



**UNIVERSIDADE
ESTADUAL DO
MARANHÃO**

**UNIVERSIDADE ESTADUAL DO MARANHÃO
CENTRO DE CIÊNCIAS TECNOLÓGICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DA COMPUTAÇÃO
E SISTEMAS**

Márcio Fabiano Oliveira de Moura Santos

**CLASSIFICAÇÃO DE LIBRAS EM IMAGENS ATRAVÉS DE REDES
NEURAS CONVOLUCIONAIS**

**São Luís - MA
2022**



**UNIVERSIDADE
ESTADUAL DO
MARANHÃO**

Márcio Fabiano Oliveira de Moura Santos

CLASSIFICAÇÃO DE LIBRAS EM IMAGENS ATRAVÉS DE REDES NEURAS CONVOLUCIONAIS

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia de Computação e Sistemas, da Universidade Estadual do Maranhão como requisito parcial para a obtenção do grau de Mestre em Engenharia de Computação e Sistemas.

Orientador: Prof. Dr. Cícero Costa Quarto

Doutor em Informática na Educação - UEMA

**São Luís - MA
2022**



UNIVERSIDADE
ESTADUAL DO
MARANHÃO

Santos, Márcio Fabiano Oliveira de Moura.

Classificação de libras em imagens através de redes neurais convolucionais / Márcio Fabiano Oliveira de Moura Santos. – São Luís, 2022. 65 f.

Dissertação (Mestrado) - Programa de Pós-Graduação em Engenharia da Computação e Sistemas, Universidade Estadual do Maranhão, 2022.

Orientador: Prof. Dr. Cícero Costa Quarto.

1.Libras. 2.Visão computacional. 3.Redes neurais convolucionais. 4.YOLOv5. I.Título.

CDU: 004.032.26:81'221.24



UNIVERSIDADE
ESTADUAL DO
MARANHÃO

Márcio Fabiano Oliveira de Moura Santos

**CLASSIFICAÇÃO DE LIBRAS EM IMAGENS ATRAVÉS DE REDES
NEURAS CONVOLUCIONAIS**

Este exemplar corresponde à redação final da dissertação devidamente corrigida e defendida por Márcio Fabiano Oliveira de Moura Santos e aprovada pela comissão examinadora.

Aprovada em 31 de Outubro de 2022.

BANCA EXAMINADORA

Cícero Costa Quarto (orientador)

Doutor em Informática na educação - UFRGS

Ewaldo Eder Carvalho Santana

Doutor em Engenharia de eletricidade - UFPB

Antônio Phillipi Maciel Silva

Mestre em Engenharia Elétrica - UESPI



UNIVERSIDADE
ESTADUAL DO
MARANHÃO

Dedico este trabalho primeiramente a Deus por permitir que eu alcance esta grande conquista em minha vida sendo sempre minha grande fonte de inspiração, à minha mãe Carmen que sempre me ensinou com muito carinho e esforço a não desistir dos meus objetivos, ao meu pai Valter por me incentivar e acreditar em minha capacidade e ao meu orientador professor Cícero Quarto pelo apoio, força, confiança e dedicação durante a construção deste trajeto.



Resumo

A alfabetização de pessoas surdas, é atualmente um grande desafio que tem gerado muitas discussões no contexto educacional. Apesar da existência da linguagem de sinais (Libras), a capacitação de pessoas para a realização de atividades de ensino nesta área é bastante escassa, e isso tem dificultado bastante o processo de ensino e aprendizagem de indivíduos com ou sem problemas auditivos. Com o crescimento da Internet e das tecnologias computacionais, houve a necessidade da criação de aplicações avançadas de Inteligência Artificial (IA) para aprimorar este processo. Um marco bastante importante foi o surgimento da Visão Computacional, que é uma área da Inteligência Artificial que procura analisar, fazer a interpretação e a extração de determinadas informações úteis de imagens, estudando também a utilização de emoções, reconhecimentos, e análise de movimentos interativos de seres humanos através de sistemas informatizados de IA. que simulam os pensamentos e ações de seres humanos. O tema deste trabalho aborda uma pesquisa relacionada à aplicação de redes neurais convolucionais (ou profundas), que são ligadas à visão computacional de forma análoga. Foram realizados experimentos através de uma base de dados de Libras que serviu de suporte para o treinamento nas imagens através do algoritmo de redes neurais profundas YOLOv5 para a realização da Classificação de alguns grupos de 6 e 7 imagens. Posteriormente, foram comparados os resultados dos testes, e observados quais épocas obtiveram uma melhor performance durante a classificação das imagens de Libras.

Palavras-Chave: Libras. Visão computacional. Redes Neurais Convolucionais. YOLOv5.



Abstract

The literacy of deaf people is currently a major challenge that has generated many discussions in the educational context. Despite the existence of sign language (Libras), the training of people to carry out teaching activities in this area is quite scarce, and this has made the teaching and learning process of people with or without hearing problems very difficult. With the increasing growth of the internet and computer technologies, it was needed to create advanced artificial intelligence applications to improve this process. A very important milestone was the emergence of Computer Vision, which is an area of artificial intelligence that seeks to analyze, interpret and extract certain useful information from images, also studying the use of emotions, recognition, and analysis of interactive movements of human beings through computerized AI systems that simulate the thoughts and actions of human beings. The main subject of this work addresses a research related to the application of convolutional (or deep) neural network, which are similarly linked to computer vision. Experiments were carried out using a Libras database that served as support for the training of images through the YOLOv5 deep neural network algorithm to perform the Classification of some groups of 6 and 7 images. Subsequently, the results of the tests were compared, and it was observed which periods had a better performance during the classification of Libras images.

Keywords: Libras. Computer Vision. Convolutional Neural Network. YOLOv5.

Agradecimentos

A Deus pela força, pela orientação e pela fé para perseverar durante as etapas desta conquista.

À UEMA, pela confiança, pela disponibilidade e pelo grande apoio durante a pesquisa.

Ao Prof. Dr. Cícero Costa Quarto, pela excelente orientação, pela confiança e pela oportunidade.

Aos amigos e colegas de turma pelo grande apoio, pela amizade e pela força que foram de suma importância para obtenção do êxito neste triunfo.



UNIVERSIDADE
ESTADUAL DO
MARANHÃO

*A fé é a certeza daquilo que
esperamos e a prova das coisas
que não vemos.*

Hebreus 11:1

Lista de figuras

Figura 1 - Estrutura de um neurônio artificial análoga um neurônio biológico.	22
Figura 2 - Visão geral de uma Rede Neural Convolutacional.....	25
Figura 3 -Demonstração de funcionamento do YOLO por Redmon na Ted Talks.....	26
Figura 4 - Problema de regressão para detecção de objetos com YOLO.....	27
Figura 5 – Comparação do YOLOv4 com outras versões.....	28
Figura 6 – Fases do método aplicados à pesquisa	34
Figura 7 – Imagens com métricas de classificação	35
Figura 8 – Base de dados no site do Roboflow.	36
Figura 9 - Informações da GPU utilizada durante os experimentos.....	37



Lista de tabelas

Tabela 1 - Possíveis tarefas de uma rede neural.	23
Tabela 2 – Classes do conjunto de dados Libras Computer Vision Project.	36
Tabela 3 – Classificação dos casos de teste (letras) - treinamento de 100 épocas.	39
Tabela 4 - Classificação dos casos de teste (números) - treinamento de 100 épocas....	39
Tabela 5 - Classificação dos casos de teste (palavras) - treinamento de 100 épocas. ...	40
Tabela 6 - Classificação de um grupo de imagens com a letra A - 100 épocas.....	40
Tabela 7 - Classificação de um grupo imagens com a letra B - 100 épocas.....	40
Tabela 8 - Classificação de um grupo de imagens com a letra C - 100 épocas.....	41
Tabela 9 - Classificação de um grupo de imagens com a letra D - 100 épocas.....	41
Tabela 10 - Classificação de um grupo de imagens com a letra E - 100 épocas.....	41
Tabela 11 - Classificação de um grupo de imagens com a letra F - 100 épocas.....	41
Tabela 12 - Classificação de um grupo de imagens com a letra G - 100 épocas.	42
Tabela 13 - Classificação de um grupo de imagens com a letra I - 100 épocas.....	42
Tabela 14 - Classificação de um grupo de imagens com a letra L - 100 épocas.....	42
Tabela 15 - Classificação de um grupo de imagens com a letra M - 100 épocas.....	42
Tabela 16 - Classificação de um grupo de imagens com a letra N - 100 épocas.....	43
Tabela 17 - Classificação de um grupo de imagens com a letra O - 100 épocas	43
Tabela 18 - Classificação de um grupo de imagens com a letra P - 100 épocas.....	43
Tabela 19 - Classificação de um grupo de imagens com a letra Q - 100 épocas.	43
Tabela 20 - Classificação de um grupo de imagens com a letra R - 100 épocas.....	44
Tabela 21 - Classificação de um grupo de imagens com a letra S - 100 épocas.	44
Tabela 22 - Classificação de um grupo de imagens com a letra T - 100 épocas.....	44
Tabela 23 - Classificação de um grupo de imagens com a letra U - 100 épocas.....	44
Tabela 24 - Classificação de um grupo de imagens com a letra V - 100 épocas.....	45
Tabela 25 - Classificação de um grupo de imagens a letra W - 100 épocas	45
Tabela 26 - Classificação de um grupo de imagens a letra X - 100 épocas.	45
Tabela 27 - Classificação de um grupo de imagens com a letra Y - 100 épocas.....	45
Tabela 28 - Classificação dos casos de teste (letras) - treinamento de 500 épocas.	46
Tabela 29 - Classificação dos casos de teste (números) - treinamento de 500 épocas. .	46
Tabela 30 - Classificação dos casos de teste (palavras) - treinamento de 500 épocas. .	47
Tabela 31 - Classificação de um grupo de imagens com a letra A - 500 épocas.....	47
Tabela 32 - Classificação de um grupo de imagens com a letra B - 500 épocas.....	47



Tabela 33 - Classificação de um grupo de imagens com a letra C - 500 épocas.....	47
Tabela 34 - Classificação de um grupo de imagens com a letra D - 500 épocas.....	48
Tabela 35 - Classificação de um grupo de imagens com a letra E - 500 épocas.....	48
Tabela 36 - Classificação de um grupo de imagens com a letra F - 500 épocas.....	48
Tabela 37 - Classificação de um grupo de imagens com a letra G - 500 épocas.	48
Tabela 38 - Classificação de um grupo de imagens com a letra I - 500 épocas.....	49
Tabela 39 - Classificação de um grupo de imagens com a letra L - 500 épocas.....	49
Tabela 40 - Classificação de um grupo de imagens a letra M - 500 épocas.....	49
Tabela 41 - Classificação de um grupo de imagens com a letra N - 500 épocas.....	49
Tabela 42 - Classificação de um grupo de imagens com a letra O - 500 épocas.	50
Tabela 43 - Classificação de um grupo de imagens com a letra P - 500 épocas.....	50
Tabela 44 - Classificação de um grupo de imagens com a letra Q - 500 épocas.	50
Tabela 45 - Classificação de um grupo de imagens com a letra R - 500 épocas.....	50
Tabela 46 - Classificação de um grupo de imagens com a letra S - 500 épocas.	51
Tabela 47 - Classificação de um grupo de imagens com a letra T - 500 épocas.....	51
Tabela 48 - Classificação de um grupo de imagens com a letra U - 500 épocas.....	51
Tabela 49 - Classificação de um grupo de imagens com a letra V - 500 épocas.....	51
Tabela 50 - Classificação de um grupo de imagens com a letra W - 500 épocas.	52
Tabela 51 - Classificação de um grupo de imagens com a letra X - 500 épocas.....	52
Tabela 52 - Classificação de um grupo de imagens com a letra Y - 500 épocas.....	52
Tabela 53 - Classificação dos casos de teste (letras) - treinamento de 1000 épocas....	53
Tabela 54 - Classificação dos casos de teste (números) - treinamento de 1000 épocas	53
Tabela 55 - Classificação dos casos de teste (palavras) - treinamento de 1000 épocas	53
Tabela 56 - Classificação de um grupo de imagens com a letra A - 1000 épocas.....	54
Tabela 57 - Classificação de um grupo de imagens com a letra B - 1000 épocas.....	54
Tabela 58 - Classificação de um grupo de imagens com a letra C - 1000 épocas.....	54
Tabela 59 - Classificação de um grupo de imagens com a letra D - 1000 épocas.....	54
Tabela 60 - Classificação de um grupo de imagens com a letra E - 1000 épocas.....	55
Tabela 61 - Classificação de um grupo de imagens com a letra F - 1000 épocas.....	55
Tabela 62 - Classificação de um grupo de imagens com a letra G - 1000 épocas.....	55
Tabela 63 - Classificação de um grupo de imagens com a letra I - 1000 épocas.....	55
Tabela 64 - Classificação de um grupo de imagens com a letra L - 1000 épocas.....	56
Tabela 65 - Classificação de um grupo de imagens com a letra M - 1000 épocas.....	56



Tabela 66 - Classificação de um grupo de imagens com a letra N - 1000 épocas.....	56
Tabela 67 - Classificação de um grupo de imagens com a letra O - 1000 épocas	56
Tabela 68 - Classificação de um grupo de imagens com a letra P - 1000 épocas	57
Tabela 69 - Classificação de um grupo de imagens com a letra Q - 1000 épocas	57
Tabela 70 - Classificação de um grupo de imagens com a letra R - 1000 épocas.....	57
Tabela 71 - Classificação de um grupo de imagens com a letra S - 1000 épocas	57
Tabela 72 - Classificação de um grupo de imagens com a letra T - 1000 épocas.....	58
Tabela 73 - Classificação de um grupo de imagens com a letra U - 1000 épocas.....	58
Tabela 74 - Classificação de um grupo de imagens com a letra V - 1000 épocas.....	58
Tabela 75 - Classificação de um grupo de imagens com a letra W - 1000 épocas	58
Tabela 76 - Classificação de um grupo de imagens com a letra X - 1000 épocas.....	59
Tabela 77 - Classificação de um grupo de imagens com a letra Y - 1000 épocas.....	59
Tabela 78 - Soma das precisões dos testes T1 à T7 em 100, 500 e 1000 épocas	59



Sumário

1	CONSTRUINDO O OBJETO DE PESQUISA	13
1.1	Contextualização.....	13
1.2	Motivação	15
1.3	A questão de pesquisa.....	15
1.4	Objetivos.....	16
1.4.1	Objetivo geral	16
1.4.2	Objetivos específicos.....	16
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	A tecnologia da informação e a alfabetização de surdos	17
2.2	Visão computacional.....	19
2.3	Redes Neurais Artificiais	21
2.3.1	Redes Neurais Convolucionais.....	24
2.4	Trabalhos relacionados	30
2.4.1	Considerações sobre trabalhos relacionados	33
3	METODOLOGIA DE PESQUISA	34
3.1	Obtenção das imagens	35
3.2	Subdivisão do <i>dataset</i>	35
3.3	Arquitetura utilizada	36
3.4	Ambiente utilizado para os experimentos.....	37
3.5	Realização do experimento	38
4	RESULTADOS	38
5	ANÁLISE E DISCUSSÕES DE RESULTADOS	59
6	CONCLUSÃO.....	61
7	REFERÊNCIAS.	62



1 CONSTRUINDO O OBJETO DE PESQUISA

1.1 Contextualização

O uso das tecnologias digitais no ensino de Libras é uma inovação no campo do conhecimento que proporciona novas maneiras de interação e comunicação entre surdos através de computadores. A capacitação de pessoas para o processo de ensino, é realizada na maioria das vezes por meio de cursos especializados que possuem grande relevância para enfrentar desafios no sentido de desenvolvimento das habilidades para a aplicação de técnicas de ensino visando melhorar os aspectos sociais, educacionais e a alfabetização destes alunos em sala de aula (PACHECO, 2007; SILVA, 2016).

De acordo com BARELLI (2018), uma importante área da inteligência artificial que utiliza redes neurais como base para o seu funcionamento, é a Visão Computacional que se caracteriza como a ciência e a tecnologia das máquinas que enxergam pela forma como o computador distingue à sua volta através da obtenção de informações importantes pela captura de imagens de diferentes dispositivos, pois esta desenvolve as teorias e técnicas para a construção de sistemas artificiais que extraem informações úteis de imagens ou dados multidimensionais. Um dos seus principais aspectos está no fato desta utilizar sistemas de reconhecimento com características semelhantes às de seres humanos como identificações biométricas, de faces, íris dentre várias outras. O reconhecimento de padrões de objetos é o campo da ciência que estuda técnicas para classificação ou detecção de variados tipos. As várias formas de interações humanas através da comunicação, estão divididas entre falas e sinais que têm sido bastante aperfeiçoadas na Visão Computacional, chegando bem próximo à interface natural do usuário, que é responsável pela exploração das formas comportamentais características do corpo humano que poderão ser utilizadas na aplicação de máquinas digitais de inúmeras áreas, pois com o elevado crescimento da utilização de dispositivos e softwares, a interação homem-computador tem se expandido constantemente durante as últimas décadas, incentivando assim o surgimento de diversas novas definições e técnicas, como estudos relacionados a movimentação de membros superiores, que são os responsáveis pela interlocução não verbal entre pessoas através de sinais que podem expressar os sentidos humanos, realizando assim a comunicação entre os usuários e o computador de forma intuitiva dando ênfase à usabilidade independente (Pavlovic, 1997). Com isso, surge um grande desafio em relação a utilização de complexos algoritmos baseados em Visão Computacional que

possam ou não ser aplicados a partir de equipamentos que funcionem a distância ou em tempo real e que identifiquem os movimentos reais das mãos humanas através da visualização de imagens digitais (Gonzaga, 2011). A utilização de aplicações para o ensino de Libras é algo um pouco complexo devido à dificuldade de desenvolvimento destes tipos de softwares computacionais.

As Redes Neurais Convolucionais, do inglês *Convolutional Neural Networks (CNN)*, ao serem treinadas, conseguem aprender características constantes utilizando hierarquias multiníveis de determinados aspectos, extraíndo de forma implícita, particularidades de determinados padrões de imagens apresentados como entrada, classificando-os ou detectando-os de forma categórica através de recursos que são extraídos sem depender de escala, iluminação ou pose (Lecun, et al., 2010). Geralmente, são constituídas por arquiteturas de treinamento que se encontram em inúmeros estágios, e cada um destes é composto por três camadas que são uma camada convolucional, uma camada de subamostragem e a terceira camada caracteriza-se por ser totalmente conectada (Kang et al., 2014). A classificação de objetos é atualmente um dos modelos de visão computacional mais conhecidos e com maior versatilidade que os demais, pois buscam fazer análises em determinados tipos de imagens conforme sua relevância. Pode-se citar como exemplo o reconhecimento do uso de máscaras, que é algo importante para a redução do risco do vírus da Covid-19, onde foi utilizado um tipo de reconhecimento de imagens necessário para a realização do treinamento de um determinado modelo de classificação de objetos para que fosse possível identificá-los e classificá-los para um determinado fim (Moura et al., 2022). Um dos sistemas de classificação ou detecção de imagens mais utilizados da atualidade é o algoritmo YOLO (do inglês *You only look once*), que faz a modelagem como um problema de regressão, dividindo a imagem em um sistema de grade onde há a predição das células através da classificação da precisão ou em caixas delimitadoras que utilizam níveis de confiança para mostrar as possibilidades de ocorrência das classes utilizadas para análise em sua estrutura através de inferências. Um outro aspecto interessante deste algoritmo é que este também é capaz de identificar objetos em tempo real, além de possuir muita rapidez e precisão quando equiparado com outros detectores de imagens, pois ele aplica uma rede neural à imagem completa para poder fazer a classificação dos objetos, e após isso, a rede neural faz o particionamento da imagem em determinadas regiões fazendo a previsão das possíveis ocorrências para cada região. Porém, sob outra perspectiva, outros tipos de algoritmos utilizados para a detecção de objetos, fazem geralmente a execução das redes neurais a uma imagem que se encontra em variados locais e em diferentes proporcionalidades. Resumindo, o

algoritmo YOLO primeiramente visualiza toda a imagem, de uma maneira na qual as previsões são notificadas através de uma circunstância abrangente da imagem (Tamang et al., 2022). Atualmente, a ferramenta possui 5 versões (YOLOv1, YOLOv2, YOLOv3, YOLOv4 e YOLOv5). Os capítulos posteriores descreverão um pouco cada uma delas.

1.2 Motivação

Alguns estudos relacionados ao desenvolvimento de aplicações voltadas para o ensino de pessoas surdas têm sido desenvolvidos com frequência. Isto ocorre devido à complexidade da junção do processo de implementação deste tipo de software com o ensino de Libras, pois o pesquisador precisará conhecer um pouco de ambos para que o seu objetivo final seja atingido, além da necessidade de adaptação do sistema às características dos usuários do mesmo, pois a utilização destes programas poderão ser de interesse de professores, estudantes, pesquisadores ou pessoas que queiram aprender Libras dentre vários outros públicos como, por exemplo, profissionais liberais que queiram expandir o seu negócio através da inclusão social de surdos, ministrantes de palestras, vendedores ou proprietários de cursos profissionalizantes (Pavlovic, 1997). Através do conhecimento de Libras, percebe-se o quanto é necessária a difusão e a formação da língua de sinais em todas as instâncias da sociedade que busquem garantir o acesso de surdos. A utilização de alguns recursos visuais para a sinalização da linguagem sinais e cores que produzem efeitos na comunicação que são muito importantes para o desenvolvimento da aprendizagem de pessoas com surdez, e neste contexto, tais recursos podem servir como base de contribuição para que o deficiente auditivo possa ser incluído no mundo alfabetizado através de aplicações computacionais (Botelho, 2002). Neste contexto, surgiu-se a ideia da construção de uma aplicação interativa que conseguisse classificar a precisão de imagens de Libras através de redes neurais convolucionais baseadas em treinamentos que pudessem servir de suporte a um futuro desenvolvimento de outras aplicações que sirvam como base de estudos para pesquisadores ou usuários interessados em aprender a linguagem de sinais através de técnicas de visão computacional.

1.3 A questão de pesquisa

Diante do cenário apresentado nos tópicos anteriores para a identificação da área estudada e do problema relacionado a aprendizagem de Libras, esta pesquisa se norteia de acordo com a questão de pesquisa que segue:



“A Classificação de imagens através de Redes Neurais Convolucionais torna produtiva a análise de sinais de Libras?”.

1.4 Objetivos

De acordo com MARCONI e LAKATOS (2001), toda e qualquer pesquisa deverá possuir metas para que haja a possibilidade de compreensão do que será explorado e o que se pretende alcançar, pois a delimitação dos objetivos é uma condição para que uma investigação científica seja realizada. Para isso, é necessário que haja clareza, coerência e precisão na escolha do tema que será estudado, pois este apresentará a motivação para a pesquisa.

1.4.1 Objetivo geral

Verificar a eficiência da classificação de Libras através da rede neural convolucional YOLOv5 no processo de aprendizagem.

1.4.2 Objetivos específicos

- ✓ Realizar o treinamento do conjunto de dados de Libras através da arquitetura YOLOv5 em 100, 500 e 1000 épocas;
- ✓ Realizar testes de classificação em grupos específicos de imagens;
- ✓ Analisar os resultados da precisão de cada classe identificada após a classificação das imagens investigando os melhores resultados após os testes.

2 FUNDAMENTAÇÃO TEÓRICA

Um dos principais agravantes relacionados às dificuldades de aprendizagem de pessoas com surdez é o problema linguístico cognitivo, e isso ocorre devido aos mesmos não receberem estímulos auditivos, não conseguindo assim aprender a língua oral, ocasionando então no pouco desenvolvimento da comunicação e da interatividade com outros indivíduos.

Um dos principais aspectos da vida dos surdos, encontram-se nos primórdios de sua existência caracterizados através do atraso no processo comunicativo, onde seus pensamentos não conseguem se desenvolver adequadamente, ocasionando em problemas de interlocução com outras crianças de sua idade devido à defasagem do processo cognitivo, pois embora uma



boa parte das crianças surdas possua um intelecto preservado devido à falta dos estímulos comuns iniciais, elas terão dificuldades de compreensão podendo afastar-se do convívio social.

Já na escola, poderá haver um atraso em relação aos outros colegas de classe, e para evitar que isso aconteça, é necessário a realização de uma capacitação vigorosa dos docentes e de profissionais como fonoaudiólogos, psicopedagogos, psicólogos e principalmente familiares no sistema de alfabetização de surdos visando evitar maiores deficiências durante a aprendizagem das linguagens de sinais, independentemente da faixa etária do deficiente auditivo. A partir disto, considera-se que para cada caso poderão ser tomadas medidas adequadas para determinados tipos de situações, pois existe uma infinidade de casos como a de alunos oralizados ou com surdez profunda que nunca foram incentivados antes do ingresso escolar e famílias de pessoas surdas nas quais os pais já ensinam Libras para estas desde criança.

Com isso, entende-se que as experiências obtidas pelos surdos no decorrer de suas vidas são potencialmente visuais, e que a sua língua natural é visual, baseando-se também no espaço, e deverá ser instruída através de uma linguagem não compreendida, não ouvida, e totalmente diferente das que eles estão acostumados, pois não se trata apenas de aprender outra linguagem como ouvintes, pois eles deverão também conhecê-la bem e utilizar uma língua oral e auditiva para interagir com a sociedade, o que contraria bastante a sua condição, pois os obstáculos que serão enfrentados por indivíduos desta categoria têm atrapalhado bastante o seu avanço, pois não existe uma fórmula exata que possa resolver totalmente esses problemas (Portal Educação, 2020).

2.1 A tecnologia da informação e a alfabetização de surdos

A aplicação de tecnologias digitais da informação ao processo de alfabetização de surdos, é uma área nova no contexto computacional, além de ser uma particularidade bastante importante que favorece o desenvolvimento de pessoas desta categoria nos aspectos de comunicação e na sua modalidade visual-espacial, possibilitando assim a proposição de métodos adequados para a educação dos discentes na superação das dificuldades e das desigualdades enfrentadas no ensino de Libras, e na inclusão social através destas ferramentas informatizadas que servem de auxílio pedagógico para docentes, melhorando assim a eficiência da aprendizagem por meio da prática de conteúdos apropriados para a obtenção de conhecimentos e interesses dos aprendizes, e pela utilização de formas de apresentação que

podem se adaptar aos estilos cognitivos dos mesmos na construção de estratégias sólidas utilizadas na aprendizagem (Chaves, 2019).

A utilização de softwares computacionais na educação de surdos associados à aplicação de estratégias de ensino apropriadas, estimulam eficientemente a aprendizagem interativa dos discentes, porém, a realidade das escolas impedem bastante o reconhecimento destas competências devido à escassez de recursos de software, hardware e internet, que são ferramentas úteis para execução das atividades de sala de aula através destes artifícios, evitando assim o crescimento do ambiente de aprendizagem informatizado necessário para aplicação dos métodos digitais a este contexto. Entretanto, existe um outro problema que pode impossibilitar a conexão de alunos ao mundo digital, pois nem todas as pessoas têm acesso a artifícios tecnológicos como softwares e dispositivos adaptativos ou assistivos interligados à internet, que são instrumentos extremamente necessários para a comunicação e letramento dos discentes com ou sem surdez, para intensificar a produtividade do processo cognitivo destes indivíduos através da eliminação de obstáculos que impedem desenvolvimento intelectual dos mesmos, pois apesar da revolução dos computadores, existem também a necessidade de comunicação com a web para que os surdos possam adquirir informações do mundo online para obtenção de conhecimentos através de sites e plataformas virtuais de aprendizagem como, por exemplo, o AVA, que serve de grande suporte à construção do cognitiva destes discentes dentre várias outras infinidades de aplicações digitais informatizadas (Chaves, 2019).

Um outro fator importante que precisa ser abordado é a utilização de Libras no processo educativo digital, pois são línguas naturais aplicadas às modalidades visuais-espaciais em contraste com as orais que podem ser percebidas através da audição e produzidas por meio do corpo em ambiente (Pires, 2009). De acordo com Karnopp e Quadros (2001), o status linguístico das linguagens de sinais existem e se constituíram naturalmente em comunidades de pessoas com surdez, e apresenta todos os níveis sintáticos, semânticos, morfológico, fonológico e analíticos dentre vários outros relacionados às demais línguas e, apesar de ser distinta, pode variar de acordo com a região, não podendo ser considerada como primitiva devido a sua complexidade e capacidade de exprimir ideias relacionadas ao universo, além da possibilidade do alargamento do seu vocabulário através da inclusão de neologismos para definição de novos conceitos, pois estas, assim como as demais, poderão evoluir com o tempo, apesar de utilizarem um sistema finito de elementos que se combinam construindo novas estruturas com significados que podem, por sua vez constituir um conjunto sem fim de possíveis palavras, pois as gramáticas para o ensino de Libras apresentam regras muito semelhantes às demais,

utilizando também categorias gramaticais, orais, substantivos, verbos dentre outras características.

2.2 Visão computacional

De acordo com Milano e Honorato (2010), a aplicação da visão computacional como área de pesquisa está relacionada à tentativa de repassar para as máquinas a capacidade de visão, não referindo-se somente ao ato de captação de cenas digitais de figuras, fotos ou vídeos, pois esta ciência faz a utilização da visão de um dispositivo informatizado fazendo com que o mesmo consiga enxergar o meio à sua volta para extração de importantes informações de imagens que possam ser capturadas por câmeras, scanners, sensores dentre vários outros dispositivos interessantes. Porém, este paradigma possibilita fazer o reconhecimento e a manipulação através da análise dos objetos internos. Em meados de 1970, surgiram as primeiras pesquisas relacionadas ao estudo de Visão Computacional juntamente com Inteligência artificial, e nesta época, os estudiosos acreditavam na probabilidade de realizar a representação total desta em um curto intervalo de tempo, e dentre os estudos realizados destacaram-se bastante as pesquisas com os temas *The Psychology of computer Vision* e *A framework representing knowledge* no ano de 1975, mas, no decorrer dos anos com os aparecimento de novos estudos, pôde-se observar que o nível de complexidade era bem extenso em relação ao que os cientistas imaginavam. Isso devido às poucas informações e modelos de representação da forma de interpretação das imagens do cérebro humano e da capacidade do olho humano de fazer a interpretação de objetos visuais rapidamente através do córtex visual cerebral, que é uma das partes de difícil compreensão no sistema de processamento. De acordo com Neves, Vieira e Gonzaga (2012):

“A Visão Computacional procura integrar as áreas do processamento digital de imagens e inteligência artificial, tendo como objetivo a obtenção de algoritmos capazes de interpretar o visual de imagens. Suas aplicações estão presentes em diversos segmentos tecnológicos que envolvem análise de imagens, reconhecimento de padrões e controle inteligente, abrangendo múltiplas áreas do conhecimento, tais como agronomia, astronomia, biologia, biometria, medicina e muitas outras. Constitui, portanto, uma área multidisciplinar com muitas aplicações práticas” (NEVES, VIEIRA NETO, GONZAGA, p. 1, 2012).

Entretanto, alguns cientistas do Instituto de Tecnologia de Massachusetts (MIT), concentram suas pesquisas na tentativa de compreender o funcionamento desta parte do cérebro para tentar encontrar novas ideias para esta área. Assim sendo, a Visão Computacional mostra



através de um dispositivo informatizado uma variedade de informações importantes a partir de imagens, fazendo com que o computador consiga executar tarefas inteligentes através de simulações que tentam alcançar a inteligência humana, pois suas aplicações na maioria das vezes são provenientes da resolução de uma infinidade de problemas de pesquisa de outras áreas de estudo conhecidos como sistemas especialistas que precisam de um conhecimento específico para uma solução. Porém, não existe um modelo padrão bem definido que implemente aplicações deste tipo. No mais, todos os sistemas desta área envolvem reconhecimento de objetos em imagens e transformações destes em informações que serão processadas e utilizadas para um determinado fim específico. Existem muitas funcionalidades comuns em boa parte destes softwares como a aquisição de uma ou mais imagens através de sensores de câmeras, onde os pixels indicam coordenadas de luz e propriedades físicas, podendo estas serem bidimensionais, tridimensionais ou organizadas em sequências, que é o passo inicial para que um sistema funcione. Uma outra funcionalidade importante, é o pré-processamento, que é um processo realizado antes da obtenção de informações de referência da imagem, de forma a aplicar os próprios métodos para facilitar a identificação de elementos como destaque de contornos, de bordas e de figuras. Existe também a extração de características matemáticas como textura, bordas e formatos de movimento, além da detecção e segmentação na qual o processo realizado para destacar as regiões de importância segmenta a imagem para um processamento posterior de alto nível que inclui a validação da satisfação dos dados obtidos, as estimativas de parâmetros relacionados a imagem, que é um avanço em termos de usabilidade e acessibilidade, pois o processo de rastreamento do olhar (NEVES, VIEIRA NETO, GONZAGA, 2012). Outros autores em seu artigo também afirmam o seguinte em relação aos conceitos de Visão Computacional:

“Uma das primeiras menções sobre Visão Computacional data de 1955, onde Selfridge destacou “... eyes and ears for the computer” (DAVID, SELFRIDGE, TELEPHONE apud MILANO, HONORATO, p. 1, 1962).

Então, a identificação de objetos em uma imagem é uma tarefa simples, pois o cérebro faz o processamento quando esta é captada pelos olhos, e em poucos segundos, o ser humano consegue identificar os elementos presentes. Já no caso das máquinas é diferente, pois além da qualidade das imagens captadas precisarem ser proporcionais à qualidade do equipamento utilizado, estas interpretam a imagem como uma matriz onde cada uma das posições é responsável pelo carregamento de um determinado valor que é convertido e um sinal de luz quando a imagem é mostrada. A Visão Computacional dedica seus esforços ao propósito de



fazer com que as máquinas interpretem as imagens capturadas semelhante ao ser humano. Segundo Ballard e Brown (1982):

“Visão Computacional é a iniciativa de automatizar e integrar uma ampla gama de processos e representações utilizadas para a percepção visual. Ela abrange partes de muitas técnicas úteis por si só, tais como processamento de imagem (transformação, codificação e transmissão de imagens) e classificação de padrões estatísticos (teoria da decisão estatística aplicada a padrões gerais, visuais ou não). Mais importante para nós, ele inclui técnicas para modelagem geométrica e processamento cognitivo.”

2.3 Redes Neurais Artificiais

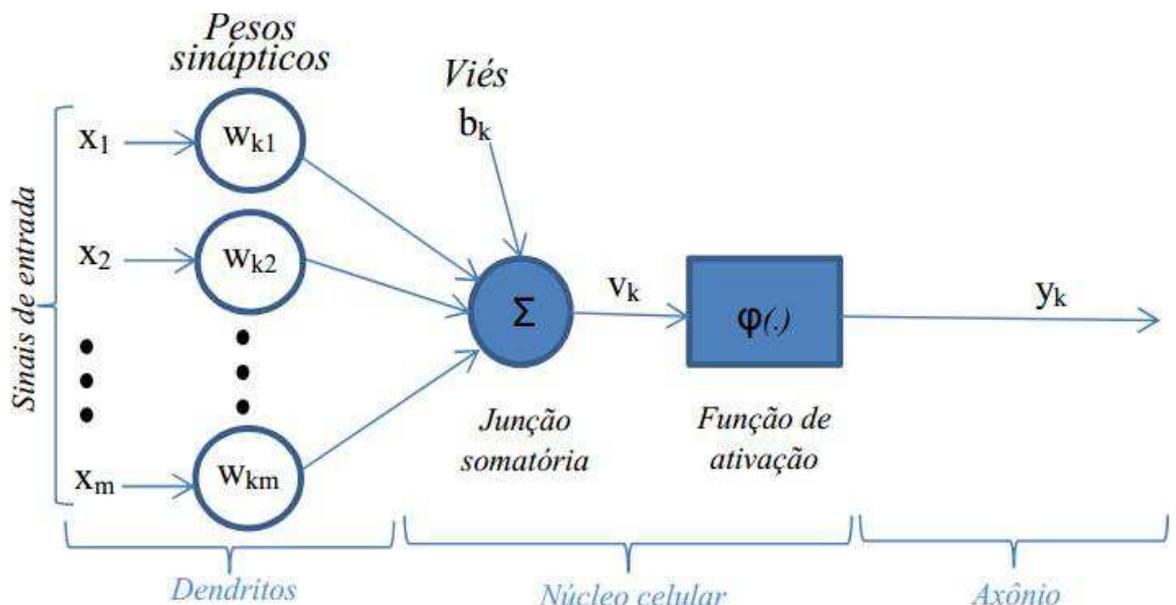
De acordo com Rauber (2005), uma das áreas mais fascinantes de pesquisa relacionada à utilização de inteligência artificial, é voltada para a simulação das capacidades cognitivas humanas através utilização de máquinas, que estão se tornando cada vez mais capazes de exibir um comportamento inteligente com uma grande semelhança às reações de pessoas. O ser humano possui a inteligência mais avançada do universo dos seres vivos, e a fonte dessa inteligência está localizada dentro do seu corpo, que é o cérebro, e as entidades básicas do mesmo são os neurônios que se encontram interconectados em redes que permitem a troca de informações entre eles, criando assim uma mentalidade biológica, que é uma das principais ambições da ciência através realização de experimentos computacionais que tentem se assemelhar ao máximo ao funcionamento do pensamento humano em um determinado ambiente técnico simulado, ou seja, os pesquisadores tentam entender como funciona a inteligência que habita nos neurônios para tentar mapeá-la de acordo com uma estrutura artificial que possa, por exemplo, fazer a combinação de hardware e software para transformar as redes neurais biológicas sem modelos. Já existe uma extensa quantidade de protótipos de redes neurais artificiais juntamente com métodos associados para a adaptação de tarefas humanas que serão executadas pela máquina computacional, mas um aviso prévio é o fato no qual esses modelos ainda não apresentam muita semelhança com os seres humanos, mas por outro lado, há um paralelismo entre os dois mundos que tem evoluído com frequência, sendo uma esperança para o futuro na resolução de problemas cognitivos de alta complexidade.

Segundo Haykin (2009), uma Rede Neural Artificial (RNA) é uma máquina projetada para modelar a maneira como o cérebro realiza uma tarefa em particular, e normalmente é implementada pela utilização de componentes eletrônicos ou simulada digitalmente através de uma linguagem de programação, sendo também um processador maciçamente e paralelamente distribuído e constituído de unidades de processamentos simples, cujo o objetivo é armazenar conhecimentos experimentais, tornando-os disponíveis para a utilização. Todavia, de acordo

com FLECK et al. (2016), a realização desta tarefa só será útil com a utilização de um meio computacional através de um processo chamado aprendizagem. A **figura 1** apresenta um exemplo de um neurônio artificial onde:

- X_i : São os valores de entrada do neurônio, que correspondem aos impulsos nervosos externos de um neurônio biológico provenientes do ambiente, em que $j = 1, 2, \dots, m$;
- m : É o número de valores de entrada, que corresponde ao número de dendritos;
- W_{kj} : Pesos sinápticos que correspondem à importância que o neurônio k atribui ao respectivo valor de entrada X_j ;
- K : É o identificador do neurônio em questão;
- b_k : É um valor que atua como um viés;
- Σ : É a função de junção somatória de todos os valores de entrada X_j ponderados pelos seus respectivos pesos W_{kj} ;
- V_k : É o resultado da função de junção somatório Σ , chamado de campo local introduzido ou potencial de ativação;
- $\varphi(\cdot)$: é a função de ativação do neurônio k ;

Figura 1 - Estrutura de um neurônio artificial análoga um neurônio biológico.



Fonte: Haykin (2009).

A aprendizagem através de um conjunto de dados (também conhecido como *dataset* de dados) é um dos principais aspectos da utilização das Redes Neurais artificiais, destacando-se



também, as principais tarefas nas quais estas são aplicadas como, por exemplo, a classificação, a categorização, a aproximação, a previsão e a otimização que são muito importantes no processo de análise de dados baseadas em padrões já existentes. Existe uma infinidade de aplicações que utilizam estas técnicas em sua estrutura de acordo com um determinado objetivo.

A **tabela 1** apresenta alguns dos métodos de aplicações mais relevantes que são utilizados com frequência e que podem ser executados através de uma rede neural em determinados contextos que são a Classificação, que é bastante utilizada também nos modelos redes profundas, a Categorização e a Previsão que são de extrema importância para realização das tarefas.

Tabela 1 - Possíveis tarefas de uma rede neural.

TAREFAS	APLICACÕES
Classificação	- Reconhecimento de caracteres;
	- Reconhecimento de imagens;
	- Diagnóstico (médico, equipamentos etc.);
Categorização	- Análise de risco de crédito, detecção de fraudes;
	- Detecção de falhas em sistemas industriais.
	- Agrupamento de sequências de DNA;
Previsão	- Mineração de dados;
	- Análise de expressão gênica;
	- Agrupamento de clientes.
	- Previsão do tempo;
	- Previsão financeira;
	- Modelagem de sistemas dinâmicos;
	- Previsão de sequências de DNA

Fonte: Medeiros (2018).

Entretanto, estes tipos de sistemas exigem um alto poder computacional que sempre estarão sujeitos a falhas durante os testes de execução, como por exemplo, simular as atividades visuais através do reconhecimento da imagem de uma pessoa, que são experiências adquiridas com o tempo. Com o passar dos anos, pesquisas relacionadas a construção de redes neurais têm

aumentado significativamente com uma grande diversidade de tipos de aplicações nas quais se destacam as redes neurais *feedforward*, que utiliza um simples algoritmo de treinamento conhecido como *Backpropagation*.

Durante vários anos, estudiosos focaram na ideia de simular o cérebro humano em todo o seu potencial chegando a criar um modelo computacional que copiasse o comportamento fisiológico deste, e para isso foram utilizados neurônios artificiais muito parecidos com os do homem que se interligavam para construir redes capazes de realizar tarefas cognitivas semelhantes às do cérebro. Todavia, é possível definir uma Rede Neural como um rígido processador bem distribuído e organizado com muitas unidades de processamento simples propensos a armazenar conhecimentos experimentais fazendo com que estes sejam possíveis de executar.

2.3.1 Redes Neurais Convolucionais

Uma Rede Neural Convolutiva, do inglês *Convolutional Neural Networks* (CNN), caracteriza-se como uma classe das redes neurais artificiais (Lecun, et al., 1998), que possuem uma grande eficácia na resolução de problemas de classificação, sendo uma técnica exequível em relação às tradicionais, que utiliza modelos de aprendizagem baseados no cérebro humano, sendo aplicada principalmente à análise de imagens relacionadas a classificação da forma matricial, reconhecimento de vídeos, segmentação de imagens dentre outras importantes áreas como, por exemplo na utilização de sistemas de recomendação e interface cérebro-computador.

Contudo, uma das desvantagens da utilização destas redes, está no fato da necessidade de rotulações de grandes quantidades de imagens para que se possa realizar a extração de padrões. Para isso, poderão existir três componentes básicos que são a camada de convolução, o *pooling* e a rede totalmente conectada, visto que a arquitetura básica de uma rede neural convolutiva possui esses elementos em sua estrutura.

Segundo Santos (2017), a camada de convolução utiliza perceptrons multicamadas que fazem a conexão total das redes onde cada um dos neurônios de uma camada se encontra conectado aos demais da próxima camada. Porém, o agrupamento dessas redes possui uma tendência a causar um *overfitting* (sobre ajuste) onde o modelo poderá se ajustar estatisticamente ao conjunto de dados analisado, mas não terá mais uma previsão eficaz dos resultados de novos testes. É uma técnica de aprendizagem profunda (*Deep learning*) que foi desenvolvida para resolver problemas de uma variedade de dados bidimensionais que se baseiam no funcionamento da estrutura do córtex visual humano conhecidas como campos

receptivos que fazem a ativação de vários neurônios, apresentando um nível de sobreposição em relação aos campos receptivos dos mais próximos.

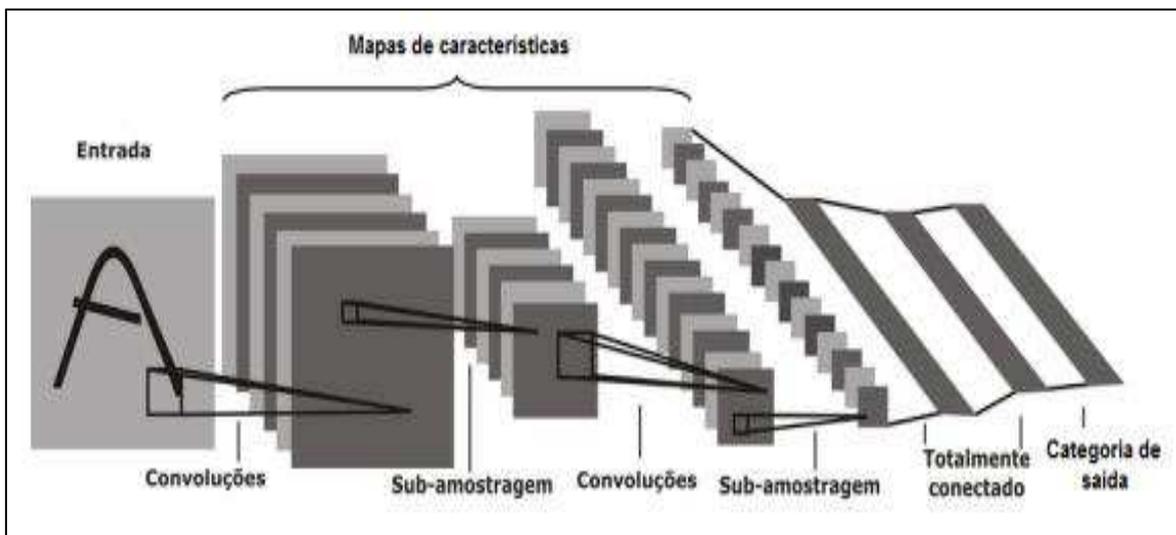
A atuação do cérebro humano serviu de grande incentivo para construção de sistemas de extração de características específicas de um conjunto de dados, fazendo a junção de arquiteturas com objetivo de deslocamento, escala e distorção.

De acordo com Santos (2017), alguns aspectos importantes destas arquiteturas de redes neurais convolucionais são:

- Mapeamento de características ou campos receptivos locais como um dos pontos mais similares em relação às redes neurais biológicas garantindo assim mais robustez nas distorções locais;

Pesos compartilhados que permitem a realização de uma redução dos parâmetros livres e invariância geométrica; Subamostragem temporal ou espacial, que diminuem o tamanho total dos mapas de características da camada inicial à última camada somente com valores de uma única dimensão, tornando-as equivalentes desse ponto em diante a uma rede neural MLP. A **figura 2** apresenta um esquema relacionado a visão geral do funcionamento de uma Rede Neural Convolucional.

Figura 2 - Visão geral de uma Rede Neural Convolucional.



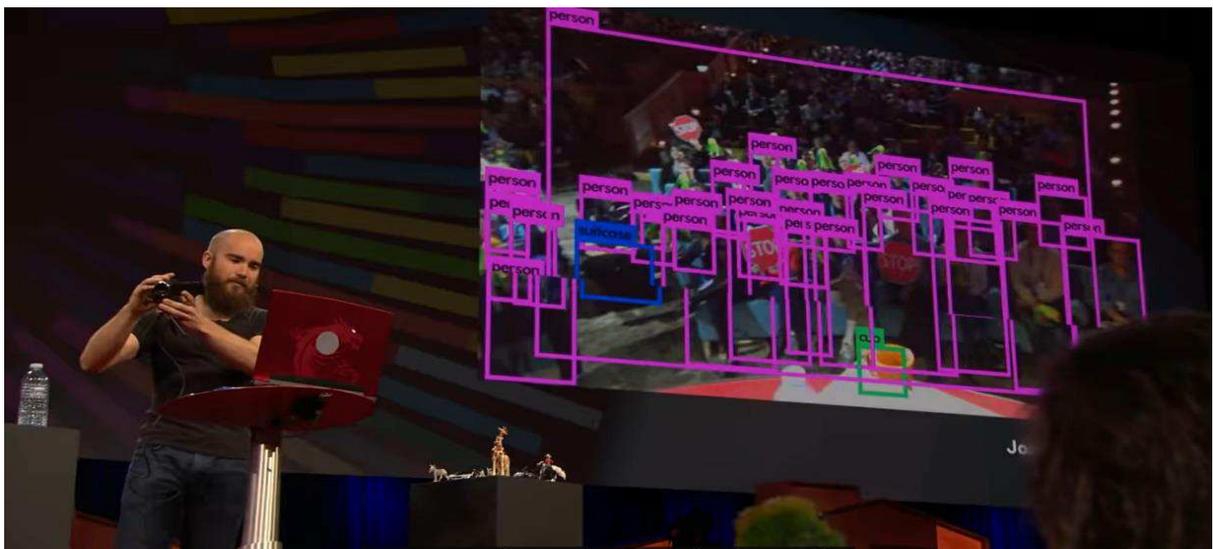
Fonte: Santos (2017).

2.3.1.1 O algoritmo YOLO

O YOLO é uma ferramenta de Visão Computacional lançada em 2015 por Joseph Redmon que fez uma demonstração ao vivo da primeira versão em uma palestra na *TED Talks*,

e por Ali Farhad durante o seu doutorado, que foi reconhecida como uma técnica inovadora com uma nova abordagem capaz de obter uma precisão igual ou muito superior a outros métodos de detecção de objetos, pois utiliza o conceito de passada única (*single pass*) e apresenta uma estrutura de convolução que atua como um extrator de características (*features*), que se distingue dos algoritmos antigos da mesma categoria, como o R-CNN ou Faster R-CNN pelo fato de o mesmo precisar analisar a imagem uma única vez, e após isso enviar as características exploradas para a rede neural convolucional. Devido a isso, recebe como nome as primeiras letras abreviadas da palavra “*You Only Look Once*”, que traduzida do inglês significa “Você olha somente uma vez”. Na **figura 3**, durante a palestra na *Ted Talks*, Redmon conseguiu demonstrar que o YOLO é capaz de executar em sua GPU uma detecção ou classificação com até 80 classes de objetos simultâneos com uma taxa de aproximadamente 30 FPS com uma ótima precisão, o que se caracterizou como uma grande inovação (Alves, 2020).

Figura 3 -Demonstração de funcionamento do YOLO por Redmon na Ted Talks.



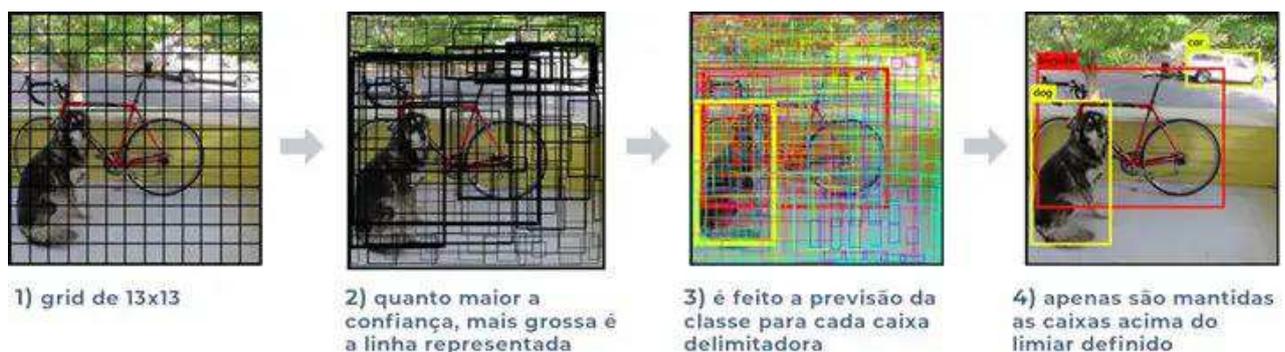
Fonte: Redmon (2015).

Este grande aspecto deste método que possui a capacidade de fazer uma detecção ou uma classificação mais rápida, mais eficiente e com um bom nível de precisão em relação às demais técnicas concorrentes, fez com que o YOLO conquistasse um espaço considerável no meio científico, pois enquanto os métodos mais precisos levavam aproximadamente 0.5 segundos (ou mais) por exemplo, para realizar o processamento de uma imagem, a ferramenta processava com o mesmo nível de precisão em um tempo inferior a 0.05 segundos, permitindo assim a sua utilização em aplicações de tempo real, além de ter uma capacidade de execução

de taxas de 30 frames por segundo e ser de código aberto, livre de licenças de uso desde o programa fonte, até a arquitetura de rede neural utilizada juntamente com os pesos rotulados ou pré-treinados, sendo considerado uma das ferramentas mais rápidas no quesito detecção de objetos, pois possui uma maior acurácia de execução em tempo real em experimentos realizados em *datasets* (*MS COCO* e alguns outros), e em apenas 5 anos após o seu lançamento, a ferramenta já obteve a sua quarta (Alves, 2020) e quinta versões oficiais publicadas.

O funcionamento do método YOLO é através de um processo de detecção, classificação dentre outras técnicas aplicadas a objetos em um simples problema de regressão, onde primeiramente o algoritmo faz a divisão da imagem em um grid constituído por células com tamanho $S \times S$ que pode ser alterado de acordo com a versão, onde cada uma destas divisões é responsável pela realização da predição, utilizando caixas delimitadoras ou um método de classificação sobre cada um dos objetos identificados, além de mostrar uma pontuação de confiança (na detecção) e de precisão (na classificação) que, após a análise preditiva demonstra o quanto de certeza está relacionada à existência das categorias de uma ou mais classes capturadas por um *bouding box* ou na porcentagem de precisão, funcionando assim como um classificador no qual é fornecido um valor de probabilidade para cada uma das classes possíveis, onde há a combinação das confianças para a caixa delimitadora com a predição categórica em uma pontuação final, que vai afirmar a possibilidade da existência de um objeto específico. Uma observação que deve ser feita em relação a utilização da rede neural YOLO, está no fato desta considerar de forma eficiente somente caixas de detecção com uma pontuação final mínima de 30%, que é o valor limiar conhecido como *threshold*, que pode ser modificado de acordo com a precisão. Valores encontrados abaixo deste percentual poderão não ser encontrados, pois as caixas não encontrarão o objeto e não farão a delimitação da(as) categoria(as) aplicadas às imagens durante a realização dos experimentos.

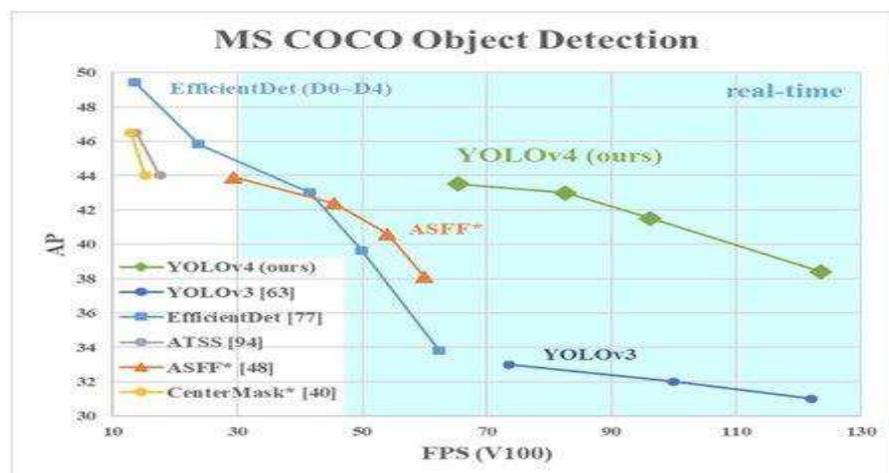
Figura 4 - Problema de regressão para detecção de objetos com YOLO.



Fonte: Alves (2020).

Como citado anteriormente, Joseph Reimond apresentou a primeira versão do YOLO “*You Only Look Once: Unified, Real-Time Object Detection*” que havia sido publicada por ele juntamente com o doutorando Ali Farhadi em um paper em julho do ano de 2015. Posteriormente, foram introduzidas a segunda versão da ferramenta no ano de 2016 intitulada como YOLOv2 no segundo paper com o título “*YOLO9000: Better, Faster, Stronger*”, a terceira em abril de 2018 com o tema “*YOLOv3: An Incremental Improvement*“, que demonstrou uma considerável melhoria na eficiência e na predição, porém não era tão rápida como a versão anterior, o que possibilitou predizer uma imagem em 3 escalas diferentes, resolvendo assim o problema da versão anterior que era a dificuldade de realização de reconhecimentos de objetos muito pequenos em imagens, o que era o principal motivo da pouca velocidade em relação a seu antecessor, exigindo também mudanças na arquitetura e no funcionamento, e tornando o processamento bastante pesado. Foi então que no ano de 2020, surgiu penúltima versão conhecida como YOLOv4 publicada no paper “*YOLOv4: Optimal Speed and Accuracy of Object Detection*” por Alexey Bochkovskiy e Chien-Yao Wang e Hong-Yuan Mark Liao, destacando como melhores aspectos a melhoria da velocidade de inferência e da acurácia e precisão em relação às demais versões, além de ser bem mais eficiente e poder rodar em GPUs (Graphics Processing Units), sendo otimizada para utilizar uma menor quantidade de memória, demonstrando ser o melhor detector de objeto para experimentos em tempo real de acordo com as métricas do *MS COCO*, um conhecido *dataset* que é utilizado para a avaliação de sistemas que fazem a detecção ou classificação de objetos em imagens. A **figura 5** apresenta um gráfico comparativo entre o YOLOv4 e algumas das outras versões (Alves, 2020).

Figura 5 – Comparação do YOLOv4 com outras versões.



Fonte: Alves (2020).

Várias abordagens relacionadas à resolução de problemas de detecção de objetos surgiram no decorrer dos anos, como, por exemplo a técnica *Haar Cascades* que foi considerada a primeira a obter resultados satisfatórios que pudessem ser implementados em aplicações executadas em tempo real, e a HOG (*Histogram of Oriented Gradients*), que foi considerada também bem eficiente. Porém, com o grande crescimento do aprendizado profundo, surgiram várias técnicas baseadas em Redes Neurais Convolucionais.

A grande vantagem do YOLO em relação aos demais métodos, está no fato deste conseguir fazer previsões da classe com uma única passada de imagem nas redes, diferentemente de outros sistemas de detecção de objetos, que faziam a detecção dividindo a imagem em várias partes e executando o classificador em cada pedaço.

O YOLO utiliza também em seu funcionamento uma rede neural profunda de código aberto, cuja arquitetura é conhecida como *Darknet*, que é utilizada principalmente para detecção de objetos, e é bem mais rápida em relação a outros frameworks de aprendizado profundo, sendo uma estrutura especializada em velocidade e precisão quando utilizada juntamente com o YOLO, chegando a obter em até 500 vezes maior velocidade em GPUs.

2.3.1.2 O algoritmo YOLOv5

Após o lançamento do **YOLOv4**, Glenn Jocher, pesquisador e CEO da *Ultralytics* da LCC publicou em 18 de maio de 2020 o **YOLOv5**, através framework *Pytorch*, que é a versão mais atualizada da aplicação, para evitar conflitos de nomenclatura com as antigas versões. Todavia, o novo algoritmo não é oriundo do versionamento anterior que era baseado no *Darknet*, que é uma biblioteca de aprendizagem de máquina escrita em C com suporte à CPU, GPU e CUDA, rápida de fácil instalação, que utiliza o mesmo nome do framework usado na implementação do detector, que foi desenvolvida pelo próprio Joseph Redmon.

No **YOLOv5** foram adicionados alguns recursos e alguns aprimoramentos voltados para a integração do estado da arte para redes de aprendizagem profunda, através de funções utilizadas para o aumento de dados que foram adotados de forma parcial da versão anterior, no caso o **YOLOv4** (Bochkovskiy et al., 2020). Esta versão é extremamente eficaz quando utilizada no processo de classificação de qualquer imagem pequena após a realização do treinamento.



2.4 Trabalhos relacionados

O processo de encontrar soluções para estudo de Libras através da utilização de tecnologias da informação aplicadas aos conceitos de linguagem de sinais visando uma melhor aprendizagem, é um conhecimento recente, porém já existem alguns trabalhos científicos relacionados à área. A complexidade da construção de redes neurais dependerá do tipo do problema em questão, pois o treinamento poderá ou não ser demorado, sem contar que após os resultados, a probabilidade da ocorrência de erros poderá ser alta ou baixa. No entanto, quando os resultados são satisfatórios, a detecção e a classificação de imagens se tornam bastante produtivas, possibilitando assim que a identificação do objeto estudado seja bastante eficiente, fazendo com que os testes sejam de grande produtividade após a execução da aplicação (Alves, 2020).

A ocorrência da dificuldade de aprendizagem de Libras no contexto educacional e social é algo visível, e devido a isso, o surgimento destas técnicas baseadas em redes neurais são úteis para a população (Bastos, 2015). Diversos trabalhos científicos relatam a utilização destas tecnologias computacionais baseadas em aprendizagem de máquina incorporadas ao processo de ensino, que são de extrema relevância para o público surdo e para pesquisadores científicos de tecnologias computacionais de linguagem de sinais, que visem desenvolver aplicações digitais para esta comunidade. Os trabalhos variam de acordo com o contexto no qual as técnicas são aplicadas.

Em Pavan, Ossada, Modesto (2010), é utilizada uma metodologia capaz de realizar o reconhecimento de sinais com o objetivo de extrair características da mão segmentada de imagens dinâmicas para identificação de padrões de Libras pelos usuários, com a utilização de filtros específicos de processamento de imagens, nos quais os dados especificados poderão ser comparados aos modelos pré-estabelecidos na aplicação, reproduzindo em seguida textos ou áudios de letras identificadas pelo mecanismo através da comparação de dados e informações extraídas, possibilitando assim a execução do software em algumas áreas como educação e entretenimento por exemplo, além de melhorar a comunicação dos surdos usuários da aplicação. No entanto este trabalho utilizou imagens em extensões .jpg, que poderiam ou não ser capturadas por uma webcam, e vídeos gerando assim um baixo custo computacional. Já em Santos (2011), foi proposto um sistema de reconhecimento de sinais de mãos humanas através da captura, do processamento e da extração de um vetor de características de imagens de vídeo utilizado por uma Rede Neural Artificial treinada para o reconhecimento do alfabeto de Libras

através de uma câmera ligada ao computador. O sistema foi desenvolvido na linguagem de programação C juntamente com a biblioteca OpenCV utilizada na construção de aplicativos com visão computacional. Os resultados apresentaram condições nas quais o algoritmo mostrou bons desempenhos na interação humano-computador, pois os testes foram realizados em ambientes com boas condições nas quais o sistema pôde obter uma ótima performance, com execuções precisas e eficientes sem o auxílio de luvas ou dispositivos que possam facilitar a identificação das mãos humanas, focando sempre nas melhores formas de identificação das imagens com um fundo simples e homogêneo, onde as características são obtidas em quadros capturados em intervalos regulares para que a variação do posicionamento da mão seja reconhecida, e após isso, o intervalo de tempo de captura dos quadros foi analisado para que o sistema obtenha o melhor desempenho possível. O trabalho de Queifer (2019), apresenta uma estratégia para acionamento de objetos na detecção de sinais manuais utilizando o algoritmo *HAAR CASCADE* juntamente com redes neurais convolucionais, onde são utilizadas técnicas de visão computacional com internet das coisas que buscam fazer a interpretação de cenários de imagens capturadas através de um *Raspberry PI* com uma câmera integrada dispositivo computacional. O foco no caso, foi o desenvolvimento de um protótipo para aquisição de sinais emitidos por sinais de mãos através de uma webcam ou imagens de sinais com extensões png, ou .jpg adquiridas ou não através de câmeras digitais para fazer o acionamento e a detecção destes objetos através da utilização do algoritmo, observando qual destes possuirá o melhor desempenho em imagens de vídeo em tempo real.

A utilização do classificador *Haar*, é uma abordagem que apesar de ser utilizada no contexto de aprendizagem de máquinas, são extremamente lentas se comparadas às novas tecnologias de Visão Computacional atuais, pois o treinamento através deste método é realizado com várias imagens onde são extraídos os recursos desta técnica imagem por imagem, adaptando os classificadores para realizar a detecção dos objetos. Já existem modelos no quais é possível a aplicação de uma única rede neural às imagens por completo para realização de suas previsões (Base app, 2018).

No trabalho de Santos (2020), foi desenvolvido um sistema de reconhecimento de sinais e ações em tempo real baseado em Visão Computacional com o objetivo de investigar e propor alguns mecanismos que pudessem além de conhecer, fazer a antecipação de sinais dinâmicos com ações baseando-se em vídeos em RGB. Foram apresentadas seis propostas principais onde duas destas eram para a representação de movimento em um vídeo, outra para antecipação de ações, a seguinte para antecipar sinais e as duas últimas para reconhecer e antecipar sinais de



Libras online em ambientes com uma câmera ou várias câmeras. A validação das propostas foi realizada através de experimentos cujos resultados foram comparados com várias linhas de base, e após os testes, observou-se que modelos que utilizaram somente vídeos RGB também são efetivos quando comparados a dados multimodais para o reconhecimento de sinais de Libras, e que também a escolha empírica da informação de contexto é eficiente na separação entre classes com movimentos ambíguos, principalmente em pequenos conjuntos de dados e que na tarefa de antecipação, a incerteza sobre a predição do teste é um modelo limiar e eficaz e mais confiável do que a probabilidade por ele estimada, com tempos de execução viáveis e mais confiáveis do que a probabilidade estimada. Na pesquisa de Bastos (2015), foram utilizados métodos de reconhecimento de sinais de Libras através de vetores de características resultantes das aplicação de descritores voltados para as formas e contornos presentes em imagens utilizando redes neurais, onde foi aplicado um classificador Perceptron Multicamada disposto em uma arquitetura na qual o processo de classificação foi dividido em dois estágios, com o auxílio de especialistas em linguagens de sinais e alunos surdos devido à escassez de conjuntos de dados públicos de Libras, fazendo com que a abordagem partisse então da criação de um *dataset* até a etapa final de classificação dos sinais, onde foram obtidos quase 96,77% de taxa de acerto, sendo que estes resultados foram validados considerando possíveis ameaças à abordagem como a realização de testes com um indivíduo não presente no conjunto treinado do classificador e a aplicação da abordagem em um conjunto público de dados de sinais.

Em Góes (2019), foi abordado o aperfeiçoamento de um sistema de padrões utilizado para a detecção do alfabeto de Libras utilizando uma luva com um sensor adicionando um sensor inercial e promovendo melhorias de hardware necessárias para suportar o processamento dos dados do sensor inercial. Para isso foi portado um código existente para o microcontrolador STM32F103C8T6, e houve a implementação de um sensor inercial MPU-6050, e posteriormente foi feita uma coleta de dados para treinamento e validação de um algoritmo de classificação além da utilização de um algoritmo de aprendizagem em Python para realizar o treinamento e as simulações que foram implementadas com esse microcontrolador. Foi realizado também o desenvolvimento de uma interface para visualização dos resultados da classificação e em seguida o sistema foi testado e validado a partir de uma quantidade de usuários, pois a metodologia deste trabalho foi separada na compreensão do funcionamento e na transferência do código para o novo microcontrolador, implementação do sensor inercial, processamento dos sinais, treinamento das redes neurais e implementação das redes já treinadas. Foram utilizados alguns hardwares físicos durante a pesquisa e como resultado, foi obtido um

sistema computacional com uma rede neural com uma capacidade de fazer o reconhecimento das letras do alfabeto com um percentual de acerto de 90,67%.

2.4.1 Considerações sobre trabalhos relacionados

A utilização de sinais no processo de comunicação, caracteriza-se como a expressão de significados de palavras através de sinais de ações não verbais utilizando as mãos, dedos, face e braços para interação humana por meio da linguagem de sinais. No decorrer dos anos, alguns trabalhos relacionados a utilização de visão computacional para detecção Libras têm sido publicados devido a elevada aplicabilidade dos conceitos de tecnologias da informação como suporte a alfabetização de surdos e afins. A opção de escolher quais técnicas utilizar para realização deste processo é bem ampla, podendo haver uma diversificação de qual estratégia utilizar para as pesquisas, pois existem inúmeros trabalhos que se baseiam em modelos estatísticos após a execução de testes.

O que diferencia este trabalho dos demais primeiramente, é que em vez de aplicar o método de detecção de imagens através da utilização de pequenas caixas delimitadoras conhecidas também como *bounding boxes*, foi utilizada a técnica de classificação de imagens que se baseia na precisão obtida a partir de um conjunto de dados formado por letras, números e palavras para treinamento através do algoritmo **YOLOv5-S**.

Para passar uma imagem para um modelo de inteligência artificial utilizado para receber a classificação, podemos citar como exemplo um ótimo exemplo o diagnóstico de exames de Raios-X. Através da radiografias de pulmões, um médico consegue fazer a identificação de um câncer no órgão do paciente, e mesmo que o cientista de dados não possua conhecimentos medicinais, no caso da existência de um determinado conjunto de dados específico de imagens de pulmões saudáveis juntamente com seus diagnósticos, é possível treinar o algoritmo do YOLOv5 para fazer esta classificação, e através do ajuste do modelo, é possível analisar a probabilidade de que um exame pulmonar possa apresentar câncer ou não baseado nos milhares de casos já classificados no *dataset* utilizado, auxiliando nos prognósticos médicos. Este é o principal propósito do método de classificação de imagens. O algoritmo utilizado em vez de extrair informações imagem por imagem durante o treino para a detecção, como é feita pela maioria das técnicas utilizadas pelos processos de detecções, utiliza um método conhecido como *single pass* (de passada única). Apesar do YOLOv5 ser famoso por ser um algoritmo de detecção de objetos que utiliza um método *single pass* através de uma rede neural convolucional que atua como extrator de características, que diferentemente dos algoritmos anteriores de

detecção, como *R-CNN* ou *Faster-R-CNN*, este precisa olhar apenas uma vez para a imagem para poder enviar suas características para a rede neural convolucional que faz a divisão das imagens em um sistema de grade onde cada célula é responsável por detectar objetos em si, sendo famoso por sua velocidade e precisão. Foram realizados alguns experimentos em algumas épocas de treinamento que serão abordados nas seções posteriores.

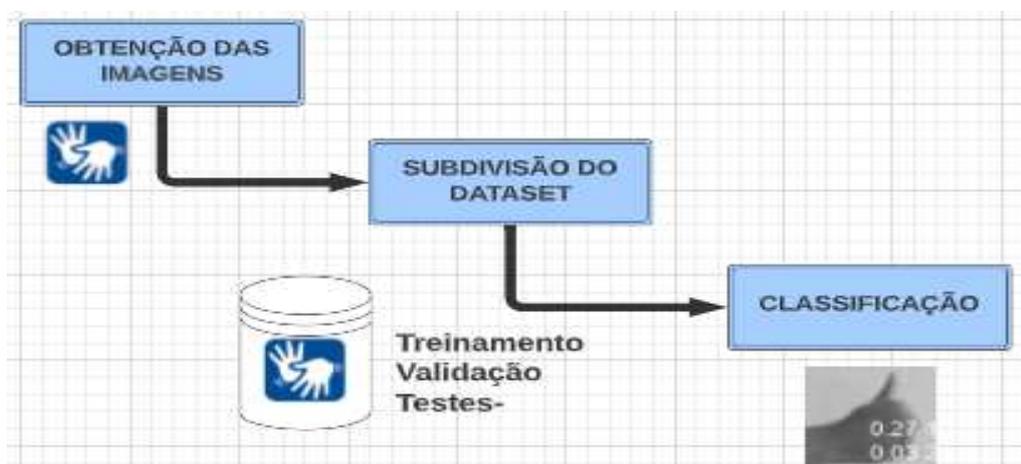
3 METODOLOGIA DE PESQUISA

Nesta seção são apresentadas as principais particularidades da metodologia que foi aplicada na construção deste trabalho. Inicialmente, foi realizada uma revisão das literaturas com conteúdos relacionados ao tema em questão que foram utilizadas para fundamentação desta pesquisa, que é de caráter experimental e descritiva.

Posteriormente, foi aplicada uma técnica de classificação de imagens de sinais de Libras extraídas de uma base de dados constituída de letras, números e palavras através de uma Rede Neural Convolucional, onde o principal objetivo foi identificar o que estava presente na imagem, pois o modelo procura compreendê-la através da atribuição de classificações provenientes dos treinamentos realizados no conjunto de dados utilizado. A utilização deste método foi dividida em etapas que foram importantes para a realização dos experimentos de acordo as épocas nas quais os testes foram realizados as seguintes etapas:

- Obtenção das imagens através do site *Roboflow* (Roboflow, 2021);
- Subdivisão do *dataset*;
- Realização dos testes Classificação através do YOLOv5.

Figura 6 – Fases do método aplicados à pesquisa

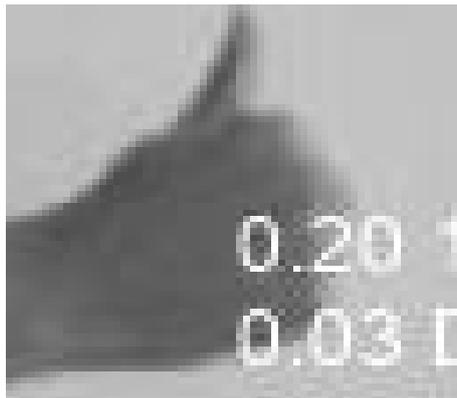


Fonte: O autor

3.1 Obtenção das imagens

O conjunto de dados das amostras de imagens de Libras foram adquiridas através do site *Roboflow*, que é uma empresa que auxilia desenvolvedores na construção de determinados modelos rápidos e precisos de visão computacional, além de disponibilizar uma infinidade destas bases de dados gratuitamente. Foi baixado e utilizado o dataset *Libras Computer Vision Project* com 8.455 imagens que estão divididas em um conjunto de treinamento (65% do total), um conjunto de validação (20% do total) e um conjunto de testes (15% do total). As imagens adquiridas estavam no formato JPEG com resolução 64 x 64 pixels e com composição de cores em preto e branco. O exemplo da **figura 7** faz parte das imagens obtidas durante a classificação, e a partir desta é possível visualizar os valores de algumas métricas atingidas.

Figura 7 – Imagens com métricas de classificação



Fonte: O autor.

3.2 Subdivisão do *dataset*

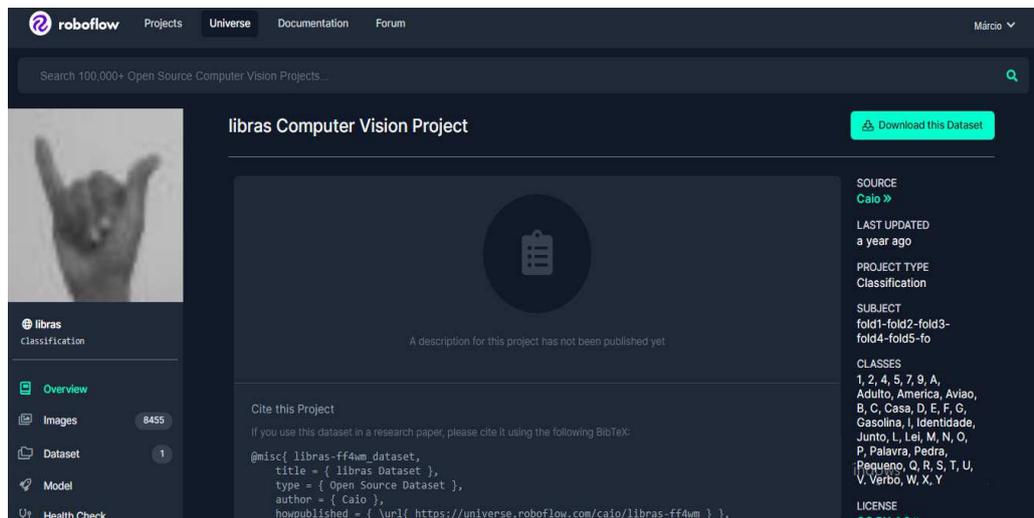
Para a realização da pesquisa, foi utilizada uma base de dados com imagens de sinais de Libras que foi disponibilizada pelo site *Roboflow*, que é uma grande referência em suporte a treinamentos e anotações de imagens, dentre vários outros mecanismos importantes para a comunidade científica que estuda redes neurais (Roboflow, 2021). Este *dataset* serviu como suporte para treinar as diretrizes necessárias para a experimentação científica, pois após este processo, foi possível a realização dos testes a partir da execução da rede neural. As 40 classes utilizadas para o treino são formadas por letras, números e palavras de acordo com a tabela a seguir:

Tabela 2 – Classes do conjunto de dados *Libras Computer Vision Project*.

CLASSES					
LETRAS			NÚMEROS	PALAVRAS	
A	M	V	1	Adulto	Pequeno
B	N	W	2	America	Verbo
C	O	X	4	Aviao	
D	P	Y	5	Casa	
E	Q		7	Gasolina	
F	R		9	Identidade	
G	S			Junto	
I	T			Lei	
L	U			Palavra	
				Pedra	

Fonte: Roboflow (2021)

Figura 8 – Base de dados no site do Roboflow.



Fonte: Roboflow (2021)

3.3 Arquitetura utilizada

Após a obtenção das imagens extraídas do site *Roboflow* com o fluxo de trabalhos de classificação de acordo com a padronização exclusiva do algoritmo de visão computacional aplicado, a versão mais apropriada para a realização dos testes foi a do **YOLOv5**, pois esta adiciona treinamentos de classificação, validação, previsão e exportação para modelos pequenos pré-treinados.

A versão inicial é de simples utilização, além de ser mais rápida e com grande eficiência em relação as demais versões (Alves, 2022). Portanto, foi feita uma análise das competências

da base utilizada para poder classificar imagens de sinais de Libras através da aplicação do algoritmo citado.

3.4 Ambiente utilizado para os experimentos

Para a execução dos testes, foi utilizado um ambiente virtual de programação de GPUs conhecido como *Google Colaboratory (Colab)* disponibilizado na nuvem pela *Google* nas versões gratuita ou paga (com mais recursos) que utiliza um terminal *Linux*. A arquitetura de rede neural utilizada foi uma versão do **YOLOv5-S** de classificação de imagens desenvolvida na linguagem *Python* pela plataforma site *Roboflow* (Robloflow, 2021).

A plataforma virtual online, possibilitou o desenvolvimento da rede neural, pois foi utilizado o acesso gratuito a uma versão do *Jupyter notebook*, que é uma importante interface de construção de softwares aplicada ao ensino e aprendizagem de várias linguagens, podendo ser executada simplesmente através de um navegador, com suporte às linguagens Python, R e Julia que são muito utilizadas na área de inteligência artificial.

O ambiente do *colab* também possibilita a criação de uma ou mais sessões nas quais o usuário poderá acessar na nuvem um processador com dois núcleos, 12 GBytes de memória RAM e cache L3 de 40-50 Mbytes, além de disponibilizar ao usuário acessos a GPUs e TPUs e a um terminal *Linux* que poderá ser configurado de acordo com a necessidade do usuário (Ferreira, Canescho e Carvalho, 2020). Foi utilizada a versão paga do *Colab pro* devido a eficiência da utilização de GPUs, que são extremamente rápidas e potentes para a realização de treinamento, classificação ou detecção de imagens de redes neurais.

Figura 9 - Informações da GPU utilizada durante os experimentos.

```
Sat Oct 8 18:54:45 2022
+-----+
| NVIDIA-SMI 460.32.03   Driver Version: 460.32.03   CUDA Version: 11.2   |
+-----+
| GPU  Name          Persistence-M| Bus-Id        Disp.A | Volatile Uncorr. ECC |
| Fan  Temp   Perf    Pwr:Usage/Cap|      Memory-Usage | GPU-Util  Compute M. |
|                                           MIG M.         |
+-----+-----+
|  0   Tesla T4             Off      | 00000000:00:04.0 Off  |           0          |
| N/A   41C    P8             9W / 70W |  0MiB / 15109MiB |    0%      Default  |
|                                           N/A              |
+-----+-----+

+-----+
| Processes:                                |
| GPU  GI    CI          PID  Type   Process name                      GPU Memory |
|   ID  ID    ID                   |              Usage                   |
+-----+-----+
| No running processes found              |
+-----+-----+
```

Fonte: O autor (2022).

3.5 Realização do experimento

Durante a experimentação, foram feitos alguns treinamentos da base de dados de Libras com as 40 classes citadas anteriormente através do algoritmo de redes neurais convolucionais **YOLOv5-S** em uma GPU do *Google Colab*. No primeiro treino foram executadas 100 épocas, posteriormente 500 épocas, e por último 1000 épocas.

4 RESULTADOS

Após os processos realizados através da execução do algoritmo de redes neurais convolucionais (YOLOv5), na base de dados de teste do experimento, foram gerados resultados nos quais foram apresentados parâmetros de especificação das classes juntamente com algumas métricas para descrever a precisão das tarefas de classificação que é dada pelo número de previsões corretas pelo total de previsões. São estes:

- **Class:** Refere-se as classes nas quais os testes foram realizados.
- **Images:** Quantidade de imagens presentes em cada uma das classes.
- **top1_acc:** É a precisão convencional referente à previsão do modelo com a maior probabilidade em relação a todos resultados, ou seja, deve ser a resposta esperada de forma exata. Faz a medida da proporção de exemplos para os quais o rótulo previsto irá corresponder ao rótulo de destino único.
- **top5_acc:** É a precisão relativa aos 5 principais resultados, ou seja, significa afirmar que qualquer um dos 5 resultados com maior probabilidade do modelo corresponderá à resposta esperada. Considera uma classificação correta se qualquer uma das 5 previsões corresponder ao rótulo de destino.

Os resultados obtidos nas tabelas a seguir são referentes aos treinamentos de 100, 500 e 1000 épocas da base de dados de Libras (*Libras Computer Vision Project*) através do algoritmo YOLOv5 executado através interface do google *colab*. Pôde-se observar algumas discrepâncias relacionadas às resultâncias atingidas após a realização dos testes. O resultado das tabelas a seguir são referentes à execução de 100 épocas da classificação dos casos de teste:



Tabela 3 – Classificação dos casos de teste (letras) - treinamento de 100 épocas.

CLASSIFICAÇÃO DOS CASOS DE TESTES			
<i>Class</i>	<i>Images</i>	<i>top1_acc</i>	<i>top5_acc</i>
A	32	0.844	1
B	30	0.933	1
C	36	1	1
D	34	0.971	1
E	34	1	1
F	30	0.967	1
G	32	0.938	1
I	36	1	1
L	33	0.97	1
M	33	0.97	1
N	33	1	1
O	39	0.949	1
P	9	0.556	1
Q	31	1	1
R	35	0.8	1
S	46	0.935	1
T	6	0	1
U	36	1	1
V	32	0.656	1
W	38	1	1
X	18	1	1
Y	45	0.978	1

Fonte: O autor (2022).

Tabela 4 - Classificação dos casos de teste (números) - treinamento de 100 épocas.

CLASSIFICAÇÃO DOS CASOS DE TESTES			
Class	Images	top1_acc	top5_acc
1	43	1	1
2	42	1	1
4	33	0.939	1
5	40	1	1
7	35	1	1
9	35	1	1

Fonte: O autor (2022).



Tabela 5 - Classificação dos casos de teste (palavras) - treinamento de 100 épocas.

CLASSIFICAÇÃO DOS CASOS DE TESTES			
Class	Images	top1_acc	top5_acc
Adulto	15	0.867	1
America	36	1	1
Aviao	36	1	1
Casa	39	1	1
Gasolina	36	1	1
Identidade	41	0.927	1
Junto	5	1	1
Lei	35	1	1
Palavra	31	1	1
Pedra	12	1	1
Pequeno	28	1	1
Verbo	28	1	1

Fonte: O autor (2022).

Os resultados abaixo, são referentes às predições de grupos com 6 e 7 imagens de acordo com cada letra, número e palavra utilizados durante os testes, onde são mostradas as imagens, as classes (CL) com os resultados de suas respectivas precisões (RP) e o tempo de execução de cada teste. Nestes primeiros resultados foram realizadas **100 épocas** de treinamento.

Tabela 6 - Classificação de um grupo de imagens com a letra **A** - 100 épocas.

Images	CL 1	RP1	CL 2	RP2	CL 3	RP3	CL 4	RP4	CL 5	RP5	T. exec.
1/7	A	0.12	S	0.07	I	0.06	L	0.05	Adulto	0.05	3.8 ms
2/7	A	0.34	B	0.05	E	0.04	S	0.04	N	0.03	3.9 ms
3/7	A	0.15	S	0.07	L	0.06	Adulto	0.05	G	0.05	3.8ms
4/7	A	0.07	I	0.07	R	0.06	A	0.06	Identidade	0.05	4.2 ms
5/7	I	0.07	A	0.06	G	0.05	L	0.05	Adulto	0.04	6.5 ms
6/7	A	0.08	U	0.05	I	0.05	G	0.05	S	0.05	4.2 ms
7/7	A	0.07	I	0.05	N	0.05	M	0.04	F	0.04	6.2 ms

Fonte: O autor (2022).

Tabela 7 - Classificação de um grupo imagens com a letra **B** - 100 épocas.

Images	CL 1	RP1	CL 2	RP2	CL 3	RP3	CL 4	RP4	CL 5	RP5	Temp. exec.
1/7	B	0.33	A	0.05	E	0.04	G	0.03	N	0.03	3.8 ms
2/7	B	0.34	A	0.04	G	0.04	E	0.04	U	0.03	3.8 ms
3/7	B	0.32	A	0.06	E	0.04	G	0.04	O	0.03	3.8 ms
4/7	B	0.29	A	0.06	E	0.05	O	0.03	G	0.03	3.9 ms
5/7	B	0.38	A	0.05	G	0.04	E	0.04	U	0.03	3.8 ms
6/7	B	0.08	R	0.07	I	0.06	U	0.06	Identidade	0.06	3.8 ms
7/7	B	0.11	R	0.07	I	0.06	E	0.05	Adulto	0.05	3.7 ms

Fonte: O autor (2022).

Tabela 8 - Classificação de um grupo de imagens com a letra **C** - 100 épocas.

<i>Images</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	C	0.38	Pequeno	0.04	O	0.03	S	0.03	D	0.02	3.8 ms
2/7	C	0.39	Pequeno	0.04	D	0.03	America	0.02	M	0.02	3.7 ms
3/7	C	0.17	O	0.10	Pequeno	0.05	Lei	0.03	5	0.03	4.0 ms
4/7	C	0.22	O	0.06	5	0.05	Pequeno	0.04	Adulto	0.03,	3.8 ms
5/7	C	0.16	D	0.06	Pequeno	0.05	5	0.04	O	0.04	3.8 ms
6/7	C	0.37	Pequeno	0.05	S	0.03	D	0.03	Adulto	0.03	3.7 ms
7/7	C	0.19	F	0.06	Pequeno	0.05	America	0.04	L	0.03	3.9 ms

Fonte: O autor (2022).

Tabela 9 - Classificação de um grupo de imagens com a letra **D** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 1</i>	<i>RP2</i>	<i>CL 1</i>	<i>RP3</i>	<i>CL 1</i>	<i>RP4</i>	<i>CL 1</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	D	0.33	L	0.05	U	0.05	F	0.04	R	0.04	3.9 ms
2/7	D	0.36	F	0.05	U	0.04	L	0.04	R	0.04	4.1 ms
3/7	D	0.27	L	0.05	U	0.04	R	0.04	F	0.04	3.8ms
4/7	D	0.26	F	0.05	L	0.04	R	0.04	U	0.04	3.8ms
5/7	D	0.31	F	0.04	U	0.04	L	0.04	R	0.03	3.8ms
6/7	D	0.35	U	0.05	F	0.04	R	0.04	L	0.04	4.0ms
7/7	D	0.35	F	0.04	U	0.04	R	0.04	L	0.03	3.9ms

Fonte: O autor (2022).

Tabela 10 - Classificação de um grupo de imagens com a letra **E** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	E	0.26	N	0.05	O	0.04	A	0.03	S	0.03	3.8ms
2/7	E	0.33	Adulto	0.05	A	0.04	A	0.04	L	0.03	3.8ms
3/7	E	0.29	N	0.06	S	0.04	B	0.04	O	0.04	3.7ms
4/7	E	0.25	O	0.04	A	0.04	N	0.03	S	0.03	3.7ms
5/7	E	0.22	A	0.05	O	0.05	B	0.03	N	0.04	3.8ms
6/7	E	0.31	Adulto	0.05	S	0.05	S	0.05	A	0.04	3.7ms
7/7	E	0.15	O	0.04		0.04	Adulto	0.03	B	0.03	3.8ms

Fonte: O autor (2022).

Tabela 11 - Classificação de um grupo de imagens com a letra **F** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	F	0.47	Pequeno	0.03	U	0.03	R	0.02	D	0.02	3.7ms
2/7	F	0.24	U	0.04	R	0.04	N	0.04	Pequeno	0.03	3.8ms
3/7	F	0.44	Pequeno	0.03	R	0.03	U	0.03	D	0.02	3.7ms
4/7	F	0.44	R	0.03	Pequeno	0.03	U	0.03	D	0.02	3.8ms
5/7	F	0.52	U	0.02	R	0.02	Pequeno	0.02	America	0.02	3.8ms
6/7	F	0.23	R	0.04	U	0.04	I	0.04	Pequeno	0.03	4.0ms
7/7	F	0.13	U	0.09	R	0.07	Pequeno	0.04	I	0.04	3.9m

Fonte: O autor (2022).

Tabela 12 - Classificação de um grupo de imagens com a letra **G** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	G	0.24	L	0.04	B	0.04	S	0.04	I	0.04	3.8ms
2/7	G	0.22	L	0.04	U	0.04	B	0.04	I	0.03	3.7ms
3/7	G	0.27	L	0.06	U	0.05	W	0.03	V	0.03	4.1ms
4/7	G	0.26	L	0.06	U	0.04	Y	0.04	V	0.03	3.8ms
5/7	G	0.12	I	0.07	U	0.07	R	0.05	L	0.04	3.9ms
6/7	G	0.15	U	0.08	I	0.06	V	0.06	L	0.05	3.7ms
7/7	G	0.08	Y	0.05	I	0.04	A	0.04	N	0.04	3.9ms

Fonte: O autor (2022).

Tabela 13 - Classificação de um grupo de imagens com a letra **I** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	I	0.17	S	0.06	Y	0.05	L	0.05	R	0.04	3.9ms
2/7	I	0.22	S	0.07	Y	0.04	N	0.04	R	0.03	4.0ms
3/7	I	0.20	S	0.05	U	0.05	R	0.04	L	0.04	4.0ms
4/7	I	0.20	S	0.04	U	0.04	O	0.04	R	0.03	3.9ms
5/7	I	0.25	B	0.05	S	0.05	U	0.04	R	0.04	4.0ms
6/7	I	0.21	S	0.05	R	0.04	, U	0.04	Adulto	0.03	4.0ms
7/7	I	0.11	R	0.08	U	0.06	Identidade	0.04	L	0.04	3.9ms

Fonte: O autor (2022).

Tabela 14 - Classificação de um grupo de imagens com a letra **L** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	L	0.22	G	0.05	U	0.03	Adulto	0.03	Y	0.03	3.8ms
2/7	L	0.24	U	0.04	Aviao	0.03	R	0.03	Pequeno	0.03	3.8ms
3/7	L	0.26	Pequeno	0.04	U	0.03	F	0.03	I	0.03	3.8ms
4/7	L	0.29	U	0.04	F	0.03	R	0.03	Pequeno	0.03	5.7ms
5/7	L	0.27	U	0.05	I	0.03	Adulto	0.03	S	0.03	4.2ms
6/7	L	0.24	G	0.06	U	0.04	Y	0.03	Adulto	0.03	3.7ms
7/7	L	0.30	U	0.05	G	0.03	I	0.03	Aviao	0.03	3.8ms

Fonte: O autor (2022).

Tabela 15 - Classificação de um grupo de imagens com a letra **M** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	M	0.32	N	0.07	C	0.04	E	0.03	Pequeno	0.03	3.7ms
2/7	M	0.43	N	0.10	Q	0.03	Pequeno	0.02	L	0.02	3.9ms
3/7	M	0.35	N	0.09	Q	0.04	O	0.03	B	0.03	3.9ms
4/7	M	0.24	N	0.07	Q	0.04	S	0.03	R	0.03	3.8ms
5/7	M	0.41	N	0.11	O	0.03	Q	0.03	E	0.03	3.8ms
6/7	M	0.13	9	0.07	N	0.05	Pequeno	0.05	C	0.04	3.9ms
7/7	M	0.24	N	0.07	Q	0.04	S	0.03	R	0.03	3.8ms

Fonte: O autor (2022).

Tabela 16 - Classificação de um grupo de imagens com a letra **N** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	N	0.54	E	0.03	A	0.02	M	0.02	B	0.02	3.9ms
2/7	N	0.56	M	0.03	E	0.02	A	0.02	B	0.02	3.8ms
3/7	N	0.51	A	0.03	M	0.02	E	0.02	B	0.02	3.9ms
4/7	N	0.57	M	0.03	E	0.02	A	0.02	B	0.02	3.9ms
5/7	N	0.55	M	0.03	E	0.02	A	0.02	B	0.02	3.9ms
6/7	N	0.54	M	0.03	E	0.02	A	0.02	B	0.02	3.8ms
7/7	N	0.16	M	0.10	I	0.04	S	0.04	B	0.04	3.8ms

Fonte: O autor (2022).

Tabela 17 - Classificação de um grupo de imagens com a letra **O** - 100 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	O	0.27	E	0.04	N	0.04	G	0.03	U	0.03	3.7ms
2/7	O	0.44	N	0.04	W	0.02	U	0.02	E	0.02	3.7ms
3/7	O	0.14	N	0.06	S	0.05	I	0.04	E	0.04	5.7ms
4/7	O	0.20	N	0.05	S	0.04	M	0.04	E	0.04	4.8ms
5/7	O	0.30	I	0.03	U	0.03	M	0.03	N	0.03	3.7ms
6/7	O	0.11	Adulto	0.06	I	0.05	R	0.05	A	0.05	3.7ms
7/7	O	0.10	Pequeno	0.05	D	0.05	R	0.05	F	0.05	3.7ms

Fonte: O autor (2022).

Tabela 18 - Classificação de um grupo de imagens com a letra **P** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	P	0.14	Pequeno	0.09	7	0.05	F	0.04	X	0.04	3.9ms
2/7	P	0.14	Pequeno	0.08	7	0.05	America	0.05	9	0.04	5.8ms
3/7	P	0.19	Pequeno	0.07	7	0.04	America	0.04	9	0.04	3.8ms
4/7	Pequeno	0.08	F	0.07	X	0.07	7	0.07	P	0.06	3.7ms
5/7	Pequeno	0.10	7	0.08	P	0.07	Gasolina	0.05	America	0.05	3.7ms
6/7	Pequeno	0.11	7	0.11	P	0.07	America	0.05	X	0.05	3.7ms
7/7	Pequeno	0.11	7	0.07	P	0.07	X	0.06	America	0.05	3.7ms

Fonte: O autor (2022).

Tabela 19 - Classificação de um grupo de imagens com a letra **Q** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	Q	0.26	N	0.10	M	0.10	R	0.03	S	0.03	3.9ms
2/7	Q	0.28	M	0.12	N	0.10	R	0.03	U	0.03	6.1ms
3/7	Q	0.27	M	0.11	N	0.10	R	0.03	S	0.03	5.6ms
4/7	Q	0.33	M	0.10	N	0.08	R	0.03	L	0.03	3.8ms
5/7	Q	0.22	N	0.10	M	0.09	R	0.03	B	0.03	3.8ms
6/7	Q	0.40	M	0.09	N	0.05	R	0.03	L	0.02	4.5ms
7/7	Q	0.34	M	0.09	N	0.06	R	0.03	B	0.02	3.9ms

Fonte: O autor (2022).



Tabela 20 - Classificação de um grupo de imagens com a letra **R** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	R	0.34	U	0.10	F	0.04	I	0.03	Pequeno	0.03	6.3ms
2/7	R	0.31	U	0.11	W	0.04	F	0.04	I	0.03	3.9ms
3/7	R	0.28	U	0.10	F	0.05	Pequeno	0.04	L	0.03	4.4ms
4/7	R	0.29	U	0.10	F	0.04	W	0.04	Pequeno	0.03	4.0ms
5/7	U	0.17	R	0.14	V	0.08	W	0.05	I	0.03	3.8ms
6/7	R	0.18	U	0.16	I	0.06	V	0.05	L	0.04	3.7ms
7/7	R	0.19	U	0.18	V	0.05	I	0.04	L	0.03	3.7ms

Fonte: O autor (2022).

Tabela 21 - Classificação de um grupo de imagens com a letra **S** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	S	0.33	E	0.04	N	0.04	Adulto	0.03	M	0.03	4.3ms
2/7	S	0.38	M	0.04	N	0.04	L	0.03	Y	0.03	3.8ms
3/7	S	0.14	A	0.11	I	0.06	L	0.05	Adulto	0.04	3.9ms
4/7	S	0.42	N	0.03	M	0.03	Y	0.03	W	0.03	4.0ms
5/7	S	0.12	L	0.07	I	0.05	U	0.05	Adulto	0.04	3.9ms
6/7	S	0.25	R	0.04	M	0.04	N	0.04	U	0.03	4.2ms
7/7	S	0.31	L	0.04	Adulto	0.04	I	0.03	Y	0.03	3.8ms

Fonte: O autor (2022).

Tabela 22 - Classificação de um grupo de imagens com a letra **T** - 100 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/6	T	0.08	F	0.17	I	0.04	R	0.04	5	0.03	3.7ms
2/6	T	0.10	F	0.15	R	0.04	I	0.03	5	0.03	3.7ms
3/6	T	0.04	F	0.11	Palavra	0.04	5	0.04	U	0.04	3.8ms
4/6	T	0.06	F	0.12	Palavra	0.04	5	0.04	I	0.04	3.9ms
5/6	T	0.04	R	0.05	U	0.04	I	0.04	F	0.13	3.8ms
6/6	T	0.05	F	0.12	R	0.04	Pequeno	0.04,	U	0.04	3.8ms

Fonte: O autor (2022).

Tabela 23 - Classificação de um grupo de imagens com a letra **U** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	U	0.31	R	0.06	V	0.05	W	0.05	F	0.04	4.2ms
2/7	U	0.32	V	0.06	R	0.06	L	0.06	B	0.04	3.9ms
3/7	U	0.31	R	0.06	V	0.04	W	0.04	F	0.03	4.1ms
4/7	U	0.19	V	0.07	R	0.06	I	0.05	L	0.05	4.0ms
5/7	U	0.25	V	0.08	B	0.06	I	0.06	L	0.06	4.2ms
6/7	U	0.21	R	0.09	B	0.06	Adulto	0.04	I	0.04	4.0ms
7/7	U	0.14	R	0.09	I	0.06	B	0.06	W	0.05	4.0ms

Fonte: O autor (2022).

Tabela 24 - Classificação de um grupo de imagens com a letra **V** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	V	0.13	U	0.11	W	0.09	I	0.05	L	0.05	3.9ms
2/7	V	0.27	W	0.11	U	0.09	L	0.04	M	0.03	3.9ms
3/7	V	0.29	U	0.09	W	0.07	L	0.04	R	0.03	4.0ms
4/7	V	0.28	W	0.10	U	0.09	L	0.04	N	0.03	3.8ms
5/7	V	0.24	W	0.14	U	0.10	L	0.04	R	0.03	3.7ms
6/7	V	0.22	U	0.11	I	0.06	W	0.05	L	0.04	3.9ms
7/7	V	0.25	U	0.08	W	0.08	N	0.03	A	0.03	3.7ms

Fonte: O autor (2022).

Tabela 25 - Classificação de um grupo de imagens a letra **W** - 100 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	W	0.31	V	0.07	U	0.04	N	0.04	S	0.04	3.8ms
2/7	W	0.27	V	0.06	U	0.05	N	0.04	L	0.04	3.9m
3/7	W	0.31	V	0.07	U	0.05	L	0.03	N	0.03	3.9ms
4/7	W	0.29	V	0.07	U	0.05	L	0.03	M	0.03	4.0ms
5/7	W	0.28	U	0.05	V	0.05	R	0.04	S	0.03	3.8ms
6/7	W	0.17	V	0.06	U	0.05	I	0.05	R	0.04	5.2ms
7/7	W	0.18	U	0.05	R	0.05	I	0.04	N	0.04	5.8ms

Fonte: O autor (2022).

Tabela 26 - Classificação de um grupo de imagens a letra **X** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	X	0.20	Pequeno	0.07	F	0.04	2	0.03	U	0.03	3.9ms
2/7	X	0.19	Pequeno	0.07	F	0.05	9	0.04	7	0.03	4.6ms
3/7	X	0.19	Pequeno	0.07	F	0.06	R	0.04	U	0.04	3.9ms
4/7	X	0.18	Pequeno	0.07	F	0.05	9	0.04	7	0.03	4.1ms
5/7	X	0.18	Pequeno	0.07	F	0.04	U	0.03	D	0.03	4.0ms
6/7	X	0.20	Pequeno	0.06	F	0.05	9	0.04	7	0.03	3.8ms
7/7	X	0.18	Pequeno	0.08	9	0.04	F	0.04	U	0.04	4.1ms

Fonte: O autor (2022).

Tabela 27 - Classificação de um grupo de imagens com a letra **Y** - 100 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	Y	0.14	L	0.07	I	0.05	G	0.04	O	0.04	3.9ms
2/7	Y	0.16	L	0.04	S	0.04	I	0.03	Pequeno	0.03	3.9ms
3/7	Y	0.18	S	0.10	I	0.05	W	0.04	L	0.04	4.0ms
4/7	Y	0.15	I	0.07	S	0.05	G	0.05	L	0.04	4.2ms
5/7	Y	0.18	S	0.05	I	0.04	L	0.04	R	0.03	5.0ms
6/7	Y	0.15	I	0.07	S	0.06	O	0.04	Adulto	0.04	3.7ms
7/7	Y	0.19	L	0.06	S	0.04	I	0.04	Aviao	0.03	3.8ms

Fonte: O autor (2022).

Posteriormente, foi executado um treinamento da rede neural com a base de dados de Libras em **500 épocas**. A realização dos testes nas imagens de casos de uso foram eficientes e atingiram um bom nível de precisão. As tabelas a seguir apresentam os resultados das execuções realizadas:



Tabela 28 - Classificação dos casos de teste (letras) - treinamento de 500 épocas.

CLASSIFICAÇÃO DOS CASOS DE TESTES			
Class	Images	top1_acc	top5_acc
A	32	0.969	1
B	30	0.967	1
C	36	1	1
D	34	1	1
E	34	0.971	1
F	30	0.967	1
G	32	0.969	1
I	36	1	1
L	33	1	1
M	33	1	1
N	33	1	1
O	39	0.974	1
P	9	0.889	1
Q	31	1	1
R	35	1	1
S	46	0.978	1
T	6	1	1
U	36	1	1
V	32	1	1
W	38	1	1
X	18	1	1
Y	45	1	1

Fonte: O autor (2022).

Tabela 29 - Classificação dos casos de teste (números) - treinamento de 500 épocas.

CLASSIFICAÇÃO DOS CASOS DE TESTES			
Class	Images	top1_acc	top5_acc
1	43	1	1
2	42	1	1
4	33	1	1
5	40	1	1
7	35	1	1
9	35	1	1

Fonte: O autor (2022).

Tabela 30 - Classificação dos casos de teste (palavras) - treinamento de 500 épocas.

CLASSIFICAÇÃO DOS CASOS DE TESTES			
Class	Images	top1_acc	top5_acc
Adulto	15	1	1
America	36	1	1
Aviao	36	1	1
Casa	39	1	1
Gasolina	36	1	1
Identidade	41	1	1
Junto	5	1	1
Lei	35	1	1
Palavra	31	1	1
Pedra	12	1	1
Pequeno	28	1	1
Verbo	28	1	1

Fonte: O autor (2022).

Tabela 31 - Classificação de um grupo de imagens com a letra A - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	A	0.42	B	0.04	N	0.03	E	0.02	U	0.02	4.7ms
2/7	A	0.49	N	0.03	B	0.03	E	0.03	O	0.02	4.0ms
3/7	A	0.51	N	0.03	B	0.03	O	0.03	E	0.02	4.1ms
4/7	A	0.52	N	0.03	B	0.03	U	0.02	O	0.02	4.2ms
5/7	A	0.48	O	0.03	B	0.03	U	0.02	E	0.02	4.2ms
6/7	A	0.51	E	0.02	O	0.02	B	0.02	U	0.02	4.1ms
7/7	A	0.55	O	0.03	N	0.02	B	0.02	E	0.02	4.1ms

Fonte: O autor (2022).

Tabela 32 - Classificação de um grupo de imagens com a letra B - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	B	0.44	A	0.04	S	0.02	E	0.02	N	0.02	4.9ms
2/7	B	0.43	A	0.04	E	0.03	S	0.02	N	0.02	4.2ms
3/7	B	0.49	A	0.05	E	0.02	N	0.02	S	0.02	4.0ms
4/7	B	0.46	A	0.04	E	0.02	S	0.02	dentidade	0.02	4.3ms
5/7	B	0.44	A	0.04	S	0.03,	E	0.02	Identidade	0.02	4.0ms
6/7	B	0.40	A	0.05	S	0.03	E	0.03	M	0.02,	4.3ms
7/7	B	0.41	A	0.05	E	0.03	N	0.03	S	0.02	4.0ms

Fonte: O autor (2022).

Tabela 33 - Classificação de um grupo de imagens com a letra C - 500 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	C	0.30	D	0.04	O	0.03	Pequeno	0.03	N	0.03	3.8ms
2/7	C	0.38	O	0.03	D	0.03	Pequeno	0.03	M	0.02	3.8ms
3/7	C	0.32	O	0.05	Pequeno	0.03	A	0.03	4	0.03	3.8ms
4/7	C	0.31	Pequeno	0.04	D	0.04	O	0.03	5	0.02	4.7ms
5/7	C	0.41	Pequeno	0.07	5	0.05	D	0.04,	4	0.03	5.6ms
6/7	C	0.37	D	0.03	Pequeno	0.03	Q	0.02	M	0.02	3.8ms
7/7	C	0.46	5	0.06	D	0.05	Pequeno	0.04	2	0.02	3.8ms

Fonte: O autor (2022).

Tabela 34 - Classificação de um grupo de imagens com a letra **D** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	D	0.55	5	0.03	Pequeno	0.02	R	0.02	Gasolina	0.02	4.0ms
2/7	D	0.49	L	0.03	5	0.02	R	0.02	Pequeno	0.02	4.3ms
3/7	D	0.56	5	0.03	Pequeno	0.02	R	0.02	C	0.02	4.1ms
4/7	D	0.55	5	0.03	Pequeno	0.02	R	0.02	F	0.02	3.9ms
5/7	D	0.59	5	0.03	R	0.02	Pequeno	0.02	Gasolina	0.02	4.0ms
6/7	D	0.55	5	0.03	Pequeno	0.02	F	0.02	R	0.02	4.0ms
7/7	D	0.56	5	0.03	Pequeno	0.02	R	0.02	Gasolina	0.02	3.9ms

Fonte: O autor (2022).

Tabela 35 - Classificação de um grupo de imagens com a letra **E** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	E	0.43	A	0.04	O	0.03	S	0.03	B	0.02	3.9ms
2/7	E	0.43	A	0.04	O	0.03	S	0.03	G	0.02	3.7ms
3/7	E	0.34	A	0.05	S	0.04	O	0.04	N	0.03	4.0ms
4/7	E	0.42	A	0.04	O	0.03	S	0.03	N	0.03	4.0ms
5/7	E	0.44	A	0.05	O	0.03	S	0.03	N	0.03	3.8ms
6/7	E	0.40	A	0.04	O	0.03	S	0.03	N	0.03	3.8ms
7/7	E	0.45	A	0.04	O	0.03	S	0.03	N	0.02	4.2ms

Fonte: O autor (2022).

Tabela 36 - Classificação de um grupo de imagens com a letra **F** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	F	0.47	Pequeno	0.03	D	0.02	U	0.02	R	0.02	3.8ms
2/7	F	0.46	R	0.03	S	0.03	U	0.02	D	0.02	4.0ms
3/7	F	0.47	5	0.03	S	0.02	Pequeno	0.02	D	0.02	4.0ms
4/7	F	0.45	Pequeno	0.02	R	0.02	D	0.02	S	0.02	3.8ms
5/7	F	0.48	5	0.03	Pequeno	0.02	U	0.02	2	0.02	3.9ms
6/7	F	0.49	S	0.03	U	0.02	R	0.02	D	0.02	3.9ms
7/7	F	0.45	S	0.03	Pequeno	0.02	R	0.02	U	0.02	4.0m

Fonte: O autor (2022).

Tabela 37 - Classificação de um grupo de imagens com a letra **G** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	G	0.35	I	0.03	S	0.03	L	0.03	A	0.03	3.7ms
2/7	G	0.29	L	0.05	A	0.04	S	0.04	Y	0.03	3.7ms
3/7	G	0.40	L	0.03	U	0.03	I	0.03	A	0.03	3.9ms
4/7	G	0.38	L	0.04	I	0.03	S	0.03	U	0.03	3.7ms
5/7	G	0.33	L	0.04	U	0.03	S	0.03	I	0.03	3.9ms
6/7	G	0.29	L	0.05	S	0.04	I	0.03	Y	0.03	3.8ms
7/7	G	0.33	L	0.04	S	0.03	I	0.03	U	0.03	4.1ms

Fonte: O autor (2022).

Tabela 38 - Classificação de um grupo de imagens com a letra **I** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	I	0.24	S	0.07	A	0.04	B	0.03	N	0.03	4.1ms
2/7	I	0.27	S	0.07	B	0.04	L	0.03	R	0.03	3.8ms
3/7	I	0.21	S	0.05	Adulto	0.04	A	0.03	R	0.03	3.8ms
4/7	I	0.29	S	0.06	B	0.04	R	0.04	A	0.03	3.7ms
5/7	I	0.24	S	0.05	Adulto	0.04	A	0.04	B	0.04	3.9ms
6/7	I	0.26	S	0.11	A	0.04	Y	0.04	B	0.03	4.8ms
7/7	I	0.24	S	0.05	Adulto	0.04	R	0.03	L	0.03	4.0ms

Fonte: O autor (2022).

Tabela 39 - Classificação de um grupo de imagens com a letra **L** - 500 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	L	0.32	G	0.04	U	0.02	E	0.02	O	0.02	3.8ms
2/7	L	0.32	Y	0.03	O	0.03	Aviao	0.03	A	0.02	3.8ms
3/7	L	0.31	Pequeno	0.03	F	0.02	C	0.02	U	0.02	4.0ms
4/7	L	0.35	R	0.03	U	0.02	Pequeno	0.02	F	0.02	4.0ms
5/7	L	0.32	R	0.03	U	0.03	S	0.03	F	0.02	4.0ms
6/7	L	0.35	A	0.03	D	0.02	R	0.02	Adulto	0.02	4.0ms
7/7	L	0.36	G	0.07	Y	0.03	I	0.03	S	0.02	3.8ms

Fonte: O autor (2022).

Tabela 40 - Classificação de um grupo de imagens a letra **M** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	M	0.40	N	0.05	D	0.03	C	0.02	Gasolina	0.02	3.9ms
2/7	M	0.36	N	0.10	Q	0.04	D	0.03	L	0.02	4.3ms
3/7	M	0.40	N	0.06	Q	0.04	C	0.03	D	0.03	3.7ms
4/7	M	0.36	N	0.05	C	0.04	Q	0.04	D	0.03	5.2ms
5/7	M	0.39	N	0.06	Q	0.03	D	0.03	B	0.03	5.9ms
6/7	M	0.30	N	0.08	Q	0.03	L	0.03	D	0.02	3.7ms
7/7	M	0.40	N	0.06	Q	0.04	B	0.03	O	0.02	3.9ms

Fonte: O autor (2022).

Tabela 41 - Classificação de um grupo de imagens com a letra **N** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	N	0.52	Q	0.03	M	0.02	A	0.02	O	0.02	3.8ms
2/7	N	0.47	Q	0.03	M	0.02	A	0.02	E	0.02	3.8ms
3/7	N	0.47	Q	0.02	A	0.02	E	0.02	M	0.02	4.1ms
4/7	N	0.48	Q	0.03	A	0.03	E	0.02	O	0.02	4.3ms
5/7	N	0.44	Q	0.03	A	0.03	E	0.02	D	0.02	3.8ms
6/7	N	0.49	Q	0.03	M	0.02	E	0.02	A	0.02	4.0ms
7/7	N	0.49	Q	0.03	A	0.02	O	0.02	E	0.02	4.0ms

Fonte: O autor (2022).

Tabela 42 - Classificação de um grupo de imagens com a letra **O** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	O	0.41	A	0.04	E	0.04	N	0.03	Pequeno	0.02	4.0ms
2/7	O	0.36	N	0.05	A	0.04	U	0.03	V	0.03	3.8ms
3/7	O	0.44	A	0.03	Pequeno	0.03	E	0.03	S	0.02	3.9ms
4/7	O	0.43	N	0.03	Pequeno	0.03	A	0.03	E	0.02	3.9ms
5/7	O	0.44	Pequeno	0.02	A	0.02	D	0.02	I	0.02	4.1ms
6/7	O	0.48	D	0.02	Pequeno	0.02	A	0.02	N	0.02	4.0ms
7/7	O	0.43	A	0.03	E	0.03	I	0.02	Pequeno	0.02	b4.0ms

Fonte: O autor (2022).

Tabela 43 - Classificação de um grupo de imagens com a letra **P** - 500 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	P	0.25	Pequeno	0.08	7	0.06	X	0.04	1	0.03	4.0ms
2/7	P	0.30	7	0.06	Pequeno	0.06	Gasolina	0.04	X	0.03	4.0ms
3/7	P	0.33	7	0.06	Pequeno	0.05	Gasolina	0.04	X	0.03	4.9ms
4/7	P	0.18	Pequeno	0.09	7	0.08	2	0.07	Gasolina	0.06	3.9ms
5/7	P	0.20	Pequeno	0.09	7	0.08	2	0.06	X	0.06	4.1ms
6/7	P	0.23	Pequeno	0.10	7	0.09	X	0.07	2	0.05	4.0ms
7/7	P	0.25	Pequeno	0.09	7	0.06	X	0.05	Gasolina	0.04	4.0ms

Fonte: O autor (2022).

Tabela 44 - Classificação de um grupo de imagens com a letra **Q** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	Q	0.52	N	0.05	M	0.03	A	0.02	B	0.02	3.9ms
2/7	Q	0.49	N	0.06	M	0.04	A	0.02	O	0.02	3.7ms
3/7	Q	0.47	N	0.06	M	0.03	A	0.02	B	0.02	3.7ms
4/7	Q	0.51	N	0.04	M	0.03	1	0.02	B	0.02	3.8ms
5/7	Q	0.53	N	0.04	M	0.04	L	0.02	D	0.02	3.8ms
6/7	Q	0.49	N	0.05	M	0.03	A	0.02	1	0.02	3.9ms
7/7	Q	0.56	N	0.05	M	0.03	A	0.02	1	0.02	3.8ms

Fonte: O autor (2022).

Tabela 45 - Classificação de um grupo de imagens com a letra **R** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	R	0.30	U	0.08	S	0.04	F	0.03	B	0.03	6.2ms
2/7	R	0.32	U	0.08	S	0.04	Adulto	0.04	F	0.03	4.4ms
3/7	R	0.33	U	0.07	S	0.04	F	0.03	Adulto	0.03	4.1ms
4/7	R	0.32	U	0.09	S	0.04	Adulto	0.03	F	0.03	4.0ms
5/7	R	0.33	U	0.07	S	0.04	F	0.03	D	0.03	4.8ms
6/7	R	0.32	U	0.07	S	0.04	Adulto	0.03	F	0.03	3.9ms
7/7	R	0.32	U	0.08	S	0.04	Adulto	0.04	5	0.03	3.8ms

Fonte: O autor (2022).

Tabela 46 - Classificação de um grupo de imagens com a letra **S** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	S	0.45	N	0.03	F	0.02	M	0.02	I	0.02	4.0ms
2/7	S	0.51	N	0.02	I	0.02	B	0.02	M	0.02	3.7ms
3/7	S	0.50	I	0.02	N	0.02	B	0.02	R	0.02	3.9ms
4/7	S	0.40	I	0.0	B	0.02	R	0.02	N	0.02	5.7ms
5/7	S	0.52	I	0.02	N	0.02	M	0.02	F	0.02	4.1ms
6/7	S	0.49	I	0.03	A	0.02	N	0.02	B	0.02	3.8ms
7/7	S	0.47	I	0.03	B	0.02	R	0.02	F	0.02	3.8ms

Fonte: O autor (2022).

Tabela 47 - Classificação de um grupo de imagens com a letra **T** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/6	T	0.13	5	0.06	F	0.04	D	0.04	Adulto	0.03	3.9ms
2/6	T	0.14	5	0.05	F	0.05	D	0.04	Adulto	0.03	3.9ms
3/6	T	0.13	F	0.06	5	0.05	2	0.04	Pequeno	0.04	4.6ms
4/6	T	0.18	F	0.06	5	0.06	Pequeno	0.04	D	0.03	4.1ms
5/6	T	0.14	F	0.08	5	0.04	O	0.04	Pequeno	0.03	4.0ms
6/6	T	0.17	F	0.07	5	0.06	Pequeno	0.04	D	0.04	4.1ms

Fonte: O autor (2022).

Tabela 48 - Classificação de um grupo de imagens com a letra **U** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	U	0.49	V	0.04	R	0.04	S	0.03	Adulto	0.02	4.3ms
2/7	U	0.46	R	0.04	V	0.04	S	0.03	W	0.03	4.1ms
3/7	U	0.48	R	0.04	V	0.04	W	0.03	S	0.03	4.1ms
4/7	U	0.47	V	0.04	S	0.03	R	0.03	W	0.03	4.2ms
5/7	U	0.49	R	0.04	S	0.04	V	0.04	W	0.02	4.0ms
6/7	U	0.46	R	0.05	V	0.04	S	0.03	Adulto	0.03	4.1ms
7/7	U	0.48	V	0.05	R	0.03	S	0.03,	W	0.03	4.0ms

Fonte: O autor (2022).

Tabela 49 - Classificação de um grupo de imagens com a letra **V** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	V	0.35	W	0.08	U	0.08	S	0.03	L	0.02	4.0ms
2/7	V	0.32	U	0.09	W	0.05	S	0.03	Adulto	0.03	4.0ms
3/7	V	0.30	U	0.10	W	0.08	S	0.03	L	0.03	4.0ms
4/7	V	0.34	U	0.07	W	0.06	S	0.04	L	0.03	4.0ms
5/7	V	0.36	U	0.12	W	0.04	R	0.03	S	0.02	3.9ms
6/7	V	0.34	U	0.09	W	0.07	S	0.03	B	0.03	3.8ms
7/7	V	0.32	U	0.08	W	0.04	R	0.03	L	0.02	3.8ms

Fonte: O autor (2022).

Tabela 50 - Classificação de um grupo de imagens com a letra **W** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	W	0.42	V	0.06	U	0.04	S	0.03	M	0.02	3.9ms
2/7	W	0.41	V	0.07	U	0.04	S	0.03	M	0.03	4.6ms
3/7	W	0.39	V	0.07	U	0.04	S	0.03	M	0.03	3.7ms
4/7	W	0.38	V	0.06	U	0.04	S	0.03	M	0.03	3.7ms
5/7	W	0.38	V	0.08	U	0.05	S	0.03	B	0.02	3.8ms
6/7	W	0.41	V	0.08	U	0.04	S	0.03	M	0.02	3.8ms
7/7	W	0.39	V	0.08	U	0.04	S	0.02	N	0.02	3.8ms

Fonte: O autor (2022).

Tabela 51 - Classificação de um grupo de imagens com a letra **X** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	X	0.31	Pequeno	0.07	7	0.05	F	0.03	2	0.03	4.1ms
2/7	X	0.29	Pequeno	0.06	7	0.05	2	0.03	F	0.03	4.3ms
3/7	X	0.29	Pequeno	0.06	7	0.06	9	0.03	F	0.03	4.2ms
4/7	X	0.30	7	0.06	Pequeno	0.06	2	0.04	F	0.04	4.2ms
5/7	X	0.33	7	0.06	Pequeno	0.05	2	0.03	F	0.03	4.0ms
6/7	X	0.29	7	0.09	Pequeno	0.07	2	0.05	Gasolina	0.04	4.2ms
7/7	X	0.31	7	0.08	Pequeno	0.07	2	0.04	F	0.03	3.8ms

Fonte: O autor (2022).

Tabela 52 - Classificação de um grupo de imagens com a letra **Y** - 500 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	Y	0.33	Pequeno	0.03	I	0.03	O	0.03	2	0.03	5.5ms
2/7	Y	0.39	I	0.03	Pequeno	0.03	2	0.03	S	0.03	3.7ms
3/7	Y	0.37	I	0.04	S	0.03	Pequeno	0.03	O	0.02	3.8ms
4/7	Y	0.37	S	0.04	W	0.03	2	0.03	I	0.03	4.0ms
5/7	Y	0.37	S	0.05	I	0.03	W	0.03	V	0.03	3.8ms
6/7	Y	0.36	S	0.05	I	0.03	W	0.03	N	0.02	3.7ms
7/7	Y	0.34	L	0.03	I	0.03	Aviao	0.03	S	0.03	3.7ms

Fonte: O autor (2022).

Na última etapa foi executado um treinamento da rede neural convolucional de **1000 épocas**, onde pôde-se observar que os valores das precisões dos símbolos de Libras classificados, foram bem mais eficientes e mais elevados do que os executados anteriormente. As tabelas a seguir apresentam os resultados obtidos:



Tabela 53 - Classificação dos casos de teste (letras) - treinamento de 1000 épocas.

CLASSIFICAÇÃO DOS CASOS DE TESTES			
<i>Class</i>	<i>Images</i>	<i>top1_acc</i>	<i>top5_acc</i>
A	32	0.938	1
B	30	0.833	1
C	36	1	1
D	34	1	1
E	34	0.941	1
F	30	1	1
G	32	0.906	0.938
I	36	1	1
L	33	1	1
M	33	1	1
N	33	1	1
O	39	0.974	1
P	9	0.778	1
Q	31	1	1
R	35	1	1
S	46	0.978	1
T	6	1	1
U	36	1	1
V	32	1	1
W	38	1	1
X	18	1	1
Y	45	1	1

Fonte: O autor (2022).

Tabela 54 - Classificação dos casos de teste (números) - treinamento de 1000 épocas

CLASSIFICAÇÃO DOS CASOS DE TESTES			
Class	Images	top1_acc	top5_acc
1	43	0.977	1
2	42	1	1
4	33	0.97	1
5	40	1	1
7	35	1	1
9	35	1	1

Fonte: O autor (2022).

Tabela 55 - Classificação dos casos de teste (palavras) - treinamento de 1000 épocas

CLASSIFICAÇÃO DOS CASOS DE TESTES			
Class	Images	top1_acc	top5_acc
Adulto	15	1	1
America	36	1	1
Aviao	36	1	1
Casa	39	1	1
Gasolina	36	1	1
Identidade	41	0.976	1



Junto	5	1	1
Lei	35	1	1
Palavra	31	1	1
Pedra	12	1	1
Pequeno	28	1	1
Verbo	28	1	1

Fonte: O autor (2022).

Tabela 56 - Classificação de um grupo de imagens com a letra **A** - 1000 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	A	0.29	N	0.04	B	0.04	S	0.03	I	0.03	3.8ms
2/7	A	0.36	N	0.05	B	0.03	E	0.03	O	0.02	3.9ms
3/7	A	0.37	N	0.05	B	0.03	E	0.03	O	0.03	3.9ms
4/7	A	0.33	N	0.05	B	0.03	U	0.03	Identidade	0.02	4.0ms
5/7	A	0.37	N	0.05	B	0.03	U	0.02	O	0.02	4.0ms
6/7	A	0.33	N	0.03	B	0.03	Identidade	0.02	5	0.02	3.9ms
7/7	A	0.36	N	0.03	E	0.03	S	0.02	Identidade	0.02	3.8ms

Fonte: O autor (2022).

Tabela 57 - Classificação de um grupo de imagens com a letra **B** - 1000 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	B	0.24	S	0.03	A	0.03	N	0.03	5	0.03	4.1ms
2/7	B	0.26	A	0.03	S	0.03	N	0.03	E	0.03	4.1ms
3/7	B	0.22	S	0.04	A	0.03	Identidade	0.03	5	0.03	4.0ms
4/7	B	0.23	A	0.03	S	0.03	Identidade	0.03	N	0.03	3.9ms
5/7	B	0.25	S	0.03	A	0.03	E	0.03	N	0.03	4.0ms
6/7	B	0.26	A	0.04	S	0.03	Identidade	0.03	N	0.03	4.1ms
7/7	B	0.24	A	0.03	S	0.03	N	0.03	5	0.03	3.9ms

Fonte: O autor (2022).

Tabela 58 - Classificação de um grupo de imagens com a letra **C** - 1000 épocas.

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	C	0.26	5	0.04	Pequeno	0.03	O	0.03	I	0.03	3.8ms
2/7	C	0.24	O	0.04	N	0.03	A	0.03	9	0.03	4.0ms
3/7	C	0.25	D	0.04	O	0.03	I	0.03	S	0.03	4.0ms
4/7	C	0.32	Q	0.04	M	0.03	S	0.03	9	0.03	3.8ms
5/7	C	0.28	O	0.06	5	0.03	A	0.03	L	0.03	3.9ms
6/7	C	0.33	Pequeno	0.07	5	0.06	D	0.04	O	0.03	4.1ms
7/7	C	0.36	5	0.09	D	0.05	Pequeno	0.04	O	0.03	3.9ms

Fonte: O autor (2022).

Tabela 59 - Classificação de um grupo de imagens com a letra **D** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	D	0.41	5	0.04	R	0.03	U	0.03	F	0.02	3.9ms
2/7	D	0.39	5	0.04	L	0.03	R	0.03	U	0.03	7.4ms
3/7	D	0.37	5	0.03	U	0.03	R	0.03	L	0.03	5.8ms
4/7	D	0.39	5	0.03	R	0.03	U	0.03	F	0.03	4.5ms
5/7	D	0.42	5	0.04	R	0.03	U	0.03	L	0.02	4.0ms
6/7	D	0.44	5	0.04	R	0.03	O	0.03	F	0.03	3.9ms
7/7	D	0.43	5	0.04	R	0.03	O	0.03	4	0.03	3.8ms

Fonte: O autor (2022).

Tabela 60 - Classificação de um grupo de imagens com a letra **E** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	E	0.25	A	0.05	N	0.04	O	0.04	I	0.03	4.6ms
2/7	E	0.25	S	0.05	O	0.04	N	0.04	A	0.03	4.1ms
3/7	E	0.28	A	0.05	N	0.04	O	0.04	I	0.03	4.1ms
4/7	E	0.26	N	0.05	A	0.05	S	0.04	O	0.03	3.9ms
5/7	E	0.34	A	0.04	N	0.03	O	0.03	S	0.03	4.2ms
6/7	E	0.35	A	0.03	S	0.03	N	0.03	I	0.03	4.0ms
7/7	E	0.34	A	0.04	N	0.03	O	0.03	S	0.03	4.2ms

Fonte: O autor (2022).

Tabela 61 - Classificação de um grupo de imagens com a letra **F** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	F	0.32	U	0.03	5	0.03	2	0.03	S	0.03	3.9ms
2/7	F	0.30	Gasolina	0.03	5	0.03	2	0.03	Pequeno	0.03	4.0ms
3/7	F	0.32	U	0.04	R	0.04	S	0.03	D	0.03	3.9ms
4/7	F	0.32	R	0.04	U	0.04	S	0.03	Pequeno	0.03	4.1ms
5/7	F	0.34	U	0.03	2	0.03	D	0.03	R	0.03	3.8ms
6/7	F	0.32	S	0.04	U	0.03	5	0.03	R	0.03	4.0ms
7/7	F	0.32	U	0.04	5	0.03	R	0.03	S	0.03	3.9ms

Fonte: O autor (2022).

Tabela 62 - Classificação de um grupo de imagens com a letra **G** - 1000 épocas

<i>Image</i>	<i>CL1</i>	<i>RP1</i>	<i>CL2</i>	<i>Acc2</i>	<i>CL3</i>	<i>RP3</i>	<i>CL4</i>	<i>RP4</i>	<i>CL5</i>	<i>RP5</i>	<i>Temp. Exec</i>
1/7	G	0.18	S	0.05	I	0.04	B	0.04	A	0.04	3.8ms
2/7	G	0.22	I	0.04	S	0.04	A	0.04	U	0.03	3.9ms
3/7	G	0.18	S	0.04	I	0.04	U	0.04	B	0.03	4.1m
4/7	G	0.20	S	0.05	I	0.04	L	0.04	U	0.04	3.9ms
5/7	G	0.18	S	0.05	I	0.05	L	0.04	B	0.04	3.8ms
6/7	G	0.21	S	0.05	I	0.04	L	0.04	B	0.04	3.9ms
7/7	G	0.21	I	0.04	U	0.04	V	0.04	A	0.04	3.8ms

Fonte: O autor (2022).

Tabela 63 - Classificação de um grupo de imagens com a letra **I** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	I	0.28	S	0.05	F	0.04	R	0.03	5	0.03	4.3ms
2/7	I	0.26	S	0.07	A	0.03	R	0.03	F	0.03	3.9ms
3/7	I	0.22	S	0.05	A	0.04	F	0.04	N	0.03	3.9ms
4/7	I	0.25	S	0.04	F	0.03	R	0.03	U	0.03	4.0ms
5/7	I	0.22	S	0.04	5	0.04	F	0.04	Pequeno	0.03	3.8ms
6/7	I	0.26	S	0.05	R	0.03	F	0.03	B	0.03	3.8ms
7/7	I	0.23	S	0.09	A	0.04	F	0.03	R	0.03	5.5ms

Fonte: O autor (2022).

Tabela 64 - Classificação de um grupo de imagens com a letra **L** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	L	0.23	E	0.03	G	0.03	C	0.03	S	0.03	5.9ms
2/7	L	0.27	C	0.03	Aviao	0.03	D	0.03	Y	0.03	4.1ms
3/7	L	0.28	C	0.03	D	0.03	U	0.03	S	0.03	3.8ms
4/7	L	0.24	C	0.04	D	0.03	S	0.03	A	0.03	3.8ms
5/7	L	0.33	D	0.03	U	0.03	S	0.02	I	0.02	3.8ms
6/7	L	0.36	D	0.03	U	0.03	Pequeno	0.02	S	0.02	4.4ms
7/7	L	0.41	D	0.03	U	0.02	S	0.02	Q	0.02	4.6ms

Fonte: O autor (2022).

Tabela 65 - Classificação de um grupo de imagens com a letra **M** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	M	0.23	D	0.03	S	0.03	C	0.03	B	0.03	4.0ms
2/7	M	0.21	N	0.05	Pequeno	0.03	L	0.03	A	0.03	4.0ms
3/7	M	0.24	Q	0.04	L	0.04	D	0.03	N	0.03	3.9ms
4/7	M	0.22	Q	0.04	C	0.04	D	0.03	A	0.03	3.7ms
5/7	M	0.20	L	0.04	Q	0.04	D	0.03	A	0.03	3.7ms
6/7	M	0.26	L	0.04	Q	0.04	N	0.04	D	0.03	3.9ms
7/7	M	0.21	Q	0.05	L	0.05	N	0.03	D	0.03	3.9ms

Fonte: O autor (2022).

Tabela 66 - Classificação de um grupo de imagens com a letra **N** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	N	0.29	Q	0.03	A	0.03	M	0.03	B	0.03	4.8ms
2/7	N	0.31	Q	0.03	A	0.03	M	0.03	B	0.03	4.1ms
3/7	N	0.27	A	0.03	B	0.03	Q	0.03	M	0.03	4.0ms
4/7	N	0.32	A	0.03	Q	0.03	B	0.03	M	0.02	6.0ms
5/7	N	0.28	A	0.03	Q	0.03	B	0.03	E	0.03	3.8ms
6/7	N	0.28	A	0.03	Q	0.03	B	0.03	M	0.03	4.0ms
7/7	N	0.29	M	0.07	S	0.05	Q	0.04	I	0.04	3.8ms

Fonte: O autor (2022).

Tabela 67 - Classificação de um grupo de imagens com a letra **O** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	O	0.28	E	0.05	A	0.05	N	0.03,	S	0.03	3.7ms
2/7	O	0.32	N	0.04	5	0.03	M	0.03	U	0.03	4.0ms
3/7	O	0.28	A	0.03	S	0.03	E	0.03	5	0.03	3.9ms
4/7	O	0.27	N	0.03	D	0.03	E	0.03	5	0.03	3.9ms
5/7	O	0.26	S	0.03	D	0.03	5	0.03	A	0.03	3.9ms
6/7	O	0.30	D	0.03	5	0.03	A	0.03	S	0.03	3.9ms
7/7	O	0.33	D	0.03	A	0.03	E	0.03	N	0.03	3.8ms

Fonte: O autor (2022).



Tabela 68 - Classificação de um grupo de imagens com a letra **P** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	P	0.14	7	0.07	Pequeno	0.06	X	0.05	9	0.04	4.0ms
2/7	P	0.19	7	0.07	F	0.05	Pequeno	0.04	Gasolina	0.04	4.0ms
3/7	P	0.23	7	0.06	F	0.06	America	0.05	Pequeno	0.04	3.8ms
4/7	7	0.12	P	0.10	Pequeno	0.06	F	0.06	X	0.05	3.8ms
5/7	P	0.16	Pequeno	0.08	7	0.08	Gasolina	0.06	2	0.05	3.8ms
6/7	P	0.19	Pequeno	0.09	7	0.08	Gasolina	0.05	X	0.05	4.0ms
7/7	P	0.20	Pequeno	0.08	7	0.06	F	0.05	Gasolina	0.04	3.9ms

Fonte: O autor (2022).

Tabela 69 - Classificação de um grupo de imagens com a letra **Q** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	Q	0.20	N	0.04	S	0.03	O	0.03	M	0.03	4.0ms
2/7	Q	0.19	N	0.04	S	0.04	M	0.03	O	0.03	3.7ms
3/7	Q	0.19	N	0.05	S	0.03	L	0.03	M	0.03	3.8ms
4/7	Q	0.19	N	0.04	M	0.04	S	0.04	D	0.03	3.9ms
5/7	Q	0.18	N	0.04	S	0.03	M	0.03	D	0.03	3.9ms
6/7	Q	0.18	D	0.04	S	0.04	N	0.04	L	0.04	4.0ms
7/7	Q	0.21	N	0.05	M	0.03	S	0.03	O	0.03	4.2ms

Fonte: O autor (2022).

Tabela 70 - Classificação de um grupo de imagens com a letra **R** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	R	0.25	U	0.06	S	0.05	D	0.03	Identidade	0.03	3.9ms
2/7	R	0.27	U	0.08	S	0.04	5	0.04	D	0.04	4.4ms
3/7	R	0.31	U	0.09	S	0.04	F	0.04	5	0.03	3.9ms
4/7	R	0.27	U	0.08	S	0.04	5	0.04	D	0.04	3.7ms
5/7	R	0.27	U	0.08	S	0.05	5	0.04	Adulto	0.03	3.9ms
6/7	R	0.25	U	0.06	S	0.04	F	0.04	D	0.03	3.9ms
7/7	R	0.31	U	0.08	S	0.04	Identidade	0.03	5	0.03	3.9ms

Fonte: O autor (2022).

Tabela 71 - Classificação de um grupo de imagens com a letra **S** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	S	0.48	F	0.03	5	0.02	N	0.02	D	0.02	3.7ms
2/7	S	0.50	I	0.02	F	0.02	A	0.02	B	0.02	3.7ms
3/7	S	0.46	F	0.03	I	0.02	Pequeno	0.02	U	0.02	3.9ms
4/7	S	0.48	I	0.02	F	0.02	A	0.02	B	0.02	3.8ms
5/7	S	0.46	I	0.03	5	0.02	R	0.02	N	0.02	3.7m
6/7	S	0.49	I	0.03	A	0.02	F	0.02	M	0.02	3.8ms
7/7	S	0.51	F	0.02	I	0.02	5	0.02	N	0.02	3.9ms

Fonte: O autor (2022).

Tabela 72 - Classificação de um grupo de imagens com a letra **T** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/6	T	0.09	5	0.05	D	0.04	R	0.03	F	0.03	3.9ms
2/6	T	0.12	5	0.04	D	0.04	F	0.04	W	0.03	3.8ms
3/6	T	0.16	5	0.05	D	0.04	F	0.04	Adulto	0.03	3.8ms
4/6	T	0.15	5	0.05	D	0.05	O	0.04	F	0.03	3.8ms
5/6	T	0.10	F	0.05	5	0.05	O	0.04	D	0.04	3.8ms
6/6	T	0.14	5	0.06	F	0.05	D	0.04	4	0.03	4.0ms

Fonte: O autor (2022).

Tabela 73 - Classificação de um grupo de imagens com a letra **U** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/6	U	0.40	V	0.04	S	0.04	R	0.03	Identidade	0.03	4.6ms
2/6	U	0.33	V	0.08	R	0.04	S	0.03	Pequeno	0.03	3.9ms
3/6	U	0.31	S	0.07	R	0.04	V	0.04	F	0.03	3.8ms
4/6	U	0.37	R	0.04	S	0.03	F	0.03	V	0.03	4.0ms
5/6	U	0.37	S	0.04	R	0.03	V	0.03	W	0.03	3.7ms
6/6	U	0.38	V	0.04	S	0.04	R	0.03	W	0.03	5.7ms

Fonte: O autor (2022).

Tabela 74 - Classificação de um grupo de imagens com a letra **V** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	V	0.22	U	0.06	W	0.04	S	0.04	F	0.0	4.3ms
2/7	V	0.22	U	0.07	F	0.04	W	0.03	Pequeno	0.03	4.0ms
3/7	V	0.23	U	0.07	S	0.04	W	0.04	F	0.04	3.9ms
4/7	V	0.23	U	0.06	W	0.05	S	0.03	D	0.03	3.8ms
5/7	V	0.20	U	0.05	W	0.04	F	0.04	D	0.04	3.8ms
6/7	V	0.27	U	0.06	W	0.04	S	0.04	F	0.03	3.8ms
7/7	V	0.22	U	0.07	R	0.03	S	0.03	I	0.03	4.3ms

Fonte: O autor (2022).

Tabela 75 - Classificação de um grupo de imagens com a letra **W** - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	W	0.24	V	0.07	U	0.03	S	0.03	Y	0.03	3.8ms
2/7	W	0.27	V	0.07	U	0.04	S	0.02	I	0.02	4.0ms
3/7	W	0.24	V	0.06	U	0.03	Y	0.03	4	0.03	3.9ms
4/7	W	0.29	V	0.08	U	0.05	S	0.02	B	0.02	4.0ms
5/7	W	0.29	V	0.07	U	0.05	S	0.03	B	0.02	3.8ms
6/7	W	0.28	V	0.07	U	0.04	S	0.03	R	0.03	3.8ms
7/7	W	0.28	V	0.08	U	0.04	2	0.03	F	0.03	4.2ms

Fonte: O autor (2022).

Tabela 76 - Classificação de um grupo de imagens com a letra X - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/7	X	0.22	Pequeno	0.06	7	0.05	F	0.03	P	0.03	4.3ms
2/7	X	0.23	Pequeno	0.05	7	0.04	F	0.04	P	0.03	3.7ms
3/7	X	0.20	Pequeno	0.06	7	0.04	F	0.03	R	0.03	3.8ms
4/7	X	0.20	Pequeno	0.05	F	0.04	7	0.04	9	0.03	4.0ms
5/7	X	0.19	Pequeno	0.05	7	0.04	F	0.04	9	0.03	3.9ms
6/7	X	0.24	Pequeno	0.05	7	0.04	F	0.03	R	0.03	4.0ms
7/7	X	0.21	Pequeno	0.05	7	0.04	F	0.04	R	0.03	4.0ms

Fonte: O autor (2022).

Tabela 77 - Classificação de um grupo de imagens com a letra Y - 1000 épocas

<i>Image</i>	<i>CL 1</i>	<i>RP1</i>	<i>CL 2</i>	<i>RP2</i>	<i>CL 3</i>	<i>RP3</i>	<i>CL 4</i>	<i>RP4</i>	<i>CL 5</i>	<i>RP5</i>	<i>Temp. exec.</i>
1/6	Y	0.24	Pequeno	0.04	O	0.03	F	0.03	5	0.03	3.9ms
2/6	Y	0.27	Pequeno	0.04	I	0.03	S	0.03	F	0.03	4.3ms
3/6	Y	0.22	I	0.04	S	0.04	Pequeno	0.03	5	0.03	3.8ms
4/6	Y	0.23	Pequeno	0.03	O	0.03	I	0.03	S	0.03	3.7ms
5/6	Y	0.23	I	0.05	Aviao	0.04	O	0.04	S	0.03	3.8ms
6/6	Y	0.21	I	0.05	S	0.05	N	0.04	M	0.03	3.8ms

Fonte: O autor (2022).

5 ANÁLISE E DISCUSSÕES DE RESULTADOS

Após a obtenção dos resultados dos testes, foi possível observar através do treinamento das épocas quais destes apresentaram um melhor desempenho de acordo com a precisão. O principal fator de definição de boas resultâncias de precisão, foi com certeza, a quantidade de épocas realizadas após cada treino, pois foi possível observar que houve uma melhor produtividade na execução de 500 épocas. A **tabela 78** apresenta a soma das precisões dos testes das sete imagens utilizadas durante a execução de 100, 500 e 1000 épocas.

Tabela 78 - Soma das precisões dos testes T1 à T7 em 100, 500 e 1000 épocas

Classe	Épocas	T1 Precisão	T2 Precisão	T3 Precisão	T4 Precisão	T5 Precisão	T6 Precisão	T7 Precisão	Total (Precisão)
A	100	0,12	0,34	0,15	0,07	0,07	0,08	0,07	0,90
	500	0,42	0,49	0,51	0,52	0,48	0,51	0,55	3,48
	1000	0,29	0,36	0,37	0,33	0,37	0,33	0,36	2,41
B	100	0,33	0,34	0,32	0,29	0,38	0,08	0,11	1,85
	500	0,44	0,43	0,49	0,46	0,44	0,40	0,41	3,07
	1000	0,24	0,26	0,22	0,23	0,25	0,26	0,24	1,70
C	100	0,38	0,39	0,17	0,22	0,16	0,37	0,19	1,88
	500	0,30	0,38	0,32	0,31	0,41	0,37	0,46	2,55
	1000	0,26	0,24	0,25	0,32	0,28	0,33	0,36	2,04



D	100	0,33	0,36	0,27	0,26	0,31	0,35	0,35	2,23
	500	0,55	0,49	0,56	0,55	0,59	0,55	0,56	3,85
	1000	0,41	0,39	0,37	0,39	0,42	0,44	0,43	2,85
E	100	0,26	0,33	0,29	0,25	0,22	0,31	0,15	1,81
	500	0,43	0,43	0,34	0,42	0,44	0,40	0,45	2,91
	1000	0,25	0,25	0,28	0,26	0,34	0,35	0,34	2,07
F	100	0,47	0,24	0,44	0,44	0,52	0,23	0,13	2,47
	500	0,47	0,46	0,47	0,45	0,48	0,49	0,45	3,27
	1000	0,32	0,30	0,32	0,32	0,34	0,32	0,32	2,24
G	100	0,24	0,22	0,27	0,26	0,12	0,15	0,08	1,34
	500	0,35	0,29	0,40	0,38	0,33	0,29	0,33	2,37
	1000	0,18	0,22	0,18	0,20	0,18	0,21	0,21	1,38
I	100	0,17	0,22	0,20	0,20	0,25	0,21	0,11	1,36
	500	0,24	0,27	0,21	0,29	0,24	0,26	0,24	1,75
	1000	0,28	0,26	0,22	0,25	0,22	0,26	0,23	1,72
L	100	0,22	0,24	0,26	0,29	0,27	0,24	0,30	1,82
	500	0,32	0,32	0,31	0,35	0,32	0,35	0,36	2,33
	1000	0,23	0,27	0,28	0,24	0,33	0,36	0,41	2,12
M	100	0,32	0,43	0,35	0,24	0,41	0,13	0,24	2,12
	500	0,40	0,36	0,40	0,36	0,39	0,30	0,40	2,61
	1000	0,23	0,21	0,24	0,22	0,20	0,26	0,21	1,57
N	100	0,54	0,56	0,51	0,57	0,55	0,54	0,16	3,43
	500	0,52	0,47	0,47	0,48	0,44	0,49	0,49	3,36
	1000	0,29	0,31	0,27	0,32	0,28	0,28	0,29	2,04
O	100	0,27	0,44	0,14	0,20	0,30	0,11	0,10	1,56
	500	0,41	0,36	0,44	0,43	0,44	0,48	0,43	2,99
	1000	0,28	0,32	0,28	0,27	0,26	0,30	0,33	2,04
P	100	0,14	0,14	0,19	0,08	0,10	0,11	0,11	0,87
	500	0,25	0,30	0,33	0,18	0,20	0,23	0,25	1,74
	1000	0,14	0,19	0,23	0,12	0,16	0,19	0,20	1,23
Q	100	0,26	0,28	0,27	0,33	0,22	0,40	0,34	2,10
	500	0,52	0,49	0,47	0,51	0,53	0,49	0,56	3,57
	1000	0,20	0,19	0,19	0,19	0,18	0,18	0,21	1,34
R	100	0,34	0,31	0,28	0,29	0,17	0,18	0,19	1,76
	500	0,30	0,32	0,33	0,32	0,33	0,32	0,32	2,24
	1000	0,25	0,27	0,31	0,27	0,27	0,25	0,31	1,93
S	100	0,33	0,38	0,14	0,42	0,12	0,25	0,31	1,95
	500	0,45	0,51	0,50	0,40	0,52	0,49	0,47	3,34
	1000	0,48	0,50	0,46	0,48	0,46	0,49	0,51	3,38
T	100	0,08	0,10	0,04	0,06	0,04	0,05	0,00	0,37
	500	0,13	0,14	0,13	0,18	0,14	0,17	0,00	0,89
	1000	0,09	0,12	0,16	0,15	0,10	0,14	0,00	0,76



U	100	0,31	0,32	0,31	0,19	0,25	0,21	0,14	1,73
	500	0,49	0,46	0,48	0,47	0,49	0,46	0,48	3,33
	1000	0,40	0,33	0,31	0,37	0,37	0,38	0,00	2,16
V	100	0,13	0,27	0,29	0,28	0,24	0,22	0,25	1,68
	500	0,35	0,32	0,30	0,34	0,36	0,34	0,32	2,33
	1000	0,22	0,22	0,23	0,23	0,20	0,27	0,22	1,59
W	100	0,31	0,27	0,31	0,29	0,28	0,17	0,18	1,81
	500	0,42	0,41	0,39	0,38	0,38	0,41	0,39	2,78
	1000	0,24	0,27	0,24	0,29	0,29	0,28	0,28	1,89
X	100	0,20	0,19	0,19	0,18	0,18	0,20	0,18	1,32
	500	0,31	0,29	0,29	0,30	0,33	0,29	0,31	2,12
	1000	0,22	0,23	0,20	0,20	0,19	0,24	0,21	1,49
Y	100	0,24	0,27	0,22	0,23	0,23	0,21	0,00	1,40
	500	0,33	0,39	0,37	0,37	0,37	0,36	0,34	2,53
	1000	0,14	0,16	0,18	0,15	0,18	0,15	0,19	1,15

Fonte: O autor (2022).

6 CONCLUSÃO

Através da análise dos resultados obtidos, pôde-se observar que os níveis de precisão variaram bastante de acordo com a quantidade de treinamentos realizados durante a execução do algoritmo YOLOv5. Após o treino de 100 épocas, pôde-se observar que os valores das precisões dos testes processados nas sete imagens de sinais de Libras não alcançaram valores satisfatórios para a maioria das classes. Porém, a classe “N” atingiu o maior nível, mas ficando abaixo de 60%. Já no treinamento de 500 épocas, houve uma melhora do percentual dos resultados, pois os valores atingidos ficaram entre 28% e 59% com maioria acima de 40%, sendo razoáveis para realização da classificação. E por fim, após treinamento de 1000 épocas, as classes “D” e “S”, foram as que obtiveram uma melhor precisão, pois os valores ficaram entre 40%, e 51%, um pouco acima da execução de 100 épocas, porém abaixo de 500 épocas.

A maioria dos resultados obtidos pelas demais classes foram menores do que os valores do treino anterior. Portanto, concluiu-se assim que, as precisões após os testes das imagens com o algoritmo YOLOv5 atingiram bons resultados após o treinamento de 500 épocas.

Como sugestão de trabalhos futuros, recomenda-se a ampliação do conjunto de dados de Libras através da inserção de mais letras e palavras para a realização de testes de classificação ou detecção através do algoritmo YOLOv5 em palavras e textos.



REFERÊNCIAS

- ALMEIDA, S. M. S. **Intérprete da Língua de Sinais – LIBRAS: mediador ou educador.** Trabalho de Conclusão de Curso de Graduação em Letras -
- ALVES, Gabriel. Detecção de Objetos com Yolo: uma abordagem moderna. **IA Expert**, Porto União, SC. 13 de Out. de 2020. Disponível em: <<https://iaexpert.academy/2020/10/13/deteccao-de-objetos-com-yolo-uma-abordagem-moderna>>. Acesso em: 20 de abr. de 2021.
- ALVES, Gabriel. **Simplifying Classification Workflows With YOLOv5.** ultralytics. 30 de Abr de 2022. Disponível em: <<https://ultralytics.com/article/Simplifying-Classification-Workflows-With-YOLOv5-v6.2>>. Acesso em: 20 de Ago. de 2022.
- ALVES, Melo Priscila. **Inteligência Artificial e Redes Neurais.** IPEA, 11 de jun. de 2020. Disponível em: <<https://www.ipea.gov.br/cts/pt/central-de-conteudo/artigos/artigos/106-inteligencia-artificial-e-redes-neurais>>. Acesso em: 20 de set. de 2021.
- applications invasion. In: IEEE. Circuits and Systems (ISCAS), Proceedings of 2010**
- APPOLINÁRIO, F. **Dicionário de metodologia científica: um guia para a produção do conhecimento científico.** São Paulo: Atlas, 2004.
- BALLARD, Dana H; BROWN, Christopher M. ISBN 0-13-165316-5. **Computer Vision.** New Jersey: Editora Prentice Hall, 1982.
- BARELLI, Felipe. **Introdução à Visão Computacional. Uma abordagem prática com Python e OpenCV.** 1º.ed. São Paulo: Casa do Código, 2018.
- BASTOS, I. L. O. **Reconhecimento de sinais de libras utilizando descritores de forma e redes neurais artificiais.** 2015. Dissertação (mestrado) – Pós-Graduação em Ciência da Computação da Universidade Federal da Bahia e Universidade Estadual de Feira de Santana. 2015. Disponível em: <<https://repositorio.ufba.br/ri/bitstream/ri/19374/1/Igor%20%20Bastos%20-%20Disserta%3%a7%3%a3o%20VFinal.pdf>>. Acessado em: 10 de fevereiro de 2021.
- BOCHKOVSKIY, A.; WANG, C.-Y.; LIAO, H.-Y.M. Yolov4: **Optimal speed and accuracy of object detection.** *arXiv preprint arXiv: 2004.10934*, 2020.
- BORGES, Lucas C.; Obara, Eduardo N.; Leite, Claudia Z.; Rocha, Fabiano G. (2015). **Glossário interativo de Libras para a área de Computação.** *Computer on the Beach*, Florianópolis/SC.
- BOTELHO, Paula. **Linguagem e letramento na Educação dos Surdos: ideologias e práticas pedagógicas.** Belo Horizonte: autêntica, 2002.
- BRASIL. **Lei nº 10.436, de 24 de abril de 2002, que dispõe sobre a Língua Brasileira de Sinais – Libras.** Brasília: MEC, 2002.
- CHAVES, Magaly. **Recomendações pedagógicas para desenvolvimento de ambientes virtuais de aprendizagem, construcionistas, para surdos, na perspectiva do usuário.** 2019.



Dissertação de mestrado - Pós-Graduação em Modelagem Computacional de Sistemas da Universidade Federal do Tocantins. 2019. Disponível em: <<https://repositorio.uft.edu.br/bitstream/11612/1447/1/Magaly%20Liliane%20Chaves%20Campos%20-%20Disserta%C3%A7%C3%A3o.pdf>> . Acessado em: 10 de fevereiro de 2021.

DETECÇÃO de rosto OpenCV vs Detecção de Rosto Colo. **Base App**, 2018. Disponível em: <<https://www.baseapp.com/deepsight/opencv-vs-yolo-face-detector>>. Acesso em: 12 de janeiro. de 2021.

DIFICULDADES de Aprendizagem em Surdos. **Portal Educação**. 2020. Disponível em: <https://siteantigo.portaleducacao.com.br/conteudo/artigos/idiomas/dificuldades-de-aprendizagem-em-surdos/26871> . Acesso em: 10 de jun. de 2021.

FERREIRA, Ricardo. CANESCHE, Michael; CARVALHO, Westerley. **Minicurso de programação em GPU do ambiente Google Colaboratory**. 2020. Disponível em: <<http://wscad.sbc.org.br/2020/artigos/minicursos/minicurso3-Prog-GPU-Colaboratory-texto.pdf>>. Acessado em: 22 fev. de 2021.

FLECK, Leandro; TAVARES, Maria Hermínia Ferreira; EYNG, Eduardo; HELMANN, Andrieli Cristina; ANDRADE, Minéia Aparecida de Moares. **Redes Neurais Artificiais: Princípios básicos**. Revista Eletrônica Científica Inovação e Tecnologia. 2016. Disponível em: <<https://periodicos.utfpr.edu.br/recit/article/view/4330>>. Acessado em: 10 de julho de 2021.

GÓES, J. W. F. **Aperfeiçoamento de um sistema de reconhecimento de padrões do alfabeto de libras utilizando luva sensora**. 2019. Disponível em: <http://repositorio.utfpr.edu.br/jspui/bitstream/1/24355/1/PB_COENC_2019_1_03.pdf> . Acessado em: 20 de fevereiro de 2021.

GONZAGA, A. **Kanguera: Olho Local Mão Distante**. 2011. Disponível em: <<http://iris.sel.eesc.usp.br/weblab/default.html>>. Acesso em 14 de junho de 2021.

HAYKIN, S. S. **Neural netwo L. FLECK, M. Tavares, E. Eyng, A. Helmann, and M. Andrade, “Redes neuraisartificiais: Princípios básicos,”Revista Eletrônica Científica Inovação e Tecnologia,vol. 1, no. 13, pp. 47–57, 2016. rks and Learning Machines. vol. 3. Pearson Upper Saddle River, NJ, USA: 2009**

KARNOPP, Lodenir; QUADROS, Ronice Muller de. **Educação infantil para surdos**. In: ROMAN, Eurilda Dias; STEYER, Vivian Edite. (Org.). A criança de 0 a 6 anos e a educação infantil: um retrato multifacetado. Canoas, 2001, p. 214-230.

LAKATOS, E. M.; MARCONI, M. A. **Fundamentos metodologia científica**. 4.ed. São Paulo: Atlas, 2001.

LECUN, Yann et al. **Gradient-based learning applied to document recognition**. Proceedings of the IEEE, v. 86, n. 11, p. 2278-2324, 1998.

LECUN, Y.; KAVUKCUOGLU, K.; FARABET, C. **Convolutional networks and applications in vision**. Paris: IEEE, 2010.

LÉVY, Pierre. **Cibercultura**. São Paulo: Editora 34, 2005.



MEDEIROS, Moisés de. **Seleção de principais atributos para Redes Neurais Artificiais do tipo MLP: um estudo de caso sobre mineração de dados para diagnóstico de dengue.** Trabalho de Conclusão de Curso de Graduação em Sistemas de Informação da Universidade Federal do Rio Grande do Norte, UFRN. Caicó, 2018.

MILANO, Danilo de; HONORATO, Luciano Barrozo. **Visão computacional.** Universidade Estadual de Campinas, 2010.

MOURA, Débora Rodrigues. **Módulo1: introdução à surdez e a Libras.** Enap. 2016. Disponível em: <https://repositorio.enap.gov.br/handle/1/3172> . Acessado em: 22 de abril de 2021.

MOURA, Flávio Rafael Trindade, et al. "**Contamination risk estimation model for respiratory diseases in monitored environments using YOLOv5.**" Anais do XLIX Seminário Integrado de Software e Hardware. SBC, 2022.

NEVES, Luiz Antônio Pereira; VIEIRA NETO, Hugo; GONZAGA, Adilson. SBN: 978- 85-64619-09-8. **Avanços em Visão Computacional.** Curitiba: Omnipax Editora, 2012.
PACHECO, J. **Caminhos para a inclusão:** um guia para o aprimoramento da equipe escolar. Porto Alegre: Artmed, 2007.

PAVAN, Adilson. OSSADA JUNIOR, J. C. MODESTO, F. **reconhecimento de gestos com segmentação de imagens dinâmicas aplicadas a libras.** Campinas, SP, 2010. Disponível em: <<https://repositorio.pgsskroton.com/bitstream/123456789/1240/1/artigo%2023.pdf>>. Acessado em: 08 de maio de 2020.

PAVLOVIC, V. I; SHARMA, R.; HUAN, T. S. **Visual Interpretation of Hand Gestures for Human-Computer Interaction.** IEEE Transactions on Pattern Analysis and Machine Intelligence, vol 19, no 7, 1997.

PIRES, Vanessa De Oliveira Dagostim. **Andamento Coletivo como Prática de Ensino-Aprendizagem de Língua Portuguesa para Surdos.** 2009. 143 f. Dissertação (Mestrado) - Programa de Pós-graduação em Linguística Aplicada, Universidade do Vale do Rio Dos Sinos, São Leopoldo, 2009.

QUEIFER, H. S. **Reconhecimento de gestos para acionamento de objetos usando CNN e o algoritmo haar cascade.** 2019. Disponível em: <<https://dspace.bc.uepb.edu.br/jspui/handle/123456789/21842>>. Acessado em: 03 de abril de 2021.

RAUBER, T. W. **Redes neurais artificiais.** Universidade Federal do Espírito Santo, Departamento de Informática, 2005.

REDMON, Joseph. **How computers learn to recognize objects instantly.** Youtube, 17 de ago. 2017. Disponível em: <<https://www.youtube.com/watch?v=CgxsV1riJhI&t=356s>>. Acesso em: 15 jan. 2021.

RODRIGUES, Diego Alves. **Deep Learning e redes neurais convolucionais: reconhecimento automático de caracteres em placas de licenciamento automotivo.** 2018. Monografia – Universidade Federal da Paraíba (Centro de Informática). Disponível em:



<https://repositorio.ufpb.br/jspui/bitstream/123456789/15606/1/DARP20052019.pdf>

Acessado em: 01 de abril de 2021.

Rosa, A. S., & Cruz, C. C. (2001). **Internet: Fator de inclusão da pessoa surda**. Revista Online da Biblioteca Prof. Joel Martins, 2, 38-54. <https://doi.org/10.20396/etd.v2i3.580>.

SACRAMENTO, Gabriel. **Dataset: entenda o que é e conheça 10 fontes confiáveis**. Somostera, 10 de setembro de 2021. Disponível em: <<https://blog.somostera.com/data-science/dataset>>. Acesso em: 20 de agosto de 2022.

SANTOS, Carlos Alexandre Silva dos. **Reconhecimento de Imagens de Marcas de Gato Utilizando Redes Neurais Convolucionais**. 2017. Dissertação de mestrado – Pós-graduação em Engenharia Elétrica - Universidade Federal do Pampa. Disponível em: <<http://dspace.unipampa.edu.br/jspui/handle/rii/2028>>. Acesso em: 12 de março de 2021.

SANTOS, Clebeson Canudo dos. **Sistemas de Reconhecimento de Gestos e ações em tempo real baseado em visão computacional**. 2020. Tese (Doutorado) – Curso de Engenharia Elétrica, Universidade Federal do Espírito Santo, Centro Tecnológico. 2020.

SANTOS, Rodrigo Neves dos. **Reconhecimento de gestos de mão humana em imagens de vídeo**. São Carlos SP, 2011. Disponível em: <<http://www.tcc.sc.usp.br/tce/disponiveis/18/180450/tce-29032012-085236/?&lang=brDISCENTE>>. Acesso em: 14 de abril de 2021.

SILVA, Carine Mendes da; SILVA, Daniele Nunes Henrique. **Libras na educação de surdos: o que dizem os profissionais da escola? Psicologia Escolar e Educacional**, Maringá, 2016. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-85572016000100033&lng=en&nrm=iso>. Acesso em: 5 dezembro. 2020.

SITE OFICIAL DO ROBOFLOW, Roboflow, 2021. Disponível em: <<https://roboflow.com/>>. Acesso em: 14, mar 2021.

TAMANG, Benjamin et al. **Customized Deep Learning Technique for vehicle detection along with speed estimation**. EasyChair, 2022.