



**INSTITUTO
FEDERAL**

Ceará

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ

CAMPUS FORTALEZA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELECOMUNICAÇÕES

MESTRADO ACADÊMICO EM ENGENHARIA DE TELECOMUNICAÇÕES

JOCELANI DORIGO DE CASTILHOS

**SISTEMA DE VISÃO COMPUTACIONAL PARA DETECÇÃO DE FENÓTIPO DA
LIPODISTROFIA GENERALIZADA CONGÊNITA: UMA FERRAMENTA DE
AUXÍLIO AO DIAGNÓSTICO DA DOENÇA RARA**

FORTALEZA

2023

JOCELANI DORIGO DE CASTILHOS

SISTEMA DE VISÃO COMPUTACIONAL PARA DETECÇÃO DE FENÓTIPO DA
LIPODISTROFIA GENERALIZADA CONGÊNITA: UMA FERRAMENTA DE AUXÍLIO
AO DIAGNÓSTICO DA DOENÇA RARA

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia de Telecomunicações do Programa de Pós-Graduação em Engenharia de Telecomunicações do Campus Fortaleza da Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Telecomunicações. Área de Concentração: Engenharia de Telecomunicações

Orientador: Dr. Victor Hugo Costa de Albuquerque

FORTALEZA

2023

Dados Internacionais de Catalogação na Publicação

Instituto Federal do Ceará - IFCE

Sistema de Bibliotecas - SIBI

Ficha catalográfica elaborada pelo SIBI/IFCE, com os dados fornecidos pelo(a) autor(a)

C352s Castilhos, Jocelani Dorigo de.

Sistema de Visão Computacional para detecção de fenótipo da Lipodistrofia Generalizada Congênita: uma ferramenta para auxílio ao diagnóstico da Doença Rara / Jocelani Dorigo de Castilhos. - 2023.

81 f. : il.

Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Engenharia de Telecomunicações, Campus Fortaleza, 2023.

Orientação: Prof. Dr. Victor Hugo Costa de Albuquerque.

1. Lipodistrofia Generalizada Congênita. 2. Imagens. 3. Redes Neurais Convolucionais. I. Título.

CDD 621.382



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
Av. 13 de maio, 2081 - Bairro Benfica - CEP 60040-531 - Fortaleza - CE - www.ifce.edu.br

AVALIAÇÃO

Processo: 23256.016247/2023-46

Interessado: Jocelani Dorigo de Castilhos

JOCELANI DORIGO DE CASTILHOS

SISTEMA DE VISÃO COMPUTACIONAL PARA DETECÇÃO DE FENÓTIPO DA LIPODISTROFIA GENERALIZADA CONGÊNITA: UMA FERRAMENTA DE AUXÍLIO AO DIAGNÓSTICO DA DOENÇA RARA

Dissertação apresentada ao curso de Pós-Graduação em Engenharia de Telecomunicações do Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE) - *Campus Fortaleza*, como requisito parcial para obtenção do Título de Mestre em Engenharia de Telecomunicações.
Área de concentração: Sistemas de Telecomunicações

Aprovado em: **28 / 11 / 2023**

BANCA EXAMINADORA

Prof. Dr. **Victor Hugo Costa de Albuquerque** - orientador
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE

Profa. Dra. **Juliana Martins de Oliveira**
Universidade de Fortaleza - UNIFOR

Prof. Dr. **Jefferson Silva Almeida**
Universidade Federal do Ceará - UFC

Profa. Dra. **Natália Bitar da Cunha Olegário**
UNIFAMETRO

Dedico este trabalho a todos os pacientes do banco de dados que estiveram comigo nesta jornada.

AGRADECIMENTOS

Agradeço a todos que sempre torceram por mim e que me ajudaram. Aos meus amados filhos que me motivam diariamente e a querida Val, que ficou com eles quando tive que me ausentar.

Obrigada ao meu orientador, professor Dr. Victor Hugo, por me aceitar neste projeto e estar junto comigo nessa jornada.

Obrigada ao amigo Paulo Cirillo, por todas as dicas e conversas.

Agradeço ao professor Joel Sotero da Cunha Neto que em um momento decisivo, foi crucial para conclusão desse trabalho.

A professora Dra. Juliana Martins de Oliveira, pela disponibilidade em participar da defesa da minha dissertação.

Ao professor Dr. Jefferson Silva Almeida, pela disponibilidade em participar da defesa da minha dissertação e por todas as considerações enviadas.

A professora Dra. Natália Bitar da Cunha Olegário, pela disponibilidade em participar da defesa da minha dissertação e pelas correções enviadas.

Obrigada ao Comitê de Ética da Universidade de Federal do Ceará por ter autorizado utilizar o banco de dados.

Obrigada pelo Instituto Federal do Ceará por essa oportunidade.

Agradeço a CAPES, Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, pela confiança e auxílio financeiro através da bolsa de estudo durante esse processo.

“A persistência realiza o impossível.”

(Provérbio Chinês)

RESUMO

A Lipodistrofia Generalizada Congênita é uma condição genética rara caracterizada pela perda quase total de gordura corporal (tecido adiposo). Por isso os pacientes que apresentam essa doença, adquirem uma aparência física bem característica, como os músculos do corpo proeminentes. Por causa das características fenotípicas, formou-se um conjunto de dado composto por 192 imagens de pacientes que tem a lipodistrofia generalizada congênita, de propriedade da Universidade Federal do Ceará, e outro com 101 imagens de pessoas sem a doença retirada da internet. Essas imagens passaram por uma etapa de pré-processamento utilizando os algoritmos: Correção Gamma, Equalização de Histograma (HE), Equalização Dinâmica de Histograma (DHE) e Fusão de Exposição (Ying). Utilizou-se também nas imagens o método de remoção de fundo. Com o pré-processamento finalizado, foi verificada a qualidade das imagens e processados em redes neurais convolucionais para analisar os resultados das classificações. As redes neurais utilizadas foram; uma rede própria CNN, chamada de IINET, MobileNetV2, ResNet50 e VGG19. Os modelos MobileNetV2, Resnet50 e VGG19 utilizaram o modelo pré-treinado da Imagenet, *transfer learning* e todos os modelos utilizaram o otimizador Adam, matriz confusão e curva ROC para avaliar seus desempenhos. O modelo que obteve a melhor acurácia foi o VGG19 com 99,01% e f1score de 98,98% com o método de retirada do fundo e obteve o resultado da área sob a curva com 0,94. A rede IINET manteve seu bom desempenho com a acurácia de 92,43%, f1score de 93,39% e área sob a curva de 0,93 com o conjunto de dados original. O modelo MobileNetV2 obteve o melhor custo computacional. Os resultados demonstram a capacidade dos modelos da rede neural convolucional pré-treinadas em identificar os pacientes, assim como a CNN proposta, IINET, observando que o banco de dados não é padronizado e se aproxima da realidade de fotos tiradas no dia a dia. Fato benéfico para auxílio de diagnósticos para os profissionais de saúde a partir de uma imagem fotográfica tirada no consultório.

Palavras-chave: Lipodistrofia Generalizada Congênita. Imagens. Redes neurais convolucionais.

ABSTRACT

Congenital Generalized Lipodystrophy is a rare genetic condition characterized by almost total loss of body fat (adipose tissue). Therefore, patients who have this disease acquire a very characteristic physical appearance, such as prominent body muscles. Because of the phenotypic characteristics, one dataset was formed consisting of 192 images of patients who have congenital generalized lipodystrophy, owned by the Federal University of Ceara, and 101 images of people without the disease taken from the internet. These images went through a pre-processing stage using the algorithms: Gamma Correction, Histogram Equalization (HE), Dynamic Histogram Equalization (DHE) and Exposure Fusion (Ying). The background removal method was also used in the images. With the pre-processing completed, the quality of the images was checked and processed in convolutional neural networks to analyze the classification results. The neural networks used were; its own CNN network, called IINET, MobileNetV2, ResNet50 and VGG19. The MobileNetV2, Resnet50 and VGG19 models used Imagenet's pre-trained model, transfer learning, and all models used the Adam optimizer, confusion matrix and ROC curve to evaluate their performance. The model that obtained the best accuracy was VGG19 with 99.01% and f1score of 98.98% with the background removal method and obtained the result of the area under the curve with 0.94. The IINET network maintained its good performance with an accuracy of 92.43%, f1score of 93.39% and area under the curve of 0.93 with the original dataset. The MobileNetV2 model obtained the best computational cost. The results demonstrate the ability of pre-trained convolutional neural network models to identify patients, as well as the proposed CNN, IINET, noting that the database is not standardized and approximates the reality of photos taken on a daily basis. This is a beneficial fact to aid diagnoses for healthcare professionals based on a photographic image taken in the office.

Keywords: Congenital generalized lipodystrophy. Images. Neural network convolucional.

LISTA DE FIGURAS

Figura 1 – Características fenotípicas: (a) hipertrofia muscular, (b) gordura concentrada nos pés, (c) hérnia umbilical, (d) hipertrofia muscular e <i>acantose nigricans</i> , (e) hérnia umbilical e gordura concentrada nas mãos.	24
Figura 2 – Imagem capturada pela câmera com amostragem e quantização.	28
Figura 3 – Gráfico Gamma; à esquerda imagem sem o processamento e à direita com o processamento.	30
Figura 4 – Histogramas formados após processamento da imagem: (1) baixo contraste, (2) alongamento de contraste, (3) histograma equalizado, (4) Histograma adaptativo.	30
Figura 5 – Gráfico à esquerda ampliado do histograma e à direita o particionamento dos histogramas.	31
Figura 6 – Função de ativação ReLU e a função ReLU na forma analítica.	37
Figura 7 – Etapas do trabalho: 1- aquisição do banco de dados; 2- aplicação dos algoritmos de melhoramento nos bancos de dados; 3- técnicas de extração de parâmetros e 4- classificação das imagens.	45
Figura 8 – Exemplo de cada classe, (a) Pessoa com LGC (b) Pessoa saudável.	46
Figura 9 – Pastas criadas do banco de dados.	49
Figura 10 – Aplicação dos algoritmos de Melhoramento. (a)Original, (b)DHE, (c)HE, (d)Ying, (e)Gamma correction, (f)Removel background, (g)Removel+DHE, (h)Removel+He, (i)Removel+Ying, (j)Removel+Gamma, (k)Gamma+DHE, (l)Gamma+HE, (m)Gamma+Ying.	50
Figura 11 – Imagem no formato PNG, que necessita ser cortada.	51
Figura 12 – Aspecto da imagem após ser modificada do formato PNG para JPG.	52
Figura 13 – Arquitetura da IINET.	53
Figura 14 – Arquitetura da MobileNetV2.	53
Figura 15 – Arquitetura da Resnet50, sendo 1- camada base, camada 1 a 7 formadas por: convolução2D+Normalização+Ativação, 8- dropout, 9- Maxpooling, 10- flatten e 11- Convolução densa.	54
Figura 16 – Arquitetura da VGG19.	54
Figura 17 – Matriz Confusão binária	55

Figura 18 – Imagem à esquerda do aplicativo sendo procurado na <i>Apple Store</i> e à direita a tela de início do app.	60
Figura 19 – Curva ROC da rede IINET com o banco original.	66
Figura 20 – Curva ROC da rede RESNET50 com o método de retirada do fundo.	67
Figura 21 – Curva ROC da rede MobileNetV2 com o banco original.	67
Figura 22 – Curva ROC da rede VGG19 com o método de retirada do fundo.	68

LISTA DE TABELAS

Tabela 1 – Tipos de LGC.	25
Tabela 2 – Características clínicas dos tipos da LGC.	26
Tabela 3 – Descrição do Banco de Dados (Autora, 2023)	47
Tabela 4 – Parâmetros utilizados nas Redes Neurais Convolucionais	55
Tabela 5 – Comparativo entre as Redes Neurais Convolucionais	55
Tabela 6 – Valores da Area under the curve ROC (AUC) e suas respectivas interpretações	57
Tabela 7 – Tempo de Processamento dos algoritmos de melhoramento e retirada do fundo da imagem.	60
Tabela 8 – Qualidades Métricas aplicadas nas imagens.	61
Tabela 9 – Parâmetros utilizados nas Redes Neurais Convolucionais.	62
Tabela 10 – Número de imagens geradas após o uso da ferramenta <i>Data augmentation</i> .	62
Tabela 11 – Tempo do Custo Computacional das Redes Neurais Convolucionais e os algoritmos de melhoramento das imagens	63
Tabela 12 – Resultados das métricas média das Redes Neurais Convolucionais	65
Tabela 13 – Matriz de Confusão da rede IINET com o banco de dados original	66
Tabela 14 – Matriz de Confusão da rede RESNET50 com o método de retirada do fundo	66
Tabela 15 – Matriz de Confusão da rede MobileNetV2 com o banco de dados original .	67
Tabela 16 – Matriz de Confusão da rede VGG19 com o método de retirada do fundo . .	68
Tabela 17 – Comparativo entre as pesquisas passadas e a atual	69

LISTA DE ALGORITMOS

Algoritmo 1 – Data augmentation for IINET, Resnet50 and VGG19	48
Algoritmo 2 – Data augmentation for MobilenetV2	49

LISTA DE ABREVIATURAS E SIGLAS

AG	Average Gradient
AMBE	Absolute Mean Brightness Error
ANVISA	Agência Nacional de Vigilância Sanitária
AUC	Area under the curve ROC
AVC	Acidente Vascular Cerebral
BSCL	Berardinelli-Seip lipodystrophy
CNN	Convolutional Neural Network
CQ	Classificador Quadrático
CRN	Contrast-to-noise ratio
CV	Visão Computacional
DHE	Equalização de histograma dinâmico
DR	Doenças Raras
HDL	Níveis reduzidos de lipoproteínas
HE	Equalização de histograma
HIV	Vírus da Imunodeficiência Humana
HUWC	Hospital Universitário Walter Cantídio
IA	Inteligência Artificial
IAGCWD	Improved adaptive gamma correction weight distribution
IINET	Image Identification Network
IOT	Internet of Things
JPG	Joint Photographic Experts Group
KNN	K-Nearest Neighbors
LGC	Lipodistrofia Generalizada Congênita
OLS	Ordinary Least Squares
OMIM	Online Mendelian Inheritance in Man
PNG	Portable Network Graphics
PSNR	Peak Signal-to-Noise Ratio
ReLU	Rectified Linear Unit
RESNET50	Residual Neural Network
RGB	Red, green, blue
RMSE	Root Mean Square Error

ROC	Receiver Operator characteristic Curve
SSIM	Structural Similarity Index
SVM	Support Vector Machine
TNR	Taxa Verdadeira Negativa
TPR	Taxa Verdadeira Positiva
TRL	Terapia de Reposição de Leptina
UFC	Universidade Federal do Ceará
VGG19	Very Geometry Group 19

LISTA DE SÍMBOLOS

o	Operador morfológico <i>opening</i>
μ	Média de um histograma
σ	Desvio padrão
$\forall$	Qualquer
ε	Pertence
τ	Iteração

SUMÁRIO

1	INTRODUÇÃO	18
1.1	Justificativa	20
1.2	Objetivos	21
1.2.1	<i>Objetivo Geral</i>	21
1.2.1.1	<i>Objetivos Específicos</i>	21
1.3	Contribuições	22
1.4	Organização do trabalho	22
2	REFERENCIAL TEÓRICO	23
2.1	Lipodistrofia Generalizada Congênita	23
2.1.1	<i>Tipos de Lipodistrofia Generalizada Congênita</i>	25
2.1.2	<i>Tratamento para amenizar os sintomas</i>	26
2.2	Inteligência Artificial	27
2.2.1	<i>Benefícios da Inteligência Artificial</i>	27
2.2.2	<i>Visão Computacional</i>	28
2.2.2.1	<i>Técnicas de Aprimoramento de Imagens</i>	29
2.2.2.2	<i>Métricas de Qualidade</i>	32
2.3	Redes Neurais Convolucionais	35
2.3.1	<i>Rede de Identificação de Imagens</i>	37
2.3.2	<i>MobileNetV2</i>	38
2.3.3	<i>ResNet50</i>	39
2.3.4	<i>VGG19</i>	39
2.4	Data Augmentation	40
2.5	Transfer Learning	41
2.6	Otimizador Adam	41
2.7	Revisão da Literatura	42
3	METODOLOGIA	45
3.1	Etapa 1: Aquisição do banco de dados	46
3.2	Pré-processamento	48
3.3	Etapa 2: Melhoramento das imagens	49
3.4	Etapa 3: Técnicas de Extração	52

3.5	Etapa 4: Classificação	55
3.6	Tecnologias aplicadas	57
3.6.1	<i>Ambiente de desenvolvimento e testes</i>	58
4	RESULTADOS E DISCUSSÃO	59
4.1	Doenças Raras e LGC	59
4.2	Algoritmos de melhoramento	59
4.3	Parâmetros analisados	62
4.4	Classificação das Redes convolucionais	62
4.5	Matriz Confusão e Curva ROC	64
5	CONCLUSÃO	70
5.1	Trabalhos Futuros	71
	REFERÊNCIAS	72
	ANEXOS	77
	ANEXO A – Código da Matriz Confusão	78
	ANEXO B – Código treino e teste das classes	79
	ANEXO C – Curva ROC	80

1 INTRODUÇÃO

Segundo a Agência Nacional de Vigilância Sanitária (ANVISA), para uma doença ser considerada rara, ela afeta 65 pessoas em cada 100.000 indivíduos com base em dados oficiais nacionais, consulta realizada em outubro de 2023, na página digital. As doenças genéticas raras, que afetam uma quantidade limitada da população, formam um grupo diversificado de condições patológicas em todo mundo. Em sua grande maioria, são doenças causadas por mutações genéticas hereditárias, que causam disfunções metabólicas, estruturais ou funcionais em diferentes sistemas do corpo humano (BOMFIM *et al.*, 2023). Somente no Brasil, aproximadamente 13 milhões de pessoas convivem com uma doença rara, mas acredita-se que o número pode ser maior, tendo em vista que o diagnóstico correto possa levar em média de oito a nove anos (JUNQUEIRA *et al.*, 2023).

A Lipodistrofia Generalizada Congênita (LGC), que é uma doença genética rara, foi registrada em países como Estados Unidos, Noruega, Líbano, Portugal, Omã e no Brasil. Sendo sua maior ocorrência no estado do Rio Grande do Norte com uma proporção de 1 : 128000. Através do Painel de Monitoramento da Mortalidade (CID-10), pôde ser observado que em 2022, foram registrados três óbitos relacionados a lipodistrofia; um na Região do Nordeste, Maranhão; um na Região do Sudeste, Rio de Janeiro e outro na Região do Centro-oeste, Distrito Federal. Em 2023 já foi registrado um óbito na Região Sudeste, São Paulo. Site atualizado em agosto de 2023. Doença classificada com a seguinte identificação: E88.1. Importante pontuar que não é especificado o tipo de lipodistrofia no painel ((GOV.BR), 2023).

A lipodistrofia generalizada congênita é composta por distúrbios autossômicos recessivos que é caracterizada pela perda total do tecido adiposo, causando atrofia do tecido adiposo subcutâneo e extrema resistência a insulina desde o nascimento, associados a intolerância à glicose, hiperinsulinismo, diabetes mellitus, hipertrigliceridemia, esteatose hepática, musculatura proeminente, o umbigo e veias ressaltadas, cardiomiopatia hipertrófica e cistos. A perda do tecido adiposo é o que acarreta complicações metabólicas favorecendo a maioria das manifestações clínicas presentes nos indivíduos com a doença. A LGC tem quatro tipos genéticos identificado na literatura, sendo mais dois casos registrados com características fenotípicas semelhantes aos pacientes com lipodistrofia que apresentam mutações nos genes **PPARG** e **FOS** (SILVA, 2017).

Os músculos mais marcados podem ser confundidos com um porte atlético, principalmente se tratando do sexo masculino. Outras características também podem ser observados como acúmulo de gordura nas mãos, pés e no rosto, com aumento do nariz e orelhas. É uma

doença que não tem cura, sendo diagnosticada através de acompanhamento do prontuário do paciente através de um médico clínico e exames genéticos. Em recém-nascidos devido ao seu padrão fenotípico, pode ser observada através da presença marcada de hipertrofia muscular e completa falta de tecido adiposo (BISPO; FREITAS, 2023) (JUNQUEIRA *et al.*, 2023).

No município de Curais Novos, localizado no estado RN, existe a Associação dos Pais e Pessoas com a Síndrome de Berardinelli do Estado do Rio Grande do Norte (ASPOSBERN). Esta associação foi fundada por duas mães, cujos filhos tem a síndrome, em 1998. Na reportagem de 2020, a associação contava com 38 pessoas diagnosticadas com a síndrome no estado, sendo a única no mundo relacionada à doença, que recebeu até portadores de outros países. Segundo dados da Secretaria de Saúde Pública do RN (Sesap), este número representa 69% do total de casos no país, que, de acordo com o Instituto Vidas Raras, são 55 no total. O município que mais reúne pacientes é Carnaúba dos Dantas, cidade no Seridó potiguar com cerca de 7,5 mil habitantes. Nesse município, a incidência é de um indivíduo para 180 pessoas. Importante ressaltar a prevalência de consanguinidade reconhecida em alguns municípios da região que pode chegar a 33% ((ASPOSBERN), 2022).

A Inteligência Artificial (IA) tem proporcionado muitos benefícios na medicina, assim como no auxílio para identificar doenças raras. Seu recurso vem sido utilizado desde 1972, quando um sistema elaborado pela Universidade de Stanford foi utilizado no tratamento de infecções sanguíneas. Desde então as pesquisas na área não pararam mais e tem evoluído cada vez mais rápidas. O uso de redes neurais para o aprendizado de como interpretar os dados e retirar benefícios deles para classificação ou previsões, tem sido aplicados cada vez mais aos pacientes de forma individualizada. E os dados crescem cada vez mais, sendo de suma importância a IA para coletar todos esses dados em um tempo menor e com qualidade (SOARES; FARIAS, 2023).

Um exemplo do crescente aumento do número de dados é o trabalho que utilizou um banco de dados com 10.000 imagens de fundo de olhos para identificar oito doenças. Três modelos foram construídos para avaliar o desempenho; VGG16, InceptionV3 e Resnet50. Utilizando a ferramenta de *transfer learning*, a Resnet50 obteve uma acurácia de 97,1% e VGG16 obteve 96,2%. Resultados que comprovam a habilidade desses modelos pré-treinados em identificar as imagens com eficiência (EMIR; COLAK, 2023).

Outro exemplo de acessibilidade, são as redes móveis sendo incorporadas na área da saúde para auxílio de diagnósticos. Vários protótipos tem sido criados para identificação

de doenças, como por exemplo, identificação de lesões bucais. Utilizando uma rede neural convolucional, a MobileNetV2, o modelo tem a capacidade de classificar cinco classes diferentes obtendo um acerto de 80% de quatro classes (GONZÁLEZ; QUINTERO-ROJAS, 2021).

A maior motivação desse estudo é auxiliar os profissionais de saúde no diagnóstico mais breve possível e assertivo para que os mesmos possam oferecer o tratamento correto aos pacientes cometidos pela LGC. Muitos exames são dispendiosos, como por exemplo um exame genético. Através de uma rede neural convolucional e de acesso fácil, auxiliar os diagnósticos de uma maneira mais econômica, rápida e objetiva. Assim como trabalhos apresentados com imagens fotográficas de pele para detecção de câncer de pele ou psoríases, imagens de raio-x e tantos outros são utilizadas para auxiliar os profissionais, esta pesquisa tem o intuito de oferecer essa colaboração.

1.1 Justificativa

Na busca pelos artigos e publicações nas bases conhecidas, as pesquisas foram feitas utilizando as palavras chaves "*Congenital Generalized Lipodystrophy*" AND "CNN"; ou "Lipodistrofia" AND "*Machine Learning*" ou "LGC" AND "*Artificial intelligence*" e seus sinônimos e combinações, e foi encontrado um artigo relacionado sobre o tema. Quando a pesquisa foi realizada, foram encontrados artigos de Lipodistrofia Generalizada, Adquirida e Parcial ou associados ao Vírus da Imunodeficiência Humana (HIV), pois a doença pode ocorrer por causa da manifestação do vírus. Importante ressaltar que se tratando da LGC, o assunto se torna mais restrito e reduzido para se encontrar pesquisas relacionadas. Por isso a importância de explorar o assunto.

A LGC, por ser uma doença genética rara, o diagnóstico precoce, evita graves distúrbios metabólicos, hiper androgênicos e muitos outros agravantes. Os pacientes acometidos pela síndrome, sofrem de modificações na sua aparência física, além das limitações metabólicas acometidas pelo agravamento da doença. Tal fator tem impacto na autoestima do paciente, pois, sofrem diversos preconceitos nas relações sociais, familiares e profissionais. Além do desgaste psicológico de saber que se tem uma doença sem cura e que necessita de cuidados diários (DAMASCENO *et al.*, 2018).

Na busca pelo diagnóstico mais rápido e assertivo, a medicina realiza estudos e pesquisas constantemente. Aliada a essa busca, a IA tem auxiliado a medicina, com seus avanços tornando a preditiva, participativa, mais personalizada e preventiva. Desta forma, os algoritmos

estão auxiliando na forma de processar grandes volumes de dados ou volumes reduzidos, através dos modelos computacionais para auxiliar nos diagnósticos, tratamentos e previsões de resultados nas mais diversas situações. Auxiliam no desenvolvimento de medicamentos, monitoramento de pacientes e planos de tratamento personalizados (RUIZ; VELÁSQUEZ, 2023) (SOARES; FARIAS, 2023).

Como exemplo de aplicações da IA na medicina na prática, vários exemplos podem ser citados como: o uso de imagens de mamografia *on-line* para detecção e diagnóstico do câncer de mama (SILVA *et al.*, 2022), detecção automática de tuberculose usando Very Geometry Group 19 (VGG19) (MOHAN *et al.*, 2022), o uso de *transfer learning* para classificação de imagens médicas (KIM *et al.*, 2022), detecção e classificação multi classe de lesões cutâneas via teledermatologia (KHAN *et al.*, 2021), reconhecimento de imagens médicas *on-line* através de aprendizagem profunda baseada em uma Internet of Things (IOT) aberta (DOURADO *et al.*, 2020), através de chapas de raio-x, é possível detectar se o paciente está com pneumonia ou COVID-19 (RUIZ; VELÁSQUEZ, 2023) e entre tantos outros trabalhos publicados e realizados.

1.2 Objetivos

Os objetivos dessa dissertação se encontram no objetivo geral, como um objetivo maior e nos objetivos específicos, onde outros tópicos podem ser avaliados também.

1.2.1 Objetivo Geral

O objetivo geral dessa dissertação é propor um sistema de visão computacional para detecção de fenótipo da LGC: uma ferramenta de auxílio ao diagnóstico da doença rara.

1.2.1.1 Objetivos Específicos

Os objetivos específicos dessa dissertação são:

- Comparar a performance da IA na análise de imagens de pacientes. Neste caso, pessoas com LGC e pessoas sem a síndrome.
- Avaliar o impacto dos formatos de arquivo na análise das imagens.
- Avaliar os diferentes tamanhos e dimensões das imagens nos processamentos dos algoritmos de melhoramento.
- Propor uma Convolutional Neural Network (CNN) para classificação das imagens, identi-

ficada com IINET.

- Comparar as diferentes redes neurais convolucionais, como Residual Neural Network (RESNET50), MobileNetV2 e VGG19.

1.3 Contribuições

Propor um banco de dados sem padrão, que obtém uma avaliação satisfatória.

Propor uma ferramenta de auxílio ao diagnóstico da LGC.

Analisar e testar as redes neurais convolucionais para verificar sua eficiência para a classificação de imagens sem padrão.

1.4 Organização do trabalho

Esta trabalho está organizado em cinco capítulos. O capítulo 1, é apresentado a Introdução, com uma breve apresentação, trazendo o tema das doenças raras, LGC, a IA e as redes neurais convolucionais. Neste capítulo também traz as justificativas para a dissertação assim como os objetivos. As contribuições propostas e a organização do trabalho.

No capítulo 2, é proposta uma pequena revisão do referencial teórico, trazendo um pouco da lipodistrofia generalizada congênita, seus tipos e tratamento para anemizar a doença; IA, assim como seus benefícios e visão computacional, seguindo para as redes neurais convolucionais utilizadas nesta dissertação.

No capítulo 3, a metodologia, explana como o trabalho foi realizado e processado. A aquisição do banco de dados, métodos utilizados, os algoritmos de melhoramento utilizados assim como o método de retirada de fundo das imagens e as redes neurais.

No capítulo 4, tem os resultados alcançados com os algoritmos de melhoramento aplicados nas imagem e processados nas redes neurais. Contém também resultados com as métricas utilizadas. Por fim, o capítulo 5, contém as conclusões do trabalho e proposta para trabalhos futuros.

2 REFERENCIAL TEÓRICO

Neste Capítulo, serão abordados uma breve explicação sobre LGC e as formas de amenizar os sintomas da doença, assim como suas características principais, seus tipos e como chegar ao diagnóstico da doença. O uso do recurso de melhoramento das imagens, explicando cada uma, assim como as métricas de qualidade das imagens e referenciando um pouco as redes utilizadas, Image Identification Network (IINET), RESNET50, MobileNetV2 e VGG19. Um tópico sobre a técnica de *data augmentation* e suas camadas utilizadas na pesquisa. Após será abordado uma breve explicação de *transfer learning*, otimizador *Adam* e por fim revisão da literatura.

2.1 Lipodistrofia Generalizada Congênita

De acordo com Ceccarini (2021), estudos recentes na Europa apresentaram a ocorrência de 0,96 e 1,67 casos/milhão de lipodistrofia generalizada e parcial, respectivamente, observando que apenas 25% dos casos são registrados. A lipodistrofia é uma doença rara com uma estimativa de prevalência de 3/1.000.000, descrita pela primeira vez por Waldemar Berardinelli e Martin Seip, Berardinelli-Seip lipodystrophy (BSCL). A LGC, consta de quatro tipos de genes associados a doença (SARMENTO *et al.*, 2019).


Os sintomas mais predominantes nos pacientes com LGC são: níveis elevados de triglicerídeos; níveis reduzidos de lipoproteína, Níveis reduzidos de lipoproteínas (HDL); leptina e adiponectina (controlam a ingestão de alimentos, isto quer dizer, fome/saciedade); resistência à insulina; hiperinsulinemia; diabetes mellitus; hepatoesplenomegalia (aumento do fígado e baço) e esteatose hepática (aumento de gordura no fígado). Morfologicamente, apresentam hipertrofia muscular ou hiperplasia, prognatismo (desarmonia facial), protusão umbilical (hérnia umbilical), *acantose nigricans* (manchas escuras nas dobras do corpo), lesões ósseas e flebomegalia (veias espessas). Distúrbios cardiovascular, respiratório e muscular também são comuns (CAMPOS *et al.*, 2021).

Conforme Rodriguez (2015), as manifestações clínicas em crianças se tornam perceptíveis nos primeiros 2 anos de vida. Porém, pode ser percebida até no nascimento. A quantidade de gordura no corpo se concentra no couro cabeludo, órbitas oculares, boca, língua, palmas das mãos, plantas dos pés, períneo e regiões periarticulares. As crianças podem ter apetite ávido, crescimento linear maior que a média, aumento da taxa metabólica e idade óssea avançada.

Assim como pode ser identificado nas crianças as modificações físicas citadas acima, nos adolescentes e adultos, podem ser observados mudanças na aparência também, como: músculos mais aparentes; umbigo vultuoso (hérnia umbilical); veias mais esparsas; acúmulo de gordura nos pés, mãos e couro cabeludo e aumento das extremidades das mãos, pés e mandíbula. (BISPO; FREITAS, 2023).

A síndrome tem características fenotípicas que podem ser analisadas através de imagens fotográficas. Na Figura 1, pode ser observada algumas dessas características.

Figura 1 – Características fenotípicas: (a) hipertrofia muscular, (b) gordura concentrada nos pés, (c) hérnia umbilical, (d) hipertrofia muscular e *acantose nigricans*, (e) hérnia umbilical e gordura concentrada nas mãos.



Fonte: Autora, 2023.

Os critérios essenciais para o diagnóstico da LGC começam com o médico fazendo um exame físico, fazendo perguntas detalhadas sobre o histórico médico e familiar e solicitando alguns exames para confirmar ou descartar as chances de comprovação. Esses exames incluem: ressonância magnética para avaliar a composição e distribuição de gordura do corpo, painel metabólico abrangente para saber sobre o equilíbrio químico e o metabolismo do corpo, painel lipídico para verificar medições de colesterol e triglicerídeos, teste de leptina para prever como o corpo da pessoa responde ao tratamento de reposição de leptina, testes genéticos para verificar se a pessoa tem uma forma hereditária da doença e biópsia renal para avaliar se os rins da pessoa são afetados pelo problema (JUNIOR *et al.*, 2020) (GARG, 2004).

Segundo Sarmiento (2019), geralmente a doença é identificada com uma análise clínica e revisão de prontuário realizada por um médico clínico, onde pode ser observado uma sequência de danos a saúde com características próprias da doença. Mas o método mais eficaz são os testes genéticos. Os critérios para o diagnóstico clínico são: lipodistrofia de forma

generalizada em face, membros e troncos, hepatomegalia, hipertrigliceridemia e resistência à insulina (BISPO; FREITAS, 2023).

2.1.1 Tipos de Lipodistrofia Generalizada Congênita

Os tipos de LGC registrados podem ser observados na Tabela 1.

Tabela 1 – Tipos de LGC.

Tipo	Código da doença	Nome da doença	Código do gene*	Nome da proteína
Generalizada	BSCL1/CGL1	Tipo 1 Berardinelli-Seip	AGPAT2(608594)	1-AGPAT2
Generalizada	BSCL2/CGL2	Tipo 2 Berardinelli-Seip	BSCL2(269700)	Seipin
Generalizada	BSCL3/CGL3	Tipo 3 Berardinelli-Seip	CAV1(612526)	Caveolin-1
Generalizada	BSCL4/CGL4	Tipo 4 Berardinelli-Seip	CAVIN1(613327)	Cavin-1

Fonte: Online Mendelian Inheritance in Man (OMIM), modificada pela autora, 2023.

*o número da classificação da doença no site OMIM.

A LGC tipo 1, é causada por variações genéticas no gene AGPAT2, localizado no cromossomo 9q34.3, que é essencial para o desenvolvimento pós-natal e manutenção do tecido adiposo branco e tecido adiposo marrom (SORKINA; CHICHKOVA, 2021).

A LGC tipo 2, ocorre por mudanças genéticas no gene BSCL2, localizado no cromossomo 11q12.3, que desempenha o importante papel na regulação do transporte de triglicérides do retículo endoplasmático para gotas de lipídeos, convertendo esses lipídeos nascentes em maduros. A proteína Seipin também é vital para o desenvolvimento do tecido adiposo humano através da coordenada 1 função AGPAT2 (CAMPOS *et al.*, 2021).

A LGC tipo 3, é o tipo mais raro, ocorrendo variações genéticas no gene CAV1, codificando a proteína scaffold (Caveolae) da membrana celular na maioria das células: caveolina-1. Foi descrita somente em uma paciente de 20 anos de idade e brasileira (PATNI; GARG, 2015).

A LGC tipo 4, apresenta variações no gene CAVIN1, que resulta em Caveolae com densidade reduzida; que fazem parte da membrana plasmática principalmente do colesterol e esfingolipídeos (CAMPOS *et al.*, 2021).

As características clínicas mais comuns em relação a cada tipo da LGC, podem ser verificadas na Tabela 2.

Suas formas mais prevalentes são **LGC tipo 1** (40%) e **tipo 2** (50%, com alta incidência no Nordeste do Brasil. (CAMPOS *et al.*, 2021) (JUNQUEIRA *et al.*, 2023).

Tabela 2 – Características clínicas dos tipos da LGC.

DESORDEM	LGC tipo 1	LGC tipo 2	LGC tipo 3	LGC tipo 4
Tecido adiposo	Ausência de tecido adiposo ativo; Preservação do tecido adiposo mecânico	Ausência do tecido adiposo ativo e do tecido adiposo mecânico	Ausência de tecido adiposo ativo; Preservação do tecido adiposo mecânico e da medula óssea	Ausência de tecido adiposo ativo; Preservação do tecido adiposo mecânico e da medula óssea
Complicações cardiovasculares	Sem relatos	Cardiomiopatia (inflamação no músculo cardíaco)	Sem relatos	Cardiomiopatia, Arritmias ventriculares, QT longo (intervalo do batimento), Morte súbita
Ossos, articulações e marcha	Lesões líticas focais (destruído) em ossos longos após puberdade	Marcha espástica (em tesoura)	Baixa estatura	Osteopenia (perda de cálcio), deformação metáfise distal, rigidez articular e instabilidade atlanto-axial (frouxidão ligamentar alar)
Complicações gastrointestinais	Sem relatos	Sem relatos	Megaesôfago funcional (obstáculo funcional representado pelo reto)	Estenose pilórica congênita (hipertrofia muscular do piloro)
Musculatura esquelética	Sem relatos	Sem relatos	Sem relatos	Miopatia congênita
Outras características	Face acromegalóide com aumento da mandíbula, mãos e pés	Teratozoospermia (grande porcentagem de espermatozoides em formato anormal)	Hipocalcemia secundária resistência à vitamina D	Início tardia da LC na infância

Fonte: Adaptada de PATNI, 2015.

2.1.2 Tratamento para amenizar os sintomas

A LGC não tem cura, mas quando diagnosticada previamente, o paciente tem uma qualidade de vida melhor. Segundo Rodriguez (2015), a Terapia de Reposição de Leptina (TRL) foi testada em pacientes com LGC e seu resultado foi tão relevante que em 2014, foi aprovada pela Food and Drug Administration (FDA) dos EUA.

A TRL é importante pois auxilia nas complicações metabólicas e hepáticas nos pacientes com lipodistrofia, assim como na diminuição da deposição ectópica de gordura no fígado e no músculo esquelético. Melhora anormalidades do metabolismo de glicose e lipídios, a sensibilidade à insulina aumenta, reduz o risco de aumento de uma doença hepática gordurosa (causada por não alcoolismo) e restaura o hormônio gonadotrofina. Observa-se que seu uso está aprovado para lipodistrofia generalizada não oriunda do HIV (RODRIGUEZ *et al.*, 2015).

Insulina, sulfonilureias, metformina e pioglitazona são usados para controlar a hiperglicemia, enquanto fibras e estatinas auxiliam para controlar a hipertrigliceridemia. A plasmaferese é usada para diminuir os níveis altos de triglicerídeos, que servem para controlar os tumores dolorosos e prevenir a pancreatite. Remédios são receitados para regular os níveis de triglicerídeos e colesterol. Cirurgias e procedimentos estéticos podem ser recomendadas para determinadas áreas do corpo (ALZU'BI *et al.*, 2020) (JUNQUEIRA *et al.*, 2023).

2.2 Inteligência Artificial

O termo “*Artificial Intelligence*” foi usado pela primeira vez em 1956 por McCarthy e estudado por pesquisadores como Marvin Minsky e Herbert Simon. A IA pode ser definida como a arte de criar máquinas que exercem funções que requerem inteligência quando operadas por pessoas, Kurzweil (1990). Para o psicólogo cognitivo Robert J. Sternberg, a IA seria a capacidade que os humanos têm de aprender com a experiência utilizando processos metacognitivos para desenvolver a aprendizagem e a capacidade de se ajustar ao meio. A IA é caracterizada como a capacidade de resolver problemas, aprender com o meio, apresentação de estruturas cognitivas e orientar metas (NAZAR *et al.*, 2021) (MEDEIROS, 2018). Seu desenvolvimento trouxe inúmeros benefícios para a nossa sociedade. Um de seus campos estudados é a Visão computacional, que busca o entendimento do sistema cognitivo-visual.

2.2.1 Benefícios da Inteligência Artificial

Alguns dos benefícios da IA podem ser observados nos trabalhos com sistemas computacionais envolvendo IOT, *Big Data*, *framework*, *wearables* e Aprendizado de Máquina. Através do sistema de IOT, um médico pode analisar uma imagem de raio-x e verificar o diagnóstico com grande precisão (DOURADO *et al.*, 2020) (NAZAR *et al.*, 2021) (SILVA *et al.*, 2022).

Dourado (2020), menciona que o uso do IOT juntamente com outros softwares auxiliam vários pacientes no monitoramento de diversas adversidades, como por exemplo detecção e classificação de Acidente Vascular Cerebral (AVC). Mas não só pacientes com AVC, auxiliam pessoas com diabetes através de seu monitoramento, ou o processamento de imagens para identificar câncer de pele através de imagens fotográficas, além de aumentar o banco de dados, pois estará sempre apresentado imagens e dados novos, auxilia nos diagnósticos (KHAN *et al.*, 2021).

De acordo com Nazar (2021) os algoritmos mais utilizados para desenvolvimento de resultados médicos nos últimos tempos foram Support Vector Machine (SVM) e Redes Neurais. As características de entrada dos pacientes geralmente são a idade, sexo, histórico de doenças, diagnósticos por imagem, exames clínicos e físicos, codificação genética, sintomas clínicos e medicamentos sendo tomados.

A pesquisa utilizando imagens médicas para auxílio no diagnóstico tem sido am-


plamente utilizada com redes neurais convolucionais. E o uso de arquiteturas de aprendizagem profunda que substituem a camada convolucional tradicional por camadas mais conectadas e de menor custo computacional, como a MobileNetV2, tem sido amplamente explorada. Assim como no uso de redes pré-treinadas utilizando *ImageNet*, como VGG19 e RESNET50, que foram treinadas em um conjunto de dados com pesos e vieses que utilizam os recursos aprendidos, transferindo para os novos banco de dados (KSHATRI; SINGH, 2023).

2.2.2 Visão Computacional

O sistema cognitivo-visual desperta o interesse dos pesquisadores na área de Visão Computacional (CV), pois o sistema neural humano é muito complexo e completo. Seu estudo busca pesquisar novas ferramentas e recursos combinando técnicas locais e globais para detectar novos padrões e novas inovações de processamento para obtenção de um melhor processamento dos algoritmos.

Atualmente as imagens são normalmente adquiridas diretamente por câmeras digitais que capturam e armazenam uma imagem de uma cena em termos de um conjunto de números ordenados chamados pixels. Sua representação pode ser observada na Figura 2 (VENKATESAN; LI, 2017).

Figura 2 – Imagem capturada pela câmera com amostragem e quantização.



Fonte: Adaptado do livro *Convolutional Neural Network*, 2023.

Após a captura, este campo da IA, utiliza de técnicas para melhorar a qualidade das imagens para que fiquem mais atraentes para o olho humano e para auxiliar a máquina para obter um resultado melhor na classificação das imagens para diagnóstico ou segmentação para detectar e isolar lesões, por exemplo. Para obter um processamento melhor, algumas técnicas foram implementadas, como os algoritmos de melhoramento de imagens: Improved adaptive gamma correction weight distribution (IAGCWD), Equalização de histograma (HE), Equalização de histograma dinâmico (DHE), *Fusion expouse*. Para uma experimentação utilizou-se a retirada de *background* das imagens. Após isto, serão apresentadas as métricas de qualidade das imagens para verificar as diferenças e resultados entre elas; analisando os erros, diferença de brilho,

diferença de gradiente médio, ruído e processamento entre duas imagens.

2.2.2.1 Técnicas de Aprimoramento de Imagens

O **Gamma Correction** é uma adaptação não linear ao qual todo e qualquer valor de pixel é submetido. É também responsável por realizar métodos nos pixels de entrada (não-lineares) e remodelar a saturação da imagem aplicada (CAO *et al.*, 2018). Esta aplicação tem um bom efeito em regiões de baixo contraste. Observando a Equação 2.1, onde a função densidade de probabilidade P_m é definida; tem-se P_{max} e P_{min} que representam os valores máximos e mínimos de $P[V_{x,y}]$.

$$P_m[V_{x,y}] = P_{max} \left\{ \frac{P[V_{x,y}] - P_{min}}{P_{max} - P_{min}} \right\} \quad (2.1)$$

O parâmetro $V_{x,y}^{ACGWD}$ pode ser analisada na Equação 2.2. Onde V_{max} representa o valor máximo de $P[V_{x,y}]$. $C_m[V_{x,y}]$ é a função de distribuição cumulativa que se é encontrada através $P[V_{x,y}]$.

$$V_{x,y}^{ACGWD} = V_{max} \left(\frac{V_{x,y}}{V_{max}} \right)^{1-C_m[V_{x,y}]} \quad (2.2)$$


Na Figura 3 pode-se observar como o gráfico da imagem apresentando-se com a correção Gamma.

O **Histograma Equalizado** é utilizado para melhorar o contraste da imagem. Alguns métodos podem ser utilizados como alongamento de contraste, baixo contraste e limitação de contraste. O histograma de equalização é uma técnica que estrutura os níveis de cinza de uma imagem e como resultado alonga a faixa dinâmica da imagem e aumenta o contraste da imagem. Sua aplicação ocorre em vários campos, como processamento de imagens médicas e processamento de imagem de sonar. Através da Equação 2.3, pode-se observar sua aplicação. Na equação temos: E , denota expectativa ou média estática; Y , imagem de saída e X_G , é a média da escala cinza (CHEN; Rahman Ramli, 2004), (MUSTAFA; KADER, 2018).

$$E(Y) = X_G = \frac{1}{2}(X_0 + X_L - 1) \quad (2.3)$$

Como se pode observar na Figura 4, há 4 tipos de gráficos de histograma e após o uso do algoritmo, o resultado esperado é uma imagem com um histograma uniforme (CAO *et*


Figura 3 – Gráfico Gamma; à esquerda imagem sem o processamento e à direita com o processamento.



Fonte: Autora, 2023.

al., 2018). O que se pode observar nessa imagem, é o comportamento do gráfico ao se aplicar diferentes intensidades de contrastes e o histograma equalizado.

Figura 4 – Histogramas formados após processamento da imagem: (1) baixo contraste, (2) alongamento de contraste, (3) histograma equalizado, (4) Histograma adaptativo.




Fonte: Autora, 2023.

O **Histograma Dinâmico Equalizado** utiliza-se da operação de particionamento sobre o histograma da entrada da imagem para transformá-lo em vários sub-histogramas para que nenhum deles tenha um valor dominante entre todos gerados. Cada um desses sub-histogramas passará por uma equalização de histograma para que se possa ocupar um intervalo de nível de cinza especificado aprimorado na imagem de saída. Este processo pode ser observado na

Figura 5 à esquerda, que foi ampliado para melhor observação. Desta forma, um contraste aprimorado geral se é obtido com um nível controlado dinâmico de níveis de cinza, retirando assim a possibilidade dos componentes de um baixo histograma da foto causar uma imagem desbotada (ABDULLAH-AL-WADUD *et al.*, 2007).

Figura 5 – Gráfico à esquerda ampliado do histograma e à direita o particionamento dos histogramas.



Fonte: Autora, 2023 e Abdullah-Al-Wadud *et al.*, 2007.

O histograma dinâmico divide o histograma com base em mínimos locais. Primeiramente aplica um filtro unidimensional 3×1 para suavizar, para eliminar os mínimos insignificantes e depois faz a partição, que são os sub-histogramas que cairá entre dois mínimos locais, como pode-se observar na Figura 5 à direita.

Continuando a análise, na Figura 5 (a), foram aplicados os particionamentos; na parte (b), os mínimos foram determinados, e para verificar se qualquer parte possa ser dominante, μ foi encontrado, que é média e σ que é o desvio padrão, das devidas frequências de cada sub-histograma. Se os níveis de cinza dentro da faixa $(\mu + \sigma)$ e $(\mu - \sigma)$ do sub-histograma analisado, ficarem acima de 68,3%, este será considerado distribuição normal de frequência. Mas se a faixa ficar abaixo 68,3%, será considerado como porção dominante.

Neste caso, o DHE divide esse sub-histograma em três menores sub-histogramas, e particiona novamente em três níveis de cinza, sendo que a primeira e terceira seção passa pelo teste de dominação e o do meio é considerado livre de dominação. Estas operações alivia as baixas de frequências quando o HE for aplicado (ABDULLAH-AL-WADUD *et al.*, 2007).

Os níveis de cinza de um sub-histograma é calculado através das Equações 2.4 e 2.5. Onde $span_i$ é o intervalo de nível de cinza dinâmico usado no i da entrada da imagem; m_i

é i -ésimo mínimo local do histograma da imagem de entrada e $range_i$ é intervalo de nível de cinza dinâmico para o i do sub-histograma da imagem de saída (ABDULLAH-AL-WADUD *et al.*, 2007).

$$span_i = m_i - m_{i-1} \quad (2.4)$$

$$range_i = \frac{span_i}{\sum span_i} * (L - 1) \quad (2.5)$$

Os níveis de cinza alocados podem ser observados na Figura 5 à direita letra (c). Esses níveis dos sub-histogramas de saída são os mesmos de entrada. O objetivo é uniformizar os valores de pixel na faixa de nível de cinza dinâmico e obter uma imagem de saída com histograma linear cumulativo (ABDULLAH-AL-WADUD *et al.*, 2007).

O **Método de Fusão** tem por objetivo equilibrar todos os pixels da imagem. Isso ocorre porque quando uma câmara fotográfica é usada, não é possível obter um alcance dinâmico na sua totalidade, o alcance é limitado. Então para se obter esse equilíbrio de pixels, é utilizada a imagem que se deseja, juntamente com o conjunto de exposição, o mapa de peso da i -ésima imagem e o índice dos três canais de cor. Após esse processo, o peso é normalizado. A imagem fundida é obtida através da Equação 2.6; onde **R** é o resultado melhorado, **W** é mapa de pesos, **P** é o conjunto de exposição, **W** é a estimativa de pesos, g resposta da câmera e k razão de exposição (YING *et al.*, 2017).

$$R^c = W \circ P^c + (1 - W) \circ g(P^c, k) \quad (2.6)$$

Para se extrair o fundo das imagens, foi utilizada a página <www.removebg.com> (REMOVEBG, 2023).

2.2.2.2 Métricas de Qualidade

Root Mean Square Error (RMSE) O erro quadrado é uma métrica de qualidade que quantifica a magnitude média do erro entre os valores de duas imagens. É frequentemente usado para medir a diferença entre uma imagem original e uma nova imagem reconstruída ou processada. É usado na avaliação da qualidade da imagem, remoção de ruído, compactação

e outras tarefas de processamento. Fornece uma medida quantitativa da diferença entre duas imagens, com valores mais baixos indicando maior semelhança com a de referência (SILVA *et al.*, 2022). A Equação 2.7 é usada para representá-lo.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}}, \quad (2.7)$$

onde, P_i é a imagem original, O_i é o valor previsto da nova imagem, n é o número de dados e $\sum$ é o número total de valores.

Contrast-to-noise ratio (CRN) A relação contraste-ruído, que pode ser observada na Equação 2.8, é usada em imagens médicas para avaliar a qualidade e detectabilidade de características em uma imagem, onde é possível avaliar a visibilidade e detectabilidade de características, como tumores ou lesões, em imagens médicas (RODRIGUEZ-MOLARES *et al.*, 2019).

$$CNR = \frac{|\mu_i - \mu_o|}{\sqrt{\sigma_i^2 + \sigma_o^2}} \quad (2.8)$$

onde,

$$\sigma_i = E(|s_i|^2 - \mu_i)^2, \quad (2.9)$$

$$\sigma_o = E(|s_0|^2 - \mu_0)^2 \quad (2.10)$$

Absolute Mean Brightness Error (AMBE) Erro Absoluto de Brilho Médio é, simplificando, uma medida de preservação do brilho da imagem original, onde a preservação da imagem original está associada ao menor valor da Equação 2.11 (VIJAYALAKSHMI *et al.*, 2020).

$$AMBE = |I(y) - I(x)|, \quad (2.11)$$

onde, $I(x)$ é o brilho da imagem original e $I(y)$ é o brilho equilibrado da imagem processada.

Average Gradient (AG) O gradiente médio, exposto na Equação 2.12, mede a taxa de alteração dos valores dos pixels em uma imagem. Ele fornece informações sobre o nível geral

de detalhe e nitidez de uma imagem. Imagens com gradientes médios mais altos geralmente têm bordas e texturas mais evidenciadas (CUI *et al.*, 2015).

$$AG = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N \sqrt{\frac{(\frac{\partial f}{\partial x})^2 + (\frac{\partial f}{\partial y})^2}{2}}, \quad (2.12)$$

onde, M e N são a largura e a altura da imagem, $(\frac{\partial f}{\partial x})$ e $(\frac{\partial f}{\partial y})$ são os gradientes médios horizontais e verticais.

Peak Signal-to-Noise Ratio (PSNR) A relação sinal-ruído de pico, evidenciado na Equação 2.13, é uma métrica amplamente utilizada na área de processamento de imagens para quantificar a qualidade de uma imagem reconstruída ou processada em comparação com o original ou a de referência. É particularmente comum em tarefas como compactação de imagens, a remoção de ruído. Valores PSNR baixos indicam pior qualidade de imagem e altos indicam melhor qualidade de imagem (MIRZA *et al.*, 2023).

$$PSNR = 20 \log_{10} \left(\frac{MAX_f}{\sqrt{MSE}} \right), \quad (2.13)$$

onde, MAX_f é o valor máximo do sinal medido e $\sqrt{MSE}$ é o resultado da relação sinal-ruído.

Structural Similarity Index (SSIM) O índice de similaridade estrutural, observado na Equação 2.14, é uma métrica usada em processamento de imagens e visão computacional para avaliar a semelhança estrutural entre duas imagens. Ele foi projetado para medir a qualidade percebida ou semelhança entre uma imagem de referência e uma imagem distorcida ou processada. A métrica normalmente varia de 0 a 1, com mais próximo de 1 indicando melhor qualidade (JANA *et al.*, 2023).

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}, \quad (2.14)$$

onde, uma imagem $I(x, y)$ e μ_x é a luminância de x , μ_y é a luminância de y , σ_x é o contraste de x , σ_y é o contraste de y , c_1 e c_2 são as variáveis usadas para fazer a divisão se o divisor for 0.

2.3 Redes Neurais Convolucionais

A rede neural convolucional é amplamente utilizada para reconhecimento de padrões em imagens e é baseada no uso de camadas convolucionais. Uma característica da rede neural é o grande número de camadas que podem ser configuradas e utilizadas, sendo essas camadas compostas de vários números de neurônios ocultos, levando em conta que essas redes possuem diferentes tipos de camadas que podem ser combinadas, assim como, a variedade dos parâmetros e filtros (BENGIO, 2009).

A CNN gradualmente vai modificando o sinal de entrada, pois inicialmente detecta os sinais mais fáceis da entrada, para depois detectar sinais mais específicos que a rede deseja realmente investigar. Os filtros que serão utilizados são estabelecidos de acordo com a base de dados de treinamento e a estrutura geral da rede. Esta estrutura é formada por uma série de camadas consecutivas de convolução, Rectified Linear Unit (ReLU) que é a ativação, *pooling* ou variações; em um estágio chamado de extração de características e seguido por outro estágio que é a classificação (BENGIO, 2009).

A utilização da convolução é a aplicação do processamento de imagens, levando em conta a aplicação de diferentes filtros nos dados da imagem para retirar características precisas e necessárias, como por exemplo, detecção de bordas ou aumento da nitidez ou brilho. O maior esforço computacional de uma máquina ao processar uma CNN, são os cálculos das convoluções 2D. Por isso, o cálculo da convolução é feito em paralelo, realizando a respectiva soma das multiplicações (BENGIO, 2009). As camadas utilizadas nas redes usadas nesta pesquisa e suas devidas funções serão comentadas logo abaixo.

A **Camada pooling** faz um trabalho muito importante na rede. Os neurônios das camadas tem uma conectividade local e esparsa ao mesmo tempo. Isso quer dizer que cada neurônio aprende uma característica local ao qual ele está conectado e aprende um modelo que pode ser usado somente nesses locais. Isso permite estudar características que combinam valores locais adjacentes como por exemplo um tom de cor. E permite estudar características locais como gradientes, arestas ou bolhas. Se o neurônio conectado a uma localização de uma imagem, aprender a detectar um tom específico, o objetivo é que esse aprendizado seja útil em todos os locais da imagem e em qualquer outro lugar a ser analisado. Ao conectar esse neurônio em outras k entradas adjacentes, esse aprendizado irá deslizar pela rede e não será necessário novos pesos para cada conexão feita. Isso efetivamente nos permite mover o neurônio e coletar a resposta do neurônio em diferentes locais do sinal. Então os pesos sendo compartilhados por

neurônios em locais diferentes, observa a capacidade de reter a ideia original de um neurônio e sua conectividade esparsa. Isso mostra sua capacidade de conectar o início do sinal do começo da rede e deslizando esse sinal até o final, coletando a resposta do neurônio sobre cada localização do sinal, dada sua ordem aos arredores, chegamos ao cálculo da convolução (VENKATESAN; LI, 2017).

Uma **Camada Convolutacional 2D** é como uma camada convolutacional 1D, o que difere é que os pesos dos filtros são ordenados em duas dimensões. Cada neurônio pode começar em algum canto do sinal 2D. No caso das imagens, no canto superior esquerdo e avançar através da imagem em uma direção e terminar em um canto oposto, como o canto inferior direito. Cada entrada em si pode ser uma coleção de mapas de recursos ou canais de imagens. Ao convolver cada neurônio com cada mapa de características ou cada canal da entrada, as saídas de cada canal podem ser somadas em uma adição local, de modo que cada neurônio tenha uma saída média de resposta. A operação de convolução pode ser observada na Equação 2.15.

$$z^{(j)} = \sum_{i=1}^k x^{(j+i-1)} w_k, \forall j = [1, 2, \dots, d - k + 1] \quad (2.15)$$

Onde, $z^{(j)}$ é *output*, x é *input* de alguma camada, w são os pesos, k é o filtro, $(j + i - 1)$ é o comprimento da saída (VENKATESAN; LI, 2017).

A **Função Ativação** utilizada nas redes é Retificador ou Unidade linear retificadora ReLU. Esta função foi implementada pela primeira vez nos anos 2000 e retornou em 2010 (Hahnloser et al., 2000; Nair e Hinton, 2010). O retificador pode ser observado na Equação 2.16.

$$a_{ReLU}(t) = \max(0, t) \quad (2.16)$$


Sua forma analítica de uso pode ser analisado na Equação 2.17.

$$a'_{ReLU}(t) = \ln(1 + e^x) \quad (2.17)$$

A aplicação gráfica das equações pode ser observada na Figura 6, onde essa suavização do retificador é chamada de *softplus*. Na prática, a suavização auxilia nos problemas de sobreajuste.

A ativação da função *Softmax* é utilizada para fazer uma normalização na última camada do algoritmo, antes da classificação. Os vetores quando chegam a última camada ainda

Figura 6 – Função de ativação ReLU e a função ReLU na forma analítica.



Fonte: Venkatesan, 2017.

não foram normalizados, isto quer dizer que não são probabilidades. O *softmax* ativado na saída da camada pode ser observado na Equação 2.18 (VENKATESAN; LI, 2017).

$$P(y_i = j | x_i) = \sigma(l_1^{(j)}) = \frac{e^{l_1^{(j)}}}{\sum_{k=1}^c e^{l_1^{(k)}}}, j \in [1, 2, \dots, c] \quad (2.18)$$

A **Normalização** envolve variar os valores das imagens em $(-0,5; 0,5)$ com uma média de 0. Numa rede de aprendizagem profunda, a distribuição da entrada de cada camada varia por lote e amostra, porque os parâmetros mudam durante cada atualização. Como as amostras diferem em suas propriedades estatísticas entre lotes de dados, até mesmo entre a mesma classe, há a necessidade de normalizar as ativações da saída de cada camada. A normalização em lote pode ser observada na Equação 2.19.

$$Z_{bn} = \frac{Z - \mu_z * \alpha_z}{\sigma_z} \quad (2.19)$$

Onde z são as ativações, μ_z é a média e σ_z a variância do lote a ser processado e α_z os parâmetros. A normalização auxilia a rede a aprender mais rápido, sendo seu uso amplamente utilizado (VENKATESAN; LI, 2017).

Após verificar o funcionamento das camadas e suas funções, segue-se para apresentação das redes neurais convolucionais implementadas nesta pesquisa.

2.3.1 Rede de Identificação de Imagens

Esta rede neural convolucional, IINET, foi montada baseada no livro *Neural Networks with R: Smart models using CNN, RNN, deep learning, and artificial intelligence principles, 2017*. Após montar uma rede base, composta de camadas de convoluções seguida de camadas

Maxpooling, foi-se adaptando os parâmetros e pesos para obter um resultado que fosse considerado apropriado. Primeiramente foi realizada a normalização dos dados e logo depois as imagens foram redimensionadas.

Seu diferencial foi acrescentar a camada *Flatten*, que é responsável por transformar os dados em um vetor unidimensional. Após ela tem a camada Densa com ativação de 1024 neurônios, outra camada Densa com 528 neurônios e por fim, outra camada Densa com 2 neurônios com ativação *softmax*, que é a quantidade de classes propostas no problema. Após a rede realizar o treinamento com 80% das amostras, 20% das amostras foram utilizadas para realizar os testes (CIABURRO; VENKATESWARAN, 2017).

2.3.2 MobileNetV2

MobileNet são arquiteturas neurais desenvolvidas especificamente para redes móveis e aplicações de visão incorporada. Uma característica importante das redes é que elas usam uma camada de convolução separável em profundidade. O resultado do uso dessas técnicas é uma redução drástica no número de parâmetros e no custo computacional em comparação com camadas convolucionais padrão. As convoluções padrão tem uma tendência a produzir muitos parâmetros, que podem aumentar a medida que a rede se torna mais profunda. E isto leva a dois problemas: *overfitting* e muitos parâmetros, aumentando o custo computacional. Para calcular o custo computacional, pode-se considerar a seguinte Equação 2.20 (HOWARD *et al.*, 2017).

$$(D_k \times D_k \times M) \times (D_f \times D_f) \times N = (D_k^2 \times D_f^2 \times M \times N), \quad (2.20)$$

onde, D_f é o tamanho do mapa de recursos de entrada; D_k é o tamanho do *kernel*; M são os canais do mapa de recursos de entrada e N é a saída dos canais.

Uma convolução separável em profundidade, pode ser realizada em duas operações mais simples; a primeira uma convolução *wise* e a outra uma convolução pontual. Com isso a filtragem e a combinação ocorrem em duas etapas. Isso faz com que o números de parâmetros e os cálculos reduzem melhorando o desempenho do modelo. E essa separação é conhecida como convolução separável e *depthwise* (HOWARD *et al.*, 2017).

Os parâmetros adicionados nesta rede são α e o ρ . Sua operação pode ser observada na Equação 2.21. Onde definindo um valor maior para α e o ρ , observa-se menos canais e mapa de recursos menores, sendo possível adequar a rede quanto ao custo computacional e

desempenho (HOWARD *et al.*, 2017).

$$(D_k \times D_k \times \alpha M \times \rho D_f \times \rho D_f) + (\alpha M \times \alpha N \times \rho D_f \times \rho D_f) \quad (2.21)$$

2.3.3 ResNet50

A Rede Neural Residual é uma variação da arquitetura ResNet com 50 camadas profundas treinada em pelo menos um milhão de imagens do banco de dados *ImageNet*. A ResNet obteve grandes avanços na classificação de imagens. A rede convolucional aprende as características profundas das imagens acrescentando o número de camadas convolucionais e camadas de *pooling*, mas com este acréscimo apareceram problemas como a degradação da rede e desaparecimento do gradiente. Isso fez com que a velocidade de convergência ficasse mais lenta e o desempenho da rede reduzir (ZHOU *et al.*, 2023).

Para melhorar este problema, HE Kaiming em 2016, desenvolveu a rede RESNET50, que aperfeiçoa a capacidade de extração de métodos realizando a fusão de camadas cruzadas e melhora o desempenho quando aprofunda gradualmente a rede. Então uma camada residual foi proposta para reprogramar cada camada de entrada. O conceito residual consiste entre a diferença do valor de observação real e do valor estimado. Cada camada residual será adicionada de acordo com a necessidade de cada projeto (HE *et al.*, 2016). A função residual pode ser observada na Equação 2.22.

$$F(x_l, w_l) = H(x) - x, \quad (2.22)$$

onde $F(x_l, w_l)$ é a função residual, $H(x)$ é o mapa de identificação e x é o mapa de entrada sobre o bloco SE - *Squeeze-and-Excitation*.

2.3.4 VGG19

Desenvolvida por *Visual Geometry Group* pela Univesidade de Oxford, a VGG19 é um modelo CNN baseada na VGG16 pré-treinada. A rede possui 19 camadas profundamente conectadas. O modelo é composto de camadas convolucionais totalmente conectadas que possibilitam uma melhor extração de recursos. Experimentos feitos com a rede, chegou-se a conclusão que para obter melhores resultados de classificação é necessário aumentar a profundidade da

rede. Outro aspecto é a camada convolucional, que capta mais informações espectrais-espaciais (Victor Ikechukwu *et al.*, 2021).

Sua arquitetura é caracterizada pelo processamento da imagem por várias camadas convolucionais, que utilizam filtros 3×3 . Há também camadas com filtros de convolução com filtros 1×1 , que são uma transformação linear dos canais de entrada seguido de uma camada não linear. O passo de convolução é fixado em 1 pixel. Por isso a resolução espacial é preservada. Este agrupamento espacial é aplicado por cinco camadas *Maxpooling* que tem 2×2 pixels com passo 2, a camada reduz a resolução da classificação anterior usando a função de ativação *softmax*. As três camadas totalmente conectadas tem as duas primeiras camadas com 4096 canais e a última contém 1000 canais. Utilizando a *ImageNet* é possível extrair pesos e treinamento para utilizar em novo modelo otimizando o tempo de treinamento e custo computacional (SIMONYAN; ZISSERMAN, 2014) .

2.4 Data Augmentation

Como o conjunto de dados é limitado, fez-se o uso da técnica *data augmentation* para aumento do número das imagens. Nesse trabalho foram utilizadas as seguintes camadas:

- *RandomFlip* que gira as imagens aleatoriamente verticalmente e horizontalmente. Esta é uma das estratégias mais utilizadas para aumentar o tamanho ou a diversidade de dados. Mas deve ser observado ao uso de dados que têm propriedades exclusivas.
- *RandomRotation* essa técnica gira as imagens aleatoriamente e pode ser determinada os valores da angulação. As imagens criadas são utilizadas ao lado das originais como amostra de treinamento. Sua desvantagem é a perda de informações no limite da imagem.
- *RandomContrast* que ajusta aleatoriamente o contraste das imagens. Isto é possível porque há uma troca dos valores dos pixels da posição em que se encontrava.
- *RandomZoom* amplia ou reduz aleatoriamente o eixo das imagens (ALOMAR *et al.*, 2023).

Uma característica do uso da técnica *data augmentation* também é que pode ser usada para melhorar a diversidade dos dados. O uso da técnica tem auxiliado nas classificações de imagens na área médica como o uso de inversões horizontais e verticais, rotação, deslocamento, zoom, cisalhamento e alteração de brilho, para classificação de imagens de câncer de cérebro utilizando uma rede ResNet (ISMAEL *et al.*, 2020).

2.5 Transfer Learning

O *Transfer Learning* tem por objetivo melhorar o desempenho do novo sistema proposto, pois utiliza-se de tarefas aprendidas e conjunto de dados anteriormente. Além de transferir os dados aprendidos na *ImageNet*, o período de treinamento e o custo computacional diminui. A *ImageNet* é um banco de dados de estimados 3 bilhões de fotos no *flickr*, quantidade semelhante de vídeos clipes no *YouTube* e uma quantidade maior de imagens no banco de dados da *Google* (KIM *et al.*, 2022) (DENG *et al.*, 2009).

Uma rede neural não treinada utiliza peso inicial aleatório, e durante o processo, esses pesos vão se ajustando aos valores rotulados até otimizarem o algoritmo. Este processamento leva um período de tempo grande. No trabalho de Yosinski, 2014; foi provado que iniciar uma rede treinada como pesos já estabelecidos, mesmo com um conjunto de dados diferente do problema proposto, melhora o desempenho da rede em comparação com a iniciação aleatória (YOSINSKI *et al.*, 2014).

Um exemplo do uso do *transfer learning*, foi no início da pandemia COVID-19, que precisava de muitos dados de raio-x de tórax para treinar um modelo de aprendizado. Utilizando a técnica, a IA conseguiu detectar a doença com precisão satisfatória utilizando um conjunto de dados limitado. Outra aplicação do aprendizado por transferência é a utilização de redes móveis, celulares. A transferência reduz a necessidade de poder de processamento e de treinamento limitado (IMAN *et al.*, 2023).

2.6 Otimizador Adam

Os processos matemáticos na fase de treinamento envolvem alterar os pesos da maneira certa para atingir o objetivo de minimizar os erros. Esse processo de alteração, dependente dos pesos que estão sendo manipulados, são as técnicas de otimização baseadas em gradientes. O gradiente de uma função em relação a um de seus componentes é a taxa na qual a função muda com uma pequena mudança desse componente. Simplificando, o gradiente mede a curvatura ou a inclinação da função em um ponto e o mínimo está no ponto de inclinação zero. Logo, o gradiente descendente é um algoritmo de aprendizagem iterativo. Equacionado, se em alguma iteração τ , estiver na localização w^τ , os pesos podem ser alterados ou atualizados conforme a Equação 2.23.

$$w^{\tau+1} = w^{\tau} - \eta^{\tau} e'(w^{\tau}) \quad (2.23)$$

O otimizador Adam além de ser bom no manejo de problemas com grandes quantidades de dados e/ou parâmetros, objetivos não estacionários e gradientes ruidosos e/ou esparsos, também possuiu hiperparâmetros que normalmente requer poucos ajustes (SANTOS *et al.*, 2023) (VENKATESAN; LI, 2017).

2.7 Revisão da Literatura

As Doenças Raras (DR) elevam muito os custos na área de saúde. E isso ocorre por causa da demora no diagnóstico e as consequências degenerativas que agravam a saúde dos pacientes. Atualmente, para reduzir os custos e acelerar a assistência aos pacientes, novas ferramentas tem sido apresentadas, como técnicas avançadas de imagem, estudo da ciência multiômica, caracterização molecular de doenças e muitas outras que apresentam uma fonte imensa de informações. O aprendizado de máquinas utiliza esses dados através de conjunto de dados, para realizar previsões em geral, utilizando algoritmos específicos. A maior limitação dos algoritmos para aplicações em DR, é o número limitado de dados. Para ampliar esses dados não rotulados, utiliza-se *transfer learning* para ajustar o modelo. Para que este modelo possa ser interpretado, recorre-se a modelos menos complexos como modelos lineares e não lineares baseados em regras como árvores de decisões ou redes neurais (J *et al.*, 2023).

Um trabalho semelhante a esta dissertação foi de Pezo et al., 2020. A partir de imagens fotográficas, apresentou-se um sistema para detecção de doenças de pele. Redes neurais convolucionais como; Inception V3, VGG16 e ResNet50, foram implementadas para classificar dois tipos de manifestações de doença dermatológicas: impetigo e psoríase. Como sua manifestação tem sinais morfológicos, distribuição e disposição da lesão no corpo, cor, descamação, e entre outros sinais; é possível determinar se a lesão é psoríase ou não através de imagens. Foram utilizadas 102 imagens de impetigo e 126 imagens de psoríase, totalizando 228 imagens. Utilizou-se da técnica de *data augmentation* para aumento do banco de dados e os melhores resultados foram obtidos com 10 épocas. O melhor desempenho foi da rede Inception V3, com resultados satisfatórios (PEZO *et al.*, 2020).

As síndromes genéticas, afetam 8% da população, considerando todas suas manifestações. Muitas dessas síndromes apresentam características faciais reconhecíveis que são

consideradas importantes para os geneticistas clínicos. Estudos atuais mostram que o avanço das tecnologias de análise facial podem auxiliar os profissionais especialistas a identificar algumas síndromes. Pensando nessa problemática, um sistema de análise de imagens faciais foi apresentado, DeepGestalt. Este sistema, usando Visão Computacional e aprendizagem profunda, quantifica semelhanças com várias síndromes. Interessante que a DeepGestalt superou os especialistas em três experimentos iniciais. Quando realizado o experimento final, que foi um caso real de ambiente clínico, a DeepGestalt alcançou 91% de precisão da acurácia na identificação correta dos 10 primeiros casos analisados de síndromes corretas em 502 imagens diferentes. O modelo foi treinado com um conjunto de dados de mais de 17.000 imagens representando mais de 200 síndromes, com curadoria de uma plataforma de fenotipagem dirigida pela comunidade médica. A DeepGestalt alcançou um valor considerável às avaliações fenóticas em genética clínica, testes genéticos, pesquisa e medicina de precisão (GUROVICH *et al.*, 2019).

Em seu estudo, Pedro Landim (2021), iniciou o estudo de imagens de pacientes com LGC e pessoas sem a doença utilizando a IA como ferramenta para a identificação de cada classe, utilizando uma rede neural convolucional, CNN. Na elaboração das camadas da CNN, foram utilizadas 2 camadas de convolução com 1024 neurônios por camada, uma taxa de aprendizagem de 0.001 e função de ativação (ReLU). Utilizou-se também a técnica de *Data Augmentation* para ampliar o banco de dados. Conseguiu obter uma acurácia de 63% e uma taxa de acerto de 62,9% (LANDIN, 2021).

Continuando o estudo iniciado por Landim, foram implementados outros algoritmos de aprendizado de máquina supervisionado para avaliar os resultados de identificação do conjunto de dados. Foram implementados os classificadores K-Nearest Neighbors (KNN), Ordinary Least Squares (OLS) e Classificador Quadrático (CQ) que obtiveram resultados acima de 70% e a CNN que obteve 92,46% de acurácia. A rede neural convolucional demonstrou ser a melhor rede para esse tipo de classificação. Nesta CNN foram utilizadas uma camada escondida com 2048 neurônios, taxa de aprendizagem de 0.01. A camada de convolução foi seguida de uma camada de *Maxpooling* que faz a abordagem *Kernel*. Para avaliar resultados utilizou-se de características de performance como acurácia, sensibilidade e especificidade (CASTILHOS, 2021). Através da Tabela 17, é possível observar a evolução do trabalho até o presente momento.

Neste artigo de 2023, os autores criaram um banco de dados de 337 imagens de indivíduos de diferentes idades, sendo composto por três subcategorias: imagens com pacientes que tem a LGC, pessoas com desnutrição e pessoas eutróficas com constituição atlética. As


imagens dos pacientes foram cedidas e autorizado o uso pelo comitê de ética da Universidade Federal do Ceará (UFC) e as outras imagens foram retiradas da internet de um acesso aberto. Um modelo de aprendizagem profunda usando uma rede neural convolucional foi apresentada para avaliar a eficácia da classificação das imagens. Como a doença apresenta características fenóticas, é possível identifica-las através das imagens fotográficas. Para verificar os resultados foi aplicada a técnica de validação cruzada quádrupla, utilizando 75% dos dados no treinamento e 25% nos testes. Como resultado, obteve médias de precisão, sensibilidade e especificidade com valores de $90,85\% \pm 2,20\%$, $90,63\% \pm 3,53\%$ e $91,41\% \pm 1,10\%$, respectivamente. O estudo apresentou pela primeira vez um modelo de aprendizagem profunda capaz de identificar características fenóticas da lipodistrofia generalizada congênita com excelente precisão, sensibilidade e especificidade, podendo ser uma ferramenta estratégica para auxiliar na detecção desta doença (OLEGARIO *et al.*, 2023).

3.1 Etapa 1: Aquisição do banco de dados

O conjunto de dados, foi composto por duas etapas. A primeira, referente apenas às imagens de 22 pacientes com LGC, que foram acompanhados no ambulatório de endocrinologia do Hospital Universitário Walter Cantídio (HUWC), no município de Fortaleza - CE. As imagens foram adquiridas com a UFC e aprovadas pelo Comitê de Ética em Pesquisa do HUWC, com parecer número 5.364.464. São 192 fotos com pacientes que tem a doença, arquivadas no formato Portable Network Graphics (PNG) de dimensões variadas; como 960×1280 e 4000×3000 . São quatorze tipos de dimensões diferentes e os mais diversos tamanhos.

A segunda etapa, se deu na escolha de imagens retiradas da *internet* de acesso aberto de pessoas que não possuem LGC. Essas imagens constituem 48 pessoas saudáveis, 16 pessoas de porte atlético, 15 pessoas com desnutrição e 10 pessoas acima do peso. Dessas fotos, 32 pessoas são mulheres, 26 são homens e 18 são crianças. Estão arquivadas no formato PNG e Joint Photographic Experts Group (JPG) com diversas dimensões e tamanhos também. No total são 101 fotos de pessoas sem a doença. Para não beneficiar nenhuma classe, as imagens escolhidas tem um padrão semelhante as imagens do banco de dados da UFC. Então optou-se em poses parecidas e cores do fundo com os mesmos tons de cores. As poses das fotos constam de seis poses básicas: rosto; abdômen; corpo de lado (esquerdo e direito); corpo de frente e corpo de costas. O conjunto de dados completo pode ser observado na Tabela 3. Na Figura 8 pode-se observar uma imagem de cada classe.

Figura 8 – Exemplo de cada classe, (a) Pessoa com LGC (b) Pessoa saudável.



Fonte: Autora, 2023.

Algumas observações devem ser consideradas sobre o conjunto de dados:

- a) No geral, as imagens não possuem padrão de qualidade e tamanho.
- b) Não há uma padronização no processo de captura das imagens pela câmera

Tabela 3 – Descrição do Banco de Dados (Autora, 2023)

Tipo	Resolução	Quantidade	Tipo	Resolução	Quantidade
CGL	960 × 1280	37	NCGL	917 × 906	1
CGL	2999 × 3999	55	NCGL	314 × 626	1
CGL	3000 × 4000	11	NCGL	633 × 633	1
CGL	2811 × 3749	1	NCGL	338 × 487	1
CGL	720 × 1280	3	NCGL	340 × 420	1
CGL	1224 × 1632	1	NCGL	276 × 280	1
CGL	1280 × 1280	4	NCGL	256 × 333	1
CGL	1802 × 2417	1	NCGL	394 × 443	1
CGL	3193 × 3553	1	NCGL	385 × 384	1
CGL	2666 × 3412	1	NCGL	340 × 506	1
CGL	2192 × 2802	1	NCGL	373 × 402	1
CGL	4000 × 3000	74	NCGL	335 × 331	1
CGL	1403 × 2268	1	NCGL	320 × 453	1
CGL	1280 × 960	1	NCGL	1000 × 1331	1
NCGL	197 × 551	1	NCGL	175 × 184	1
NCGL	200 × 320	1	NCGL	194 × 259	1
NCGL	211 × 569	1	NCGL	888 × 768	1
NCGL	314 × 524	1	NCGL	495 × 495	1
NCGL	480 × 867	1	NCGL	500 × 554	1
NCGL	293 × 704	1	NCGL	226 × 226	1
NCGL	293 × 704	1	NCGL	512 × 342	1
NCGL	286 × 731	1	NCGL	450 × 337	1
NCGL	540 × 373	1	NCGL	600 × 400	1
NCGL	291 × 313	1	NCGL	277 × 208	1
NCGL	196 × 575	1	NCGL	230 × 229	1
NCGL	199 × 567	1	NCGL	363 × 363	1
NCGL	279 × 645	1	NCGL	150 × 201	1
NCGL	485 × 921	1	NCGL	273 × 154	1
NCGL	363 × 894	1	NCGL	243 × 335	1
NCGL	195 × 571	1	NCGL	412 × 412	1
NCGL	194 × 571	1	NCGL	481 × 481	1
NCGL	194 × 570	1	NCGL	156 × 234	1
NCGL	338 × 600	1	NCGL	644 × 644	1
NCGL	421 × 420	1	NCGL	203 × 204	1
NCGL	800 × 1200	1	NCGL	340 × 582	1
NCGL	287 × 569	1	NCGL	350 × 577	1
NCGL	389 × 792	1	NCGL	322 × 424	1
NCGL	357 × 430	1	NCGL	233 × 201	1
NCGL	1200 × 1200	2	NCGL	700 × 900	1
NCGL	193 × 300	1	NCGL	551 × 551	1
NCGL	323 × 323	2	NCGL	303 × 405	1
NCGL	1000 × 1000	1	NCGL	640 × 640	1
NCGL	300 × 300	1	NCGL	780 × 1105	1
NCGL	683 × 1024	1	NCGL	600 × 829	1
NCGL	1000 × 1500	1	NCGL	214 × 235	1
NCGL	510 × 511	1	NCGL	544 × 544	1
NCGL	274 × 577	1	NCGL	1200 × 630	1
NCGL	626 × 824	1	NCGL	1024 × 1024	1
NCGL	412 × 412	1	NCGL	386 × 795	1
NCGL	388 × 786	1	NCGL	480 × 253	1
NCGL	814 × 720	1	NCGL	620 × 1240	1
NCGL	634 × 939	1	NCGL	502 × 767	1
NCGL	1200 × 480	1	NCGL	418 × 612	1
NCGL	612 × 405	1	NCGL	1277 × 1600	1
NCGL	400 × 463	1	NCGL	500 × 747	1
NCGL	363 × 783	1	NCGL	185 × 456	1
NCGL	320 × 544	1			

fotográfica.

- c) Há a presença de sujeitos de diferentes faixas etárias e gêneros: adultos; crianças bebês, tanto do sexo masculino, como do feminino.
- d) Não foi registrado no banco de dados dos pacientes com LGC, qual o subtipo da doença que eles tem.

3.2 Pré-processamento

As imagens foram coletadas de diferentes fontes, então se faz necessário redimensionar todas as imagens para o mesmo tamanho, de acordo com o permitido de cada biblioteca, como entrada dos modelos selecionados para essa pesquisa. As imagens foram redimensionadas para 50×50 para treinar e testar o modelo IINET, 75×75 para a rede RESNET50 e 200×200 para o MobileNetV2 e VGG19. Esses valores foram escolhidos porque a IINET teve um bom desempenho e bom custo computacional com esse valor. Já a rede RESNET50 foi escolhido automaticamente pela biblioteca *Keras*, que indicava o valor mínimo de 75×75 . Para a MobileNetV2 e VGG19, foi 200×200 porque obtiveram um resultado melhor.

Todas as imagens foram divididas por 255 para normalizar suas intensidades de pixels e colocadas em uma escala entre 0 e 1. A divisão por 255 é utilizada porque este é o maior valor de um pixel de uma imagem em escala de cinza ou Red, green, blue (RGB).

Utilizou-se da ferramenta *data augmentation*, para expandir o número de imagens. As camadas utilizadas podem ser verificadas nos Algoritmos 1 e 2.

Algoritmo 1: Data augmentation for IINET, Resnet50 and VGG19

Input: Imagens

Output: Variações de imagens

Data Augmentation **if** *Vamos_de_agumentation* **then**

for $j \leftarrow 1$ **do**

data_augmentation $\leftarrow$ tf.keras.Sequential();

data_augmentation.add(layers.RandomFlip('horizontal_and_vertical'));

data_augmentation.add(layers.RandomRotation(random.uniform(low=0.1, high=0.9)));

return *image augmentation*

end

end

Algoritmo 2: Data augmentation for MobilenetV2

Input: Imagens

Output: Variações de imagens

 Data Augmentation **if** *Vamos_de_augmentation* **then**

 for $j \leftarrow 1$ **do**

 data_augmentation $\leftarrow$ tf.keras.Sequential();

data_augmentation.add(layers.RandomFlip('horizontal'));

data_augmentation.add(layers.RandomContrast(0.5, 0.5));

data_augmentation.add(layers.RandomZoom(0.2, 0.3));


 data_augmentation.add(layers.RandomRotation(random.uniform(low=0.1,
high=0.9)));

return *image augmentation*
end
end

3.3 Etapa 2: Melhoramento das imagens

Neste banco de dados foi aplicado quatro algoritmos de melhoramento de imagens; o IAGCWD, HE, DHE, Método de fusão e o método de retirada do fundo das fotos. Na Figura 9 pode se observar todas as pastas do conjunto de dados que foram utilizados neste trabalho.

Figura 9 – Pastas criadas do banco de dados.



Fonte: Autora, 2023.


O algoritmo IAGCWD foi utilizado em 2 momentos. O primeiro momento foi quando rodou com todas as fotos com os pacientes que tem LGC e o segundo com as fotos de

peessoas sem a condição. Assim foi realizado também para os algoritmos HE, DHE e *Ying*.

Para retirada do fundo das imagens, cada imagem foi carregada manualmente no site e após ser processada, foi recortada para ser utilizada. Cada foto levou em torno de 5 segundos para retirar o fundo e mais 15 segundos para recortar e salvar a nova imagem.

Após ter formado essas 5 pastas (HE, DHE, YING, Gamma e Removel); fez-se as combinações entre os algoritmos formando as 13 pastas para aplicar nas redes neurais. O resultado de cada aplicação pode ser observada na Figura 10.

Figura 10 – Aplicação dos algoritmos de Melhoramento. (a)Original, (b)DHE, (c)HE, (d)*Ying*, (e)Gamma correction, (f)Removel background, (g)Removel+DHE, (h)Removel+He, (i)Removel+Ying, (j)Removel+Gamma, (k)Gamma+DHE, (l)Gamma+HE, (m)Gamma+Ying.




Fonte: Autora, 2023.

Quando o algoritmo Gamma foi utilizado, as imagens tratadas foram encaminhadas para uma pasta dentro do próprio algoritmo instalado, prontas para uso, não sendo necessário fazer mais nenhuma alteração. O mesmo ocorreu com as imagens sem fundo, quando foram

aplicadas neste algoritmo. Nos outros algoritmos utilizados, HE, DHE, *Ying* e combinações, as imagens tratadas estavam no formato PNG e no formato de gráfico, como na Figura 11, sendo necessário recortar todas imagens tratadas.

Figura 11 – Imagem no formato PNG, que necessita ser cortada.



Fonte: Autora, 2023.

Como o conjunto de dados não estava em formato padrão, foi observado que o custo computacional estava variando muito dependendo da imagem utilizada nos algoritmos de tratamento. E como o objetivo da pesquisa é auxiliar no diagnóstico mais rápido, decidiu-se mudar o formato das imagens que estavam em PNG para o formato JPG e testar nos códigos mais lentos. Na combinação HE+Removel, foi observado que as fotos no formato PNG, estavam levando em média 30 minutos por imagem, principalmente as imagens com dimensões maiores. Ao mudar o formato para JPG, o tempo diminuiu consideravelmente, levando em média 20,083 segundos por imagem.

Ao se aplicar as imagens ao algoritmo DHE+Removel, as imagens já foram modificadas para o formato JPG, levando em média 38,779 segundos por imagem. O algoritmo *Expouse fusion* foi o que despendeu mais tempo para sua aplicação. Exemplo disto, é a foto "LGC corpolado 5.png", que levou 36,763 minutos para apresentar o resultado final. Já a imagem "LGC nova 10.png" demorou 58,761 minutos. Um exemplo da mudança do formato, é a foto "LGC14.png", de dimensões 2999×3999 e tamanho 1,65MB, que ao ser rodada no *Ying*, foi processada em 44,8 minutos. Ao ser processada no formato JPG, finalizou em 36,61 minutos.

Então observou-se, que quanto maior a imagem, mais demorado era o processo. Para otimizar o tempo, a partir da foto "LGC nova 20.jpg", foi aplicado a ferramenta de interpolação; disponível no software do próprio computador, para reduzir as dimensões das fotos que eram 4000×3000 para 1687×3000 , como teste. Além de diminuir as dimensões, esta ferramenta

diminuiu o tamanho, que era 2,55MB para 17,2KB. Foi verificado que o custo computacional reduziu pela metade, gastando 31,38 minutos por imagem neste formato. Foi observado também que ao diminuir as dimensões, as fotos perderam qualidade, apresentando aspecto quadriculado. Um exemplo disso pode ser observado na Figura 12, que passou do tamanho original 4000×3000 para 277×366 . Nesse formato de imagem, JPG, é caracterizada por ter operações mais simples e levar menos tempo ao ser processado.

Figura 12 – Aspecto da imagem após ser modificada do formato PNG para JPG.



Fonte: Autora, 2023.


3.4 Etapa 3: Técnicas de Extração

Terminado a etapa das aplicações de melhoramento de imagens, todas as pastas criadas (12 no total e a original), foram rodadas nas redes neurais convolucionais. Na rede IINET, as imagens passam por 3 convoluções diferentes seguidas por 3 camadas de *Maxpooling*. A primeira camada de convolução tem a entrada $50 \times 50 \times 3$ com ativação propagando para a camada *Maxpooling* de *stride* igual a 2. A segunda convolução tem entrada de $64 \times 64 \times 3$ com ativação propagando para a camada *Maxpooling* de *stride* igual a 2 e a terceira convolução tem como entrada $128 \times 128 \times 3$ com ativação propagando para a camada *Maxpooling* de *stride* igual a 2. Segue para a camada *Flatten* que apresenta a saída (0, 2048), para passar por três camadas densas, com 1024 neurônios a primeira e ativação, 528 neurônios e ativação a segunda e 2 neurônios a última. As ativações desta rede foram ReLU.

Na Figura 13, pode-se observar as camadas que foram utilizadas no algoritmo IINET. Este algoritmo utilizou de 10 épocas, com um número máximo de rodadas com valor de 50, com uma taxa de aprendizado 0.001 e utilizando a ferramenta *early stopping*. Após o embaralhamento, 80% dos dados segue para o treino e 20% para o teste. Foi utilizado o otimizador *Adam*.

Na MobileNetV2, que pode ser observada na Figura 14. Nesta rede, foi utilizada a rede padrão apresentada pelo modelo. Com a primeira camada de entrada $200 \times 200 \times 3$,


Figura 13 – Arquitetura da IINET.



Fonte: Modificado pela autora, <https://github.com/ashishpatel26/Tools-to-Design-or-Visualize-Architecture-of-Neural-Network>, 2023.

passou-se para a camada *data augmentation*, seguida pelas camadas padrão da rede (modelo base), seguindo para a camada totalmente conectada de 64, para seguir para camada *dropout* de 0,5, para evitar o *overfitting*, seguindo por fim para propagar para a camada densa com 2 neurônios e ativação *Softmax*. Neste modelo foi utilizado os vieses da *transfer learning*. Foi rodada com 50 épocas, pois obteve um resultado melhor. A taxa de aprendizado utilizada foi de 0.01 e utilizou o otimizador *Adam* para métricas.

Figura 14 – Arquitetura da MobileNetV2.




Fonte: Modificado pela autora, <https://github.com/ashishpatel26/Tools-to-Design-or-Visualize-Architecture-of-Neural-Network>, 2023.

Na RESNET50, as suas camadas definidas podem ser observadas na Figura 15.

Sua arquitetura é composta pela camada base, que faz parte de sua aplicação, seguindo para as camadas que foram acrescentadas em busca de um resultado satisfatório. Segue-se 7 camadas composta pelo conjunto de uma camada convolucional mais uma uma camada de normalização e mais uma camada de ativação ReLU. Os filtros utilizados foram 8, 16, 32, 64, 128, 256 e 512, com *kernel* 3×3 . Após as camadas convolucionais, acrescentou uma camada *dropout* de 0,2, seguindo para uma camada *Maxpooling* de tamanho 2×2 e *stride* 1. Acrescentou uma camada *Flatten*, seguindo para camada densa com 2 saídas. Foi rodada com 10 épocas e

Figura 15 – Arquitetura da Resnet50, sendo 1- camada base, camada 1 a 7 formadas por: convolução2D+Normalização+Ativação, 8- dropout, 9- Maxpooling, 10- flatten e 11- Convolução densa.




Fonte: Modificado pela autora, <https://github.com/ashishpatel26/Tools-to-Design-or-Visualize-Architecture-of-Neural-Network>, 2023.

usou a taxa de aprendizagem de 0,01 e o método *Adam* para as métricas.

Por último, foi rodada a rede VGG19 que também utilizou da técnica de *transfer learning*. Assim como na rede RESNET50, o valor mínimo para entrada da imagem é 75×75 . Mas com esta dimensão, não obteve um bom resultado. Então foi experimentado a mesma dimensão da rede MobileNetV2, de 200×200 . Sua arquitetura é formada pela primeira camada sendo a camada base que contém os parâmetros da arquitetura, seguindo para a camada *flatten*. Após essa camada foi acrescentado a camada *dropout* de 0,4. Depois 2 camadas profundas conectadas com filtros de 64 e 2, seguidas de uma camada de normalização. Foi rodada com 10 épocas, taxa de aprendizagem de 0.001 e método *Adam* para as métricas. Esta rede utilizou ativação ReLU e ativação *Softmax*. As camadas da rede VGG19 podem ser observadas na Figura 16. O pseudo-código dos modelos utilizados podem ser observados nos anexos.

Figura 16 – Arquitetura da VGG19.



Fonte: Modificado pela autora, <https://github.com/ashishpatel26/Tools-to-Design-or-Visualize-Architecture-of-Neural-Network>, 2023.

Para resumir os parâmetros resumidamente utilizados nas redes neurais convolucio-

nais, podem ser observados na Tabela 4 e na Tabela 5 para uma melhor análise.

Tabela 4 – Parâmetros utilizados nas Redes Neurais Convolucionais

Rede Neural	Redimensionamento	Épocas	MaxÉpoc.	Otimizador	Parada antec.	Transfer.
IINET	50×50	10	50	Adam	Sim	Não
MOBILENETV2	200×200	50	50	Adam	Sim	Sim
RESNET50	75×75	10	50	Adam	Sim	Sim
VGG19	200×200	10	30	Adam	Sim	sim

Fonte: Autora, 2023.

Tabela 5 – Comparativo entre as Redes Neurais Convolucionais

CNN	Filtros	Neurônios	Camadas Adicionais
IINET	50	1024	Flatten
MobileNetV2	200	1280	Dropout
RESNET50	75	2048	Flatten, Dropout e BatchNormalization
VGG19	200	18432	Flatten, Dropout e BatchNormalization

Fonte: Autora, 2023.

3.5 Etapa 4: Classificação

A **Matriz Confusão** é uma ferramenta essencial para avaliar o desempenho dos algoritmos implementados. Através dela se obtém as classes previstas e reais do conjunto de dados aplicado. A matriz consiste de quatro componentes:

- **VP**: Verdadeiro positivo.
- **VN**: Verdadeiro negativo.
- **FP**: Falso positivo.
- **FN**: Falso negativo.

A matriz confusão pode ser observada na Figura 17 (HEYDARIAN *et al.*, 2022).

Figura 17 – Matriz Confusão binária

		Classes Predição	
		Verdadeiro	Falso
Classes Verdadeiras	Falso	VP	FN
	Verdadeiro	FP	VN

Fonte: Autora, 2023.

Para uma análise dos resultados foram utilizadas algumas características de performance. A **acurácia** é a probabilidade do resultado fornecer dados corretos. Ela é a probabilidade dos verdadeiros positivos e verdadeiros negativos como uma proporção de todos os resultados. Definido como a Equação 3.1 (BARBOSA, 2021).

$$Acc = \frac{(VP + VN)}{(VP + VN + FP + FN)} \quad (3.1)$$

Outra característica de performance utilizado é o *F1score* 3.2, que utiliza métricas de precisão 3.3 e *recall* 3.4 para obter uma visão mais completa do desempenho do classificador (BARBOSA, 2021).

$$f_{1score} = 2 * \frac{precision * recall}{precision + recall} \quad (3.2)$$

A precisão fornece as medições positivas por meio da Equação 3.3 (MOHAN *et al.*, 2022).

$$precision = \frac{VP}{(VP + FP)} \quad (3.3)$$

Recall, também conhecido como sensibilidade ou taxa de verdadeiro positivo, mede a capacidade do modelo de identificar todas as instâncias relevantes da classe positiva. Esta taxa é expressa na Equação 3.4 (MOHAN *et al.*, 2022).

$$recall = \frac{VP}{(VP + FN)} \quad (3.4)$$

Outra ferramenta utilizada foi a curva **Receiver Operator characteristic Curve (ROC)**. Na década de 1970, Lee Lusted propôs a adoção da curva ROC como ferramenta para desempenho no diagnóstico em radiologia. A partir de então, pesquisadores passaram a utilizar a curva ROC como ferramenta de avaliação de classificação binária em diversas áreas, até se tornar a métrica mais utilizada em trabalhos científicos para classificação binária.

A curva ROC conecta os pontos de coordenadas usando especificidade (taxa de falso positivo) no eixo x e sensibilidade (Taxa de verdadeiro positivo) no eixo y. Resultados positivos

geram mais pontos para esquerda e resultados negativos geram mais pontos para direita e para cima. As vantagens do uso da curva ROC é a visualização geral entre as classes considerando toda a gama de resultados obtidos. Outra vantagem é que os dados não precisam ser representados como um histograma para desenhar a curva (SAHNGUN, 2022).

A AUC é amplamente utilizada para medir a acurácia das classes propostas no algoritmo. Quanto mais próxima a curva ROC estiver do canto superior esquerdo do gráfico, maior será a acurácia da classe positiva, pois é no canto superior esquerdo que a sensibilidade é igual a 1 e a taxa de falsos positivos é igual a 0. A curva ROC ideal tem, portanto, uma AUC igual a 1,0. O gráfico é desenhado na diagonal de 45° ($y = x$) da curva ROC onde $AUC = 0,5$. Essa situação não representa nenhuma classe e não tem significado como classificação. Para que a classe possa ser avaliada positivamente, a AUC deve ser maior que 0,5 e, em geral, deve ser maior que 0,8 para ser considerada aceitável. Os resultados podem ser interpretados através da Tabela 6. Ao se comparar os desempenhos de várias redes, é considerada o melhor resultado a curva ROC com maior AUC (SAHNGUN, 2022) (HAMMAD *et al.*, 2023).

Tabela 6 – Valores da AUC e suas respectivas interpretações

(AUC)	Interpretação
$0.9 \leq AUC$	Excelente
$0.8 \leq AUC < 0.9$	Bom
$0.7 \leq AUC < 0.8$	Regular
$0.6 \leq AUC < 0.7$	Ruim
$0.5 \leq AUC < 0.6$	Falhou

Fonte: Adaptado pela autora de Nahm, 2022.

O gráfico gerado utiliza a métrica da Taxa Verdadeira Positiva (TPR), que pode ser observada na Equação 3.5 e a Taxa Verdadeira Negativa (TNR) na Equação 3.6.

$$TPR = \frac{TP}{TP + FN} \quad (3.5)$$

$$TNR = \frac{TN}{TN + FP} \quad (3.6)$$

3.6 Tecnologias aplicadas

Para que a pesquisa fosse realizada, algumas tecnologias foram utilizadas, podendo ser citadas:

- As arquiteturas das Redes Neurais utilizadas,
- Utilização da ferramenta *Transfer learning*,
- Bibliotecas: *Tensorflow 2.11.0*, *Keras 2.11.0* e *Torch 1.13.1*,
- Pré-processamento das imagens utilizando de redimensionamento das imagens, normalização antes de usar as redes e *data augmentation*,
- Otimizador Adam, Regularização *dropout*,
- Métricas de desempenho como acurácia, precisão, recall, F1-score, curva ROC e matriz confusão.

3.6.1 Ambiente de desenvolvimento e testes

As implementações realizadas neste trabalho, foram desenvolvidas em um computador pessoal com processador 12th Gen Intel(R) Core(TM) i7-12700 2.10GHz, memória RAM 16GB e sistema operacional de 64 bits, processador baseado em x64. Utiliza-se a linguagem de programação *Python* versão 3.7.6 para implementação e execução dos algoritmos, através do ambiente de desenvolvimento integrado, *Visual Studio Code*.

4 RESULTADOS E DISCUSSÃO

Neste capítulo, apresenta-se os resultados obtidos por meio da análise dos dados e experimentos realizados. Com base nas seções anteriores, será apresentado os resultados alcançados, como os parâmetros analisados, tempo de processamento dos algoritmos de melhoramento, análise das métricas de qualidade, processamento de cada rede e comparação dos resultados obtidos.

4.1 Doenças Raras e LGC

As Doenças Raras, por acometer pouca porcentagem da população e se tratar de inúmeros registros, de 6000 a 8000, o tema deve ser abordado incentivando mais pesquisas nessa área, além de utilizar dos artifícios da IA para auxiliar nessa problemática.

No intuito de auxiliar e amplificar o alcance sobre lipodistrofia, um aplicativo móvel que pode ser adquirido tanto na *Apple store* ou *Google Play* para auxílio na identificação de síndromes lipodistróficas raras foi lançado em 2020 de acordo com os estudos de D. Araújo-Villar *et al.* O algoritmo desenvolvido identifica mais de 40 subtipos de lipodistrofia descritos. É um aplicativo gratuito de nome LipoDDx®. Através de uma série de perguntas implementadas, o algoritmo chegará a um resultado sugerindo o subtipo da síndrome ou não. Sua assertividade foi de $79 \pm 20\%$. Na figura pode-se observar a aparência do aplicativo (ARAÚJO-VILAR *et al.*, 2020).


O uso combinado de estratégias como o aplicativo LipoDDx® mais identificação de fenótipo da LGC através de imagens, podem ser ferramentas muito úteis para os profissionais da área de saúde, como tantas outras ferramentas existentes.

A página da associação pode ser encontrada através da página da internet ((ASPOS-BERN), 2022), assim como a página do *facebook* < <https://www.facebook.com/asposbern/> >. Importante ressaltar que foi tentando contato através das páginas citadas, assim como o telefone fixo que consta na página, mas não houve sucesso.

4.2 Algoritmos de melhoramento

Nesta etapa da pesquisa é possível analisar o tempo de processamento dos algoritmos de tratamento das imagens na Tabela 7. A correção Gamma foi a mais rápida do processo, gastando 2,88 segundos para finalizar. O algoritmo mais lento foi *YING*, gastando 284.886,75

Figura 18 – Imagem à esquerda do aplicativo sendo procurado na *Apple Store* e à direita a tela de início do app.



Fonte: Autora, 2023.

segundos, o que equivale a 79,13 horas.

Tabela 7 – Tempo de Processamento dos algoritmos de melhoramento e retirada do fundo da imagem.

Algoritmos	Tempo de processamento(s)
GAMMA	2,88
HE	2091,30
DHE	2091,57
YING	284886,75
GAMMA+HE	2092,34
GAMMA+DHE	2093,01
GAMMA+YING	2093,53
REMOVEL	1460,10
REMOVEL+GAMMA	3,00
REMOVEL+HE	5864,24
REMOVEL+DHE	11323,80
REMOVEL+YING	2095,36

Fonte: Autora, 2023.

Para avaliar as imagens processadas foram aplicadas qualidades métricas, que podem ser analisadas na Tabela 8. A imagem processada foi "LGCnova18.png". Pode-se observar, que o algoritmo *YING* obteve o menor valor em RMSE com 11,648. Resultado que avalia que essa imagem tem maior semelhança com a original e melhor qualidade. O que pode ser observado também, que os resultados altos com o método de retirada de fundo é explicado, pois como o

fundo foi removido, a diferença se faz marcante. Isto se comprava com o maior resultado em *GAMMA+REMOVEL*, que foi de 156,718.

Tabela 8 – Qualidades Métricas aplicadas nas imagens.

Algoritmos	RMSE	CRN	AMBE	AG	PSNR	SSIM
GAMMA	43,110	0,084	36,626	1,394	28,163	0,871
HE	55,322	0,090	42,711	2,063	27,706	0,786
DHE	37,707	0,023	18,324	2,076	28,002	0,852
YING	11,648	0,007	2,679	2,045	34,654	0,925
GAMMA+HE	55,299	0,092	43,217	2,063	27,710	0,786
GAMMA+DHE	69,538	0,090	50,983	2,078	27,840	0,679
GAMMA+YING	46,175	0,090	38,445	2,064	27,964	0,827
REMOVEL	153,716	0,365	118,989	2,055	29,405	0,366
GAMMA+REMOVEL	156,718	0,220	99,298	2,064	27,304	0,345
REMOVEL+HE	68,862	0,006	0,431	2,038	27,636	0,857
REMOVEL+DHE	126,594	0,206	75,574	2,048	27,501	0,554
REMOVEL+YING	153,241	0,368	118,904	2,051	28,931	0,359

Fonte: Autora, 2023.

Observando a próxima métrica CRN, o algoritmo que ficou com menor ruído foi *REMOVEL+HE* com 0,006. Já o maior valor foi *REMOVEL+YING* com 0,368 seguido pelo *REMOVEL*.

No caso da métrica AMBE, o algoritmo com o menor valor foi *REMOVEL+HE* que obteve 0,431, mantendo o brilho mais próximo da original. Ficando o método *REMOVEL* com o maior valor.

Analisando o AG, o algoritmo que teve maior alteração foi o *GAMMA+DHE* seguido pelo *DHE*. Os valores nesta métrica manteve uma proximidade evidenciando uma discrepância no algoritmo Gamma, 1,394. O algoritmo de melhoramento *Gamma correction*, faz alteração nas imagens remodelando a saturação do contraste, e como esse processo já havia sido realizado, explica o valor menor em relação aos outros.

Seguindo para os valores do PSNR, o algoritmo com o maior valor foi o *YING* com 34,654. Como o algoritmo *YING* faz um equilíbrio de pixels na imagem final, isto explica o valor dessa métrica ser alta, pois foi a imagem que manteve a melhor qualidade. Sendo a pior imagem em termos de qualidade a *Gamma+REMOVEL*.

Observando o SSIM, o algoritmo com o menor valor foi *Gamma+REMOVEL* com 0,345. Isto quer dizer que foi com a pior qualidade. Métrica que reforça os resultados anteriores, sendo este mesmo algoritmo o pior na métrica PSNR. Já o algoritmo que obteve a melhor qualidade foi o *YING*. Sendo comprovado também na métrica PSNR.

4.3 Parâmetros analisados

Os parâmetros processados em cada rede convolucional são importantes, pois quanto mais parâmetros, maior será o custo computacional. Na Tabela 9 pode-se analisar os parâmetros de cada rede. A RESNET50, é a rede que tem mais parâmetros, mas por ter camadas residuais, tem um custo computacional menor.

Tabela 9 – Parâmetros utilizados nas Redes Neurais Convolucionais.

Algoritmos	Parâmetros Treinados	Total de Parâmetros
IINET	1187050	1187505
MOBILENETV2	82114	82114
RESNET50	1727082	25316826
VGG19	1179974	21204490

Fonte: Autora, 2023.

Após o uso da ferramenta *Data augmentation*, o número das imagens do banco de dados houve um acréscimo para processamento nas redes neurais convolucionais, que pode ser observado na Tabela 10. Um ponto importante a ser mencionado, que foi programado para que as classes ficassem com o mesmo número de amostras, para não favorecer nenhuma classe.

Tabela 10 – Número de imagens geradas após o uso da ferramenta *Data augmentation*

Rede Convolucional	Total de imagens geradas	Total de imagens analisadas
IINET	244	537
MobileNetV2	236	529
ResNet50	236	529
VGG19	244	537

Fonte: Autora, 2023

Outro ponto importante de ressaltar é que ao utilizar o método de retirada de fundo, mais imagens foram geradas, por isso que ao analisar mais adiante as matrizes da rede RESNET50 e VGG19, terão mais imagens classificadas. Nas duas redes, o total de imagens geradas foi 469, totalizando 762 imagens analisadas.

4.4 Classificação das Redes convolucionais

Antes de analisar as métricas dos resultados, se faz necessário observar os tempos de processamento dos algoritmos de melhoramento aplicados com as redes neurais convolucionais propostas, pois o objetivo é obter um resultado melhor e com menor tempo possível. Na Tabela 11 é possível observar os tempos de todas as redes, com os tempos de treinamento, teste e tempo total. Importante frisar, que foi calculado o tempo médio.

Tabela 11 – Tempo do Custo Computacional das Redes Neurais Convolucionais e os algoritmos de melhoramento das imagens

Algoritmos	Tempo médio(s)	IINET	RESNET	MOBILENETV2	VGG19
ORIGINAL	Treino	309,19	354,94	52,12	6201,75
	Teste	88,34	98,84	12,00	1771,93
	Total	441,70	494,20	64,12	8859,64
GAMMA	Treino	322,19	346,20	52,00	4661,14
	Teste	92,06	98,92	11,97	1331,75
	Total	460,28	494,58	63,97	6658,77
HE	Treino	326,57	338,71	51,00	5028,15
	Teste	93,30	96,77	10,90	694,24
	Total	466,52	483,87	61,90	7441,22
DHE	Treino	325,24	352,75	50,00	6693,40
	Teste	92,93	100,79	12,24	1912,40
	Total	464,63	503,94	62,24	9562,01
YING	Treino	351,23	343,67	39,01	4414,37
	Teste	100,35	98,19	8,55	681,96
	Total	501,75	490,96	47,56	6306,25
GAMMA+HE	Treino	313,28	337,62	55,00	4636,33
	Teste	89,51	96,46	12,36	1324,67
	Total	447,55	482,32	67,36	6623,33
GAMMA+DHE	Treino	359,98	340,46	50,87	5247,27
	Teste	102,85	97,27	10,95	1077,92
	Total	514,25	486,37	61,82	7496,10
GAMMA+YING	Treino	328,26	365,77	31,00	4972,19
	Teste	93,79	104,50	7,96	649,16
	Total	468,94	522,52	38,97	7103,13
GAMMA+REMOVEL	Treino	332,29	338,28	29,00	4875,66
	Teste	94,94	96,65	7,00	685,77
	Total	474,70	483,26	36,00	6965,23
REMOVEL	Treino	2396,88	656,02	52,01	9941,33
	Teste	684,82	187,43	11,30	1400,93
	Total	3424,12	937,17	63,31	14201,90
REMOVEL+HE	Treino	356,48	344,23	51,99	5023,45
	Teste	101,85	98,35	12,02	458,04
	Total	509,26	491,76	64,00	7176,36
REMOVEL+DHE	Treino	331,94	362,81	50,89	4871,56
	Teste	94,84	103,66	11,69	686,30
	Total	474,20	518,30	62,58	6959,37
REMOVEL+YING	Treino	325,22	341,59	50,02	4548,15
	Teste	92,92	97,60	10,69	529,94
	Total	464,61	487,99	60,70	6497,36

Fonte: Autora, 2023.

Analisando a Tabela 11, observa-se que a rede que teve maior custo computacional foi a VGG19 e a que teve menor custo computacional foi a MobileNetV2. O maior custo computacional foi a VGG19 associado ao algoritmo *Removel* com 14201,90 segundos e o menor

foi o MobileNetV2 adicionado com *GAMMA+REMOVEL* com 36,00 segundos, considerando o tempo total.

Um ponto a ser relembrando é que a MobileNetV2, provavelmente teria um tempo menor, se fosse levado em conta as épocas, pois para se obter uma acurácia melhor, foi necessário aumentar as épocas para 50. Outra observação importante, que deve ser mencionado, é que para obter esses tempos de processamento, foi gasto mais tempo com aplicação dos algoritmos de melhoramento, o que aumentaria mais o tempo de processamento total.

Com a Tabela 12, é possível analisar a acurácia, precisão, *recall* e o *f1score*. Esta Tabela traz a média de todas as rodadas. Utilizando os algoritmos de melhoramento, foi observado na IINET que houve melhora com o algoritmos *Ying*, *Gamma+Removel*, *Removel* e *Removel+Ying*. Os algoritmos *Gamma+Removel* e *Removel* obtiveram a mesma acurácia, sendo que o desvio foi menor no método sem fundo e o *f1score* foi maior também.

Na rede RESNET50 o melhor resultado foi com *Removel*. Com os outros métodos, todos os resultados ficaram abaixo de 80%. Esta rede foi a rede que obteve o pior resultado. Um ponto que chama atenção nesta rede é que a precisão foi mais alta em relação ao *Recall*, indicando que o modelo fez a predição dos positivos corretamente, algo importante para os diagnósticos médicos.

A próxima rede, MobileNetV2, teve um resultado melhor com o banco de dados original, obtendo 91,70%. O *f1score* teve um resultado inferior a acurácia, o que indica que os números dos falsos positivos e os falsos negativos fizeram diferença nessa rede.

Analisando a VGG19, observa-se que com os algoritmos de melhoramento, a rede obteve acurácias melhores com a combinação DHE e *Removel*. Com o DHE a diferença de 0,02% em relação ao conjunto de dados original, foi muito pequena, mas analisando o *f1score*, foi maior com o conjunto de dados original. Com o método *Removel*, obteve a maior acurácia de todos os modelos com 99,01%. O que se pode analisar também, é que a rede em todos seus resultados, houve um equilíbrio entre os parâmetros analisados, indicando que o modelo fez previsões corretas e recuperou instâncias corretamente.

4.5 Matriz Confusão e Curva ROC

Nesta seção se encontra as matrizes confusão das redes, juntamente com cada curva de cada modelo, com o melhor resultado encontrado, considerando a acurácia, sendo que foi feita média de todas as rodadas. No caso da IINET, foi o modelo com as imagens originais

Tabela 12 – Resultados das métricas média das Redes Neurais Convolucionais

ALGORITMOS	MÉTRICAS	IINET	RESNET50	MOBILENETV2	VGG19
ORIGINAL	Acurácia	92,43±2,85%	73,46±7,96%	91,70±2,60%	94,64±2,43%
	Precisão	95,38%	90,58%	95,65%	95,57%
	Recall	90,51%	78,64%	73,33%	96,58%
	F1-score	93,39±3,03%	83,71±8,46%	83,02%	96,20±2,77%
GAMMA	Acurácia	91,07±3,36%	78,39%±7,26%	90,01±1,86%	93,94±2,77%
	Precisão	91,67%	95,43%	100,00%	94,59%
	Recall	91,67%	80,34%	76,67%	94,83%
	F1-score	92,30±3,84%	87,39±7,57%	82,20%	94,70±3,05%
HE	Acurácia	87,19±4,03%	76,18±7,81%	88,32±2,67%	92,63±2,85%
	Precisão	92,09%	94,19%	83,87%	94,30%
	Recall	89,80%	75,86%	86,67%	94,79%
	F1-score	90,93±4,52%	84,24±8,79%	85,25%	94,37±4,25%
DHE	Acurácia	90,77±3,55%	73,73±9,19%	85,01±5,62%	94,66±2,33%
	Precisão	94,74%	91,21%	95,83%	95,32%
	Recall	91,53%	75,94%	76,67%	94,85%
	F1-score	93,12±3,94%	83,02±11,33%	85,19%	95,01±2,98%
YING	Acurácia	93,31±3,02%	74,11±8,37%	82,57±4,43%	89,17±3,52%
	Precisão	93,91%	97,61%	77,38%	92,01%
	Recall	92,88%	75,74%	83,33%	91,43%
	F1-score	93,38±3,29%	85,45±9,04%	80,13%	91,89±5,67%
GAMMA+HE	Acurácia	87,53±3,75%	74,19±10,25%	86,69±2,41%	93,62±2,62%
	Precisão	93,14%	94,22%	86,21%	91,08%
	Recall	89,83%	77,00%	83,33%	98,58%
	F1-score	91,37±4,31%	84,46±13,97%	84,75%	94,49±3,21%
GAMMA+DHE	Acurácia	90,76±3,37%	78,14±7,49%	83,29±5,84%	93,94±2,38%
	Precisão	92,43%	97,45%	91,30%	95,60%
	Recall	92,19%	75,05%	70,00%	97,87%
	F1-score	92,22±3,84%	84,88±7,74%	79,24%	96,44±2,68%
GAMMA+YING	Acurácia	91,61±3,29%	76,22±8,43%	88,35±4,11%	90,65±3,26%
	Precisão	94,97%	99,49%	83,87%	94,08%
	Recall	93,80%	73,22%	86,67%	89,88%
	F1-score	94,28±3,77%	84,34±6,46%	81,97%	91,87±5,70%
GAMMA+REMOVEL	Acurácia	98,88±3,96%	76,08±7,98%	75,01±11,11%	91,68%
	Precisão	93,98%	99,75%	95,30%	99,89%
	Recall	90,43%	75,47%	63,33%	87,88%
	F1-score	91,93±4,31%	86,01±6,63%	78,60%	93,57±5,64%
REMOVEL	Acurácia	98,88±1,31%	86,42±6,51%	88,34±3,57%	99,01±1,09%
	Precisão	98,71%	93,36%	85,29%	99,11%
	Recall	99,74%	87,11%	96,67%	98,82%
	F1-score	99,22±1,36%	88,45±5,66%	90,63%	98,98±1,01%
REMOVEL+HE	Acurácia	85,68±4,17%	68,15±5,94%	80,01±6,65%	90,25±3,11%
	Precisão	92,78%	98,43%	73,08%	92,62%
	Recall	92,20%	66,73%	63,33%	92,90%
	F1-score	88,86±4,61%	79,34±6,71%	67,86%	92,72±6,85%
REMOVEL+DHE	Acurácia	87,19±3,90%	70,49±9,49%	90,02±3,49%	92,74±2,91%
	Precisão	90,33%	96,52%	88,46%	94,94%
	Recall	88,53%	74,62%	76,67%	95,66%
	F1-score	89,42±4,43%	84,20±12,76%	83,51%	95,31±5,01%
REMOVEL+YING	Acurácia	93,18±3,04%	77,56±7,85%	78,34±3,78%	90,27±3,20%
	Precisão	95,50%	95,26%	85,19%	91,75%
	Recall	93,17%	77,02%	76,67%	90,55%
	F1-score	94,27±3,44%	85,09±8,0%	85,15%	91,21±6,92%

Fonte: Autora, 2023.


Tabela 13 e Figura 19.

Tabela 13 – Matriz de Confusão da rede IINET com o banco de dados original

n	Predição: Sim	Predição: Não
Real: Sim	36	3
Real: Não	3	19

Fonte: Autora, 2023

Figura 19 – Curva ROC da rede IINET com o banco original.



Fonte: Autora, 2023.

O que se pode observar na matriz da rede IINET, que 36 imagens foram classificadas como portadores da síndrome e 19 imagens foram classificadas como sem a síndrome. 3 imagens foram classificadas incorretamente como tendo LGC e 3 classificados incorretamente como não tendo LGC. Observando a curva ROC e avaliando a Tabela 6, podemos classificar o modelo como excelente.

A matriz confusão da rede RESNET50 foi com o método de retirada do fundo, com as classificações na Tabela 14. A curva ROC gerada pelo modelo pode ser observada na Figura 20.


Tabela 14 – Matriz de Confusão da rede RESNET50 com o método de retirada do fundo

n	Predição: Sim	Predição: Não
Real: Sim	73	7
Real: Não	3	36

Fonte: Autora, 2023

Avaliando a matriz confusão dessa rede, observa-se que 73 imagens foram classificadas como contendo a LGC e 36 imagens foram classificadas como não contendo a LGC. 7 imagens foram classificadas incorretamente como se tivessem a doença e 3 imagens foram

Figura 20 – Curva ROC da rede RESNET50 com o método de retirada do fundo.



Fonte: Autora, 2023.

classificadas incorretamente como se não tivessem a doença. Ao observar a curva ROC, Figura 20 da rede, conforme a Tabela 6, a rede é classificada como boa.


Partindo para a rede MobileNetV2, a matriz confusão gerada foi a rede com o banco de dados original, Tabela 15 e a curva ROC Figura 21.

Tabela 15 – Matriz de Confusão da rede MobileNetV2 com o banco de dados original

n	Predição: Sim	Predição: Não
Real: Sim	41	7
Real: Não	5	12

Fonte: Autora, 2023

Figura 21 – Curva ROC da rede MobileNetV2 com o banco original.



Fonte: Autora, 2023.

Foram classificados com a doença 73 imagens e sem a doença 12 imagens. 7 imagens

foram classificadas incorretamente como tendo a lipodistrofia generalizada congênita e 5 foram classificadas como não tendo a síndrome. Analisando a curva como a Tabela 6, o modelo foi classificado como bom.


A matriz confusão da VGG19, pode ser observada na Tabela 16. A curva gerada pelo modelo pode ser analisada na Figura 22.

Tabela 16 – Matriz de Confusão da rede VGG19 com o método de retirada do fundo

n	Predição: Sim	Predição: Não
Real: Sim	74	0
Real: Não	1	44

Fonte: Autora, 2023

Figura 22 – Curva ROC da rede VGG19 com o método de retirada do fundo.



Fonte: Autora, 2023.

74 imagens foram classificadas corretamente como tendo a síndrome e 44 imagens foram classificadas corretamente como não tendo a doença. Zero imagens foram classificadas incorretamente como tendo a síndrome e 1 imagem foi classificada incorretamente como não tendo a síndrome. Como são modelos para auxiliar o diagnóstico, os erros tem pesos diferentes e devem ser analisados. O pior erro analisando essa temática seria o paciente ser diagnosticado erroneamente como tendo não tendo a LGC. Então esse parâmetro deve ser devidamente analisado nos modelos apresentados.

Para que uma análise da evolução dos trabalhos relacionados seja observado, foi montada a Tabela 17.

Tabela 17 – Comparativo entre as pesquisas passadas e a atual

Trabalhos anteriores	Landin (2021)	Castilhos (2021)	Olegario (2022)	Castilhos (2023)
Redes testadas	CNN	CNN KNN,OLS,CQ	CNN	IINET ResNet50,MobileNetv2,VGG19
Lr	0,001	0,01	0,001	0,001 0,001; 0,01; 0,001
Função de ativação		ReLU	ReLU	ReLU ReLU;ReLU;ReLU/Softmax
Cam. Convolucionais	2	3	2	3 8,3,16
Recursos Extras	x	Maxpooling, 2 densas Camada escondida	Maxpooling, densa Camada escondida	Maxpooling, 3 densas Camada escondida
Banco de dados	Próprio	LGC=180 (UFC) NLGC=77	Total=337 *	LGC=194 (UFC) NLGC=101
Acurácia (Banco original)	63%	92,46% >70%	90,85%	92,43% 73,46%; 91,70%; 94.64%

Fonte: Autora, 2023. *não tinha informação sobre o número de imagens de LGC e NLGC.

5 CONCLUSÃO

Nessa dissertação foi apresentado um sistema de visão computacional para detecção de fenótipo da LGC: uma ferramenta de auxílio ao diagnóstico da doença rara.

Foi apresentado uma rede neural convolucional chamada IINET. A rede teve um desempenho excelente analisando sua curva ROC, com o valor de 0,93 e um *f1score* de 99,22% e um desvio padrão de 1,36% com o método de retirada do fundo da imagem. Analisando sua matriz confusão, teve uma classificação abaixo que a VGG19, mas obteve um custo computacional melhor. Logo sua vantagem em relação ao modelo VGG19, é o custo computacional. E sua vantagem em relação a MobileNetV2 e RESNET50 são os resultados na classificação, assim como os valores obtidos. A sua desvantagem em relação aos outros modelos é que se torna necessário despende um certo tempo ajustando os parâmetros e pesos para obter um bom resultado.

Foram testadas quatro redes neurais convolucionais: IINET, MobileNetV2, RESNET50 e VGG19 para classificação das imagens fotográficas, obtendo um resultado melhor analisando as métricas, a rede VGG19, mas com um custo computacional alto. Foi considerada o melhor modelo, por diversas razões. Primeiro pelo o maior valor em acurácia, 99,01% e um pequeno desvio padrão de 1,09%. Segunda razão pela avaliação da matriz confusão. A classificação incorreta das classes foi a menor, numericamente, o que representa muito se tratando de diagnósticos médicos. 1 imagem foi classificada incorretamente como não tendo a síndrome e zero imagem classificada incorretamente como tendo a síndrome. Essa classificação de 1 imagem classificada, é o pior cenário, pois o paciente foi classificado incorretamente como não tendo a doença, mas na verdade tem. Mas analisando os outros modelos, a VGG19, foi a que teve o menor erro de todos. Terceira razão, foi a curva ROC, pois obteve o resultado de 0,94, sendo considerado excelente.

Foi observado que os formatos PNG e JPG fazem diferença no custo computacional quando processados nos algoritmos de melhoramento. O formato PNG é o que tem processamento mais rápido. E quanto menor as dimensões das imagens, menor o custo computacional.

Os algoritmos de melhoramento das imagens, melhoraram os resultados obtidos, mas aumentaram o custo computacional. O melhor resultado foi com o método de retirada do fundo da imagem, que pode ser realizado em um site gratuito disposto na internet, sem precisar aplicar algoritmo, mas tendo o trabalho de recortar as imagens. Este método causou uma controvérsia dos resultados, pois teve a melhor acurácia, sensibilidade e especificidade, mas teve o maior

tempo de processamento.

Algumas métricas de qualidade não foram possíveis ser avaliadas com eficiência, como CRN e AMBE. Elas são mais expressivas em imagens que tem cores claras e escuras, como por exemplo análises de raio-x.

Esta dissertação obteve um resultado melhor que o trabalho anterior (CASTILHOS, 2021) e pode fazer a análise dos algoritmos de melhoramento para classificação.

O uso do modelo VGG19, forneceu um resultado satisfatório para classificação de imagens fotográficas de pacientes que tem características fenotípicas, como a LGC. Resultado útil para usá-lo como referência para comparar com outros modelos. Com isso, tempo e recursos podem ser economizados e permitir comparações mais precisas entre diferentes abordagens. O modelo pode trazer benefício para a sociedade reduzindo gastos na rede pública de saúde e gastos para o paciente também, pois quando mais cedo o diagnóstico correto, melhor será o tratamento e menos distúrbios fisiológicos acometerá o paciente.

Esta pesquisa não propõe a automatização do processo de diagnóstico, mas sim auxiliar os profissionais da área da saúde.

5.1 Trabalhos Futuros

Para trabalhos futuros, seria interessante propor a criação de mais bases de dados de doenças raras e criar uma rede para identificá-las juntas. Poderia ser um sistema como no artigo (SILVA *et al.*, 2022), usando o sistema IOT para levar ao conhecimento de mais profissionais da área de saúde as doenças raras e auxiliar os pacientes oferecendo mais qualidade de vida. Usando a internet, automaticamente, o banco de dados vai sendo atualizado melhorando seu desempenho.

Seria interessante analisar outros hiperparâmetros e tentar aumentar as camadas da técnica *data augmentation*, para melhorar o desempenho dos modelos.

Outro ponto interessante, era propor um sistema que fizesse parte da rede, como requisito, retirar o fundo da imagem. Pois esse método auxiliou para que o modelo pudesse focar nos parâmetros mais importantes obtendo um resultado muito melhor. Outro ponto que poderia ser analisado é testar camadas de convolução separável em profundidade no modelo VGG19, para observar se o modelo continua obtendo um bom resultado e reduz o custo computacional.

Outra contribuição importante é aumentar o banco de dados da LGC.

REFERÊNCIAS

- ABDULLAH-AL-WADUD, M.; KABIR, M. H.; DEWAN, M. A. A.; CHAE, O. A dynamic histogram equalization for image contrast enhancement. **IEEE Transactions on Consumer Electronics**, v. 53, n. 2, p. 593–600, 2007.
- ALOMAR, K.; AYSEL, H. I.; CAI, X. Data augmentation in classification and segmentation: A survey and new strategies. **Journal of Imaging**, MDPI, v. 9, n. 2, p. 46, 2023.
- ALZU'BI, A. A.; AL-SARIHIN, K. K.; ETEIWI, S.; AL-ASAAD, R. A.; EYADAH, A. A. A.; KHREISAT, M.; AL-OMARI, A. A.; HADDAD, F. H. Berardinelli-seip syndrome and essential thrombocytosis: an unusual association. **Oman medical journal**, Oman Medical Specialty Board, v. 35, n. 3, p. e135, 2020.
- ARAÚJO-VILAR, D.; FERNÁNDEZ-POMBO, A.; RODRÍGUEZ-CARNERO, G.; MARTÍNEZ-OLMOS, M. Á.; CANTÓN, A.; VILLAR-TAIBO, R.; HERMIDA-AMEIJEIRAS, Á.; SANTAMARÍA-NIETO, A.; DÍAZ-ORTEGA, C.; MARTÍNEZ-REY, C. *et al.* Lipoddx: A mobile application for identification of rare lipodystrophy syndromes. **Orphanet Journal of Rare Diseases**, BioMed Central, v. 15, n. 1, p. 1–9, 2020.
- (ASPOSBERN). **Associação dos Pais e Pessoas com a Síndrome de Berardinelli do Estado do Rio Grande do Norte (ASPOSBERN)**. 2022. Disponível em: <<https://asposbern.com.br/>>. Acesso em: 12 dezembro 2022.
- BARBOSA, P. C. S. Parametrização de sinais de eletroencefalograma para classificação de padrões via matrizes de kernel. 2021.
- BENGIO, Y. **Learning deep architectures for AI**. [S.l.]: Now Publishers Inc, 2009.
- BISPO, M. B.; FREITAS, A. C. C. d. Congenital generalized lipodystrophy: a literature review. **Research, Society and Development**, v. 12, n. 2, p. e21812240288, Feb. 2023. Disponível em: <<https://rsdjournal.org/index.php/rsd/article/view/40288>>.
- BOMFIM, V. V. B. da S.; PINHEIRO, G. O.; BRITO, M. B. R. de; VARDASCA, G. H. de M.; CADÊTE, M. L. X.; COELHO, L. N. L. Avanços na terapia genética para doenças genéticas raras. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 9, n. 8, p. 1484–1490, 2023.
- CAMPOS, J. T. A. de M.; MEDEIROS, J. L. D. de; MELO, M. E. C. de; SILVA, M. A. da; SENA, M. O. de; SARMENTO, A. S. C.; LIMA, L. F. A.; FREGONEZI, G. A. de F.; LIMA, J. G. Endoplasmic reticulum stress and muscle dysfunction in congenital lipodystrophies. **Biochimica et Biophysica Acta (BBA)-Molecular Basis of Disease**, Elsevier, v. 1867, n. 6, p. 166120, 2021.
- CAO, G.; HUANG, L.; TIAN, H.; HUANG, X.; WANG, Y.; ZHI, R. Contrast enhancement of brightness-distorted images by improved adaptive gamma correction. **Computers and Electrical Engineering**, v. 66, p. 569–582, 2018. ISSN 0045-7906. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0045790616306292>>.
- CASTILHOS, J. D. de. Aprendizado de maquina aplicado para identificacao da lipodistrofia generalizada congenita. Engenharia de Producao, Universidade de Fortaleza, p. 60, 2021.

- CHEN, S.-D.; Rahman Ramli, A. Preserving brightness in histogram equalization based contrast enhancement techniques. **Digital Signal Processing**, v. 14, n. 5, p. 413–428, 2004. ISSN 1051-2004. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1051200404000387>>.
- CIABURRO, G.; VENKATESWARAN, B. **Neural Networks with R: Smart models using CNN, RNN, deep learning, and artificial intelligence principles**. [S.l.]: Packt Publishing Ltd, 2017.
- CRESWELL, J. W.; CRESWELL, J. D. **Projeto de pesquisa-: Métodos qualitativo, quantitativo e misto**. [S.l.]: Penso Editora, 2021.
- CUI, G.; FENG, H.; XU, Z.; LI, Q.; CHEN, Y. Detail preserved fusion of visible and infrared images using regional saliency extraction and multi-scale image decomposition. **Optics Communications**, v. 341, p. 199–209, 2015. ISSN 0030-4018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0030401814011833>>.
- DAMASCENO, É. d. B.; FIGUEIREDO, J. G. d.; FRANÇA, J. M. B.; VERAS, J. C. D.; BORGES, R. E. A.; MELO, L. P. d. Experiência de pessoas que vivem com a síndrome de berardinelli-seip no nordeste brasileiro. **Ciência & Saúde Coletiva**, SciELO Brasil, v. 23, p. 389–398, 2018.
- DENG, J.; DONG, W.; SOCHER, R.; LI, L.-J.; LI, K.; FEI-FEI, L. Imagenet: A large-scale hierarchical image database. In: IEEE. **2009 IEEE conference on computer vision and pattern recognition**. [S.l.], 2009. p. 248–255.
- DOURADO, C. M.; SILVA, S. P. P. da; NOBREGA, R. V. M. da; FILHO, P. P. R.; MUHAMMAD, K.; ALBUQUERQUE, V. H. C. de. An open ioht-based deep learning framework for online medical image recognition. **IEEE Journal on Selected Areas in Communications**, IEEE, v. 39, n. 2, p. 541–548, 2020.
- EMIR, B.; COLAK, E. Análise de desempenho de modelos de rede neural convolucional pré-treinados para classificação de doenças oftalmológicas. **Arquivos Brasileiros de Oftalmologia**, SciELO Brasil, 2023.
- FLICK, U. **Introdução à metodologia de pesquisa: um guia para iniciantes**. [S.l.]: Penso Editora, 2012.
- GARG, A. Acquired and inherited lipodystrophies. **New England Journal of Medicine**, Mass Medical Soc, v. 350, n. 12, p. 1220–1234, 2004.
- GONZÁLEZ, J.-D.; QUINTERO-ROJAS, J. Use of convolutional neural networks in smartphones for the identification of oral diseases using a small dataset. **Revista Facultad de Ingeniería**, Universidad Pedagógica y Tecnológica de Colombia, v. 30, n. 55, 2021.
- (GOV.BR). **Análise Epidemiológica e Vigilância de Doenças não Transmissíveis**. 2023. Disponível em: <<https://svs.aids.gov.br/daent/centrais-de-conteudos/paineis-de-monitoramento/mortalidade/cid10/>>. Acesso em: 8 novembro 2023.
- GUROVICH, Y.; HANANI, Y.; BAR, O.; NADAV, G.; FLEISCHER, N.; GELBMAN, D.; BASEL-SALMON, L.; KRAWITZ, P. M.; KAMPHAUSEN, S. B.; ZENKER, M. *et al.* Identifying facial phenotypes of genetic disorders using deep learning. **Nature medicine**, Nature Publishing Group US New York, v. 25, n. 1, p. 60–64, 2019.

- HAMMAD, M.; PŁAWIAK, P.; ELAFFENDI, M.; EL-LATIF, A. A. A.; LATIF, A. A. A. Enhanced deep learning approach for accurate eczema and psoriasis skin detection. **Sensors**, MDPI, v. 23, n. 16, p. 7295, 2023.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2016. p. 770–778.
- HEYDARIAN, M.; DOYLE, T. E.; SAMAVI, R. Mlcm: Multi-label confusion matrix. **IEEE Access**, IEEE, v. 10, p. 19083–19095, 2022.
- HOWARD, A. G.; ZHU, M.; CHEN, B.; KALENICHENKO, D.; WANG, W.; WEYAND, T.; ANDREETTO, M.; ADAM, H. Mobilenets: Efficient convolutional neural networks for mobile vision applications. **arXiv preprint arXiv:1704.04861**, 2017.
- IMAN, M.; ARABNIA, H. R.; RASHEED, K. A review of deep transfer learning and recent advancements. **Technologies**, v. 11, n. 2, 2023. ISSN 2227-7080. Disponível em: <<https://www.mdpi.com/2227-7080/11/2/40>>.
- ISMAEL, S. A. A.; MOHAMMED, A.; HEFNY, H. An enhanced deep learning approach for brain cancer mri images classification using residual networks. **Artificial intelligence in medicine**, Elsevier, v. 102, p. 101779, 2020.
- J, B.; JN, A. R. T.; DV, G. J. P.; C, G. Machine learning in rare disease. **National Library of Medicine**, Epub May 29, 2023.
- JANA, B. R.; THOTAKURA, H.; BALIYAN, A.; SANKARARAO, M.; DESHMUKH, R. G.; KARANAM, S. R. Pixel density based trimmed median filter for removal of noise from surface image. **Applied Nanoscience**, Springer, v. 13, n. 2, p. 1017–1028, 2023.
- JUNIOR, R. M. M.; LIMA, G. E. d. C. P.; FERNANDES, V. O.; MONTENEGRO, A. P. D. R.; PONTE, C. M. M.; MARTINS, L. V.; PINHEIRO, D. P.; MORAES, M. E. A. de; FILHO, M. O. de M.; D'ALVA, C. B. Leu124serfs* 26, a novel agpat2 mutation in congenital generalized lipodystrophy with early cardiovascular complications. **Diabetology & Metabolic Syndrome**, BioMed Central, v. 12, n. 1, p. 1–9, 2020.
- JUNQUEIRA, A. L. R. F.; WELICHAN, M. M.; CEZAR, A. C. N.; BORBA, L. C. F.; PEREIRA, L. R.; MATOS, A. D. de O.; MENDES, G. J.; SAMPER, I. C.; COSTA, L. F.; MOREIRA, M. R. I ciclo de palestras sobre doenças raras:: um relato de experiência. **Brazilian Medical Students**, v. 8, n. 11, 2023.
- KHAN, M. A.; MUHAMMAD, K.; SHARIF, M.; AKRAM, T.; ALBUQUERQUE, V. H. C. de. Multi-class skin lesion detection and classification via teledermatology. **IEEE Journal of Biomedical and Health Informatics**, IEEE, v. 25, n. 12, p. 4267–4275, 2021.
- KIM, H. E.; COSA-LINAN, A.; SANTHANAM, N.; JANNESARI, M.; MAROS, M. E.; GANSLANDT, T. Transfer learning for medical image classification: a literature review. **BMC medical imaging**, Springer, v. 22, n. 1, p. 69, 2022.
- KSHATRI, S. S.; SINGH, D. Convolutional neural network in medical image analysis: a review. **Archives of Computational Methods in Engineering**, Springer, v. 30, n. 4, p. 2793–2810, 2023.

LANDIN, P. L. A. Diagnostico de lipodistrofia generalizada congenita atraves de rede neural convolucional. Engenharia de Producao, Universidade de Fortaleza, p. 50, 2021.

MEDEIROS, L. F. d. Inteligência artificial aplicada: uma abordagem introdutória. **Curitiba: Intersaberes**, v. 158, 2018.

MIRZA, M. W.; SIDDIQ, A.; KHAN, I. R. A comparative study of medical image enhancement algorithms and quality assessment metrics on covid-19 ct images. **Signal, Image and Video Processing**, Springer, v. 17, n. 4, p. 915–924, 2023.

MOHAN, R.; KADRY, S.; RAJINIKANTH, V.; MAJUMDAR, A.; THINNUKOOL, O. Automatic detection of tuberculosis using vgg19 with seagull-algorithm. **Life**, MDPI, v. 12, n. 11, p. 1848, 2022.

MUSTAFA, W. A.; KADER, M. M. M. A. A review of histogram equalization techniques in image enhancement application. **Journal of Physics: Conference Series**, IOP Publishing, v. 1019, n. 1, p. 012026, jun 2018. Disponível em: <<https://dx.doi.org/10.1088/1742-6596/1019/1/012026>>.

NAZAR, M.; ALAM, M. M.; YAFI, E.; MAZLIHAM, M. A systematic review of human-computer interaction and explainable artificial intelligence in healthcare with artificial intelligence techniques. **IEEE Access**, IEEE, 2021.

OLEGARIO, N. B. da C.; NETO, J. S. da C.; BARBOSA, P. C. S.; PINHEIRO, P. R.; LANDIM, P. L. A.; MONTENEGRO, A. P. D. R.; FERNANDES, V. O.; ALBUQUERQUE, V. H. C. de; DUARTE, J. B. F.; LIMA, G. E. da C. P. *et al.* Identifying congenital generalized lipodystrophy using deep learning-deeplipo. **Scientific Reports**, Nature Publishing Group UK London, v. 13, n. 1, p. 2176, 2023.

PATNI, N.; GARG, A. Congenital generalized lipodystrophies—new insights into metabolic dysfunction. **Nature Reviews Endocrinology**, Nature Publishing Group, v. 11, n. 9, p. 522–534, 2015.

PEZO, A. R.; YAHUARCANI, I. O.; SATALAYA, A. M. N.; LLAJA, L. A. S.; CORTEGANO, C. A. G.; AHUANARI, A. F. P. Computer application for the detection of skin diseases in photographic images using convolutional neural networks. In: SPRINGER. **Latin American High Performance Computing Conference**. [S.l.], 2020. p. 193–204.

REMOVEBG. **This is how you cite a website in latex**. 2023. Url<http://remove.bg> www.remove.bg.

RODRIGUEZ, A. J.; MASTRONARDI, C. A.; PAZ-FILHO, G. J. New advances in the treatment of generalized lipodystrophy: role of metreleptin. **Therapeutics and Clinical Risk Management**, Dove Press, v. 11, p. 1391, 2015.

RODRIGUEZ-MOLARES, A.; RINDAL, O. M. H.; D’HOOGE, J.; MÅSØY, S.-E.; AUSTENG, A.; BELL, M. A. L.; TORP, H. The generalized contrast-to-noise ratio: A formal definition for lesion detectability. **IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control**, IEEE, v. 67, n. 4, p. 745–759, 2019.

RUIZ, R. B.; VELÁSQUEZ, J. D. Inteligencia artificial al servicio de la salud del futuro. **Revista Médica Clínica Las Condes**, Elsevier, v. 34, n. 1, p. 84–91, 2023.

SAHNGUN, N. F. Receiver operating characteristic curve: overview and practical use for clinicians. **Korean J Anesthesiol**, v. 75, n. 1, p. 25–36, 2022. Disponível em: <<http://ekja.org/journal/view.php?number=8778>>.

SANTOS, L.; ESPINDOLA, M. V.; MATSUBARA, E. T. Estudo de selecao de instâncias em aprendizado de métrica para o problema de classificação com aprendizado incremental. Fundação Universidade Federal de Mato Grosso do Sul, 2023.

SARMENTO, A. S. C.; FERREIRA, L. C.; LIMA, J. G.; MEDEIROS, L. B. de A.; CUNHA, P. T. B.; AGNEZ-LIMA, L. F.; URURAHY, M. A. G.; CAMPOS, J. T. A. de M. The worldwide mutational landscape of berardinelli-seip congenital lipodystrophy. **Mutation Research/Reviews in Mutation Research**, Elsevier, v. 781, p. 30–52, 2019.

SILVA, C. P. Avaliação do sono em indivíduos com lipodistrofia generalizada congênita. 2017.

SILVA, D. S. da; NASCIMENTO, C. S.; JAGATHEESAPERUMAL, S. K.; ALBUQUERQUE, V. H. C. d. Mammogram image enhancement techniques for online breast cancer detection and diagnosis. **Sensors**, MDPI, v. 22, n. 22, p. 8818, 2022.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.

SOARES, J. C.; FARIAS, S. X. d. O dilema da inteligência artificial e a inteligência humana: avanços da ia na área da saúde. Universidade Federal Fluminense, 2023.

SORKINA, E.; CHICHKOVA, V. Generalized lipoatrophy syndromes. **La Presse Médicale**, v. 50, n. 3, p. 104075, 2021. ISSN 0755-4982. Lipodystrophy syndromes. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0755498221000142>>.

VENKATESAN, R.; LI, B. **Convolutional neural networks in visual computing: a concise guide**. [S.l.]: CRC Press, 2017.

Victor Ikechukwu, A.; MURALI, S.; DEEPU, R.; SHIVAMURTHY, R. Resnet-50 vs vgg-19 vs training from scratch: A comparative analysis of the segmentation and classification of pneumonia from chest x-ray images. **Global Transitions Proceedings**, v. 2, n. 2, p. 375–381, 2021. ISSN 2666-285X. International Conference on Computing System and its Applications (ICCSA- 2021). Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2666285X21000558>>.

VIJAYALAKSHMI, D.; NATH, M. K.; ACHARYA, O. P. A comprehensive survey on image contrast enhancement techniques in spatial domain. **Sensing and Imaging**, Springer, v. 21, n. 1, p. 40, 2020.

YING, Z.; LI, G.; REN, Y.; WANG, R.; WANG, W. A new image contrast enhancement algorithm using exposure fusion framework. In: . [S.l.: s.n.], 2017. p. 36–46. ISBN 978-3-319-64697-8.

YOSINSKI, J.; CLUNE, J.; BENGIO, Y.; LIPSON, H. How transferable are features in deep neural networks? In: GHAHRAMANI, Z.; WELLING, M.; CORTES, C.; LAWRENCE, N.; WEINBERGER, K. (Ed.). **Advances in Neural Information Processing Systems**. Curran Associates, Inc., 2014. v. 27. Disponível em: <https://proceedings.neurips.cc/paper_files/paper/2014/file/375c71349b295fbc2dcdca9206f20a06-Paper.pdf>.

ZHOU, T.; CHANG, X.; LIU, Y.; YE, X.; LU, H.; HU, F. Covid-resnet: Covid-19 recognition based on improved attention resnet. **Electronics**, MDPI, v. 12, n. 6, p. 1413, 2023.

ANEXO A – CÓDIGO DA MATRIZ CONFUSÃO

```
def ConfusionMatrix(pred,real):
    MC = np.zeros((2,2))
    for i in range(pred.shape[0]):
        indexPred = pred[i,0]
        indexReal = real[i,0]
        MC[int(indexPred),int(indexReal)]+=1
    return MC

def custom_mean_squared_error(y_true,y_pred):
    return tf.math.reduce_mean(tf.square(y_true-y_pred))

MC = ConfusionMatrix(y_predito,yTeste)
VP = MC[0,0]
VN = MC[1,1]
FP = MC[0,1]
FN = MC[1,0]
Sensibilidade = VP/(VP+FN)
Especificidade = VN / (VN+FP)
Acuracia = (VP+VN)/(VP+VN+FP+FN)
Lista_acuracias.append(Acuracia)
Lista_sensibilidades.append(Sensibilidade)
Lista_especificidades.append(Especificidade)
```

ANEXO B – CÓDIGO TREINO E TESTE DAS CLASSES

Red: tamanho da imagem

```

for rod in range(Num_Rodadas):
    SEED = random.permutation(X.shape[0])
    xTreino = np.empty((0,Red,Red,3))
    yTreino = np.empty((0,1))
    z = 0

    for i in range(int(len(SEED)*.8)):
        aux = X[SEED[i],:,:,:]
        aux.shape = (1,Red,Red,3)
        xTreino = np.append(xTreino,aux,axis=0)
        aux = Y[SEED[i],:]
        aux.shape=(1,1)
        yTreino = np.append(yTreino,aux,axis=0)
        z+=1

xTeste = np.empty((0,Red,Red,3))
yTeste = np.empty((0,1))
while z<len(SEED):
    aux = X[SEED[z],:,:,:]
    aux.shape = (1,Red,Red,3)
    xTeste = np.append(xTeste,aux,axis=0)
    aux = Y[SEED[z],:]
    aux.shape = (1,1)
    yTeste = np.append(yTeste,aux,axis=0)
    z+=1

xTreino, xTeste = xTreino/255, xTeste/255

Predição:
y_predito = saved_model.predict(xTeste)
y_predito = np.argmax(y_predito,axis=1)
y_predito.shape = (len(y_predito),1)

```

ANEXO C – CURVA ROC

```
predicted_probabilities = y_predito
auc = roc_auc_score(true_labels, predicted_probabilities)
print("AUC: {:.2f}".format(auc))
fpr, tpr, thresholds = roc_curve(true_labels, predicted_probabilities)
plt.figure(figsize=(8, 6))
plt.plot(fpr, tpr, color='darkorange', lw=2, label='CNN(AUC = {:.2f})'.format(auc))
plt.plot([0, 1], [0, 1], color='navy', lw=2, linestyle='--')
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.05])
plt.xlabel('False Positive Rate')
plt.ylabel('True Positive Rate')
plt.title('Receiver Operating Characteristic (ROC) Curve')
plt.legend(loc='lower right')
plt.show()
```