesso em: 17 mar. 2021.

COHEN, J. P.; MORRISON, P.; DAO, L. **COVID-19 image data collection**. Preprint, submetido em 25 mar.2020. Disponível em: https://arxiv.org/abs/2003.11597. Acesso em: 20 mar.2021.

COMER, D. E. **Redes de Computadores e *Internet***. 2. ed. Porto Alegre: Bookman, 2001. 443 p.

COOK, D. A.; LEVINSON, A. J.; GARSIDE, S.; DUPRAS, D. M.; ERWIN, P. J.; MONTORI, V. M. *Internet*-Based Learning In The Health Professions: A Meta-Analysis. **J. Am. Med. Assoc**., v.300, n.10, p.1186-96, sep. 2008. DOI: 10.1001/jama.300.10.1181. Disponível em: https://pubmed.ncbi.nlm.nih.gov/18780847/. Acesso em: 26 mar. 2021.

COSTA, G.; TRINDADE, F. R.; PISSAIA, L. F.; COSTA, A. E. K. Inserção do Biomédico na Área da Imagenologia em Hospitais e Clínicas No Rio Grande Do Sul. **Revista Saúde.Com**., v.13. n.3, p.951-955, jul./set. 2017. Disponível em: https://periodicos2.uesb.br/index.php/rsc/article/view/3328. Acesso em: 16 mar. 2021.

CREMESP. Exame do Cremesp Reprova mais da Metade dos Médicos Recem-Formados. São Paulo: CREMESP, 2016, p.3-4.

SILVA, A. M. M. da; PATROCÍNIO, A. C.; SCHIABEL, H. Processamento e análise de imagens médicas. **Revista Brasileira De Física Médica (online)**, Porto Alegre, v. 13, n.1, 34-38, 2019. Disponível em: https://rbfm.org.br/rbfm/article/view/525. Acesso em: 21 mar. 2021.

DATA SCIENCE ACADEMY. Camadas de Pooling em Redes Neurais Convolucionais. **Deep Learning Book**. Disponível em https://www.deeplearningbook.com.br/camadas-de-pooling-em-redes-neurais-convolucionais. Acesso em 06 dez 2022.

DR. TIS TECNOLOGIA INOVAÇÃO E SAÚDE. Plataforma Pacs em Nuvem e Telemedicina Para Médicos e Instituições De Saúde. C2021. Disponível em www.drtis.com.br. Acesso Em: 1 Abr. 2024.

DUNLOSKY, J.; RAWSON, K. A.; MARSH, E**.** J.; NATHAN, M. J.; WILLINGHAM, D. T. Improving Students' Learning With Effective Learning Techniques: Promising Directions From Cognitive and Educational Psychology. **Psychological Science in the Public Interest**. v.14, n.1, p. 4-58. 2013. DOI:org/10.1177/1529100612453266. Disponível em: https://doi.org/10.1177/1529100612453266. Acesso em: 21 dez. 2021.

EPACS: Conheça o Epacs, c2000.Disponível em:https://www2.epacs.com.br/. Acesso em: 18 mar. 2021.

FENDERSON, B. A. Strategies for teaching pathology to graduate students and allied health professionals. **Human Pathology**, v. 36, e.2, p.146-153, 2005. DOI:org/10.1016/j.humpath.2004.09.022. Disponível em https://www.sciencedirect.com/science/article/abs/pii/S0046817704006264. Acesso em 26 Mar 2021.

FIGUEIREDO, J. C.; B., FURUIE, S. S.; GUTIERREZ, M. A.; MOTTA, G. H. M. B.; MORENO R. A. Sistema Compacto para Armazenamento e Distribuição de Imagens Médicas em Ambientes Clínico-Hospitalares. **Anais do Congresso Brasileiro de Informática em Saúde-CBIS**, 2002. Disponível em https://www.researchgate.net/profile/Marco-Gutierrez-15/publication/229041233_Sistema_Compacto_para_Armazenamento_e_Distribuicao_de_Imagens_Medicas_em_Ambientes_Clinico-Hospitalares/links/0c96052c6eb6243d84000000/Sistema-Compacto-para-Armazenamento-e-Distribuicao-de-Imagens-Medicas-em-Ambientes-Clinico-Hospitalares.pdf Acesso em 06 abr 2021.

FILHO, E. S. L.; SILVA, T. S. C.; VILLAR, V. B.; ROCHA, F. G. Aquisição de Imagem Para Hemeroteca Digital. **Interfaces Científicas - Exatas e Tecnológicas**, Aracaju, v.3, n.2, p. 63-74, 2018.

FYLAKTOPOULOS, G. *et al.* An overview of platforms for cloud based development. **SpringerPlus 5**, v. 38, 2016. DOI:org/10.1186/s40064-016-1688-5. Disponível em: https://doi.org/10.1186/s40064-016-1688-5. Acesso em: 17 mar. 2021.

GONZALES, R. C.; WOODS, R. E. **Processamento de Imagens Digitais**. 1. ed. São Paulo: Blucher, 2000. *E-book*. Disponível em: https://plataforma.bvirtual.com.br/Leitor/Publicacao/177647/pdf/0. Acesso em: 07 mar. 2024.

GOMES, J.; VELHO, L. **Computação Gráfica**: Imagem. Rio de Janeiro: IMPA, 2002. 373 p.

GUNDERMAN, R. B.; BALLENGER, Z. The golden rule of education. **Acad. Radiol**., v. 21, n.8, p. 1078-1079, aug.2014. doi: 10.1016/j.acra.2014.01.026. Disponível em: . Acesso em 26/03/2021.

HARRISON, M. **Machine Learning. Guia de Referência Rápida**. 1. ed. São Paulo: Novatec, 2020. 272 p.

HE, K. *et al*. **Deep Residual Learning for Image Recognition**. Preprint, submetido em 10 dez. 2015. DOI: https://doi.org/10.48550/arXiv.1512.03385. Disponível em: https://arxiv.org/abs/1512.03385. Acesso em: 23 mar.2021.

HORVAT, N. *et al.* Diagnostic radiology training for medical students - a Brazilian multicenter survey. **Einstein**, São Paulo, v. 21, eAO0184, 2023. DOI: 10.31744/einstein_journal/2023AO0184. Disponível em https://www.scielo.br/j/eins/a/jS6nNbnRM5NptRyMVCnRwkN/?format=pdf. Acesso em: 25 mar. 2021.

HUSSAIN, M.; BIRD, J.; FARIA, D. A Study on CNN Transfer Learning for Image Classification. **Conference: UKCI 2018**: 18th Annual UK Workshop on Computational Intelligence At: Nottingham, United Kingdom. Disponível em https://www.researchgate.net/publication/325803364_A_Study_on_CNN_Transfer_Learning_for_Image_Classification. Acesso em: 18 out. 2023.

JAEGER, S; KARARGYRIS, A.; CANDEMIR, S.; FOLIO, L.; SIEGELMAN, J.; CALLAGHAN, F.; XUE, Z.; PALANIAPPAN, K.; SINGH, R.K.; ANTANI, S.; THOMA, G.; WANG, Y.X.; LU, P.X.; MCDONALD, C.J. Automatic tuberculosis screening using chest radiographs. **IEEE Trans Med Imaging**. 2014, v.33, n.2, p.233-245. Disponível em: doi: 10.1109/TMI.2013.2284099. PMID: 24108713 Acesso em: 22/03/2021.

JONES, E. AWS vs Azure: Comparando os Gigantes da Computação em Nuvem. *In:* JONES, E. **BLOG Kinsta**. [*S.l.*], 08 set. 2023. Disponível em: https://kinsta.com/pt/blog/aws-vs-azure/. Acesso em 22 mar. 2023.

KABIR, A.; AMARDA, S. Transformer Neural Networks Attending to Both Sequence and Structure for Protein Prediction Tasks. **ArXiv abs/2206**.11057, 2022. DOI: 10.48550/arXiv.2206.11057. Disponível em <https://doi.org/10.48550/arXiv.2206.11057>.

KASSANI, S. H. *et al*. **Automatic detection of coronavirus disease (covid-19) in x-ray and ct images**: A machine learning-based approach. Preprint, submetido em 22 abr. 2020. DOI: https://doi.org/10.48550/arXiv.2004.10641. Disponivel em https://arxiv.org/abs/2004.10641.

KATS, L. C. L. *et al.,* Software development environments on the web: a research agenda. *In*: **Proceedings of the ACM international symposium on New ideas, new paradigms, and reflections on programming and software**. Onward!, 2012. DOI: 10.1145/2384592.2384603. Disponível em https://doi.org/10.1145/2384592.2384603 Acesso em 18 mar 2021.

KINSER, J. **Python for Bioinformatics**. Ontário: Jones and Bartlett Publishers, 2009. 417 p.

KUMAR, V.; RATHORE, R. S. Security Issues with Virtualization in Cloud Computing. *In:* **Conference: 2018 International Conference on Advances in Computing, Communication Control and Networking (ICACCCN).** 2018. p. 487 – 491.

DOI: 10.1109/ICACCCN.2018.8748405. Disponível em https://www.researchgate.net/publication/334167704_Security_Issues_with_Virtualization_in_Cloud_Computing. Acesso em 19 mar 2021.

KOK, E. M.; VAN GEEl K.; VAN MERRIËNBOER, J. J. G.; ROBBEN, S. G. F. What We Do and Do Not Know about Teaching Medical Image Interpretation. **Frente. Psychol**., Maastrich, v 8, n.309, 2017. DOI: 10.3389/fpsyg.2017.00309. Disponível em https://www.frontiersin.org/journals/psychology/articles/10.3389/fpsyg.2017.00309/full . Acesso em: 17 fev. 2021.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet Classification with Deep Convolutional Neural Networks. **Communications of the ACM**, v. 60, ed. 6, p. 84–90, 2012. DOI: 10.1145/3065386. Disponível em https://papers.nips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf. Acesso em: 23 mar. 2022.

LIKERT, R. A. Technique for The Measurement of Attitudes. **Archives of Psycology**. New York: New York University, 1932. 55 p.

LI, Y.; HU, T. A CONV-LSTM Approach of Financial Pattern Prediction with Labeling from Feature-Based DTW with Pattern Rule. **SSRN-Elsevier**. 2020. DOI: 10.2139/ssrn.3669903. Disponível em https://ssrn.com/abstract=3669903. Acesso em: 22 mar 2021

LIMA, C. A. S.; SANTOS, C. E.; BISSACO M. A. S.; AMATE, F.C.; GIANCOLI, A. P. M.; SILVA A. P.; SCARDOVELLI T. A.; BOSCHI S. R. M. S.; MARTINI S. C. Transferência de aprendizado para categorização de patologias. **Revista Contemporânea**, Curitiba, v. 3, n. 9, 2023. DOI:10.56083/RCV3N9-022. Disponível em: https://ojs.revistacontemporanea.com/ojs/index.php/home/article/view/1392/1094. Acesso em: 12 set. 2023.

LIMA, C. A. S.; SANTOS, C. E.; BISSACO M. A. S.; SILVA A. P.; SCARDOVELLI T. A.; BOSCHI S. R. M. S.; MARTINI S. C. **p**atologIA: Online platform for improving image-based diagnostics applied to medical students. **SPIE Medical Imaging**, San Diego, E.U.A., 2021. DOI: 0.1117/12.2582237. Disponível em: https://doi.org/10.1117/12.2582237. Acesso em: 16 fev. 2021.

LOWDERMILK, T. **Design Centrado no Usuário**. 1.ed. São Paulo: Novatec, 2013. 179 p.

LORENSEN, W. E.; CLINE, H. E. Marching Cubes: A high resolution 3D surface construction algorithm. **ACM SIGGRAPH Computer Graphics**, New York, 1987.

LUNA F., B.; CASSENOTE, A. J. F. **O Exame do Cremesp no contexto da expansão do ensino médico.** São Paulo, SP: Cremesp, 2018. 101 p.

MANNING. Concept Shape in Category Deep Learning. C2024. Disponível em: https://livebook.manning.com/concept/deep-learning/shape. Acesso em 06 abr 2024.

MANSSOUR, I. H.; FREITAS, C. M. D. S. F. Visualização Volumétrica. **RITA**, Porto Alegre, v. 9, n. 2, 2002. Disponível em: https://www.lume.ufrgs.br/handle/10183/19832. Acesso em: 30 mar. 2021.

MARQUES, P. M. A. Diagnóstico Realizado por Computador na Radiologia. **Radiol. Bras.**, São Paulo, v.34, n.5, p.285-293, 2001. DOI: 10.1590/S0100-39842001000500008. Disponível em: https://doi.org/10.1590/S0100-39842001000500008. Acesso em: 30 mar. 2021.

MARSLAND, S. Machine Learning: An Algorithmic Perspective. **CRC Press**. 2. ed. Florida, USA: CRC Press, 2017. 457 p.

MEDIUM. Guia: Como medir a usabilidade de produtos com System Usabilidade Scale (SUS). c2029. Disponívem em: https://brasil.uxdesign.cc/guia-como-medir-a-usabilidade-de-produtos-com-system-usability-scale-sus-e08f4361d9db. Acesso em 06/04/2021.

MEDIUM. Understanding of Convolutional Neural Network (CNN) — Deep Learning. c2020. Disponível em: https://medium.com/@RaghavPrabhu/understanding-of-convolutional-neural-network-cnn-deep-learning-99760835f148. Acesso em 06/04/2021.

MEIRINHOS, M.; OSÓRIO, A. O estudo de caso como estratégia de investigação em educação. **Eduser - Revista de Educação**, [*S.*l.], v. 2, n. 2, dec. 2016. DOI:10.34620/eduser.v2i2.24. Disponível em: https://www.eduser.ipb.pt/index.php/eduser/article/view/24. Acesso em: 21 dez. 2021.

MENDES, D. Deep Learning Book em Português, online e Gratuito. **Data Science Academy**. Brasilia: 2021, v.1, cap. 4. O Neurônio Biológico e Matemático. Disponível em https://www.deeplearningbook.com.br/page/4/?s=cap%C3%ADtulo+5. Acesso em 14 mar 2022.

MERRILL, M. D.; DRAKE, L.; LACY, M. J.; PRATT, J.; ID_2 Research Group. Reclaiming Instructional Design. **Educational Technology**, v. 36, n. 5, 1996, p. 5-7, sept./oct. 1996. Disponível em: www.jstor.org/stable/44428356. Acesso em: 26 mar. 2021.

MINIWEBPACS. Armazenamento e Districbuição de Imagens Médicas. Disponível em https://miniwebpacs.sourceforge.net/

MOREIRA I., VENTURA S., Ramos I., RODRIGUES P. Development and Assessment of an E-Learning Course on Breast Imaging for Radiographers: A Stratified Randomized Controlled Trial. **J Med Internet Res**., v.17, n.1, e3, 2015. DOI: 10.2196/jmir.3344. Disponível em: https://www.jmir.org/2015/1/e3/. Acesso em: 05 abr. 2023.

MICROSOFT. **Crie na Nuvem com uma Conta Gratuita no Azure**. 2023. Disponível em: https://azure.microsoft.com/en-us/free/. Acesso em: 22 mar. 2023.

MILLAN, J.; YUNDA, L. An Open-Access Web-Based Medical Image Atlas For Collaborative Medical Image Sharing, Processing, Web Semantic Searching And Analysis With Uses In Medical Training, Research And Second Opinion Of Cases. **Nova**, Bogotá, v. 12, n. 22, p.147-150, 2014. Disponível em:

http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S1794-24702014000200003. Acesso em: 25 mar. 2021.

MOONEY, P. **Chest X-ray images (Pneumonia)**. Kaggle Repository, 2018. Disponível em https://www.kaggle.com/paultimothymooney/chestxray-pnemonia. Acesso em 27 mar 2021.

NARIN, A.; KAYA, C.; PAMUK, Z. Automatic detection of coronavirus disease (COVID-19) using X-ray images and deep convolutional neural networks. **Pattern Anal Appl**. 2021;24(3):1207-1220. doi: 10.1007/s10044-021-00984-y. Epub 2021 May 9. PMID: 33994847; PMCID: PMC8106971. Disponível em https://pubmed.ncbi.nlm.nih.gov/33994847. Acesso em 27 mar 2022.

NIELSEN, J. **Usability engineering**. San Francisco, California: Morgan Kaufmann Publishers, 1994. 384 p.

NOVO, D. N.; FELIZARDO, G. .; SANTOS, J. F. L.; MICHELASSI, L. G. C.; OSSADA, J. C. Processo de gestão e desenvolvimento para migração em serviço de nuvem. **RECIMA21 - Revista Científica Multidisciplinar**, *[S. l.]*, v. 2, n. 8, p. e28636, 2021. doi: 10.47820/recima21.v2i8.636. Disponível em: https://recima21.com.br/index.php/recima21/article/view/636. Acesso em: 03 mar. 2022.

ODUN-AYO, I.; AJAYI, O.; OKEREKE, C. **Virtualization in Cloud Computing: Development and Trends**. *In*: Covenant University e University of Lagos Nigeria. Research Gate, 2017. p. 24-28. DOI:10.1109/ICNGCIS.2017.10. Disponível em https://www.researchgate.net/publication/328765568_Virtualization_in_Cloud_Computing_Developments_and_Trends. Acesso em 22 Abr 2022

OTOKOVIESKY, M. B.; MELO, A. M.; CRESPO, I. M. Avaliação de Usabilidade do *app* ParecerEdu. **Anais da V Escola Regional de Engenharia de Software (ERES)**. Evento *Online*, Porto Alegre: Sociedade Brasileira de Computação, 2021. p. 11-20. DOI:10.5753/eres.2021.18446. Disponivel em https://doi.org/10.5753/eres.2021.18446 Acesso em 25 Fev 2022.

PADRINI-ANDRADE, L. *et al*. Evaluation of Usability of a Neonatal Health Information System According To The User's Perception**. Revista Paulista de Pediatria [online]**. v. 37, n. 1, p. 90-96, 2019. DOI:10.1590/1984-0462/;2019;37;1;00019. Disponível em: https://doi.org/10.1590/1984-0462/;2019;37;1;00019. Acesso em: 11 fev. 2022.

PAIVA, O. A.; PREVEDELLO, L. M. O potencial Impacto da Inteligência Artificial na Radiologia. **Radiologia Brasileira**., São Paulo, v.50, n. 5, 2017. DOI: 10.1590/0100-3984.2017.50.5e1. Disponível em: http://dx.doi.org/10.1590/0100-3984.2017.50.5e1. Acesso em: 09 mar. 2021.

PANIZZON, G.; BATTISTI, J. H. F.; KOSLOVSKI, G. P.; PILLON, M. A.; MIERS C. C. Uma taxonomia de segurança de contêineres em nuvens computacionais: preocupações e soluções. **Revista de Informática Teórica e Aplicada**, Porto Alegre, v. 26, n. 1, pág. 47-59, 2019. doi: 10.22456/2175-2745.86196. Disponível em https://doi.org/10.22456/2175-2745.86196.

PCI CONCURSOS. Concurso Público – Cargo: Médico. CREMESP/SP. **Fundação Carls Chagas**, 2009. https://www.pciconcursos.com.br/provas/download/medico-cremesp-sp-fcc-2009. Acesso em 27 Jan 2024.

PCI CONCURSOS. Concurso Público – Cargo: Médico. CREMESP/SP. **Fundação Carlos Chagas**, 2009. https://www.pciconcursos.com.br/provas/download/medico-cremesp-sp-fcc-2016. Acesso em 27 Jan 2024.

PEREIRA, Luiz Antônio de Moraes. **Análise e modelagem de sistemas com a UML**: com dicas e exercícios resolvidos.1. ed. Rio de Janeiro: Luiz Antônio M. Pereira, 2011. *E-book*. Disponível em: https://luizantoniopereira.com.br/downloads/publicacoes/AnaliseEModelagemComUML.pdf. Acesso em: 03 mar. 2022.

PEREIRA, Adan Lucio; PENHA, Elton Wagner Machado; GOMES, Nazur Amorim; FREITAS, Rodrigo Randow. Computação em nuvem: a segurança da informação em ambientes na nuvem e em redes físicas. **Brazilian Journal of Production Engineering**, *[S. l.]*, v. 2, n. 1, p. 12–27, 2016. Disponível em: https://periodicos.ufes.br/bjpe/article/view/EO02_2016. Acesso em: 03 mar. 2022.

PEDROSA, P. H.; NOGUEIRA T. **Computação em Nuvem**. Disponível em: http://www.ic.unicamp.br/~ducatte/mo401/1s2011/T2/Artigos/G04-095352-120531-t2.pdf. Acesso em: 28 fev. 2022.

PIRES, S. R.; MEDEIROS, R. B.; ELIAS, S. QualIM®: software para treinamento na interpretação de imagens médicas digitais. **Radiologia Brasileira**. Colégio Brasileiro de Radiologia e Diagnóstico por Imagem, 2008, v. 41, n. 6, p. 391-395. DOI: 10.1590/S0100-39842008000600009. Disponível em http://dx.doi.org/10.1590/S0100-39842008000600009. Acesso em 09 Mar 2021.

PIROLA, S. B. F. B., PADILHA, F. D.; MAURO D. J. M. B.; GABRIEL S. A.; PIROLA L. H. F. B. A Importância da Iniciação, Científica na Graduação De Medicina. Revista **Corpus Hippocraticum**, v.1, n.1, 2020. Disponível em http://189.112.117.16/index.php/revista-medicina/article/view/232. Acesso em: 21 dez. 2021.

PINHO, B. E.*et al.* Um mecanismo de pesquisa multimodal para estudos de imagens médicas. **Journal of Digital Imaging**. v.30, p.39-48, 2017. doi: 10.1007/s10278-016-9903-z. Disponível em: https://doi.org/10.1007/s10278-016-9903-z. Acesso em: 08 jan. 2022.

PRESSMAN, R. S. **Engenharia de Software**. 6. ed. São Paulo: Mc Grall Hill, 2006. Cap. 3, p. 42, Cap. 4, p. 64, Cap. 7, p. 118.

RADIOPAEDIA.ORG. **Neurolymphomatosis**. c2005-2024. Disponível em: https://radiopaedia.org/. Acesso em: 01 abr. 2024.

RAPPIN, N.; DUNN, R. wxPython in Action. **Manning Publications**. Shelter Island: 2006. 552 p.

RUIZ, J. G. M.D.; Mintzer, M. J. M. D; LEIPZIG, R. M. M. D. O Impacto do E-Learning na Educação Médica. **Medicina Acadêmica**, v. 81, n.3, p. 207-212, mar. 2006. doi: http://dx.doi.org/10.1097/00001888-200603000-00002. Disponível em:

https://journals.lww.com/academicmedicine/fulltext/2006/03000/the_impact_of_e_learning_in_medical_education.2.aspx. Acesso em: 08 jan. 2022.

RUSSAKOVSKY, O.; DENG, J.; SU, H. *et al*., Desafio de Reconhecimento Visual de Grand Escala ImageNet. **Int J Comput Vis**., v.115, p.211-252 2015. DOI: https://doi.org/10.1007/s11263-015-0816-y. Disponível em: https://link.springer.com/article/10.1007/s11263-015-0816-y. Acesso em: 18 mar. 2021.

RYE, C.; WISE, R.; JURUKOVSKI, W.; DESAIX, J.; CHOI, J.; AVISSAR, Y. Biologia. **OpenStax**. Houston, c2026. Disponível em https://openstax.org/books/biology/pages/35-1-neurons-and-glial-cells. Acesso em 06 abr 2024.

SANTOS, M. K.; JÚNIOR, J. R. F.; WADA, D. T.; TENÓRIO, A. P. M.; BARBOSA, M. H. N.; MARQUES, P. M. A. Inteligência artificial, aprendizado de máquina, diagnóstico auxiliado por computador e radiômica: avanços da imagem rumo à medicina de precisão. **Radiol Bras**., São Paulo, v.52, n.6, p.387-396, nov./dez. 2019. DOI: 10.1590/0100-3984.2019.0049. Disponível em: http://dx.doi.org/10.1590/0100-3984.2019.0049. Acesso em: 21 dez. 2021.

SCIKITLEARN.ORG. Sklearn.utils.class_weight.compute_class_weight. c2024. Disponível em: https://scikitlearn.org/stable/modules/generated/sklearn.utils.class_weight.compute_class_weight.html. Acesso em: 27 jan. 2023.

SILVA, S. M. **Plataforma Online de Apoio Pedagógico para Auxílio na Interpretação De Imagens Médicas**. Dissertação (Mestrado em Engenharia Biomédica) - Universidade de Mogi das Cruzes, 2018 Área de concentração: Processamento de Sinais e Imagens Médicas.

SIMONYAN, K.; ZISSERMAN, A. Very Deep Convolutional Networks for Large-Scale Image Recognition. **Preprint**, submetido em 04 set. 2014. DOI: 10.48550/arXiv.1409.1556. Disponível em https://doi.org/10.48550/arXiv.1409.1556. Acesso em: 27 jan.2023.

SINGH, M. Virtualization in Cloud Computing - A Study. *In:* Government of NCT of Delhi**. International Conference on Advances in Computing, Communication Control and Networking (ICACCCN)**, 2018. p. 64-67. DOI**:** 10.1109/ICACCCN.2018.8748398. Disponível em https://ieeexplore.ieee.org/document/8748398. Acesso em 22/02/2023

SOMMERVILLE, I. **Engenharia de Software**.9. ed. São Paulo: Ed Pearson, 2011. 224 p.

SPANJERS, I. A. E.; KÖNINGS, K. D.; LEPPINK, J.; VERSTEGEN D. M. L.; JONG, N.; CZABANOWSKA, K.; JEROEN, VAN MERRIËNBOER, J.G. The promised land of blended learning: Quizzes as a moderator. **Educational Research Review**, v. 15, 2015, Pages 59-74, ISSN 1747-938X. DOI: 10.1016/j.edurev.2015.05.001. Disponível em https://doi.org/10.1016/j.edurev.2015.05.001. Acesso em 25 Mar 2023.

SILVA, A. M. M.; PATROCÍNIO A. C., SCHIABEL, H. Processamento e Análise de Imagens Médicas. **Revista Brasileira de Física Médica,** São Paulo, v.13, n.1, p.34-48, 2019. Disponível em: https://www.rbfm.org.br/rbfm/article/view/525/v13n1p34. Acesso em: 12 mar. 2021.

SRIVASTAVA, N. *et. al*. Dropout: a simple way to prevent neural networks from overfitting. **The Journal of Machine Learning Research**, JMLR. org, v. 15, n. 1, p. 1929–1958, 2014.

SRIVASTAVA, R. K.; GREFF, K.; SCHMIDHUBER, J. Highway Networks. **Preprint**, sobmetido em 22 jul. 2015. DOI: 10.48550/arXiv.1505.00387. Disponível em https://doi.org/10.48550/arXiv.1505.00387. Acesso em: 19 ago. 2023.

SRIVASTAVA, V. K.; PRADHAN, M. K. Diagnosis of COVID-19 Based on Chest X-ray Images Using Pre-trained Deep Convolutional Neural Networks. **Journal: Intelligent Decision Technologies**, v. 16, n. 1, p. 169-180, 2022. doi: 10.3233/IDT-210002 Disponível em: https://content.iospress.com/download/intelligent-decision-technologies/idt210002?id=intelligent-decision-technologies%2Fidt210002. Acesso em: 21 ago. 2023.

SUGITHRA, S.; CHANDRASHEKAR, R. "Externalizing business rules from business processes for model based testing", **International Conference on Industrial Technology**, 2012, p. 312-318. doi:10.1109/ICIT.2012.6209956. Disponível em: http://dx.doi.org/10.1109/ICIT.2012.6209956. Acesso em: 25 ago. 2023.

TEIXEIRA, F. **Introdução e boas práticas em UX Design**. São Paulo: Casa do Código, 2014. 217 p.

URTIGA, K. S.; TAKIZAWA, K.; MORENO, R. A.; GUTIERREZ, M. A. Mini-WEBPACS: Sistema Compacto para Armazenamento e Distribuição de Imagens Médicas em Ambientes Clínico-Hospitalares. Ribeirão Preto, 2004.In: **Anais do IX Congresso Brasileiro de Informática em Saúde CBIS'2004**, p. 186. Disponível em http://telemedicina.unifesp.br/pub/SBIS/CBIS2004/trabalhos/livro.pdf Acesso em 06 Abr 2021.

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:* **IEEE conference on computer vision and pattern recognition (CVPR)**, Honolulu: 2017, p. 3462–3471. DOI: 10.1109/CVPR.2017.369. Disponível em https:// doi.org/10.1109/CVPR.2017.369. Acesso em 07 Mai 2022

WU, Z.; SHEN, C.; VAN DEN HENGEL, A. Wider or Deeper: Revisiting the ResNet Model for Visual Recognition. **University of Adelaide**, SA, 5005, Australia. 2019; 90:119–133. DOI: 10.1016/j.patcog.2019.01.006. DOI: 10.1016/j.patcog.2019.01.006. Disponível em https://doi.org/10.1016/j.patcog.2019.01.006. Acesso em 24 Ago 2023.

YAMASHITA, R.; NISHIO, M.; DO, R. K. G.; *et al.,* Redes neurais convolucionais: uma visão geral e aplicação em radiologia**. NIH – National Library of Medicine**. *Insights Imaging* 9**,** p.611–629, 2018. DOI:10.1007/s13244-018-0639-9. Disponível em https://doi.org/10.1007/s13244-018-0639-9 Acesso em 12 Mar 2022.

YILIN, X.; *et.al*. Computer-Aided System for the Detection of Multicategory Pulmonary Tuberculosis in Radiographs, **Journal of Healthcare Engineering**, vol. 2020, Article ID 9205082, 12 pages, 2020. DOI: 10.1155/2020/9205082. Disponível em https://doi.org/10.1155/2020/9205082 Acesso em 15 Mai 2022.

ZAFAR, S.; SAFDAR, S.; ZAFAR, A. N. Evaluation of use of e-Learning in undergraduate radiology education: a review. **Eur. J. Radiol**., 2014, v. 83, n. 12, p. 2277–2287. DOI: 10.1016/j.ejrad.2014.08.017. Disponível em doi: 10.1016/j.ejrad.2014.08.017. Acesso em 26 Mar 2021.

ZWICKER, M. R. G. S.; SOUSA, K. D.; SOUZA, R. S.; SOUZA, L. C.; AZEVEDO, R. J. O Fórum e a Aprendizagem Ativa na EAD**.** São Paulo, **Revista *EaD Em Foco*** 2021, v.11, n.1. DOI: 10.18264/eadf.v11i1.1419. Disponível em https://eademfoco.cecierj.edu.br/index.php/Revista/article/view/1419 Acesso em 28 mar 2021.

APÊNDICES

APÊNDICE A – Questionário de Usabilidade (SUS)

Nº	Questão	Escala SUS
1	Eu gostaria de usar a Plataforma com frequência.	Discordo Plenamente 1 ○ 2 ○ 3 ○ 4 ○ 5 ○ Concordo Plenamente
2	Eu achei a Plataforma complexo.	Discordo Plenamente 1 ○ 2 ○ 3 ○ 4 ○ 5 ○ Concordo Plenamente
3	Eu achei o a Plataforma fácil de usar.	Discordo Plenamente 1 ○ 2 ○ 3 ○ 4 ○ 5 ○ Concordo Plenamente
4	Eu acho que precisaria de ajuda de uma pessoa com conhecimentos técnicos para usar a Plataforma.	Discordo Plenamente 1 ○ 2 ○ 3 ○ 4 ○ 5 ○ Concordo Plenamente
5	Eu acho que as várias funções da Plataforma estão muito bem integradas.	Discordo Plenamente 1 ○ 2 ○ 3 ○ 4 ○ 5 ○ Concordo Plenamente
6	Eu acho que a Plataforma apresenta muita inconsistência.	Discordo Plenamente 1 ○ 2 ○ 3 ○ 4 ○ 5 ○ Concordo Plenamente
7	Eu imagino que as pessoas aprenderão a usar essa Plataforma rapidamente.	Discordo Plenamente 1 ○ 2 ○ 3 ○ 4 ○ 5 ○ Concordo Plenamente
8	Eu achei a Plataforma confusa de usar	Discordo Plenamente 1 ○ 2 ○ 3 ○ 4 ○ 5 ○ Concordo Plenamente
9	Eu me senti confiante ao usar a Plataforma.	Discordo Plenamente 1 ○ 2 ○ 3 ○ 4 ○ 5 ○ Concordo Plenamente
10	Eu precisei aprender várias coisas novas antes de conseguir usar a Plataforma.	Discordo Plenamente 1 ○ 2 ○ 3 ○ 4 ○ 5 ○ Concordo Plenamente

APENDICE B – Questionário de Funcionalidade

Questionário de Funcionalidade (Estudante)						
1.	Eu creio que esse sistema poderia ser usado em cursos relacionados com interpretação de imagens médicas.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
2.	Eu consegui testar meus conhecimentos sobre interpretação de imagens médicas.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
3.	Eu acredito que o uso do sistema irá me ajudar a adquirir habilidades na interpretação de imagens médicas	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
4.	Eu melhoraria o conteúdo da plataforma adicionando mais abas para novas funcionalidades.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
5.	Eu acredito que as funcionalidades do sistema são suficientes e adequadas para seu propósito.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
6.	Eu acredito que o menu Questionário está adequado às minhas necessidades.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
7.	Eu tive facilidade para encontrar o questionário a ser respondido?	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5

8.	Eu acredito que tive facilidades em responder as perguntas do questionário.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
9.	Eu entendi com facilidade a dinâmica da Plataforma que oferecia uma segunda chance para responder uma questão.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
10.	Eu acredito que o menu Resultados está adequado às minhas necessidades.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5

APÊNDICE C – Questionário de Funcionalidade - Professor

Questionário de Funcionalidade (Professor)						
1.	Eu creio que esse sistema poderia ser usado em cursos relacionados com interpretação de imagens médicas.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
2.	Eu utilizaria essa plataforma durante as aulas de interpretação de Imagens.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
3.	Eu acredito que o menu Questionário está adequado as minhas necessidades.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
4.	Eu acredito que a menu Casos está adequado as minhas necessidades.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
5.	Eu acredito que a menu Artigos está adequado as minhas necessidades.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
6.	Eu senti que consegui agregar as funcionalidades do sistema às minhas necessidades em sala de aula.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
7.	Eu acredito que o uso do sistema poderá contribuir positivamente ao usá-lo nas aulas de Imagenologia, tornando as aulas mais dinâmicas.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5
8.	Eu melhoraria o conteúdo do sistema adicionando mais	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente

	abas para novas funcionalidades.	○	○	○	○	○
		1	2	3	4	5
9.	O menu Predições auxilia no aprendizado de interpretação de imagens.	Discordo Totalmente	Discordo	Indiferente	Concordo	Concordo Totalmente
		○	○	○	○	○
		1	2	3	4	5

Apêndice D – Roteiro para Postar as Tarefas pelo Professor

Roteiro de Tarefas – Professor

Instruções:

Junto a este Roteiro de Tarefas foram enviados três arquivos compactados. São eles:

Imagens, Pulmões e Casos

Ao descompactar estes arquivos serão criadas três pastas: Imagens, Pulmões e Casos.

O roteiro consta de 10 atividades auto descritivas. A atividade 3 refere-se à elaboração de questionário de múltipla escolha. As atividades 4, 5, e 6 referem-se à elaboração do questionário de demarcação de imagens.

A pasta Imagens contém os arquivos de imagens a serem utilizados nos questionários de múltipla escolha (atividade 3) e de demarcação de imagens (atividades 4, 5 e 6).

Os arquivos da pasta Pulmões deverão ser utilizados apenas para as tarefas de Predição. (Atividade número 7)

Atividades

1. Abra seu navegador da *Internet* e digite o endereço para acessar a plataforma.

O link é o seguinte: http://18.212.50.148:8000/

2. Crie uma conta para você na plataforma e, em seguida, faça seu Login.

Procedimento: Clique no Menu Login e em "Não tenho uma Conta".
Depois que finalizar o cadastro, retorne ao Login e entre com seus dados.

3. Crie um questionário de questões sobre imagens. (Serão criadas 2 questões)

3.1 Procedimento Cadastro Imagens: Cadastre duas Imagens de cada vez.

Menu Cadastro → Imagens.
Escolha o arquivo da imagem → Tipo → Especialidade → Incluir
Imagem1.png → Raios X – Pneumologia
Imagem2.png → Tomografia → Cardiologia

3.2 Procedimento Criação do Tipo do Questionário: Múltipla escolha

Menu Questionário → Tipo de Questionário → Múltipla Escolha → Enviar

***3.3 Procedimento Elaboração do Questionário Professor**:*

Menu Questionário → Criar Questionário:
Título do Questionário: Interpretação de Imagens 1
Descrição do Assunto do Questionário: Geral
Data do Questionário: Data Atual
Esse é um Questionário de Demarcação de Imagens: Errado
Selecione o Status do Questionário: Aberto
Clique em Elaborar Questões

3.4 Procedimento Elaborar Questões (Questão 1)

Selecione o Questionário: Interpretação de Imagens 1

Descrição da Questão 1:

Um homem de 29 anos procura atendimento médico por apresentar tosse e febre há 2 dias. Há 2 meses tratou infecção de garganta com cefalexina por 2 semanas. O seu estado clínico é bom e o médico opta por tratamento domiciliar. Os seguintes tratamentos são recomendados, EXCETO: (Fundação Carlos Chagas - CREMESP/2019)

Valor da Questão: 10

Selecione o Número da Imagem: 1

Clicar no botão Alternativas

3.5 Procedimento Elaborar Alternativas
Selecione a Descrição da pergunta: *Descrição da Questão 1*

Descrição da Alternativa.
* amoxicilina/clavulanato + azitromicina.

Nome da Opção: (A)

Selecione o Status da Alternativa: Certo

Clique no Botão Criar Próxima Opção

Selecione a Descrição da pergunta: *Descrição da Questão 1*
Descrição da Alternativa.
moxifloxacina.

Nome da Opção: (B)

Selecione o Status da Alternativa: Errado

Clique no Botão Criar Próxima Opção

Selecione a Descrição da pergunta: *Descrição da Questão 1*
Descrição da Alternativa.
amoxicilina em dose alta + doxiciclina.

Nome da Opção: (C)

Selecione o Status da Alternativa: Errado

Clique no Botão Criar Próxima Opção

Selecione a Descrição da pergunta: *Descrição da Questão 1*
Descrição da Alternativa.
ciprofloxacina + claritromicina.

Nome da Opção: (D)

Selecione o Status da Alternativa: Errado

Clique no Botão Criar Próxima Opção

Selecione a Descrição da pergunta: *Descrição da Questão 1*
Descrição da Alternativa.
cefuroxima + azitromicina.

Nome da Opção: (E)

Selecione o Status da Alternativa: Errado

Clique no Botão Terminar

3.6 Procedimento Elaborar Questões (Questão 2)

Selecione o Questionário: Interpretação de Imagens 1

Descrição da Questão 2:

Um homem de 40 anos, alcoolista, procura atendimento médico com queixa de sudorese noturna, fadiga e anorexia há 10 dias, acrescidos de febre e tosse com expectoração abundante e fétida há 2 dias. Está hemodinamicamente estável, aparentando falta de cuidados, emagrecido e febril. Qual é a conduta mais adequada pela tomografia computadorizada de tórax: (Fundação Carlos Chagas - CREMESP/2019)

Valor da Questão: 10

Selecione o Número da Imagem: 2

Clicar no botão Alternativas

Procedimento ***Elaborar Alternativas***
Selecione a Descrição da pergunta: *Descrição da Questão 2*
Descrição da Alternativa.
Iniciar vancomicina e uma cefalosporina com espectro para pseudomonas.

Nome da Opção: (A)

Selecione o Status da Alternativa: Errado

Clique no Botão Criar Próxima Opção

Procedimento ***Elaborar Alternativas***
Selecione a Descrição da pergunta: *Descrição da Questão 2*
Descrição da Alternativa.
Iniciar ceftriaxona e clindamicina.

Nome da Opção: (B)

Selecione o Status da Alternativa: Certo

Clique no Botão Criar Próxima Opção

Procedimento ***Elaborar Alternativas***
Selecione a Descrição da pergunta: *Descrição da Questão 2*
Descrição da Alternativa.
Ceftriaxona e vancomicina e locar dreno pleural para drenagem contínua. Nome da Opção: (C)

Selecione o Status da Alternativa: Errado

Clique no Botão Criar Próxima Opção

Procedimento ***Elaborar Alternativas***
Selecione a Descrição da pergunta: *Descrição da Questão 2*
Descrição da Alternativa.
Sustar antibióticos até realização de broncoscopia com aspirado do conteúdo da cavitação pulmonar, na tentativa de se estabelecer a etiologia do processo.

Nome da Opção: (D)

Selecione o Status da Alternativa: Errado

Clique no Botão Criar Próxima Opção

*Procedimento **Elaborar Alternativas***
***Selecione a Descrição da pergunta:** Descrição da Questão 2*
Descrição da Alternativa.
Iniciar clindamicina e programar punção diagnóstica e esvaziadora do abscesso pulmonar por meio de videotoracoscopia.

Nome da Opção: (E)

Selecione o Status da Alternativa: Errado

Clique no Botão Terminar

4. **Crie um questionário de questões de demarcação de imagens. (2 Questões)**
*Procedimento Criação do **Tipo** do Questionário: Demarcação de Imagens*
Menu Questionário → Tipo de Questionário → Demarcação de Imagens → Enviar

*Procedimento **Elaboração do Questionário Professor**:*
Menu Questionário → Criar Questionário:
Título do Questionário: Demarcação de Imagens 1
Descrição do Assunto do Questionário: Geral
Data do Questionário: Data Atual
*Esse é um Questionário de Demarcação de Imagens: **Certo***
Selecione o Status do Questionário: Aberto
Clique em Elaborar Questões

Selecione o Questionário: **Demarcação de Imagens 1**
*Procedimento **Elaborar Questões***
Selecione o Questionário: Demarcação de Imagens 1
Descrição do Assunto do Questionário: Pulmão e Coração:
Valor da Questão: 10

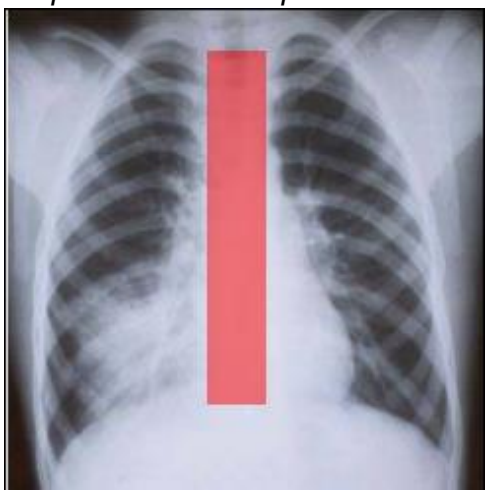
Selecione o Número da Imagem: 1

Clicar no botão Elaborar Questões

Elaboração das Questões
Selecione o Questionário: **Demarcação de Imagens 1**
Descrição da Questão: Selecione a região do Mediastino
Valor da Questão: 10
Clique no Botão Selecione a Imagem

Elaboração das Questões (Continuação)
Selecione o número da Imagem: 1

Clique no Botão Criar Demarcação
Selecione o Texto da Pergunta: Selecione a região do Mediastino
Clique no botão esquerdo do mouse e arraste sobre a região entre os pulmões.



Clique no Botão Incluir

Clique no Menu Questionário → Pergunta Demarcar
Elaboração das Questões
Selecione o Questionário: **Demarcação de Imagens 1**
Descrição da Questão: Selecione a região do Coração
Valor da Questão: 10
Clique no Botão Selecione a Imagem

Elaboração das Questões (Continuação)
Selecione o número da Imagem: 2
Clique no Botão Criar Demarcação
Selecione o Texto da Pergunta: Selecione a região do Coração
Clique no botão esquerdo do mouse e arraste sobre a região do coração.



Clique no Botão Incluir

5. Faça o Logout para sair do Sistema. Em seguida, crie uma conta de Estudante. Faça o Login como estudante e Responda ao Questionário de questões de Múltipla Escolha. Verifique o resultado.

Procedimento: Menu Questionário → Estudante
Selecione a opção "Questionário de Múltipla Escolha" → Enviar
Selecione o Nome do Questionário "Interpretação de Imagens I" → Próxima
Responda o questionário como estudante
Ao final vá ao Menu Resultado e informe o nome do estudante para ver a pontuação.
Selecione a opção "Questões de Demarcação de Imagens" → Enviar

6. Responda o Questionário de Demarcação de Imagens. Verifique o resultado.

Procedimento: Menu Questionário → Estudante
Selecione o Questionário *"Demarcação de Imagens I"*
Ao final vá ao Menu Resultado e informe o nome do estudante para ver a pontuação.
Selecione a opção "Questões de Demarcação de Imagens" → Enviar

7. Faça o *Logout* do estudante e efetue o *Login* novamente como professor. Verifique se as radiografias de pulmões contêm ou não imagem com diagnóstico de Tuberculose.

Procedimento: No Menu Predição carregue uma imagem de pulmão para verificar se possui ou não com diagnóstico de *tuberculose. As imagens de pulmão estão na pasta "Pulmões".*

8. Entre no Estudo de Casos e poste um arquivo de Estudo de Caso na plataforma.
Procedimento: Menu Estudo → Casos
Atribuir um número para o estudo de caso
Digitar o Título do Arquivo: Processamento Imagens Medicas
Escolher o arquivo Processamento Imagens Medicas.pdf na pasta "Casos"

9. Acesse o fórum de bate papo e crie uma conta para duas pessoas. Determine um assunto qualquer e simule uma interação entre elas.

Procedimento: Menu Fórum
Clique no ícone +
Digite o título do assunto
Clique no botão "Criar"

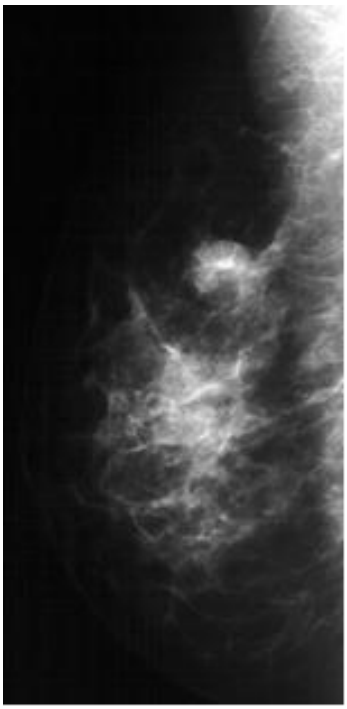
10. Faça o Logout e Feche o programa.

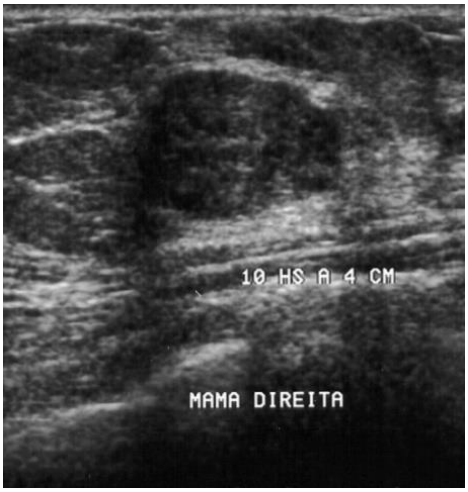
APÊNDICE E – QUESTIONÁRIO DE APRENDIZADO APLICADO AO ALUNO

Questionário de Avaliação ao Estudante:

As respostas corretas foram assinaladas em vermelho pelo próprio professor.

1 - Dê a classificação





a) BI-RADS™ 2

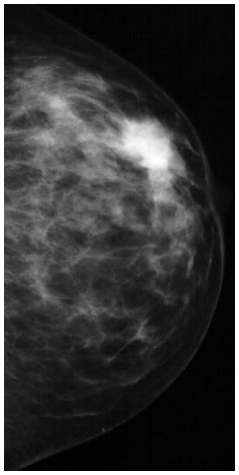
b) BI-RADS™ 3

c) BI-RADS™ 4

d) BI-RADS™ 5

e) BI-RADS™ 0

2 - Dê a conduta nesta mamografia



a) Controle mamografico dessa mama em 6 meses

b) Punção aspirativa com agulha fina (PAAF)

c) Controle anual de rotina.

d) Punção aspirativa com agulha grossa (Core Biopsia)

e) Complementação com ultrassonografia

3 – Nesse ultrassom de mama de uma paciente com mastalgia qual o seu diagnóstico:



a) Fibroadenoma

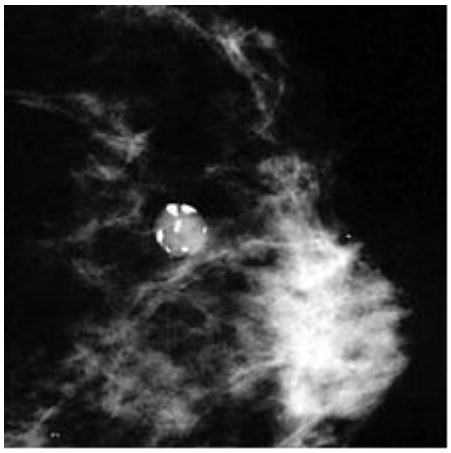
b) Agrupamento de microcistos

c) Cisto simples

d) Nódulo irregular suspeito

e) Cisto complexo

4 - Qual a classificação BIRADS™ do nódulo abaixo



a) BI

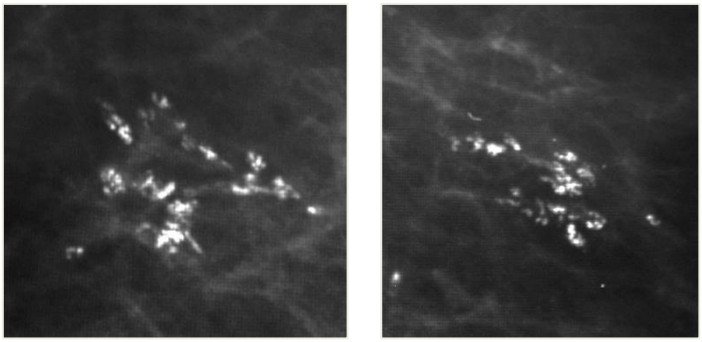
b) BII

c) BIII

d) BIV

e) BV

5 - Análise a imagem abaixo e responda: As calcificações apresentam morfologia, classificação BI-RADS e valor preditivo de malignidade (VPP), respectivamente:



a) Calcificações lineares finas, BI-RADS 5 e VPP de 95%.

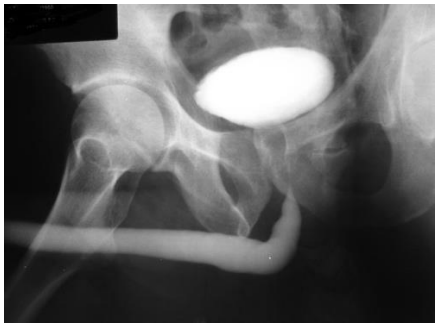
b) Calcificações amorfas, BI-RADS 4c e VPP de 50%

c) Calcificações distrofica, BI-RADS 2 e VPP de 0%

d) Calcificações puntiformes e monomórficas, BI-RADS 3 e VPP menor que 2%.

e) Calcificações em bastonetes (secretórias), BI-RADS 2 e VPP igual a 0%.

6 - Observe as imagens abaixo e marque o nome desse exame



a) Urografia excretora.

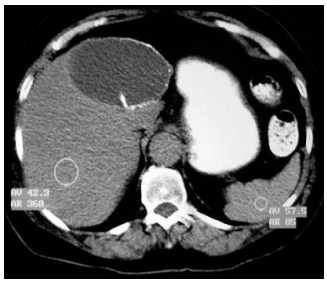
b) Uretrocistografia retrograda.

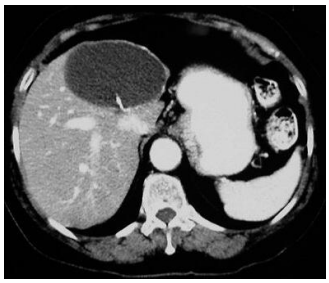
c) Uretrocistografia com correntinha.

d) Uretrocistografia miccional

e) Enema opaco

7 - Qual é o seu diagnóstico:





a) Hemangioma hepático

b) Hepatocarcinoma

c) Cisto hepático atípico

d) Cisto hepático simples

e) Esteatose Hepatica

8 - Em relação a imagem abaixo qual a sua provável etiologia?



a) Litiase bilar.

b) Trauma.

c) Abuso de drogas.

d) Diabetes Melitus

e) Abuso de alcool.

9 - Qual é o seu diagnóstico?



a) Megaesôgafo chagásico.

b) CEC de esôfago.

c) Esclerodermia.

d) Varizes de esôfago.

e) Esôfago de Barret.

10 – Na imagem abaixo observamos um ultrassom da vesicula biliar, qual o seu diagnóstico:



a) Colecistite aguda.

b) Polipo vesicular

c) Carcinoma da vesicula biliar.

d) Barro biliar.

e) Colecistopatia calculosa.

APÊNDICE F – Termos de Uso da Plataforma

Termos e condições gerais de uso do site http://18.212.50.148:8000/ e aplicativo patologIA

Os serviços do http://18.212.50.148:8000/ e patologIA são fornecidos pela pessoa física com o seguinte nome: César Alexandre Silva Lima inscrito no CPF sob o n° 461.679.866-49, titular da propriedade intelectual sobre software, website, aplicativos, conteúdos e demais ativos relacionados à plataforma patologIA e http://18.212.50.148:8000/.

1. Do objeto

A plataforma visa licenciar o uso de seu software, website, aplicativos e demais ativos de propriedade intelectual, fornecendo ferramentas para auxiliar e dinamizar o dia a dia dos seus usuários.

A plataforma caracteriza-se pela prestação do seguinte serviço: Cadastro de Imagens médicas, questionários de múltipla escolha, questionários de demarcação de imagens, postagem de documentos de casos clínicos, predição de patologias e fórum de debates.

2. Da aceitação

O presente Termo estabelece obrigações contratadas de livre e espontânea vontade, por tempo indeterminado, entre a plataforma e as pessoas físicas ou jurídicas, usuárias do site e aplicativo.

Ao utilizar a plataforma o usuário aceita integralmente as presentes normas e compromete-se a observá-las, sob o risco de aplicação das penalidade cabíveis.

A aceitação do presente instrumento é imprescindível para o acesso e para a utilização de quaisquer serviços fornecidos pela empresa. Caso não concorde com as disposições deste instrumento, o usuário não deve utilizá-los.

3. Do acesso dos usuários

Serão utilizadas todas as soluções técnicas à disposição do responsável pela plataforma para permitir o acesso ao serviço 24 (vinte e quatro) horas por dia, 7 (sete) dias por semana. No entanto, a navegação na plataforma ou em alguma de suas páginas poderá ser interrompida, limitada ou suspensa para atualizações, modificações ou qualquer ação necessária ao seu bom funcionamento.

4. Do cadastro

O acesso às funcionalidades da plataforma exigirá a realização de um cadastro prévio e, a depender dos serviços ou produtos escolhidos, o pagamento de determinado valor.

Ao se cadastrar o usuário deverá informar dados completos, recentes e válidos, sendo de sua exclusiva responsabilidade manter referidos dados atualizados, bem como o usuário se compromete com a veracidade dos dados fornecidos.

O usuário se compromete a não informar seus dados cadastrais e/ou de acesso à plataforma a terceiros, responsabilizando-se integralmente pelo uso que deles seja feito.

Menores de 18 anos e aqueles que não possuírem plena capacidade civil deverão obter previamente o consentimento expresso de seus responsáveis legais para utilização da plataforma e dos serviços ou produtos, sendo de responsabilidade exclusiva dos mesmos o eventual acesso por menores de idade e por aqueles que não possuem plena capacidade civil sem a prévia autorização.

Mediante a realização do cadastro o usuário declara e garante expressamente ser plenamente capaz, podendo exercer e usufruir livremente dos serviços e produtos.

O usuário deverá fornecer um endereço de e-mail válido, através do qual o site realizará todas comunicações necessárias.

Após a confirmação do cadastro, o usuário possuirá um login e uma senha pessoal, a qual assegura ao usuário o acesso individual à mesma. Desta forma, compete ao usuário exclusivamente a manutenção de referida senha de maneira confidencial e segura, evitando o acesso indevido às informações pessoais.

Toda e qualquer atividade realizada com o uso da senha será de responsabilidade do usuário, que deverá informar prontamente em caso de uso indevido da respectiva senha.

Não será permitido ceder, vender, alugar ou transferir, de qualquer forma, a conta, que é pessoal e intransferível.

Caberá ao usuário assegurar que o seu equipamento seja compatível com as características técnicas que viabilize a utilização da plataforma e dos serviços ou produtos.

O usuário poderá, a qualquer tempo, requerer o cancelamento de seu cadastro junto ao site http://18.212.50.148:8000/ e aplicativo patologIA. O seu descadastramento será realizado o mais rapidamente possível, desde que não sejam verificados débitos em aberto.

O usuário, ao aceitar os Termos e Política de Privacidade, autoriza expressamente a plataforma a coletar, usar, armazenar, tratar, ceder ou utilizar as informações derivadas do uso dos serviços, do site e quaisquer plataformas, incluindo todas as informações preenchidas pelo usuário no momento em que realizar ou atualizar seu cadastro, além de outras expressamente descritas na Política de Privacidade que deverá ser autorizada pelo usuário.

5. Do suporte

Em caso de qualquer dúvida, sugestão ou problema com a utilização da plataforma, o usuário poderá entrar em contato com o suporte, através do email 16casl@gmail.com telefone 11.958.750.019.

6. Das responsabilidades

É de responsabilidade do usuário:

a) defeitos ou vícios técnicos originados no próprio sistema do usuário;

b) a correta utilização da plataforma, dos serviços ou produtos oferecidos, prezando pela boa convivência, pelo respeito e cordialidade entre os usuários;

c) pelo cumprimento e respeito ao conjunto de regras disposto nesse Termo de Condições Geral de Uso, na respectiva Política de Privacidade e na legislação nacional e internacional;

d) pela proteção aos dados de acesso à sua conta/perfil (login e senha).

É de responsabilidade da plataforma patologIA e http://18.212.50.148:8000/:

a) indicar as características do serviço ou produto;

b) os defeitos e vícios encontrados no serviço ou produto oferecido desde que lhe tenha dado causa;

c) as informações que foram por ele divulgadas, sendo que os comentários ou informações divulgadas por usuários são de inteira responsabilidade dos próprios usuários;

d) os conteúdos ou atividades ilícitas praticadas através da sua plataforma.

A plataforma não se responsabiliza por links externos contidos em seu sistema que possam redirecionar o usuário à ambiente externo a sua rede.

Não poderão ser incluídos links externos ou páginas que sirvam para fins comerciais ou publicitários ou quaisquer informações ilícitas, violentas, polêmicas, pornográficas, xenofóbicas, discriminatórias ou ofensivas.

7. Dos direitos autorais

O presente Termo de Uso concede aos usuários uma licença não exclusiva, não transferível e não sublicenciável, para acessar e fazer uso da plataforma e dos serviços e produtos por ela disponibilizados.

A estrutura do site ou aplicativo, as marcas, logotipos, nomes comerciais, layouts, gráficos e design de interface, imagens, ilustrações, fotografias, apresentações, vídeos, conteúdos escritos e de som e áudio, programas de computador, banco de dados, arquivos de transmissão e quaisquer outras informações e direitos de propriedade intelectual de César Alexandre Silva Lima, observados os termos da Lei da Propriedade Industrial (Lei nº 9.279/96), Lei de Direitos Autorais (Lei n° 9.610/98) e Lei do Software (Lei n° 9.609/98), estão devidamente reservados.

Este Termo de Uso não cede ou transfere ao usuário qualquer direito, de modo que o acesso não gera qualquer direito de propriedade intelectual ao usuário, exceto pela licença limitada ora concedida.

O uso da plataforma pelo usuário é pessoal, individual e intransferível, sendo vedado qualquer uso não autorizado, comercial ou não-comercial. Tais usos consistirão em violação dos direitos de propriedade intelectual de César Alexandre Silva Lima, puníveis nos termos da legislação aplicável.

8. Das sanções

Sem prejuízo das demais medidas legais cabíveis, César Alexandre Silva Lima poderá, a qualquer momento, advertir, suspender ou cancelar a conta do usuário:

a) que violar qualquer dispositivo do presente Termo;

b) que descumprir os seus deveres de usuário;

c) que tiver qualquer comportamento fraudulento, doloso ou que ofenda a terceiros.

9. Da rescisão

A não observância das obrigações pactuadas neste Termo de Uso ou da legislação aplicável poderá, sem prévio aviso, ensejar a imediata rescisão unilateral por parte de César Alexandre Silva Lima e o bloqueio de todos os serviços prestados ao usuário.

10. Das alterações

Os itens descritos no presente instrumento poderão sofrer alterações, unilateralmente e a qualquer tempo, por parte de César Alexandre Silva Lima, para adequar ou modificar os serviços, bem como para atender novas exigências legais. As alterações serão veiculadas pelo site http://18.212.50.148:8000/ e pelo aplicativo patologIA e o usuário poderá optar por aceitar o novo conteúdo ou por cancelar o uso dos serviços, caso seja assinante de algum serviço.

11. Da política de privacidade

Além do presente Termo, o usuário deverá consentir com as disposições contidas na respectiva Política de Privacidade a ser apresentada a todos os interessados dentro da interface da plataforma.

12. Do foro

Para a solução de controvérsias decorrentes do presente instrumento será aplicado integralmente o Direito brasileiro.

Os eventuais litígios deverão ser apresentados no foro da comarca em que se encontra a sede da empresa.

ANEXOS

UNIVERSIDADE DE MOGI DAS CRUZES - UMC/SP

PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: patologIA: PLATAFORMA ONLINE PARA APRIMORAMENTO DE TREINAMENTOBASEADOS EM IMAGENS APLICADA A ESTUDANTES DO CURSO

Pesquisador: Silvia Cristina Martini

Área Temática:

Versão: 3

CAAE: 65495922.7.0000.5497

Instituição Proponente:ORGANIZACAO MOGIANA DE EDUCACAO E CULTURA SOCIEDADE SIMPLES

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 5.863.020

Apresentação do Projeto:

TODAS AS INFORMAÇÕES DESTE ITEM FORAM EXTRAÍDAS DO PARECER #5.845.896, SENDO ESTA A TERCEIRA VERSÃO EM RESPOSTA AO PARECER SUPRACITADO EMITIDO EM 6 DE JANEIRO DE 2023.

Segundo o texto apresentado pelo pesquisador responsável: de acordo com dados gerados pelo CRM, 80% dos médicos formados em 2016 não sabiam interpretar exames de imagem, mostrando dessa forma um déficit no aprendizado durante os cursos de medicina. Uma forma de melhorar a qualidade de ensino nas universidades para que os profissionais saiam mais bem preparados do curso, seria o uso de programas de computadores que pudessem auxiliar no aprendizado dos alunos com relação a análise de imagens como radiografias, tomografias, ultrasonografias e mamografias. Além de melhorar o aprendizado, programas de computadores poderiam auxiliar no diagnóstico e na interpretação de imagens por parte de profissionais já formados que não tiveram uma boa base nesse quesito. Segundo os pesquisadores: “Assim, este projeto foi concebido para auxiliar o estudante no aprendizado da interpretação de imagens médicas utilizando questionários formulados pelo professor e permitindo a interação do professor com o estudante realizando demarcações de regiões das imagens alvo do estudo. O professor poderá propor ao estudante, por exemplo, a identificação de uma determinada região da imagem demarcada por ele ou propor ao estudante que demarque uma região para identificar algum padrão anormal nela existente. A plataforma, disponibilizado em nuvem, poderá auxiliar ao estudante na identificação de patologias

Endereço: Av. Dr. Cândido Xavier de Almeida Souza, 200, Prédio 2, Sala 21-21 - Centro Cívico
Bairro: Prédio II, sala 2121(UMC) **CEP:** 08.780-911
UF: SP **Município:** MOGI DAS CRUZES
Telefone: (11)4798-7085 **Fax:** (11)4798-7085 **E-mail:** cep@umc.br

utilizando modelos de inteligência artificial e fornecerá um relatório do desempenho do estudante durante suas interações com a plataforma." Para isso, "Será utilizado a escala Likert para apuração dos resultados. A compilação das respostas se dará por meio de teste estatístico de Kruskal Wallis com nível de significância (= 0,05). A realização deste estudo visa como resultado esperado no aumento do grau de eficiência do estudante no aprendizado da interpretação de imagens médicas. Serão discorridos os resultados o qual serão enfatizados sobre a viabilidade de uso da plataforma proposto neste estudo." Neste sentido, a pesquisa apresenta como hipóteses que: " O computador é capaz de auxiliar os alunos do curso de medicina a obterem conhecimento necessário para interpretar uma imagem médica". Trata-se de uma pesquisa qualitativa com 128 participantes, dentre eles 120 estudantes do curso de medicina da Universidade de Mogi das Cruzes que tenham cursado no mínimo o sexto período do curso. Além disso, participarão da pesquisa 5 professores ou profissionais de imagens médicas 3 avaliadores que irão verificar a usabilidade dos testes. Segundo os pesquisadores, a pesquisa será realizada com questionários que irão avaliar: "Três testes serão realizados nesta pesquisa: usabilidade, funcionalidade e aprendizado. – Teste de Usabilidade (NIELSEN, 1994) define usabilidade como o grau de satisfação e eficiência que um usuário de um determinado sistema computacional pode atingir, em função dos objetivos específicos do trabalho, num dado ambiente. – Teste de Funcionalidade Este teste, também chamado de teste caixa-preta, é baseado nos requisitos funcionais da plataforma e será aplicado a estudantes de professores ou profissionais de imagens médicas. Esta técnica não está preocupada com o comportamento interno da plataforma durante a execução do teste, mas sim com a saída gerada após a entrada dos dados especificados. Este teste está focado a responder se a plataforma funciona ou não de maneira adequada segundo suas próprias funcionalidades e, neste caso, deverá responder o quanto a plataforma auxilia naquilo que se propõe, ou seja, o ensino e aprendizagem de interpretação de imagens médicas. – Teste de Aprendizado O teste de aprendizado consta do uso da plataforma tanto pelo professor quanto o aluno. O professor utilizará a plataforma para irá elaborar um questionário de 10 questões para que os estudantes possam responder. Foi programado um período de três meses que ocorrerão entre janeiro e março de 2023 a professores e alunos para utilização da plataforma utilizando laboratórios de informática nas dependências da Universidade de Mogi das Cruzes para poder treinar e rever o conteúdo postado na plataforma. Ao final deste período de uso e treinamento os estudantes passarão por um teste de conhecimentos e habilidades sobre o conteúdo ministrado pelo professor no transcorrer da disciplina de imagenologia durante este período." Como critérios de inclusão, foram informados: "O estudante que participar do teste deverá estar matriculado

regularmente e cursando no mínimo o sexto período do curso de medicina da Universidade de Mogi das Cruzes – UMC onde a disciplina de Imagenologia II é oferecida em sua grade curricular", enquanto os critérios de exclusão são: "Apenas alunos do curso de medicina poderão participar dos testes. Estudantes de outros cursos e alunos do curso de medicina que estejam cursando períodos inferiores ao sexto período e alunos que por qualquer outro motivo desistir ou se recusar a participar, serão excluídos dos testes.

Pessoas portadores de Tecnofobia, termo que descreve o "medo anormal ou a ansiedade excessiva acerca dos efeitos da tecnologia na vida", ou, a Ciberfobia que é a Ansiedade ou paranoia referentes à utilização dos computadores poderão recursar-se a participar dos testes". O plano de análise dos dados informados pelo pesquisador prevê que "Para cada teste será realizado a compilação de dados estatísticos em conformidade com o teste aplicado, utilizando-se o software SPSS. – Tratamento Estatístico de Usabilidade (Apêndice A) Para a compilação dos cálculos da medição, (BROKE,1986) propôs um cálculo obtido em duas fases. Para as respostas das questões ímpares, subtraise de 1 da pontuação que o usuário respondeu e nas questões pares, subtrai-se a resposta do 21 usuário de 5. Ao final, soma-se todos os valores obtidos das 10 questões e multiplica-se por 2,5. Em seguida é calculada a média final de onde se obtém a pontuação SUS. O resultado estará sempre no intervalo de 0 a 100. O questionário é composto por 10 perguntas padrões conforme descrição no apêndice A. Ainda, segundo (BROKE, 1986) um aplicativo para ser considerado de boa usabilidade, deverá obter média final mínima de 68 pontos. – Tratamento Estatístico de Funcionalidade (Apêndice B) A compilação dos dados será realizado com base na moda estatística, ou seja, o valor mais frequente na resposta de cada quesito. Será aplicado um formulário de 10 questões para cada tipo de usuário, ou seja, professor e alunos. Será criada uma Tabela com 10 questões para cada formulário que terá a moda como resposta de cada questão. Conforme as respostas destas questões, será possíveis compilar os resultados por meio de teste estatístico Kruskal-Wallis com nível de significância (= 0,05) entre avaliadores. Foram definidas duas hipóteses: • Hipótese nula - H: Todos os avaliadores aprovam a usabilidade da plataforma • Hipótese alternativa - H1: Existe divergência entre os avaliadores sobre a usabilidade da plataforma. – Tratamento Estatístico de Aprendizado O teste de aprendizado será compilado de acordo com a comparação entre a média aritmética, moda e desvio padrão dos dois grupos de estudantes e dos professores a fim de comparar o desempenho alcançado por cada grupo (apêndice B) e apurar se houve aprimoramento de conhecimentos em virtude do uso da plataforma." Como desfechos primário e secundário, o pesquisador informa que: "Desenvolver um sistema intuitivo e de fácil assimilação para ser uma ferramenta de auxílio ao aprendizado na interpretação de imagens médicas, e assim, prover a

responsividade da interface para que se ajuste à tela de qualquer dispositivo a ser utilizado como computadores desktop, notebooks, tablets ou aparelhos celulares. Assim, espera-se que a plataforma possa aferir e auxiliar na qualidade da formação de novos profissionais." Além disso: "Com a apresentação dos resultados desta pesquisa é esperada uma evolução na interpretação dos padrões normais e anormais de imagens médicas. Espera-se que o sistema possa ser utilizado de forma gratuita, devido a sua facilidade e flexibilidade no uso de equipamentos usuais no dia a dia dos usuários como computadores desktop, notebooks, tablets e telefones celulares." O orçamento apresentado prevê o gasto de R$ 1.730,00, o qual será custeado com financiamento próprio. O cronograma apresentado prevê o início da coleta de dados a partir de 28/02/2023 (data limite de aprovação CEP) e o término da pesquisa (defesa de tese) em 30/06/2023.

Objetivo da Pesquisa:

TODAS AS INFORMAÇÕES DESTE ITEM FORAM EXTRAÍDAS DO PARECER #5.845.896, SENDO ESTA A TERCEIRA VERSÃO EM RESPOSTA AO PARECER SUPRACITADO EMITIDO EM 6 DE JANEIRO DE 2023.

Segundo os pesquisadores, o objetivo principal da pesquisa é: "Avaliar o aprendizado de 120 estudantes regularmente matriculados no curso de medicina da Universidade de Mogi das Cruzes e que já tenham cursado pelo menos o sexto período utilizando a plataforma patologia desenvolvida no projeto de doutorado do autor; 5 professores ou profissionais de imagens médicas para avaliação dos testes de funcionalidade e três avaliadores para avaliação dos testes de usabilidade, no total de 128 pessoas envolvidas." Ainda segundo os pesquisadores, os objetivos específicos são: "Além de funcionalidades modulares, pretende-se construir uma ampla base de conhecimento baseada em um vasto repositório de imagens médicas contemplando diferentes órgãos. Inserção de novas imagens, sem laudos, quando inseridas na base de dados deverão ser pré-classificadas utilizando técnicas de I.A. Elaborar (professor) questionários para que seus estudantes possam aferir seus conhecimentos e trabalhar diretamente com imagens médicas permitindo demarcações utilizando ferramenta de desenho".

Avaliação dos Riscos e Benefícios:

TODAS AS INFORMAÇÕES DESTE ITEM FORAM EXTRAÍDAS DOS DOCUMENTOS ANEXADOS (TCLE, PROJETO E PLATAFORMA BRASIL) EM RESPOSTA AO PARECER ANTERIOR #5.845.896 EMITIDO EM 6 DE JANEIRO DE 2023.

Por tratar-se de uma pesquisa com 3 grupos de participantes, os riscos e benefícios de cada um

dos grupos foram apresentados. A saber, segundo os pesquisadores:

“-Riscos ao Participante: Ao participar deste estudo, o usuário irá responder a um questionário ao final de sua interação. Ele poderá se sentir constrangido por sentir dificuldades em interagir com a plataforma, equipamentos eletrônicos ou se sentir constrangido por qualquer outro motivo. Caso aconteça tal situação o usuário poderá contatar os pesquisadores que darão toda a assistência necessária ao participante, mas, caso queira interromper sua participação poderá comunicar sua desistência ao professor ou ao analista, interrompendo sua participação que não será computada à compilação de resultados.

-Riscos ao Estudante: Se você for sorteado para compor o grupo GE poderá sentir dificuldades em interagir com a plataforma, equipamentos eletrônicos ou sentir algum desconforto ao responder alguma das questões do questionário sobre referente aos testes de funcionalidade e aprendizado. Se estiver compondo o grupo GC, pode sentir algum desconforto ao responder ao questionário sobre o teste de aprendizado apenas.

Caso sinta algum desses desconfortos, você poderá contatar os pesquisadores que te darão toda a assistência necessária sem custos, mas, caso queira interromper sua participação poderá comunicar sua desistência ao professor ou aos pesquisadores, interrompendo sua participação sem prejuízos para você.

Nesse caso, sua participação até o momento da desistência não será computada à compilação de resultados. Há também risco de vazamento de dados, suas informações e seus dados estarão em segurança, pois os pesquisadores estarão seguindo as normas estabelecidas pela Resolução 466/12 do Conselho Nacional de Saúde e pela lei federal LGPD 13709/2018, dessa forma, os pesquisadores evitarão os riscos de vazamento de informações de dados do participante da pesquisa.

-Riscos ao Professor: O risco ao participar deste estudo é mínimo, mas, você poderá ter algum desconforto por sentir estresse ao interagir com funcionalidades mais complexas da plataforma, cansaço ou quebra do seu anonimato. Caso aconteça tal situação você poderá contatar os pesquisadores que darão toda a assistência necessária sem custos, mas, caso queira interromper sua participação poderá comunicar sua desistência ao pesquisador, 19 interrompendo sua participação sem prejuízos ou ônus para você, bem como não será computada à compilação de resultados da pesquisa. Há também risco de vazamento se dados, contudo suas suas informações e seus dados estarão em segurança, pois os pesquisadores estarão seguindo as normas estabelecidas pela Resolução 466/12 do Conselho Nacional de Saúde e pela lei federal LGPD 13709/2018, dessa forma, os pesquisadores evitarão os riscos de vazamento de informações de dados do participante da pesquisa.

-Riscos ao Avaliador: Por ser um profissional da área de informática não ocorrerão riscos de constrangimentos com relação à interação com a plataforma, mas, poderão acontecer riscos mínimos como cansaço ou desconforto pelo tempo gasto no preenchimento do questionário. Caso aconteça tal situação poderá contatar os pesquisadores que darão toda a assistência necessária sem custos, mas, caso queira interromper sua participação poderá também comunicar sua desistência, interrompendo sua participação sem prejuízos ou ônus para você, bem como não será computada à compilação de resultados da pesquisa.

Há também risco de vazamento se dados, contudo suas informações e seus dados estarão em segurança, pois os pesquisadores estarão seguindo as normas estabelecidas pela Resolução 466/12 do Conselho Nacional de Saúde e pela lei federal LGPD 13709/2018, dessa forma, os pesquisadores evitarão os riscos de vazamento de informações de dados do participante da pesquisa.

-Benefícios ao Participante: Cada participante desta pesquisa tomará ciência do benefício do aprendizado por computador no auxílio à interpretação a imagens médicas porque a plataforma estará disponível e poderá ser utilizado continuamente durante toda sua formação.

-Benefícios ao Estudante Seu principal benefício será no engrandecimento do seu próprio aprendizado referente à interpretação de imagens médicas. Ao participar da pesquisa, estudantes de medicina poderão utilizar a plataforma após esse período de validação, porque ela estará disponível e poderá ser utilizada continuamente pelos demais estudantes de medicina e por você durante toda sua formação acadêmica.

-Benefícios ao Professor O participante não terá benefício direto, mas sim indiretamente, pois irá contribuir para o aperfeiçoamento da plataforma sob a visão e lógica do professor, visto que o sistema estará a sua disposição e poderá ser utilizado continuamente pelos estudantes de medicina sob sua orientação bem como de outros professores que ministram a disciplina de imagenologia.

-Benefícios ao Avaliador: Não haverá benefícios diretos para este participante. Ao participar, você estará contribuindo para o melhorando da plataforma e, consequentemente, para que estudantes de medicina tenham uma plataforma com usabilidade atrelada com conteúdo referente a disciplina imagenologia que auxilie no aprendizado deles. Poderá demonstrar sua expertise para definir como as pessoas irão interagir com a plataforma, avaliar as tarefas que serão realizadas dentro dela, avaliar a ordem na qual as telas serão apresentadas e outros critérios de usabilidade."

Comentários e Considerações sobre a Pesquisa:

O protocolo de pesquisa trata-se de um projeto de Terceira versão e apresenta como pesquisadora responsável Dra. Silvia Cristina Martini e como assistente de pesquisa César Alexandre Silva Lima. A folha de rosto foi assinada pelo Coordenador PPG em Engenharia Biomédica Fabiano Bezerra Menegidio, pois trata-se de um projeto de doutorado do curso de engenharia biomédica da Universidade de Mogi das Cruzes.

Considerações sobre os Termos de apresentação obrigatória:

O Termo de Consentimento Livre e Esclarecido menciona os procedimentos a que os participantes serão submetidos, os riscos e benefícios da realização da pesquisa e ressalta a garantia dos direitos dos sujeitos da pesquisa quanto à informação, privacidade e encaminhamento. Indica que os itens mencionados estão sob responsabilidade do pesquisador responsável e da instituição onde os dados serão coletados em consonância à Resolução 466/12 do Conselho Nacional de Saúde e da Norma Operacional nº 001 de 2013 do CNS. As informações aos participantes da pesquisa sobre o acesso ao pesquisador e o CEP estão devidamente contempladas no TCLE.

A carta resposta relacionada as inadequações anteriores foi apresentada corretamente

Conclusões ou Pendências e Lista de Inadequações:

As pendências/inadequações descritas no Parecer Consubstanciado nº 5.845.896 foram resolvidas.
Consideramos que não há vieses que impeçam, sob o ponto de vista ético, a condução da pesquisa.

Considerações Finais a critério do CEP:

O Comitê de Ética em Pesquisa - CEP, de acordo com suas atribuições definidas na Resolução CNS 466/12, solicita ao pesquisador responsável que encaminhe o relatório final ou cópia da publicação do artigo ou resumo referentes a este projeto, através de NOTIFICAÇÃO, quando da conclusão do projeto.
Havendo qualquer evento adverso ou qualquer mudança no projeto que envolva direta ou indiretamente o participante da pesquisa, deve o pesquisador entrar em contato imediatamente com o sistema CEP/CONEP.

Mudanças que não descaracterizam o projeto aprovado como ampliação de amostra ou vigência do projeto, dentre outras, podem ser submetidas através de EMENDA para análise e aprovação por este CEP.

Endereço: Av. Dr. Cândido Xavier de Almeida Souza, 200, Prédio 2, Sala 21-21 - Centro Cívico
Bairro: Prédio II, sala 2121(UMC) **CEP:** 08.780-911
UF: SP **Município:** MOGI DAS CRUZES
Telefone: (11)4798-7085 **Fax:** (11)4798-7085 **E-mail:** cep@umc.br

Quanto ao direito à assistência, segundo o item V.6 da resolução 466/12, "o pesquisador, o patrocinador e as instituições e/ou organizações envolvidas nas diferentes fases da pesquisa devem proporcionar assistência imediata, nos termos do item II.3, bem como responsabilizarem-se pela assistência integral aos participantes da pesquisa no que se refere às complicações e danos decorrentes da pesquisa."

Em relação à proteção dos dados, o pesquisador deve respeitar também na sua pesquisa os termos da lei n. 13.709/18 (LGPD), responsabilizando-se por eventual vazamento ou uso indevido dos dados coletados dos participantes.

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicasdo Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_2023431.pdf	23/01/2023 22:01:28		Aceito
Solicitação registrada pelo CEP	Carta_resposta_cep_umc_Cesar_A_S_Lima.pdf	23/01/2023 22:00:30	Silvia Cristina Martini	Aceito
TCLE / Termos de Ausência	Tecle_Cesar_A_S_Lima_Professor.pdf	23/01/2023 21:59:53	Silvia Cristina Martini	Aceito
TCLE / Termos de Ausência	Tecle_Cesar_A_S_Lima_Estudante.pdf	23/01/2023 21:59:36	Silvia Cristina Martini	Aceito
TCLE / Termos de Ausência	Tecle_Cesar_A_S_Lima_Avaliador.pdf	23/01/2023 21:59:25	Silvia Cristina Martini	Aceito
Projeto Detalhado /Investigador	Projeto_PatologIA_CEP_Final_Cesar_Alexandre_Silva_Lima.pdf	23/01/2023 21:57:14	Silvia Cristina Martini	Aceito
Cronograma	Cronograma.pdf	11/01/2023 13:05:03	Silvia Cristina Martini	Aceito
Orçamento	Orcamento.pdf	01/11/2022 18:58:02	Silvia Cristina Martini	Aceito
Folha de Rosto	folhaDeRosto_assinado.pdf	01/11/2022	Silvia Cristina	Aceito

UNIVERSIDADE DE MOGI DAS CRUZES - UMC/SP

Continuação do Parecer: 5.863.020

Folha de Rosto	folhaDeRosto_assinado.pdf	18:55:36	Martini	Aceito

Situação do Parecer:
Aprovado

Necessita Apreciação da CONEP:
Não

MOGI DAS CRUZES, 24 de Janeiro de 2023

Assinado por:
Camila Batista da Silva de Araújo Cândido
(Coordenador(a))

Endereço: Av. Dr. Cândido Xavier de Almeida Souza, 200, Prédio 2, Sala 21-21 - Centro Cívico
Bairro: Prédio II, sala 2121(UMC) **CEP:** 08.780-911
UF: SP **Município:** MOGI DAS CRUZES
Telefone: (11)4798-7085 **Fax:** (11)4798-7085 **E-mail:** cep@umc.br