



UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS UNIVERSITÁRIO DE TUCURUÍ
FACULDADE DE ENGENHARIA DA COMPUTAÇÃO

VIGNER VIEIRA DOS SANTOS

RECONHECIMENTO DE USO DE EPI E CONTROLE DE ACESSO POR MEIO DE
VISÃO COMPUTACIONAL UTILIZANDO TÉCNICAS DE APRENDIZAGEM DE
MÁQUINA

TUCURUÍ
2023

VIGNER VIEIRA DOS SANTOS

RECONHECIMENTO DE USO DE EPI E CONTROLE DE ACESSO POR MEIO DE
VISÃO COMPUTACIONAL UTILIZANDO TÉCNICAS DE APRENDIZAGEM DE
MÁQUINA

Trabalho de Conclusão de Curso apresentado à Faculdade de Engenharia de Computação do Campus Universitário de Tucuruí, da Universidade Federal do Pará, como requisito parcial para obtenção do grau de Bacharel em Engenharia de Computação.

Orientador (a): Prof. Dr. Daniel Pinheiro.

TUCURUÍ
2023

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

V657r VIEIRA, VIGNER.
RECONHECIMENTO DE USO DE EPI E CONTROLE DE
ACESSO POR MEIO DE VISÃO COMPUTACIONAL
UTILIZANDO TÉCNICAS DE APRENDIZAGEM DE
MÁQUINA / VIGNER VIEIRA. — 2023.
68 f.

Orientador(a): Prof. Dr. Daniel Pinheiro
Trabalho de Conclusão de Curso (Graduação) - Universidade
Federal do Pará, Campus Universitário de Tucuruí, Faculdade de
Engenharia da Computação, Tucuruí, 2023.

1. Machine Learning. 2. Visão Computacional . 3.
Segurança do Trabalho . 4. Equipamentos de Proteção
Individual. 5. Inteligência Artificial. I. Título.

CDD 338.4762138195

VIGNER VIEIRA DOS SANTOS

RECONHECIMENTO DE USO DE EPI E CONTROLE DE ACESSO POR MEIO DE VISÃO COMPUTACIONAL UTILIZANDO TÉCNICAS DE APRENDIZAGEM DE MÁQUINA

Trabalho de Conclusão de Curso apresentado à Faculdade de Engenharia de Computação, do Campus Universitário de Tucuruí, da Universidade Federal do Pará, como requisito parcial para obtenção do grau de Bacharel em Engenharia de Computação.

Data da aprovação: 30/03/2023.

Conceito: Excelente.

BANCA EXAMINADORA

(Assinado digitalmente em 06/04/2023 19:34)
DANIEL DA CONCEICAO PINHEIRO
PROFESSOR DO MAGISTERIO SUPERIOR
CTUCU (11.16)
Matricula: ###345#1

(Assinado digitalmente em 17/04/2023 20:43)
FABRICIO DE SOUZA FARIAS
PROFESSOR DO MAGISTERIO SUPERIOR
CCAME (11.19)
Matricula: ###320#4

(Assinado digitalmente em 10/04/2023 09:00)
MARCOS TULLIO AMARIS GONZALEZ
PROFESSOR DO MAGISTERIO SUPERIOR
CTUCU (11.16)
Matricula: ###883#5

(Assinado digitalmente em 06/04/2023 19:57)
OTÁVIO NOURA TEIXEIRA
PROFESSOR DO MAGISTERIO SUPERIOR
CTUCU (11.16)
Matricula: ###435#4

Dedico esse trabalho aos meus amados pais que sempre me mostraram o caminho da seriedade, educação e respeito, paralelamente com a relevância de encontrar o meu caminho de carreira profissional.

AGRADECIMENTOS

Aos meus queridos pais, Jacirene Mendes Vieira e Valmir de Sousa dos Santos, que sempre me apoiaram na minha trajetória de estudos e me incentivaram a seguir o caminho da educação, desde os primeiros passos da minha vida escolar até os dias atuais, enfrentando diversos desafios, nunca me deixaram faltar nada, tudo que eu precisava eles me proporcionaram com muita luta e esforço para eu chegar até aqui.

Aos meus avós, parte de pai e mãe, que nos conceberam a graça da vida, se não fosse vocês eu não existiria, e todos os frutos colhidos hoje foi propiciado frente a essa dignidade.

Ao meu irmão, Vagner Vieira dos Santos, que me ajudou em diversos momentos da vida universitária.

A todos meus familiares que diretamente ou indiretamente me ajudaram e motivaram a alcançar conquistas para representar nossa família nessa grandiosidade de planeta terra.

Ao meu ilustríssimo orientador e grande amigo, Prof. Dr. Daniel Pinheiro, me guiou, sabiamente, durante toda minha graduação para se tornar um profissional. Tenho muito orgulho de ter a oportunidade de poder compartilhar um pouco da sua habilidade, sabedoria e conhecimento técnico.

Agradeço a todos a todos meus amigos que sempre me apoiaram e motivaram.

Agradeço a todo o corpo docente da Faculdade de Engenharia de Computação da UFPA por proporcionado minha formação.

Agradeço a Deus pela vida e pela oportunidade de tive de cursar uma Universidade Federal, seja feito a tua vontade. Amém!

“É no processo da educação que se assenta o grande segredo do aperfeiçoamento da humanidade” (Immanuel Kant).

RESUMO

Para o ser humano realizar o reconhecimento dos equipamentos de proteção individual pode ser uma habilidade natural. Já para no meio virtual não é uma tarefa tão fácil. A linguagem de máquina para reconhecimento de objetos envolve muitos cálculos e exige grande capacidade de processamento. No entanto, com a evolução da capacidade de processamento dos computadores e evolução de algoritmos, realizar essa atividade já é possível. Nesse sentido, o objetivo do trabalho foi construir um sistema de reconhecimento de equipamento de proteção individual (EPI) através de técnicas de aprendizagem de máquina. Além de fazer uma pesquisa avaliativa com abordagem quantitativa por meio de quatro grandes etapas metodológicas no processo de pesquisa para selecionar uma técnica de *Machine Learning* para ser aplicado no sistema de controle de acesso. O projeto desenvolvido, a estrutura base está atrelada nas técnicas K-Vizinhos Mais Próximos e as redes neurais residuais com arquitetura ResNet-50. As técnicas foram construídas com finalidade identificar a presença dos EPIs. É apresentada avaliações das técnicas por meio de métricas estatísticas e de *Machine Learning*. Por fim, é realizada a simulação do controle de acesso para fiscalizações de equipamento proteção individual.

Palavras-chave: *Machine Learning*, Visão Computacional, Equipamentos de Proteção Individual, Python.

ABSTRACT

For humans, recognizing personal protective equipment can be a natural ability. As for the virtual environment, it is not such an easy task. Machine language for object recognition involves a lot of calculations and requires a lot of processing power. However, with the evolution of the processing capacity of computers and evolution of algorithms, carrying out this activity is already possible. In this sense, the objective of this work was to build a personal protective equipment (PPE) recognition system through machine learning techniques. In addition to doing an evaluative research with a quantitative approach through four major methodological steps in the research process to select a Machine Learning technique to be applied in the access control system. The developed project, the base structure is linked in the K-Nearest Neighbors techniques and the residual neural networks with ResNet-50 architecture. The techniques were constructed with the purpose of identifying the presence of PPE. Evaluations of techniques through statistical metrics and Machine Learning are presented. Finally, the simulation of access control is carried out for inspection of individual protection equipment.

Keywords: *Machine Learning, Computer Vision, Personal Protective Equipment, Python.*

Sumário

1.	INTRODUÇÃO.....	13
1.1.	Problemática.....	14
1.2.	Objetivos	16
1.2.1.	Objetivo Geral:	16
1.2.1.	Objetivos Específicos	16
1.3.	Trabalhos Correlatos.....	16
1.4.	Organização do trabalho	19
2.	FUNDAMENAÇÃO TEÓRICA.....	20
2.1.	Inteligência Artificial.....	20
2.2.	Aprendizagem de Máquina (<i>Machine Learning</i>)	20
2.2.1.	K-Vizinhos Mais Próximos (KNN).....	21
2.2.2.	Redes Neurais Residuais (ResNet).....	23
2.3.	Visão Computacional.....	26
3.	NORMAS REGULAMENTADORAS (NR _s)	30
3.1.	Capacete de Proteção	32
3.2.	Óculos.....	32
3.3.	Abafador	33
3.1.	Máscara de Proteção	34
4.	METODOLOGIA.....	35
4.1.	Fase Exploratória	35
4.1.1.	Coleta de Imagens.....	36
4.1.2.	Ferramentas Utilizadas	40
4.2.	Fase de Pesquisa Aprofundada	43
4.3.	Fase Avaliação das Técnicas	43
4.4.	Fase de Implementação do Controle de Acesso:	44
5.	RESULTADOS	46
5.1.	Treinamento <i>versus</i> Acurácia.....	46
5.1.1.	Performances de Treinamento da Máscara.....	46
5.1.2.	Performances de Treinamento do Capacete	47
5.1.3.	Performances de Treinamento dos Óculos	48
5.1.4.	Performances de Treinamento dos Abafadores	49
5.1.5.	Análise geral de desempenho de treinamento <i>versus</i> assertividade	50

5.2. Análise do Treinamento Final.....	51
5.2.1. Análise do Teste do Algoritmo KNN	51
5.2.2. Análise do Teste da ResNet-50	54
6. CONCLUSÃO.....	62
7. TRABALHOS FUTUROS	63
REFERÊNCIAS BIBLIOGRÁFICAS	64
APÊNDICE A – CÓDIGO DO PROJETO	68

LISTA DE ABREVIATURAS E SIGLAS

NRs	NORMAS REGULAMENTADORAS
CLT	CONSOLIDAÇÃO DAS LEIS DO TRABALHO
EPI	EQUIPAMENTOS DE PROTEÇÃO INDIVIDUAL
MPT	MINISTÉRIO PÚBLICO DO TRABALHO
CIPA	COMISSÕES INTERNAS DAS PREVENÇÕES DE ACIDENTE
ML	MACHINE LEARNING
ETL	EXTRACT, TRANSFORM, LOAD
CNN	REDE NEURAL CONVOLUCIONAL
PDI	PROCESSAMENTO DIGITAL DE IMAGENS
BSD	BERKELEY SOFTWARE DISTRIBUION
XML	EXTENSIBLE MARKUP LANGUAGE
PCA	ANÁLISE DE COMPONENTES PRINCIPAIS
KNN	K-NEAREST NEIGHBORS
DL	DEEP LEARNING
IDE	AMBIENTE DE DESENVOLVIMENTO INTEGRADO

1. INTRODUÇÃO

No Brasil, a segurança do trabalho é uma exigência. Evitar ou minimizar os acidentes de trabalho e as doenças ocupacionais colabora significativamente para que as empresas não percam materiais, prazos estipulados, reduzam sua produtividade ou até mesmo paguem altos gastos com indenizações de vítimas e seus familiares (NASIMENTO 2021).

De acordo com Chiabonato (2009), a segurança no trabalho corresponde a um conjunto de medidas utilizadas para prevenir acidentes visando a eliminação das condições inseguras do ambiente e instruindo ou convencendo as pessoas sobre a implantação de práticas preventivas no ambiente de trabalho. Este conjunto de medidas não foca somente nos interesses dos empregados, mas pauta-se também aos empregadores, já que as consequências positivas ou negativas refletirão de forma direta nas finanças e credibilidade da marca ou empresa.

Para o médico Ítalo Ramazzini, o trabalho sempre causou lesões, doenças e até a morte. Assim, inspirou-se na publicação do livro: “*A doenças dos Artesãos*”, com a identificação de 3 tipos de doenças desenvolvidas pelo trabalho, sendo que para algumas delas foram expostas formas de tratamento ou mesmo de prevenção. Por meio desse estudo, Ramazzini passou a ser considerado o pai da medicina do trabalho, estabelecendo a relação entre saúde e trabalho. Mesmo com tantos relatos e evidências, poucas medidas protetivas foram implementadas, pois a maioria das pessoas que sofreram acidentes de trabalho eram escravos ou pertencer às camadas mais pobres da sociedade (KONZEN et al. 2020).

Com o advento da revolução Industrial ocorrida na Inglaterra no século XVIII, grandes transformações ocorreram em toda a sociedade. A partir desse período, deu-se maior ênfase às relações laborais e às mudanças implementadas no sistema produtivo. Foi nesse momento histórico que os primeiros equipamentos de proteção individual (EPI) começaram a ser introduzidos na rotina de trabalho da classe trabalhadora, que na época ia até 16 horas diárias. No entanto, apesar da importância de se ter esse equipamento de proteção, a primeira legislação sobre acidentes e segurança no trabalho só provir séculos depois (SILVA et al, 2019).

Segundo Bozza (2010), os acidentes de trabalho podem ser entendidos como situações que não foram previstas ou orçadas como possíveis e que na maioria das vezes podem ser evitadas. Como resultado, muitos assalariados podem perder parte ou toda a sua capacitância de trabalho, permanente ou temporariamente, o que pode até resultar em morte. É por isso que muitas empresas se envolveram no desenvolvimento e implementação de programas eficazes para a proteção e prevenção de riscos trabalhistas. As instituições aplicaram a disponibilidade de recursos técnicos, treinamentos intensivos e a busca pela conscientização dos empregados sobre as ameaças que enfrentam como mecanismo para atingir as metas de segurança do trabalho.

1.1. Problemática

Todas as atividades profissionais estão respaldadas conforme as Normas Regulamentadoras (NRs) as quais foram fundadas no Brasil a partir da Portaria 3.214, de 08 de junho de 1978, visando melhorar as condições no ambiente de trabalho. E de acordo com a consolidação das Leis do Trabalho (CLT) e norma 06, o Equipamento de Proteção Individual (EPI) é definido como todo produto de uso individual destinado a proteger o trabalhador dos riscos presentes no ambiente de trabalho, promovendo a segurança e saúde do mesmo. Vale ressaltar que o empregador tem responsabilidade de disponibilizar essas ferramentas aos funcionários, bem como informa sobre a utilização adequada a determinadas áreas no ambiente empresarial e formas de conservação.

Em síntese, onde possa existir algum tipo de risco físico para o trabalhador devem ser cumpridos com auxílio de EPIs, que incluem itens como capacetes, cinto de segurança, luvas, máscaras, óculos, protetores auriculares e outros itens de proteção. No entanto, o uso desses equipamentos é relativo a características particulares de cada tipo de empresa seja ela privada ou pública, haja vista que cada setor em um ambiente de trabalho há requisitos particulares de equipamentos de proteção individual, pois em fábricas, processos industriais e químicos em geral, postos de saúde e hospitais, construção civil, processos de saneamento básico, entre outros, todas existem equipamentos de proteção para o determinado setor para um empregado.

O empregador deve realizar as orientações aos trabalhadores sobre as normas de segurança no trabalho, exigir e fiscalizar o uso do EPI. Porém, a rejeição do empregado em usar o equipamento de proteção individual, não exime culpa ao proprietário da empresa quanto aos danos causados ao trabalhador em eventual acidente (RODRIGUES; SANTOS, 2020).

Nesse contexto, o amparo legal da Constituição Federal de 1988, quanto à obrigatoriedade do uso do equipamento de proteção individual. Segundo o artigo 7º inciso XXII: “*são direitos dos*

trabalhadores urbanos e rurais, além de outros que visem à melhoria de sua condição social: XXII – redução dos riscos inerentes ao trabalho, por meio de normas de saúde, higiene e segurança”. Nesse artigo, impõem a obrigação do empregador reduzir os riscos inerentes ao trabalho. Assim, está o dever de fornecer equipamentos de proteção individual e a garantia de utilização por parte do empregado mediante a fiscalização por empregador.

No artigo 166 da Consolidação das Leis Trabalhistas – CLTs: *“A empresa é obrigada a fornecer aos empregados gratuitamente, equipamentos de proteção individual adequada ao risco e em perfeito estado de conservação e funcionamento, sempre que as medidas de ordem geral não ofereçam completa proteção contra os riscos de acidentes e danos à saúde dos empregados”.* Dessa forma, percebe-se que a empresa tem o dever de fornecer os EPIs de forma gratuita e que seja de adaptado ao risco que sua atividade ofereça.

Na 6º pauta das Normas Regulamentadoras apresentam de forma legal os requisitos de utilização, aprovação de equipamentos de proteção individual e os procedimentos técnicos que os empregadores devem seguir. Quanto ao EPIs, cabe ao empregador:

- Adquirir o equipamento adequado ao risco de cada atividade;
- Exigir seu uso;
- Fornecer ao trabalhador somente o equipamento aprovado pelo órgão nacional competente em matéria de segurança e saúde no trabalho;
- Orientar e treinar o trabalhador sobre o uso adequado, além da guarda e conservação;
- Substituir imediatamente, quando danificado ou extraviado;
- Responsabilizar-se pela higienização e manutenção periódica e comunicar se tem qualquer irregularidade observada;
- Registrar o seu fornecimento ao trabalhador, podendo ser adotados livros, fichas ou sistema eletrônico;

Em síntese, é possível perceber que o encargo do empregador é exigir o uso, orientar e treinar o trabalhador. Essas etapas são essenciais para o processo de segurança do trabalho na empresa. Outro item fundamental é o posicionamento do empregado diante das leis a eles atribuídas. Quanto ao trabalhador, cabe:

- Usar, utilizando-o apenas para a finalidade a que se destina;
- Responsabilizar-se pela guarda e conservação;
- Comunicar ao empregador qualquer alteração que o torne impróprio para o uso;
- Cumprir as determinações do empregador sobre o uso adequado;

Não obstante, apesar de todas as determinações das NRs e CTLs que deixa a responsabilidade de ambos, no Brasil, ainda está longe de ser uma realidade fundamentada. Segundo Ministério Público do Trabalho (MPT) existem muitos processos trabalhistas sobre essa temática, e somando com outros, o Brasil detém as primeiras colocações em relação ao número de processos trabalhistas no mundo, com estimativa entre 50% a 65% dos processos – dados de 2001 a 2016. [MARCHESAN, 2020]

Nesse interim, o presente trabalho se encaixa, pois há uma legislação e regulamentação que estabelece responsabilidade, existem profissionais de segurança do trabalho nas empresas e Comissões Internas de Prevenção de Acidente – CIPA, portanto, por que ainda há diversos acidentes, mortes e processos na sociedade brasileira? Quando refletimos sobre a situação associando aos mecanismos de funcionamento da empresa, certamente o “gargalo” está na fiscalização.

1.2. Objetivos

1.2.1. Objetivo Geral:

O objetivo do presente trabalho é realizar o reconhecimento e controle de acesso por meio de uso Equipamentos de Proteção Individual (EPIs) através de técnicas de *Machine Learning*.

1.2.1. Objetivos Específicos

- Investigar técnicas de aprendizagem de máquina para problemas reais de classificação.
- Realizar a avaliação de duas técnicas de aprendizagem de máquina para classificação de uso de equipamento de proteção EPI.
- Propor uma solução para reconhecimento de EPIs.

1.3. Trabalhos Correlatos

Alguns dos trabalhos relacionados a este projeto disponíveis na literatura são apresentados a seguir.

- **Análise do Uso de Equipamentos de Proteção Individual por Trabalhadores em Empresas de Curitiba e São José dos Pinhais (ZWOLINKSKI, 2017):** é um trabalho que analisa os principais motivos que leva os funcionários a não utilizarem equipamentos de proteção individual. Foi aplicado um questionário abordando temas como: uso de EPI e acidente de trabalho a empresas de diferentes ramos de atividade. O resultado da pesquisa conclui-se que não é por negligência que os trabalhadores não utilizam EPIs, mas sim que há

uma grande falha na organização da gestão de Segurança do trabalho nas empresas participantes.

- **Estudo de Caso sobre a Utilização de EPI's na Construção Civil com Proposição de Melhorias** (SILVA, 2020): é um trabalho que analisa as condições de trabalho com foco no cumprimento das normas vigentes quanto ao uso de equipamentos de proteção individual e quais medidas poderiam ser tomadas para atenuar os desafios do uso dos EPIs.
- **Deep Learning para Classificação de Imagens** (MARTINS, 2018): nesse trabalho é explorado as técnicas de *Deep Learning* em problemas de Classificação de Imagens e como seu uso permite um desempenho superior às técnicas tradicionais contribuindo para a resolução de diversos problemas na área de Visão Computacional.
- **Classificação de Imagens Utilizando Aprendizado de Máquina** (ROSA, 2019): o objetivo deste trabalho foi atingir uma acurácia superior a 90% no conjunto testado com utilização de modelos de redes neurais convolucionais através da API Keras em Python.
- **Técnicas de Visão Computacional para Classificação de Peças** (RODRIGUES, 2021): tem o intuito de analisar a capacidade de resposta de um classificador em específico, o K-Vizinhas Mais Próximos (KNN), para um problema de classificação de grupo e analisar seu desempenho por meio de parâmetros de taxa de acerto e precisão.
- **Algoritmos clássicos de Aprendizagem de Máquina Aplicados ao Problema do Reconhecimento de Imagens** (MIRANDA, 2011): o foco do trabalho está na etapa de classificação e reconhecimento de um sistema de visão computacional, onde o objetivo é classificar os diferentes elementos que compõem uma determinada cena com base em informações extraídas de sua representação digital. Aqui serão abordadas diferentes formas de realizar esta etapa, utilizando-se técnicas de inteligência artificial, especificamente, a aprendizagem de máquina, cuja análise do comportamento foi abstraído através da aplicação em um conjunto de imagens selecionada.
- **Sistema de Reconhecimento Facial com Base em Técnicas de Aprendizagem de Máquina** (SANTOS 2022): o trabalho realiza estudos de técnicas de aprendizagem de máquina para reconhecimento facial. A implementação de um sistema de identificação pessoal visou comparar fluxos de informação contidos em conjuntos de dados obtidos a partir do processamento de vídeos e fotos de indivíduos como mecanismo de prevenção de fraudes. São utilizados modelos previamente treinados em bancos de dados massivos, como OpenFace

e FaceNet. Já os classificadores usados foram *Support Vector Machine* (SVM), *k-Nearest Neighbors* (KNN) e *Convolutional Neural Network* (ConvNet).

- **Deep Residual Learning for Imagem Recognition** (K. He, X. Zhang, S. Ren and J. Sun, 2016): é um trabalho que apresenta a estrutura de aprendizado da rede neural convolucional adaptada para caracterizar uma rede neural residual com objetivo de facilitar o treinamento de redes neurais substancialmente mais profundas. Apresentam explicitamente a aplicação para reconhecimento de imagem com resultados significativos através do fornecimento das evidências empíricas abrangentes mostrando que essas redes neurais são mais fáceis de otimizar e ganham precisão com uma profundidade de 50 camadas.
- **Sistema de Controle de Acesso utilizando Autenticação por RFID e gerenciamento por meio de Software WEB** (GONÇALVES, 2019): a proposta neste trabalho foi o desenvolvimento de um sistema de controle de acesso para um laboratório trazendo mais segurança a seu patrimônio, bem como o monitoramento de seus colaboradores, gerando relatórios mensais com carga horária de trabalho e permitindo a seu supervisor monitorar a carga horária da jornada de trabalho previamente estabelecida.
- **Sistema Eletrônico de Controle de Acesso** (GALHADO, 2011): apresenta um sistema que permitem ou restringem acessos de pessoas ou veículos a determinadas áreas com ou sem limitações de horários, além de registrar o momento do acesso ou tentativa deste. O indivíduo cadastrado no sistema pode realizar o acesso através de identificação pessoal a qual pode ser através de cartões de proximidade, biometrias ou senhas.
- **Sistema de Controle de Acesso em IOT** (LEGAT, 2018): o trabalho propõe a construção de um sistema de Internet das Cosias para a realização do controle de acesso através de equipamentos com sensores RFID presentes nas portas de acesso de laboratórios, Áreas Restritas.

Percebe-se que os trabalhos anteriores são focados ao tipo de ambiente de pesquisa de problemas específicos convergentes. Alternativamente, este trabalho se propõe a avaliar genericamente as técnicas de aprendizagem de máquina KNN e *Deep Learning* para classificação de Equipamentos de Proteção Individual (EPIs). Posteriormente, escolher o tipo de algoritmo que apresentar o melhor desempenho para compor o sistema de controle de acesso através do uso EPIs.

1.4. Organização do Trabalho

O trabalho está organizado em 7 capítulos, sendo que no primeiro mostra a introdução o sobre os desafios da fiscalização dos equipamentos de proteção individual e sua relevância no processo de segurança no ambiente de trabalho e legislação brasileira. Também é apresentado o objetivo geral, objetivos específicos, os trabalhos correlatos, organizações do trabalho. No Capítulo 2, apresenta a fundamentação teórica sobre a inteligência artificial com finalidade de explicar as técnicas de aprendizagem de máquina através dos algoritmos K-Vizinhos Mais Próximos e as Redes Neurais Residuais com arquitetura ResNet-50. É discutido também a Visão Computacional com os principais temas: processamento de Imagem, Segmentação, Reconhecimento de Padrões, Rastreamento. No Capítulo 3, realiza-se uma revisão sobre as Normas Regulamentadoras (NR) com ênfase na NR 06. No capítulo 4, mostra a parte metodológica do trabalho com apresentação de fases de pesquisa. É apresentado os principais recursos de hardware e software para prototipação do projeto, como apresentação das bibliotecas e módulos da linguagem de programação Python, componentes eletrônicos, banco de imagens, algoritmo de reconhecimento aplicado a EPIs. No Capítulo 5, os resultados são apresentados na forma de comparação de desempenho. No Capítulo 6, apresenta-se as alcances obtidos e as descobertas. No capítulo 7, realiza-se as considerações finais sobre o projeto sobre planos futuros.

2. FUNDAMENAÇÃO TEÓRICA

A etapa de estudo teórico é fundamental pra qualquer início de trabalho, haja vista que é a base para realizar as atividades posteriores. A seguir serão apresentadas as principais bases teóricas de suporte para propiciar os conhecimentos suficientes ao desenvolvimento.

2.1. Inteligência Artificial

A inteligência artificial é uma área de estudo da computação que o intuito é propiciar aos computadores a realização de complexos processos abstratos e lógicos que geralmente são princípios humanos. Normalmente, os sistemas que são descritos como artificialmente inteligentes simulam ações de natureza humana. Segundo o cientista Hebert Simon, que realizou diversas contribuições no campo da economia, ciência cognitivas, psicologia, sociologia, Inteligência Artificial; Tem como afirmação que “*assim como o pensamento humano, a Inteligência Artificial tem como base a procura de padronizações de informações, e na aplicação de tais padrões e na realização de ações a partir deles construídas*”.

2.2. Aprendizagem de Máquina (*Machine Learning*)

O aprendizado de máquina, do inglês *Machine Learning* (ML), permite que o computador tenha capacidade de reconhecer padrões, mesmo que não seja realizada diretamente uma programação para isso. Um sistema com raízes em algoritmos de aprendizagem tem capacidade de melhorar resultados à medida que vai sendo realizada a exposição de dados, uma vez que consegue acumular experiências a partir deles – algo parecido ao processo de aprendizagem humana. [ALPAYDIN, 2020]

Na ciência do *Machine Learning*, a ciência de dados, a estatística e probabilidade estão muito presentes nos processos de intersecção construídos a partir das amostras de dados. São ferramentas relevantes para otimização de algoritmos. Assim como a qualidade de um material de leitura didática influência na aprendizagem humana, a presença de qualidade de dados é também importante para o processo de aprendizagem de máquina.

Os conhecimentos das áreas de engenharia e ciência da computação são utilizados para desenvolvimento de códigos, máquinas, sensores e novas arquiteturas computacionais através do procedimento de ETL (*extract, transform, load*) aplicado para os dados, a fim de criar e alimentar o

modelo de aprendizagem. Ademais, são usados na resolução de problema de otimização, junto a cálculos matemáticos, e para analisar de forma avaliativa os modelos de *Machine Learning*.

Os algoritmos de aprendizagem de máquina são algoritmos que processam dados para que haja uma aprendizagem a uma função desejada, logo, possuem uma dependência dos dados utilizados para que se obtenha uma boa qualidade de resposta. Tampouco, há vários tipos de diferentes algoritmos e distintas estratégias de aprendizado. Os mais relevantes tipos de aprendizado de máquina serão abordados a seguir.

2.2.1. K-Vizinhos Mais Próximos (KNN)

O K-Nearest Neighbors será uma das técnicas do presente trabalho, o algoritmo K-vizinhos mais próximos (KNN) é uma técnica de classificação com aprendizado supervisionado, isto é, as saídas previstas às instâncias de treinamento são informadas antes para o algoritmo. É usado em distintas áreas para reconhecimento de padrões. Essa técnica assume que as instâncias são pontos em um espaço n-dimensional. A classificação acontece por meio das distâncias entre as instâncias de teste e treinamento no espaço: Tendo a instância $x = (x_1, x_2, \dots, x_n)$ e $y = (y_1, y_2, \dots, y_n)$, a distância entre as duas será $d(x, y)$. Esta distância, usada como métrica no algoritmo durante a classificação pode ser escolhida dentre as diferentes distâncias existentes, como por exemplo, a distância euclidiana, distância de *Manhattan*, distância de *Minkowski*, etc. (MITCHELL, 1997, pp.243-245).

O que caracteriza o KNN são os k vizinhos mais próximos usados para fazer a classificação. A classificação é feita de acordo com as classes das instâncias de treinamento que obtiveram a menor distância de teste. Neste cenário devem-se informar quais as saídas das instâncias do conjunto de treinamento, ou seja, suas classes (RUSSEL et al., 2010, pp.853-855).

O algoritmo nesse tipo de aprendizado aprende na forma de uma função, há um conjunto de variáveis, o domínio e seu conjunto imagem a respeito à função que se deseja assimilar. Geralmente, o programa realiza a aprendizagem observando situações em que a resposta já é conhecida e apresentada a ele, sendo esses os relevantes dados para treino. Sob esse viés, percebe-se a detecção de padronização para resposta de acordo com os valores das variáveis de entrada do sistema em cada caso particular e o intuito do algoritmo é diminuir o erro de resultados para caso que são desconhecidos, isto é, valores de entrada que não fizeram parte do treinamento do modelo.

Há, nesse sentido, a relevância da interferência de um modelo de Aprendizado Supervisionado para realização de classificações. Elas proporcionam a possibilidade de previsão de futuros casos não presente no momento do treinamento (Alpaydin, 2020). Por conseguinte, podem-se citar exemplificações de classificação: reconhecimento facial, reconhecimento de letras, reconhecimento de voz, biometrias.

Para o trabalho que tem como característica tentar classificar cada amostra de um conjunto de dados avaliando sua distância em relação aos vizinhos próximos. Se os vizinhos mais próximos forem majoritariamente de uma classe, a amostra em questão será classificada nessa categoria. O passo-a-passo do algoritmo:

- Criar um conjunto X de instâncias de treinamento e um valor com as respectivas classes relacionadas a cada instância;
- Escolher uma distância para servir de métrica para o algoritmo;
- Entrar com a instância de teste y que será classificada e o número k vizinhos mais próximos que serão escolhidos são ímpares para evitar empates;
- As distâncias entre y e todas as outras instâncias do conjunto X e ordenadas em ordem crescente;
- As k instâncias de treinamento de serão escolhidas para a classificação;
- A classificação é feita de acordo com a classe que tem o maior número de vizinhos mais próximos;

Para o presente trabalho foi considerado a distância euclidiana que tem como característica a distâncias entre duas instâncias ou pontos em um espaço n -dimensional (JOHNSON, p.30). A distância é calculada a partir da raiz quadrada da soma das diferenças entre as coordenadas ao quadrado, ou seja:

$$d(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} \quad \text{EQ(1)}$$

Esta distância será usada como o classificador KNN, visto que a distância mínima identifica uma instância de teste com uma de treinamento (representam os pontos P e K). Apesar de ser efetiva em vários casos, esta técnica pode se mostrar não satisfatória para propósitos mais estatísticos de acordo com (JOHNSON; WICHERN, 2008, p.30), porque cada coordenada contribui igualmente para o cálculo da distância. Quando as coordenadas representam terão um peso relativamente maior

na medição das distâncias e poderá ponderar a um resultado não desejado. Para suprir tal problema das variações de grandezas das variáveis, uma normalização dos dados tem de ser feita.

2.2.2. Redes Neurais Residuais (ResNet)

As Redes Neurais Residuais (ResNet) é uma técnica das redes neurais convolucionais (CNN), no entanto, com característica de possibilidade de realização de saltos entre as camadas. É importante ressaltar que as redes neurais convolucionais se apresentaram, desde sua elaboração, serem muito promissoras para solucionar problemas de classificação de imagens, se mostrando uma possível alternativa aos métodos tradicionais para esse tipo de problema. Contudo, umas das principais desvantagens das CNNs é o fato de existir a necessidade de uma grande quantidade de dados para poder haver a reconhecimento de padrões – *features*. Nesse sentido, o segundo algoritmo proposto no presente trabalho, segue os princípios estudados pelos autores Kaiaming He, Xiangyu Zhang, Shaoqing Ren e Jian Sun por meio de técnicas de redes neurais convolucionais publicado no artigo “*Deep Residual Learning for Image Recognition*” que apresenta resultados significativos para classificação de imagens por meio redes neurais residuais com 50 camadas, especificamente, 48 camadas convolucionais, uma camada de MaxPool e uma camada média de pool para treinamento de redes substancialmente mais profundas.

Para este trabalho a arquitetura ResNet segue duas regras básicas de estrutura. Primeiro, o número de filtros em cada camada é o mesmo, dependendo do tamanho do mapa de recursos de saída. Segundo, se o tamanho do mapa de recursos for reduzido pela metade, ele terá o dobro do número de filtros para manter a complexidade de tempo de cada camada. Assim, o modelo proposto para promover o processo de classificação de imagens por meio do uso de equipamentos de proteção individual (EPIs) segue os moldes de implementação da arquitetura ResNet de 50 camadas. Dessa forma, possui 5 estágios, cada um com uma convolução e um bloco de identidade. Cada bloco de convolução possui 3 camadas de convolução e cada bloco de identidade também possui 3 camadas de convolução conforme o esquema a seguir:

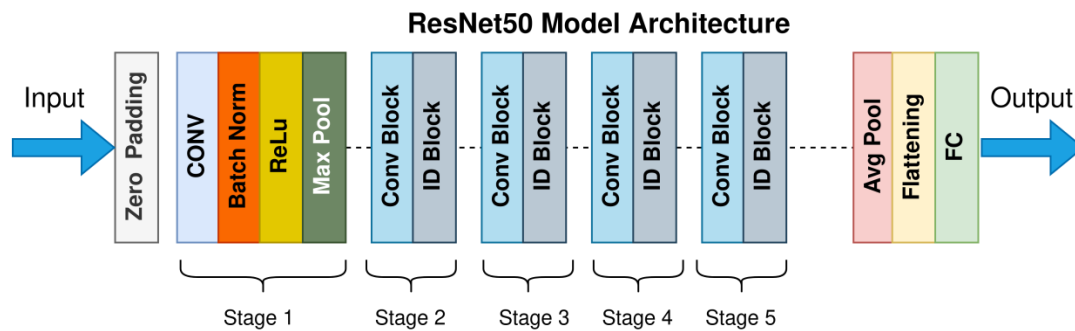


Figura 1. Arquitetura do Modelo ResNet-50.

Fonte: Towards Data Science, 2022.

Nos estágios, as camadas convolucionais têm como responsabilidade a extração das denominadas *features* de cada entrada. O método de extração dessas *features* acontece por meio dos filtros convolucionais de tamanhos reduzidos, na qual os filtros percorrem os dados de entrada em largura, altura e dimensão por meio de realizações de operação de convolução sobre os dados. Assim, os filtros vão sendo ajustados a cada processamento de entrada durante o intervalo de treinamento da rede neural de tal modo a disparar quando a entrada contiver umas características comuns aos lotes de entrada, como por exemplo, cores, arestas dentre outros aspectos. Com o andar da entrada na rede, os filtros vão realizando os aprendizados de estruturas cada vez mais complexam, isto é, quando mais filtros convolucionais, mais *features* pode ser extraído da entrada, entretanto isso tem custo de processamento e memória, o que precisa ser balanceado na hora da definição da arquitetura. A Norma de Lote (*Batch Norm*) tem o papel de realizar os agrupamentos em bloco para promover o aumento do desempenho da rede neural. A Unidade Linear Retificadora (ReLU) propiciar a aprendizagem dados complexos por meio de retificações de pessoas dados de entrada. Após cada período de treinamento ele promove os reajustes dos pesos sinápticos para classificação dos dados para as redes neurais, figura 2.

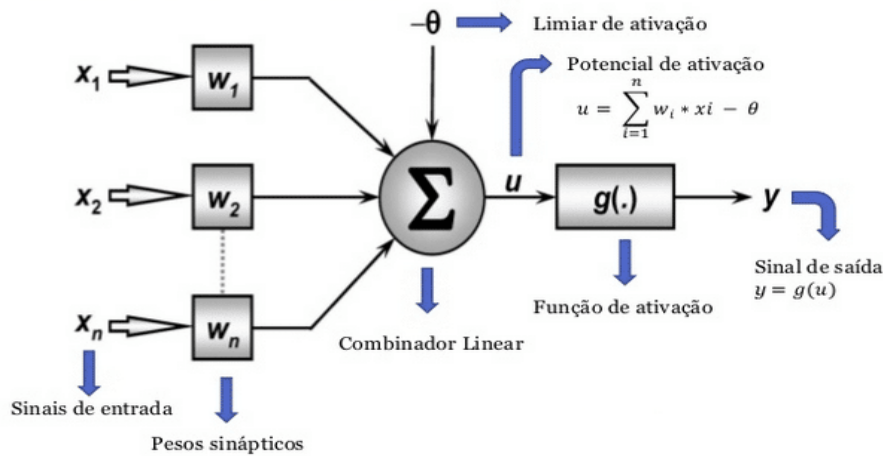


Figura 2. Função de Ativação por Unidade Linear Retificadora (ReLU).

Fonte: Research Gate, 2020.

A Camada de *pooling* tem como característica uma camada destinada a redução do tamanho de dados de entrada. Após uma camada convolucional, na ResNet-50, é usada uma camada de *pooling*, assim as seguintes camadas de convolução receberão uma nova forma de representação de dados, com possibilidade da rede realizar a aprendizagem em diversas representações dos dados (Zhang et al., 2016). Assim, é reduzido em subpartes dos dados originais pelo mais alto valor encontrado nas suas sub-regiões, reduz assim o tamanho da imagem por um fator de filtro $m \times n$ (KARPATY).




Figura 3. Image Matrix versus Max Pool.

Fonte: Research Gate, 2020.

A *Average Pooling* é uma operação de agrupamento que faz parte da ResNet-50 que calcula o valor médio para patches de um mapa de recursos e o usa para criar um mapa de recursos reduzido (em pool). Geralmente é usado após uma camada convolucional. Ele adiciona uma pequena quantidade de invariância de tradução - o que significa que traduzir a imagem em uma pequena quantidade não afeta significativamente os valores da maioria das saídas agrupadas. Ele extrai recursos de forma mais suave do que o Max Pooling, enquanto o max pooling extrai recursos mais pronunciados, como bordas. Para converter todas as matrizes bidimensionais resultantes de mapas, o *flattening*, portanto, tem o intuito de realizar o agrupamento em um único vetor linear contínuo-longo

classificada probabilisticamente pela função de ativação de saída *sigmoide* com objetivo de instância se pertence ou não a determinada classe.

2.3. Visão Computacional

De acordo com (JAHNE; HAUBECKER, 2000), a área de Visão Computacional é compreendida como um conjunto de técnicas usadas para processamento, aquisição, na análise e entendimento de dados relativamente complexos e com alto poder de dimensionalidade, as quais são extraídas do ambiente real para exploração técnica e científica. A meta das visões computacionais é modelar e automatizar o processo de reconhecimento visual (FORSYTH; PONCE, 2002). Dessa forma, a visão computacional tem como objetivo tomar decisões úteis sobre objetos físicos reais ou ter como ideal a construção de descrições de cenas a partir de imagens – visão computacional tenta simular a visão humana.

No tópico citado de Processamento Digital de Imagens, ficaram caracterizado os níveis de tratamento das imagens e apresentado que as fases de PDI os processos de baixo-nível consistem na eliminação de ruídos e melhora o contraste das imagens. Na visão computacional encontra-se na etapa do nível-médio na qual descreve as segmentações e reconhecimento de padrões e posteriormente complementar com o nível-alto responsável pelos processos cognitivos como rastreamento de um objeto numa sequência de imagens (FILHO; NETO, 1999).

O baixo-nível é a primeira etapa de carácter obrigatório para construir um sistema baseado na aprendizagem de máquina, o objetivo da técnica é a manipulação de imagens de maneira que não somente na entrada como também na saída do processo seja uma imagem. O intuito em realizar o procedimento de processamento de imagem é a representação que permite o entendimento computacional, uma vez que a imagem é transformada, ou melhor, convertida em dados. Os dados que são extraídos posteriores ao processamento são submetidos a técnicas com a ideia de abstrair variações favoráveis da imagem digital para que tais variações sejam também usadas em outros procedimentos (CÂMARA et al, 1996).

As tarefas relativas à etapa do baixo-nível para aprendizagem de máquina tem às principais técnicas:

- a) Escala de Cinza: Usada em técnicas de algoritmos de K-Vizinhos Mais Próximos, a escala de cinza é uma escala de tons de cinza, podendo reduzir os dados em três vezes

menos, em que os valores dos pixels da imagem variam de acordo com a sua luminosidade, numa escala entre o branco e preto. É calculada a partir da conversão RGB para YIQ que só normaliza os níveis de brilho da imagem. (FILHO; NETO, 1999)

- b) Histograma: Histograma de uma imagem é um conjunto de números que indica em percentual os pixels em uma dada imagem que apresentam em um nível na escala de cinza. Estes valores são geralmente representados por um gráfico de barras que fornece para cada nível de cinza o percentual de pixels correspondentes na imagem. Através da visualização do histograma de uma imagem obtemos uma indicação de sua qualidade quanto ao nível de contraste e quanto ao seu brilho médio (FILHO; NETO, 1999)
- c) Binarização: O algoritmo de binarização é normalmente utilizado quando é preciso fazer a separação entre o fundo da imagem com os objetos que representam os caracteres. A binarização é o método mais simples para segmentação de imagens que consiste em separar regiões de não interesse através da escolha de um ponto limiar. Em alguns casos não são possíveis dividir a imagem em apenas um limiar que resulte em resultados satisfatórios, nesses casos são definidos mais de um ponto de corte da imagem (FILHO; NETO, 1999).
- d) Filtros: usada na técnica do algoritmo de Rede Neural Residual, elas possuem técnicas de filtragem são transformações da imagem *pixel a pixel*, que não dependem apenas do nível de cinza de um determinado *pixel*, mas também do valor dos níveis de cinza dos *pixels* vizinhos. O processo de filtragem é feito utilizando matrizes denominadas máscaras, as quais são aplicadas sobre a imagem (FILHO; NETO, 1999).

No Médio-Nível, para a aprendizagem de máquina, é inegável reconhecer que na natureza a padronização seja uma realidade importante, pois os padrões se manifestam de várias maneiras como, por exemplo, sons, imagens, formas, cheiros e sabores e a todo tempo os seres humanos e também outros animais, tem a percepção e interagem com tais padronizações com naturalidade. Exemplos disso, é a habilidade que o ser humano tem em distinguir o som de motor de um caminhão de um som de um violino. Naturalidade inerente a estas habilidades faz com que o humano não perceba as complexidades cognitivas por trás de tais ações. Essas complexidades se tornam evidentes quando há o intuito de uma reprodução artificial por uma máquina computacional. Assim, reconhecer significa “conhecer de novo”, e isto tem implicação no processo onde existe algum

conhecimento prévio e algum tipo de armazenamento do conhecimento sobre o objeto a ser reconhecido. Essa é a etapa onde os sistemas de visão computacional possuem uma interseção com a área de inteligência artificial. Assim para fazer o reconhecimento um sistema de visão computacional necessita estruturalmente de uma base de dados para adquirir conhecimento de objetos a ser reconhecida, no caso equipamentos de proteção individual, esta base de conhecimento pode ser implementada diretamente na codificação através de um sistema com base em regras, ou esta base pode passar pelo processo de aprendizagem a partir uma amostragem de objetos na qual podem ser reconhecidas através das técnicas de *Machine Learning*.

Para a área de visão computacional o setor de reconhecimento de objetos tem grande relevância, uma vez que está bastante relacionada ao reconhecimento de padrões. Objetos em uma dada imagem representam padronização de formas, texturas, cores, dimensões entre outros e com o conhecimento individual de tais padrões é propício perceber o objeto como um todo. As técnicas de reconhecimento de padrões podem ser particionadas em duas grandes partes:

- Estruturais: padrões são descritos de forma simbólica e a estrutura é a forma padrão de relacionamento.
- Teoria de Decisão: são descritos por propriedades quantitativas e deve-se decidir se o objeto possui ou não estas propriedades.

Ao processo de reconhecimento de padrões, pode ainda ser realizado uma mistura de técnicas utilizadas nestes dois grupos. Ou seja, uma detecção da pele e uma detecção dos olhos, contudo, a segunda pode ser reconhecida utilizando uma rede neural e a primeira por análise estatística.

No Médio-Nível, também, uma imagem de entrada pode se subdividir em suas partes constituintes ou objetos. Para cada parte existe uma uniformidade e homogeneidade com respeito a algumas propriedades como, por exemplo, textura e cor. A ideia desse processo é o agrupamento de *pixels* ou conjunto de *pixels* de mesma propriedade. Existem diversas formas de realização de segmentação em imagens, mas não existe nenhum método único que seja capaz de segmentar todas as categorias de imagens. Algumas técnicas de segmentação são segmentação por detecção de borda, segmentação por corte e segmentação por crescimento de região (MARENGONI e STRINGHINI, 2009).

Há, por último, o Alto-Nível que trata-se de um procedimento de rastreamento cujo o objetivo é encontrar um padrão de movimento do objeto para que evite várias buscas na base de dados para comparação, assim os processos de rastreamento atrelam a um conhecimento sobre o movimento do objeto. Os procedimentos podem ser aplicados em diferentes áreas, indo de sistemas de vigilância a uso em sistemas de interface humano computador, por exemplo. Faz-se necessário salientar o uso de alguns algoritmos com intuito de explicar mais sobre a técnica de rastreamento:

- **Predição:** Trabalha na forma em guarda em um espaço de memória uma quantidade de caminhos que os objetos podem realizar. Dessa forma, realiza uma análise preditiva dos caminhos que poderá ser percorrido pelo objeto nos frames. O algoritmo analisa o local dentro de limite de frames, na qual verifica a quantidade de pixel de onde havia sido realizada a previsão. Assim, segue parte dos caminhos previstos e o algoritmo leva em consideração como sendo o mesmo objeto, ou outro objeto, e ainda pode ser considerado com um estado de indeterminação.
- **Baseado em Cores:** Esse tipo de algoritmo de rastreamento tem como principal referência para funcionamento às cores do objeto para identificar o movimento nas cenas de vídeo, faz o rastreamento do objeto pela cor, porém, é comum haver falhas no processo, uma vez que a possibilidade de encontrar mais objetos com a mesma tonalidade.
- **Filtro de Kalman:** é definido por um conjunto de equações matemáticas que proporcionam uma implementação computacional eficaz para estimar o estado de um processo, de modo geral, a falha é inerente a essa estimativa para minimização. No caso do rastreamento de objetos em vídeos, a situação vigente é dinâmica dos objetos previamente segmentados, enquanto que o estado do processo é representado pelo conjunto de características que serão estimadas.
- **Fluxo Óptico:** É a distribuição 2D da velocidade aparente do movimento dos padrões de intensidade no plano da imagem. Assim, o campo do fluxo óptico consiste em um campo denso de velocidade onde a cada pixel no plano da imagem está relacionado a um único vetor de velocidade. Para fins de visualização, o campo amostrado em uma malha e chamado de diagrama de agulhas. Se for conhecido o intervalo de tempo entre duas imagens consecutivas, os vetores da velocidade podem ser convertidos em vetores de deslocamento e vice-versa (SHI e SUN, 2000).

3. NORMAS REGULAMENTADORAS (NR_s)

As NRs foram criadas com o intuito de promover saúde e segurança do trabalho na empresa, ou seja, tratam-se do conjunto de requisitos e procedimentos relacionados à segurança e medicina do trabalho, sendo obrigatório para as empresas. Por conseguinte, as normas regulamentadoras foram desenvolvidas para o trabalhador ter segurança no ambiente de trabalho e, em síntese, criar um local seguro e adequado, de forma que o cumprimento delas deriva em multas, processos judiciais e outras situações adversas (SANTOS et al., 2018).

Uma empresa que está de acordo com os princípios da legislação da segurança do trabalho, e, assim, segue as normas regulamentadoras de acordo com o trabalho que oferece, provavelmente irá diminuir casos de acidentes e ainda proteger a integridade do empregado. Isso porque a segurança no trabalho reduz riscos de acidentes, propicia a saúde e a satisfação dos trabalhadores, melhora os resultados operacionais (SANTOS et al., 2018).

Para este trabalho tem-se ênfase NR 06 que se trata dos equipamentos de proteção individual. Sabe-se que são obrigação por parte do empregador fornecer os empregados, gratuitamente, os EPIs de acordo com o risco do ambiente do trabalhador, em perfeitas condições de uso e funcionamento. Se o empregado for flagrado, por órgãos de fiscalização, sem o capacete ou qualquer outro equipamento de segurança necessária, a multa é aplicada a empresa. É de suma responsabilidade do empregador, quando necessário providenciar a exigência uso, orientação e treinamento ao trabalhador, no que se refere o adequado uso dos equipamentos de proteção individual (BRASIL, 2009).

Há, entretanto, o posicionamento dos trabalhadores diante o EPI, uma vez que acumulam responsabilidades, dentre elas: utilização dos equipamentos apenas para a finalidade a que se destina ter responsabilidade quanto à conservação do patrimônio e guarda comunicar aos empregadores quando um dano ou alteração afetar seu uso, além de seguir todas as determinações dos empregadores sobre o seu uso (BRASIL, 2009).

Ainda seguindo as determinações da NR 06, a secretaria do trabalho cita uma lista dos EPIs que devem ser fornecido pelos empregadores dependendo do ambiente de trabalho do empregado. Os principais equipamentos de proteção individual estão organizados em conjuntos de proteção como:

para cabeça, olhos, face, audição, respiração, do tronco, dos membros superiores e inferiores, do corpo inteiro, contra quedas de diferença de nível. Apresentados na tabela 1, a seguir:

Tabela 1. Equipamentos de Proteção Individual da NR 6.

Grupo	Nome	Equipamentos
A	Proteção de Cabeça	Capacete e Capuz
B	Proteção dos Olhos e Face	Óculos, Protetor Facial e Máscara de Solda
C	Proteção Auditiva	Protetor Auditivo
D	Proteção Respiratória	Respiradores e Máscaras de Pó
E	Proteção dos Membros Superiores	Vestimentas de Segurança
F	Proteção dos Membros Inferiores	Luva, Creme Protetor, Manga Braçadeira, Dedeira
G	Proteção do Corpo Inteiro	Calçada, Meia Perneira, Calça;
H	Proteção Contra Quedas com Diferença de Nível	Macacão, Conjunto de Vestimenta de Corpo Inteiro
I	Proteção do Tronco	Dispositivo Trava-Queda e Cinturão

Fonte: Guia Trabalhista, 2022.

Com os equipamentos de proteção individual para o trabalhador torna-se mais prático a atividades e execução dos serviços de forma mais segura. Mas, por mais simples que seja o uso dos itens mencionados na tabela anterior, é inegável que, em um local de trabalho com tantas pessoas, se torna um desafio para que todos o façam a utilização do modo correto. Além disso, é preciso ter em mente que nem todos os empregados tem o compromisso de utilizar, basta que apenas uma pessoa desprotegida para que a segurança do ambiente esteja em risco. Assim, é evidente a relevância do monitoramento da distribuição, uso, controle de acesso dos profissionais no ambiente de trabalho em

relação à adequação pessoal. Para o presente trabalho foi adotado os principais itens do grupo A, B e D: capacete, máscara, óculos e abafador.

3.1. Capacete de Proteção

O capacete de segurança é um Equipamento de Proteção Individual de uso obrigatório em muitos ambientes de trabalho. O principal intuito destina-se a proteção da cabeça do trabalhador contra impactos causados por quedas de materiais, batidas e, de acordo com modelo, até mesmo choques elétricos. Para o presente trabalho foi inserido na base de treinamentos capacetes com características e cores aleatórias figura 4, para teste foi usado dois modelos: capacete azul e capacete branco, conforme mostrado na figura 5.



Figura 4. Algumas imagens do Banco de Treinamento.

Fonte: Autoria própria.



Figura 5. Capacete Branco *versus* Capacete Azul.

Fonte: Autoria própria.

3.2. Óculos

Os Óculos de Proteção serve unicamente para proteger os olhos dos trabalhadores no ambiente de trabalho contra diferentes tipos de riscos. Desde micróbios, bactérias e vírus, até partículas volantes que podem atingir a região dos olhos dos trabalhadores. Para o presente trabalho foi inserido na base de treinamentos óculos em diferentes pessoas com ângulos diferentes, figura 6. Para teste foi usado dois modelos: óculos escuros e óculos transparentes, conforme mostrado na figura 7.



Figura 6. Algumas imagens do Banco de Treinamento.

Fonte: Autoria própria.



Figura 7. Óculos Transparentes *versus* Óculos Escuros.

Fonte: Autoria própria.

3.3. Abafador

Os abafadores são um dos tipos de protetores auriculares mais conhecidos. Também chamados circum-auriculares, eles têm duas “conchas” de plástico que tampam os ouvidos e uma haste que se ajusta acima da cabeça ou um suporte que se acopla ao capacete. Para o presente trabalho foi inserido na base de treinamentos abafadores em diferentes ângulos e pessoas, figura 8. Para teste foi usado um abafador rosa, conforme mostrado na figura 9:




Figura 8. Algumas imagens do Banco de Treinamento.

Fonte: Autoria própria.



Figura 9. Imagens da base de imagens de teste.

Fonte: Autoria própria.

3.1. Máscara de Proteção

As Máscaras de Proteção Respiratória servem como filtro para evitar a inalação de substâncias tóxicas, fumaças, poeiras e gases que podem causar danos à saúde, sendo geralmente constituídos por um emaranhado de microfibras sintéticas combinadas em camadas e tratadas eletrostaticamente para reter apenas os materiais. Para o presente trabalho foi inserido na base de treinamentos máscaras em diferentes ângulos e pessoas, figura 10. Para teste foi usado máscara de proteção contra microfibras e poeiras de cor azul, conforme mostrado na figura 11.



Figura 10. Algumas imagens do Banco de Treinamento.

Fonte: Autoria própria.



Figura 11. Imagens da base de imagens de teste.

Fonte: Autoria própria.

4. METODOLOGIA

Para projetar o presente trabalho foi levado em consideração quatro grandes etapas: fase exploratória, fase de pesquisa aprofundada, fase de ação e fase de avaliação. O intuito é sistematizar o método para conduzir de forma lógica as descobertas e interpretações científicas.

Tabela 2. Planejamento do Método de Pesquisa.

FASES DA PESQUISA		
Ordem	Descrição	Atividades
Fase 1	Exploratória	<ul style="list-style-type: none"> ▪ Estabelecer o campo de pesquisa; ▪ Determinar os atores envolvidos; ▪ Definir o processo crítico; ▪ Levantar as atividades e situações problemáticas; ▪ Selecionar as ferramentas de coleta de dados;
Fase 2	Pesquisa Aprofundada	<ul style="list-style-type: none"> ▪ Coletar os dados internos do processo; ▪ Buscar melhores práticas;
Fase 3	Avaliação das Técnicas (Resultados)	<ul style="list-style-type: none"> ▪ Mapear o processo atual; ▪ Analisar os resultados; ▪ Escolher algoritmo com melhor desempenho; ▪ Implementar as soluções mais viáveis para controle de acesso;
Fase 4	Implementação de Controle de Acesso (Resultados)	<ul style="list-style-type: none"> ▪ Testar Controle de Acesso; ▪ Analisar criticamente; ▪ Lições aprendidas;

Fonte: Próprio autor.

4.1. Fase Exploratória

Nessa etapa buscou-se realizar o processo de verificação do campo de pesquisa de atuação para determinar os principais atores envolvidos necessários para o processo a ser pesquisado. Criticamente, sabe-se que o uso de equipamentos de proteção individual é obrigatório para empresas, principalmente, nas empresas que promovem riscos aos trabalhadores. Assim, para realização da pesquisa focou-se nos equipamentos que promovem um grau significativo de importância por

proteger áreas sensíveis do corpo humano, como a cabeça, olhos, ouvidos e boca. Sabe-se que para as Normas Regulamentadoras (NRs), obriga para esse cenário o uso, respectivamente, do capacete de proteção, óculos de proteção, abafadores e máscaras de proteção. Sendo assim, para realização da fiscalização, o presente trabalho partiu de uma pesquisa básica, estratégica, exploratória com abordagem quantitativa com meta da utilização de imagens de equipamentos de proteção individual em um dado grupo de pessoas para treinar computacionalmente uma máquina, a ponto de aprender e, portanto, conseguir realizar previsões dos equipamentos de proteção individual de outras pessoas.

4.1.1. Coleta de Imagens

O banco de dados de imagens do projeto foi organizado com imagens positivas de treinamento que contém os equipamentos de proteção individual e as imagens negativas treinamento sem os equipamentos de proteção individual e as imagens de teste. As aquisições das imagens positivas e negativas da base de treinamento foram adquiridas parte do google imagens parte de autoria própria. A distribuição segue o seguinte princípio apresentado na tabela a seguir:

Tabela 3. Aquisição das Imagens do Banco de Dados.

Equipamento de Proteção	Google Imagens	Autoria Própria
Com Máscara	84,4%	15,3%
Sem Máscara	100%	0%
Com Abafador	67,2%	32,8%
Sem Abafador	100%	0%
Com Capacete	66%	34%
Sem Capacete	100%	0%
Com Óculos	61,8%	38,1%
Sem Óculos	100%	0%

Fonte: Aquisições das Imagens.

A distribuição das imagens estão organizada na base de dados para os seguintes equipamentos: abafador, máscara, óculos e capacete. Para cada equipamento têm-se o conjunto de imagens opostas,

ou seja, com a ausência do uso de equipamentos de proteção individual. Para treinamento foram utilizadas todas as imagens (figura 12), por característica especial, foi direcionada a rede neural 15% de imagens positivas e negativas para validação nas épocas de treinamento para criação do modelo. Já o KNN que realiza o método de consulta para realizar a previsão não possui a técnica de validação. A distribuição segue a seguir:




Figura 12. Banco de Imagens do Projeto.

Fonte: Próprio Autor.

Para realização do teste, contou-se com 27 imagens de seis pessoas diferentes com total de 162 imagens teste que não estão dentro da base de treinamento com objetivo de reconhecer a presença e ausência dos EPIs de proteção de cabeça e ouvido, com consideração de três posições diferentes:




Figura 13. Imagens de testes nas posições e 0° 45°e 90°.

Fonte: Autoria própria.

Nesse cenário, para que seja realizada uma pesquisa padronizada para visar uma observação sistemática dos algoritmos projetados, as seções de fotos para teste foram tiradas respeitando uma ordem lógica e combinação de acessórios baseado no método de pesquisa quantitativa que propõe ao pesquisador analisar uma quantidade de dados de uma amostra, onde as informações serão expressas em termos numéricos e serão tratadas e entendidas por meio do uso de estatística.

Tabela 4. Captura de Imagens para Testes.

Ordem	Ângulo	Equipamento
1° Foto	90°	Óculos Pretos
2° Foto	45°	Óculos Pretos
3° Foto	0°	Óculos Pretos
4° Foto	0°	Óculos Transparentes
5° Foto	45°	Óculos Transparentes
6° Foto	90°	Óculos Transparentes
7° Foto	90°	Capacete Branco
8° Foto	45°	Capacete Branco

9° Foto	0°	Capacete Branco
10° Foto	0°	Capacete Azul
11° Foto	45°	Capacete Azul
12° Foto	90°	Capacete Azul
13° Foto	90°	Abafador
14° Foto	45°	Abafador
15° Foto	0°	Abafador
16° Foto	0°	Máscara de Proteção
17° Foto	45°	Máscara de Proteção
18° Foto	90°	Máscara de Proteção
19° Foto	90°	Completo com óculos Preto e Capacete Azul
20° Foto	45°	Completo com óculos Preto e Capacete Azul
21° Foto	0°	Completo com óculos Preto e Capacete Azul
22° Foto	0°	Completo com óculos Preto e Capacete Branco
23° Foto	45°	Completo com óculos Preto e Capacete Branco
24° Foto	90°	Completo com óculos Preto e Capacete Branco
25° Foto	90°	Completo com óculos Transparente e Capacete Branco
26° Foto	45°	Completo com óculos Transparente e Capacete Branco
27° Foto	0°	Completo com óculos Transparente e Capacete Branco

Fonte: Autoria própria.

4.1.2. Ferramentas Utilizadas

4.1.2.1. Linguagem Python

Para o presente trabalho foi usado Python 3.9, a escolha da linguagem de programação para o desenvolvimento é pelo fato de ser considerada por ser bastante versátil, por causa da sua simplicidade e dinâmica. Permite que o programador se preocupe de forma mais eficaz na lógica de programação, em comparação com a sintaxe. Além disso, para pessoas de outras áreas da computação exige menos conhecimento específico. Isso torna muito útil a utilização da linguagem, uma vez que o aprendizado de máquina é um campo transversal com diversos campos de estudo como ciência de dados, biometria, processamento de imagem, processamento de voz, marketing, estatística, probabilidade, entre outros. A tipagem forte evita erros de execução de programas, o que propicia que seja ainda mais viável para o uso das pessoas.

Nesse cenário, foi a principal a utilizada da IDE Pycharm na qual é um ambiente de desenvolvimento integrado usado para programação em Python onde oferece como principais ferramentas: Análises de código, Depurador Gráfico, Testador de Unidade Integrada, Integração com Sistemas de Controle de Versão e Suporta Desenvolvimento Web. Todavia, especificamente, ao treinamento do modelo para aprendizagem de máquina do algoritmo baseado em redes neurais residuais foi usada a GPU do Google Colab, porém, o conjunto geral de ferramentas utilizadas para as demais implementações estão a seguir:

Tabela 4. Bibliotecas e Módulos.

Nome	Função	Versão
OPENCV	Essa biblioteca quer algoritmos básicos quer algoritmos avançados na área de aprendizagem de máquina, utilizadas em diversos fins, como detecção faces, detecção de objetos, reconhecimento facial, rastreamento de movimentos através de câmeras, reconhecimento de voz e gestos, entre outras aplicações.	4.6.0
	Contém componentes direcionados das interfaces gráficas, redes, threads, estruturas de dados, álgebra	

DLIB	linear, aprendizado de máquina, processamento de imagem, mineração de dados, ciências de dados, XML e análise de texto, otimização numérica, redes bayesianas, entre outros.	19.24.0
PYFIRMATA	É uma biblioteca de comunicação utilizada para realização de uma relação mais direta e instantânea entre a linguagem python e microcontrolador arduino.	1.1.0
NUMPY	Tem como característica de suporte processamento de grandes e multidimensionais arranjos e matrizes, juntamente com uma coleção de funções matemáticas de alto nível para realização de operações.	1.22.3
PANDAS	É uma biblioteca para uso em Python de código aberto e de uso gratuito, que fornece ferramentas para manipulação e análise de dados.	1.5.3
SCIKIT-LEARN	É uma biblioteca para uso em Python de código aberto e de uso gratuito, que fornece ferramentas para manipulação e análise de dados.	1.2.1
TENSORFLOW	É uma biblioteca que contém código aberto para aprendizado de máquina aplicável a uma ampla variedade de tarefas. É um sistema para criação e treinamento de redes neurais para detectar e decifrar padrões e correlações, análogo à forma como humanos aprendem e raciocinam.	2.10.0
MÓDULO OS	Apresenta funções para nomes de arquivos, argumentos de linhas de comando e variáveis de ambiente podem ser representados usando o tipo string.	***

Fonte: Aatoria própria.

Para os equipamentos eletrônicos escolhidos com intuito de realizar um protótipo para controle de acesso com base nos procedimentos de reconhecimento de equipamentos de proteção individual. Os componentes utilizados estão apresentados na tabela 5 com objetivo de apresentar nome, função e detalhes gerais sobre suas características básicas.

Tabela 5. Equipamentos Eletrônicos para Protótipo de Controle de Acesso.

Nome	Descrição	Detalhes
Arduino	Composto por uma placa com microcontrolador Atmel AVR e um ambiente de programação baseado em <i>Wiring</i> e C++. Tanto o hardware como o ambiente de programação do Arduino é livre e qualquer pessoa pode modificá-los e reproduzi-los.	Modelo UNO
Diodo Emissor de Luz (LED)	Um diodo semiconductor (junção P-N), que quando é energizado, emite luz visível. A luz não é monocromática (como em um laser), mas consiste de uma banda espectral relativamente estreita e é produzida pelas interações energéticas do elétron. O processo de emissão de luz pela aplicação de uma fonte elétrica de energia é chamado eletroluminescência.	VERMELHO 20mA 1.63 a 2.03 VDC AMARELO 20mA 2.10 a 2.18 VDC VERDE 20mA 1.9 a 4.0 VDC
Resistor	Será utilizado resistor de 1K na etapa de prototipação no projeto com objetivo de atrapalhar o fluxo de corrente elétrica aos diodos emissores de luz.	1K
Servo Motor Arduino	Um equipamento utilizado nos mais diversificados projetos para controle de posição e movimento e está geralmente associado a projetos de pequena e média escala. Mesmo que bastante semelhantes, o servo motor é comercializado com ângulos de 180° e 360°.	Modelo Sg90

Fonte: Autoria própria

4.2. Fase de Pesquisa Aprofundada

Para buscar o melhor método de algoritmo dentro do cenário proposto foi realizado um sistema estratégico que, de maneira geral, ocorre o acesso da mesma base de imagens. As imagens que contém o uso do equipamento de proteção individual (Imagens Positivas) e as que não apresentam o uso de EPIs (Imagens Negativas) são direcionadas para os treinamentos das técnicas KNN e ResNet-50. Já as imagens de testes foram usadas para aplicar os modelos no processo de classificação para medição de resultados, como apresentado a seguir:

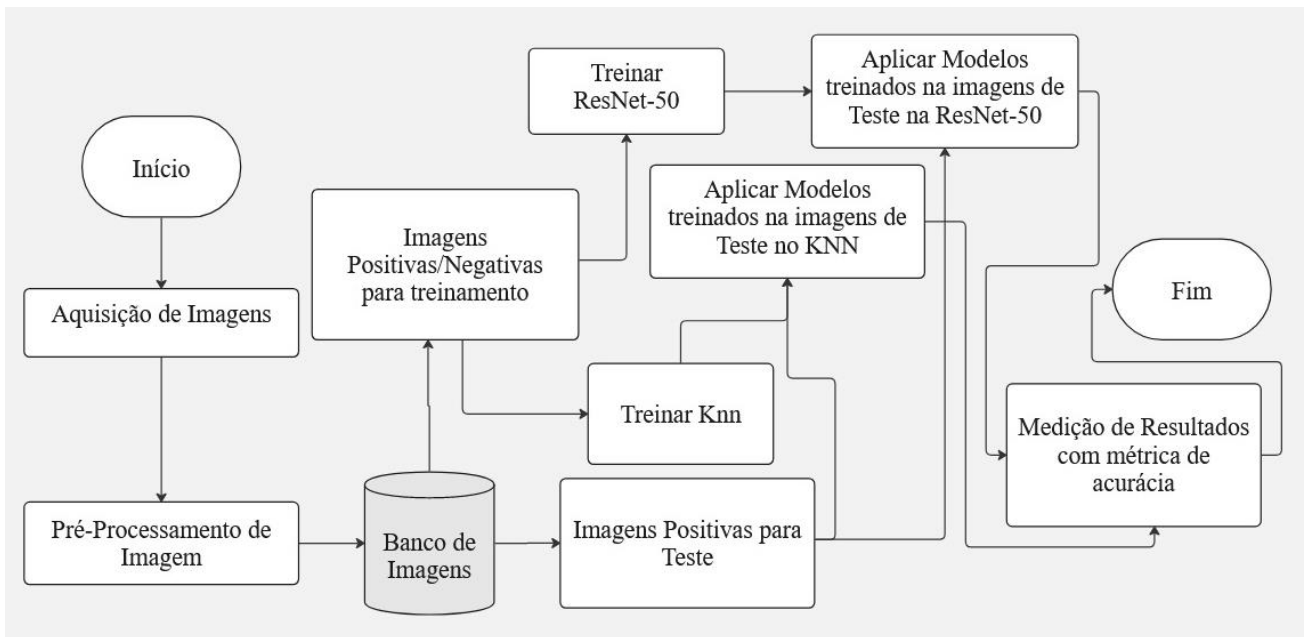


Figura 14. Processo para Coletar Resultados.

Fonte: Autoria própria.

4.3. Fase Avaliação das Técnicas

Nessa etapa de pesquisa, é proposta a verificação dos resultados por métricas estatísticas e de *Machine Learning* para tomada decisória sobre as soluções que apresentam maior assertividade na identificação da presença e ausência dos equipamentos pelos algoritmos de aprendizagem de máquina. De forma mais crítica, o princípio adotado baseia-se na Matriz de Confusão, conforme a figura 15. Será a métrica de acurácia a principal análise quantitativa para a pesquisa em questão de proporcionar a escolha do mais significativo com o foco de prever verdadeiros Positivos (TP) e Verdadeiros Negativos (TN) para compor o sistema de controle de acesso por fiscalização dos equipamentos de proteção individual através da visão computacional.

		Valor Predito	
		Sim	Não
Real	Sim	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Figura 15. Sistema de Matriz de Confusão.

Fonte: Diego Nogare, 2020.

4.4. Fase de Implementação do Controle de Acesso:

Aplicara-se um dos algoritmos ao controle acesso por meio de visão computacional conforme o fluxograma de processos:

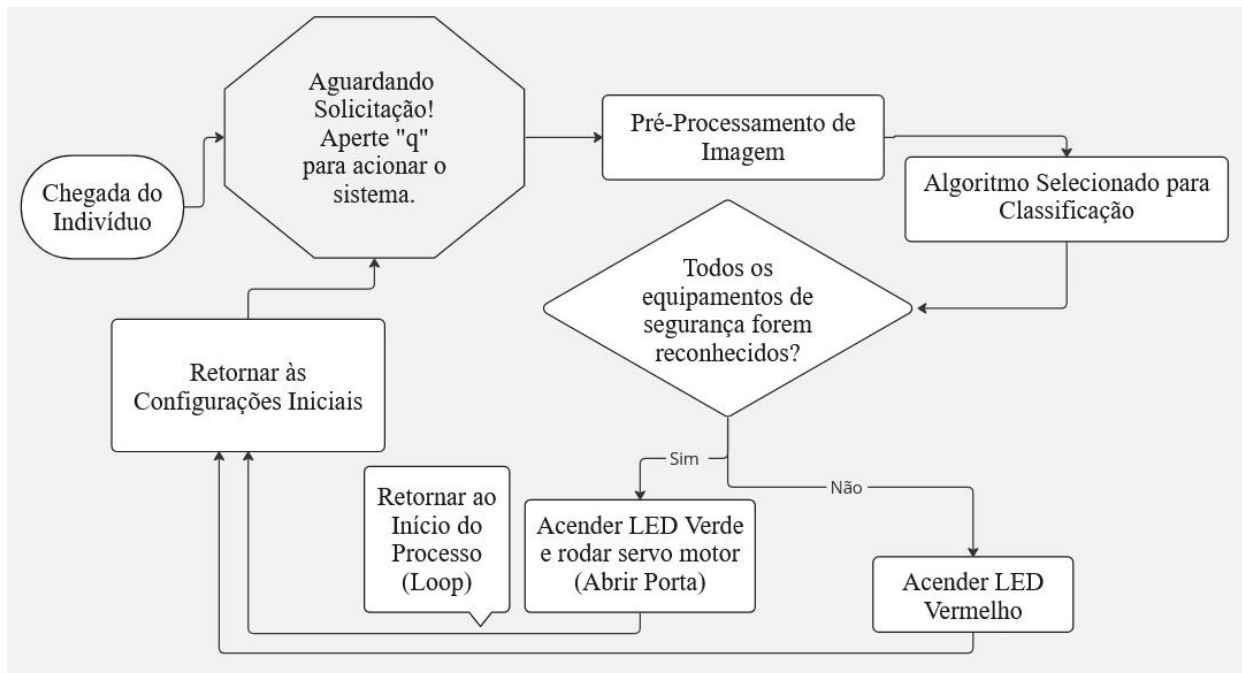


Figura 16. Processo do Controle de Acesso.

Fonte: Autoria própria.

A técnica elaborado aplica-se a um “Notebook Samsung I5 NP550XCJ-KT1BR 15.6”, HD, 8GB, 1TB para simulação. A primeira etapa acontecerá à chegada do indivíduo frente ao sistema de reconhecimento e, ao posicionar em frente a webcam do notebook, visualizará um LED acesso com luz amarela conectada ao arduino com intuito de indicar atenção. O trabalhador deve clicar na letra “q” para acionar o sistema de verificação e captura de imagem - “*uma analogia como acontece ao*

trabalhador ao usar um cartão ou digitar uma senha para acesso à área restrita em ambientes de empresa para garantia de acesso de funcionários autorizados”, o sistema obtém a imagem do indivíduo, acontece o pré-processamento da imagem para ficar de acordo com os requisitos da técnica que for selecionada para ser implementada para o processo de reconhecimento de EPIs. Após a análise do sistema, caso satisfaça a condição de identificação de todos os equipamentos, o LED amarelo apagará e ocorrerá o acionamento do LED verde, simultaneamente, o servo motor recebe um sinal através do protocolo de comunicação Stand Firmata para girar com ângulo 180° graus e na terminal de saída do python na IDE Pycharm apresentar uma mensagem “Abrir Porta”. Caso não esteja com os equipamentos necessários, é acionado o LED vermelho e apresentado uma mensagem “Não Reconhecida”. Após acende-se novamente o LED amarelo e o sistema aguarda o próximo solicitação de acesso.

5. RESULTADOS

5.1. Treinamento *versus* Acurácia

A relação entre treinamento e número de acertos contém uma relação significativa para verificar as características particulares do projeto desenvolvido para reconhecimento de equipamentos de proteção individual. Apesar da base de dados não seguir uma padronização da quantidade de imagens positivas igualmente no conjunto de treinamentos para cada equipamento. Segundo os estudiosos Aliaga e Gunderson (2002), a busca por explicação de aspectos por meio da coleta de dados numéricos e analisado através de métodos matemáticos (em particular, estatísticos), considera-se um método capaz de mostrados dados, indicadores e tendências observáveis. Nesse viés, será possível analisar aspectos individuais e gerais para verificar a desempenho dos treinamentos nos padrões de alimentação da base de dados vigentes para o trabalho, em vista de compreender o perfil crescente de assertividade à medida que evoluem os treinamentos. Para o trabalho foram utilizadas 162 (cento e sessenta e duas) imagens teste conforme as padronizações já citadas para o banco de imagens.

5.1.1. Performances de Treinamento da Máscara

Para analisar o desempenho de assertividade com as máscaras foi usada uma quantidade padrão de imagens negativas com variação de imagens positivas em quatro treinamentos distintos. É dito acerto quando o algoritmo reconhece a presença ou ausência do equipamento. Dessa maneira, a o resultado do desempenho é dado conforme a tabela a seguir:

Tabela 6. Treinamento *versus* Assertividade para Máscaras

Ordem de Treinamento	Imagens Negativas	Imagens Positivas	Imagens Teste	Acertos KNN	Acertos ResNet-50
1	360	75	162	43	52
2	360	150	162	51	79
3	360	225	162	66	103
4	360	319	162	79	128

Fonte: Autoria própria.

Na figura 17, é realizada uma análise geral do desempenho do algoritmo para o uso de máscaras em quatro momentos diferentes de imagens positivas na base de treinamento. Foram

perceptíveis, no momento inicial do treinamento, valores próximos de assertividades comparando ambos os algoritmos, porém, à medida que há a evolução da base de dados, a técnica de ResNet-50 apresentou tendência de maior eficiência em relação à técnica KNN, isto é, apresentou resultados mais significativos no cenário atribuído.




Figura 17. Treinamentos *versus* Acurácia.

5.1.2. Performances de Treinamento do Capacete

Para analisar o desempenho de assertividade com os capacetes de proteção foi usada uma quantidade padrão de imagens negativas com variação de imagens positivas em quatro treinamentos. É dito acerto quando o algoritmo reconhece a presença ou ausência do equipamento. Dessa maneira, o resultado do desempenho é dado conforme a tabela a seguir:

Tabela 7. Treinamento *versus* Assertividade para Capacete.

Ordem de Treinamento	Imagens Negativas	Imagens Positivas	Imagens Teste	Acertos KNN	Acertos ResNet-50
1	360	62	162	53	60
2	360	124	162	64	81
3	360	186	162	76	102
4	360	250	162	89	124

Fonte: Autoria própria.

Na figura 18, apresenta-se uma análise geral do desempenho do algoritmo em quatro momentos diferentes de positivas imagens na base de treinamento. Foram perceptíveis que a medida que há a evolução da base de dados, a técnica por aprendizagem profunda de máquina predomina em relação à técnica KNN, ou seja, a ResNet-50 apresenta resultados mais significativos no cenário a que foi atribuído.

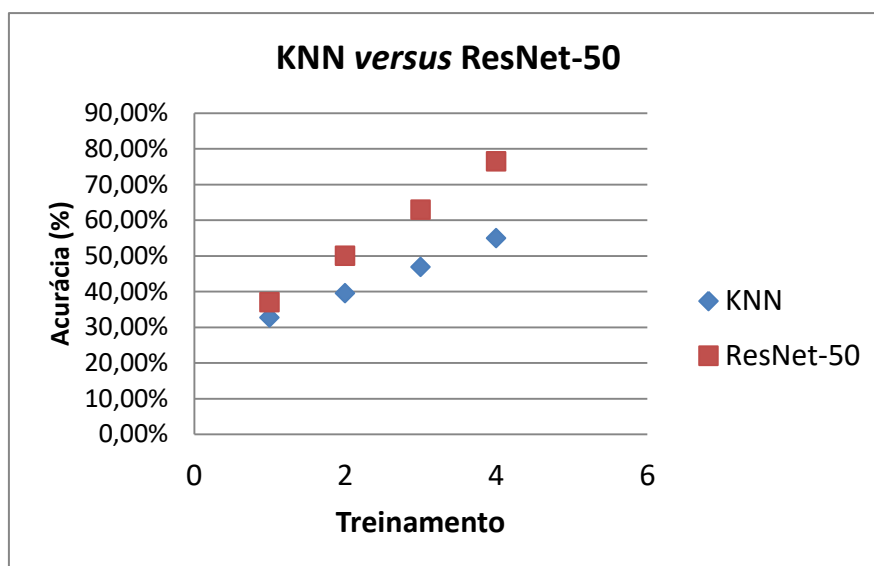


Figura 18. Treinamentos *versus* Acurácia.

5.1.3. Performances de Treinamento dos Óculos

Para analisar o desempenho de assertividade com os óculos de proteção foi usada uma quantidade padrão de imagens negativas com variação de imagens positivas em quatro treinamentos. É dito acerto quando o algoritmo reconhece a presença ou ausência do equipamento. Dessa maneira, o resultado do desempenho é dado conforme a tabela a seguir:

Tabela 8. Treinamento *versus* Assertividade para Óculos

Ordem de Treinamento	Imagens Negativas	Imagens Positivas	Imagens Teste	Acertos KNN	Acertos ResNet-50
1	360	48	162	46	53
2	360	96	162	61	69
3	360	144	162	72	80
4	360	194	162	80	89

Fonte: Autoria própria.

Na figura 19, foi realizada uma análise geral do desempenho do algoritmo em quatro conjuntos de imagens positivas na base de treinamento. Foram perceptíveis, no momento inicial do treinamento, valores próximos de assertividades comparando ambos os algoritmos, porém, à medida que há a evolução da base de dados, a técnica por aprendizagem profunda de máquina predomina em relação à técnica KNN, isto é, a aprendizagem profunda de máquina apresentou resultados mais significativos no cenário atribuído.




Figura 19. Treinamentos *versus* Acurácia.

5.1.4. Performances de Treinamento dos Abafadores

Para analisar o desempenho de assertividade com os abafadores de proteção foi usada uma quantidade padrão de imagens negativas com variação de imagens positivas em quatro treinamentos. É dito acerto quando o algoritmo reconhece a presença ou ausência do equipamento. Dessa maneira, o resultado do desempenho é dado conforme a tabela a seguir:

Tabela 9. Treinamento *versus* Assertividade para Abafadores

Treinamento	Imagens Negativas	Imagens Positivas	Imagem Teste	Acertos KNN	Acertos ResNet-50
1	360	29	162	41	52
2	360	58	162	50	63
3	360	87	162	61	76
4	360	116	162	75	93

Fonte: Aatoria própria.

Na figura 20, foi realizada uma análise geral do desempenho do algoritmo em quatro momentos diferentes de imagens positivas na base de treinamento. A técnica por ResNet-50 no cenário apresentado teve melhores eficiências em relação ao número de acertos em relação à técnica por KNN.

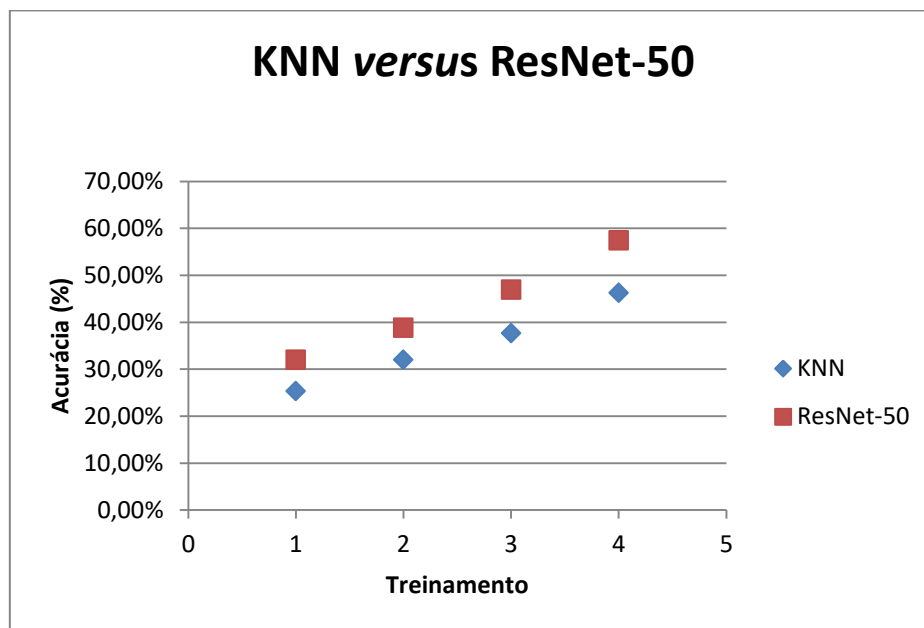


Figura 20. Treinamentos *versus* Assertividade.

5.1.5. Análise geral de desempenho de treinamento *versus* assertividade

Foram considerados cenários iguais em relação à quantidade de imagens na base de dados, ou seja, mesmo volume de imagens positivas, negativas e testes foram compartilhados por ambos os algoritmos. O algoritmo com técnica de ResNet-50 apresentou resultados de assertividade mais significativa do que a técnica por vizinhos próximos KNN.

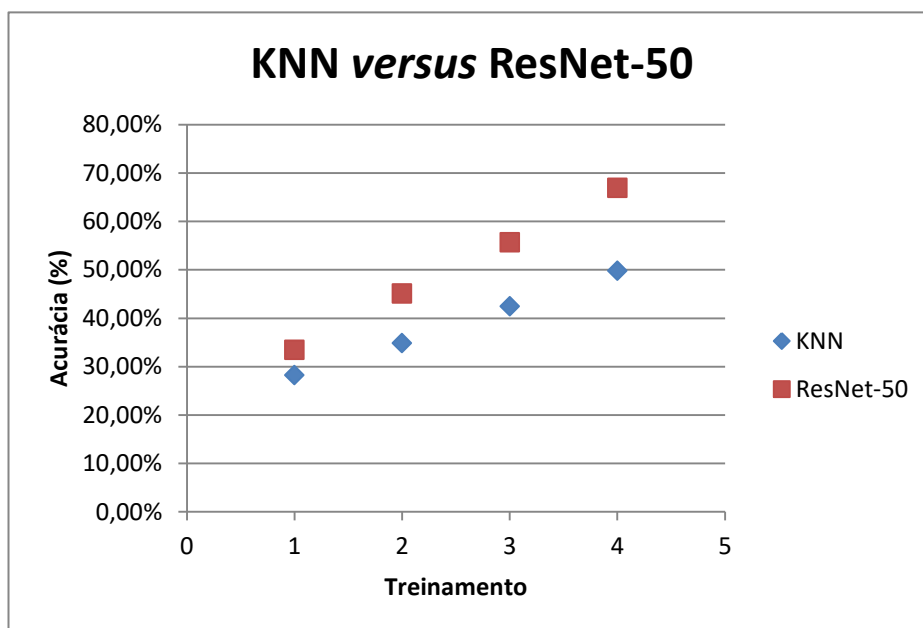


Figura 21. Treinamento *versus* Assertividade.

Fonte: Aatoria própria.

5.2. Análise do Treinamento Final

O “Treinamento Final” corresponde ao treinamento quatro. Nela está contida todas as imagens que existem na base de dados do projeto para o procedimento de testes proposto para o projeto de reconhecimento de EPIs.

5.2.1. Análise do Teste do Algoritmo KNN

Após do desenvolvimento do algoritmo com classificador KNN para reconhecimento de capacete, máscara, abafador e óculos foi realizados testes para verificação de desempenho do algoritmo usando a base de treinamento e imagens de testes citados. O teste funciona seguinte forma, caso o algoritmo com a técnica KNN detecte o uso ou ausência do equipamento recebe o valor de pontuação um, caso contrário, recebe um valor de pontuação zero. O resultado da classificação da presença ou não de EPIs acontece simultaneamente para todos os equipamentos. Para visualização desses resultados, foi analisado uma por uma após a execução do algoritmo para toda base de teste do diretório hospedado. Para cada equipamento geram no máximo 162 (cento e sessenta e dois) pontos, que totaliza ao levar em consideração os quatro equipamentos obtêm-se 648 (seiscentos e quarenta e oito) pontos.

5.2.1.1. Teste KNN para Posição 0°

Para fins de análise do desempenho do algoritmo com técnica KNN, foi realizada a verificação assertividade na posição 0° graus. Os resultados obtidos estão direcionados aos quatro equipamentos de proteção individuais destinados a este trabalho. Os resultados para cada EPI estão dividido entre acertos e erros, sendo que o somatório deve ser 54 pontos, pelo fato de ser 1/3 da quantidade total de pontos destinada a cada equipamento. Os resultados podem ser visualizados a seguir:




Figura 22. Acertos e erros para o ângulo de 0° de reconhecimento de EPIs.

Fonte: Autoria própria.

5.2.1.2. Teste KNN para Posição 45°

Para fins de análise quantitativa do desempenho do algoritmo com técnica KNN, foi realizada a verificação assertividade na posição 45° graus. Os resultados obtidos estão direcionados aos quatro equipamentos de proteção individuais destinados a este trabalho. Os resultados para cada EPI estão dividido entre acertos e erros, sendo que o somatório deve ser 54 pontos, pelo fato de ser 1/3 da quantidade total de pontos destinada a cada equipamento. Os resultados podem ser visualizados a seguir:




Figura 23. Acertos e erros para o ângulo de 45° de reconhecimento de EPIs.

Fonte: Autoria própria.

5.2.1.3. Teste KNN para Posição 90°

Para fins de análise quantitativa do desempenho do algoritmo com técnica KNN, foi realizada a verificação assertividade na posição na posição 90° graus. Os resultados obtidos estão direcionados aos quatro equipamentos de proteção individuais destinados a este trabalho. Os resultados para cada EPI estão dividido entre acertos e erros, sendo que o somatório deve ser 54 pontos, pelo fato de ser 1/3 da quantidade total de pontos destinada a cada equipamento. Os resultados podem ser visualizados a seguir:




Figura 24. Acertos e erros para o ângulo de 90° de reconhecimento de EPIs.

Fonte: Autoria própria.

5.2.1.4. Balanço Geral Algoritmo KNN

Foi realizada a um balanço geral considerando todas as posições testadas. Os resultados obtidos estão atrelados aos quatro equipamentos de proteção individuais propostos por este trabalho. O acerto é dado quando o algoritmo reconhece a presença ou ausência de equipamento de EPI. Os resultados para cada EPI estão divididos entre acertos e erros, sendo que o somatório máximo são 162 (cento e sessenta e dois) pontos por equipamento de proteção. Ao considerar os quatro equipamentos totalizam-se 648 (seiscentos e quarenta e oito) pontos. Os resultados podem ser visualizados a seguir:




Figura 25. Balanço geral de acertos e erros de reconhecimento de EPIs.

Fonte: Autoria própria.

5.2.2. Análise do Teste da ResNet-50

O teste funciona seguinte forma, caso o algoritmo com a técnica DL reconheça o uso ou ausência do equipamento recebe o valor de pontuação um, caso contrário, recebe um valor de pontuação zero. O resultado da classificação da presença ou não de EPIs acontece simultaneamente para todos os equipamentos. Para visualização desses resultados, foi analisado uma por uma após a execução do algoritmo para toda base de teste do diretório hospedado. Para cada equipamento geram no máximo 162 (cento e sessenta e dois) pontos, que totaliza ao levar em consideração os quatro equipamentos obtêm-se 648 (seiscentos e quarenta e oito) pontos.

5.2.2.1. Teste ResNet-50 para Posição 0°

Para fins de análise quantitativa do desempenho do algoritmo com técnica DL, foi realizada a verificação assertividade na posição na posição 0° graus. Os resultados obtidos estão direcionados aos quatro equipamentos de proteção individuais destinados a este trabalho. Os resultados para cada EPI estão dividido entre acertos e erros, sendo que o somatório deve ser 54 pontos, pelo fato de ser 1/3 da quantidade total de pontos destinada a cada equipamento. Os resultados podem ser visualizados a seguir:




Figura 26. Balanço geral de acertos e erros de reconhecimento de EPIs.

Fonte: Autoria própria.

5.2.2.2. Teste ResNet-50 para Posição 45°

Para fins de análise quantitativa do desempenho do algoritmo com técnica DL, foi realizada a verificação assertividade na posição 45° graus. Os resultados obtidos estão direcionados aos quatro equipamentos de proteção individuais destinados a este trabalho. Os resultados para cada EPI estão dividido entre acertos e erros, sendo que o somatório deve ser 54 pontos, pelo fato de ser 1/3 da quantidade total de pontos destinada a cada equipamento. Os resultados podem ser visualizados a seguir:

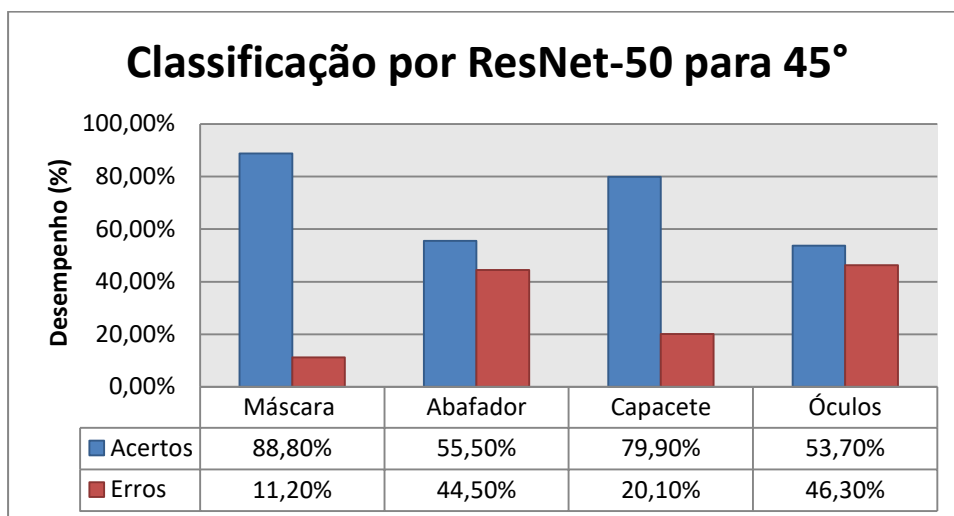


Figura 27. Balanço geral de acertos e erros de reconhecimento de EPIs.
Fonte: Autoria própria.

5.2.2.3. Teste ResNet-50 para Posição 90°

Para fins de análise quantitativa do desempenho do algoritmo com técnica ResNet-50, foi realizada a verificação assertividade na posição 90° graus. Os resultados obtidos estão direcionados aos quatro equipamentos de proteção individuais destinados a este trabalho. Os resultados para cada EPI estão dividido entre acertos e erros, sendo que o somatório deve ser 54 pontos, pelo fato de ser 1/3 da quantidade total de pontos destinada a cada equipamento. Os resultados a seguir:




Figura 28. Acertos e erros para reconhecimento de EPIs na posição 90° graus.
Fonte: Autoria própria.

5.2.2.4. Balanço Geral ResNet-50

Após a implementação do algoritmo de classificação por aprendizagem profunda através de redes neurais residuais para reconhecimento de capacete, máscara, abafador e óculos foram realizados testes para verificação de desempenho geral algoritmo com as imagens de teste. Os resultados obtidos estão direcionados aos quatro equipamentos de proteção individuais propostos por este trabalho. Os resultados para cada EPI estão dividido entre acertos e erros, sendo que o somatório deve ser 162 (cento e sessenta e dois) que corresponde a 100% de acurácia:




Figura 29. Balanço geral de acertos e erros de reconhecimento de EPIs.

Fonte: Autoria própria.

É perceptível que esta técnica apresenta um maior desempenho comparado a técnica de K-Vizinhos Mais Próximos. Todavia, ainda é perceptível uma grande variação no processo classificatório por equipamentos. Mas, ao considerar os aspectos classificatórios das imagens entre as bases de treinamento (Positivas e Negativas) com finalidade de análises mais específicas. Percebe-se que os desempenhos dos modelos são mais bem classificados com alcance de acurácia por classe de 100% considerando 15% de imagens tanto para imagens sem abafador quanto para imagens com abafadores com geração de um total de 54 amostras para imagens negativas classificadas corretamente e 18 amostras para imagens positivas classificadas de forma correta. A matriz de confusão exhibe a distribuição dos objetos em termos de suas classes atuais e de suas classes previstas, assim indica a qualidade do modelo para abafador atual, como mostrado na figura 30:

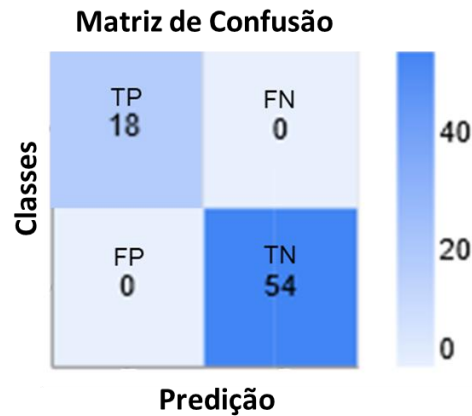


Figura 30. Matriz de Confusão para o Modelo Abafador.
Fonte: Autoria própria.

As máscaras após testar a classificação do modelo treinado em 15% das imagens positivas e negativas foi obtido uma precisão por classe de aproximadamente 96% de acurácia para as imagens sem máscaras e aproximadamente 98% de acurácia para imagens com máscaras com geração de um total de 54 amostras verdadeiras negativas e 47 amostras verdadeiras positivas classificadas. A matriz de confusão exibe a distribuição dos objetos classificados em termos de suas classes atuais e de suas classes previstas, assim indica a qualidade do modelo atual como mostrado na figura 31:




Figura 31. Matriz de Confusão para o Modelo Máscara.
Fonte: Autoria própria.

Os capacetes após testar a classificação do modelo treinado em 15% das imagens positivas e negativas foi obtido uma acurácia de 100% não somente para imagens sem capacete de proteção como também para imagens com proteção com geração de um total de 54 amostras verdadeiras negativas classificadas e 38 amostras verdadeiras positivas classificadas. A matriz de confusão exibe

a distribuição dos registros em termos de suas classes atuais e de suas classes previstas, assim indica a qualidade do modelo atual como mostrado na figura 32:

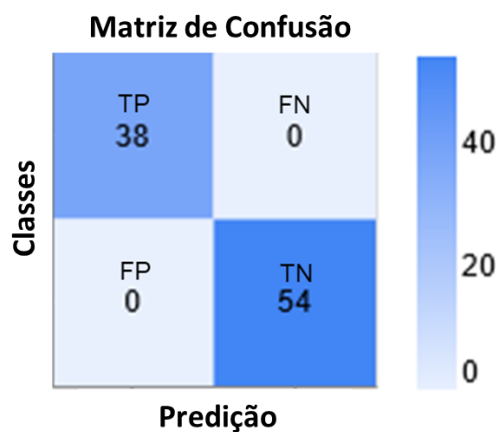


Figura 32. Matriz de Confusão para o Modelo Capacete.

Fonte: Autoria própria.

Por fim, os óculos, após testar a classificação do modelo treinado em 15% das imagens positivas e negativas da base de treinamento foi obtido acurácia de 100% tanto para imagens sem óculos quanto para imagens com óculos com geração de um total de 54 amostras verdadeiras negativas e 30 amostras verdadeiras positivas. A matriz de confusão exibe a distribuição dos registros em termos de suas classes atuais e de suas classes previstas, assim indica a qualidade do modelo atual como mostrado na figura 36:




Figura 33. Matriz de Confusão para o Modelo Óculos.

Fonte: Autoria própria.

Diante disso, a perceptível a tendência do algoritmo baseado em rede neural residual com 50 camadas apresenta indicativos mais significativos de eficiência de acordo com as análises estatísticas e de *Machine Learning* para reconhecimento de padrões de equipamentos de proteção individual, foi criada um protótipo de controle de acesso para visar aplicar o algoritmo de reconhecimento a equipamentos de controle para aperfeiçoar processos de forma mais automatizada. O esquema geral, então:




Figura 34. Protótipo Real Montado para Controle de Acesso.

Fonte: Próprio Autor.

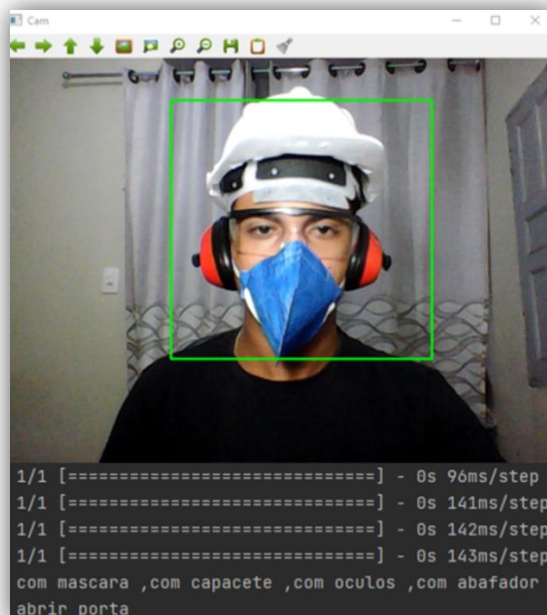


Figura 35. Teste de Controle de Acesso.

Fonte: Autoria própria.

Nesse interim, é possível perceber que foi alcançado um resultado almejado, ou seja, por meio dos mecanismos utilizados, ratifica a possibilidade de reconhecer a presença de todos equipamentos para decidir a abertura ou não de uma eventual porta através do reconhecimento por algoritmo com técnica de ResNet-50 com modelos treinados para reconhecimento padrões com ênfase nos: capacete, óculos, máscara e abafador. O processo de simulação foi realizada com equipamento arduino, porém, mesmo que seja simples utilização, sua aplicabilidade é viável não somente pela essência da comunicação entre o python e arduino por meio do PyFirmata (protocolo de comunicação de microcontroladores e software de computador) como também diversos outros componentes eletrônicos que podem se associar ao arduino para o destravamento de portas para controle de acesso, pois o arduino permite ser integrada a outros componentes existentes que podem ser contextualizados facilmente para essa finalidade. Por fim, no processo evolução para nível de assertividade descrita nas ilustrações gráficas anteriores, é possível perceber a tendência da diminuição de erros na medida que há mais treinamentos com maiores quantidades de imagens processadas e, conseqüentemente, maior no nível de acertos obtidos com o reconhecimento de presença ou ausência dos equipamentos de proteção individual, com uma suposta percepção de um caminho promissor para alcançar um alto grau de significância.

6. CONCLUSÃO

O presente trabalho alcançou seus objetivos. A contribuição desse trabalho foi realizada a medida que possibilitou o reconhecimento de equipamentos de proteção individual por meio de visão computacional através de aprendizagem de máquina com e controle de acesso com finalidade de promover fiscalização. Novos problemas na área de segurança do trabalho foram investigados, conseqüentemente, novas percepções surgiram, o que permite uma visão mais clara acerca desse cenário.

O método de classificação por técnicas de utilização de redes neurais residuais foi sugerido, de fato, a ResNet-50 apresenta um comportamento superior a técnica de aprendizagem de máquina clássica K-Vizinhos Mais Próximos (KNN) em uma simulação da realidade. Os problemas e dificuldades de previsões ainda são evidentes durante as execuções, porém, percebe-se que por aprendizagem profunda de máquina tem característica mais evidentes para propiciar correções de desempenho. Apesar de haver requisitos específicos para cada algoritmo baseados em redes neurais, diante as experiências obtidas para alcançar resultados mais significativos, a técnica por *Deep Learning* - ResNet-50 -, apresentam indicativo de maior eficiência em relação a técnica por KNN em um mesmo cenário proposto.

O sistema de controle de acesso não foi aplicado em um cenário real. Mas, embora não tenha sido implementada em uma porta real, pois não é uma proposto uma proposta de produto para validação de mercado, sabe-se que a estrutura básica para o processo de reconhecimento de EPIs e destravamento de portas foi realizado com êxito. É Inegável que ainda há a necessidade de equipamentos complementares para melhorar estética, tampouco agrupar os componentes eletrônicos em uma estrutura ideal.

Dessa forma, portanto, é evidente a possibilidade de melhoria através do aprofundamento do método e recursos eletrônicos, o que implica na solidificação cada vez mais da técnica utilizada para resolver o problema de pesquisa, proporcionando o entendimento de como um modelo pode se comportar a diferentes situações de treinamento e cenários de teste para alcançar resultados.

7. TRABALHOS FUTUROS

Diante do que foi abordado um questionamento surge, com o comportamento da aprendizagem de máquina sendo diferente a cada equipamento, a medida que houver um maior balanceamento a capacidade desempenhar melhor classificação é maior? Será que uma quantidade mais elevada de imagens para base e treinamento pode propiciar resultados muito maiores? Ou mesmo, melhores tratamentos das imagens promoverá melhores resultados a cada equipamento? Assim, para sanar dúvidas, pretende-se realizar estudos para reconhecimento com condições especiais com variação de ângulos e iluminações, aprimorar a técnica de aprendizagem de máquina para reconhecimentos de padrões de EPIS. Inserir outros equipamentos de proteção individual da NR 6, realizar estudos mais aprofundados para validações e aplicar em um cenário real em ambientes empresarias de trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

- Articulated human detection with flexible mixtures of parts IEEE Trans. Pattern Anal. Mach. Intell. (2013).
- Alpaydin, E. (2020). Introduction to Machine Learning. Adaptive Computation and Machine Learning series. MIT Press.
- BRASIL. Ministério do Trabalho e Emprego. NR 6: Equipamento de Proteção Individual. 2009.
- Bradski, G. and Kaehler, A. (2008) Learning OpenCV: Computer Vision with the OpenCV Library. O'Reilly Media, Inc., Sebastopol.
- Braga, L. F. Z. (2013). Sistemas de Reconhecimento Facial. Universidade de São Carlos.
- Câmara, G.; Casanova, M. A.; Hemerly, A. S.; Magalhães, G. A.; Medeiros, C. M. B. Anatomia de Sistemas de Informação Geográfica. 10a . Escola de Computação. Campinas. Instituto de Computação - UNICAMP. 1996. 197p.
- Chapelle, O., Schölkopf, B., and Zien, A. (2010). Semi-supervised Learning. Adaptive computation and machine learning. MIT Press.
- CNN Architectures, Dataset Characteristics and Transfer Learning. CoRR, abs/1602.03409, 2016.arXiv: 1602.03409. Disponível em: <<http://arxiv.org/abs/1602.03409>>.
- FACELI, K.; LORENA, A. C.; GAMA, J. ; CARVALHO, A. C. P. L. F. de. Inteligência artificial: uma abordagem de aprendizado de máquina. Rio de Janeiro: LTC, 2011.
- Forsyth, D.A. and Ponce, J. (2002) Computer Vision: A Modern Approach. Prentice Hall Professional Technical Reference
- HERMANN, M.; PENTEK, T.; OTTO, B. Design principles for industrie 4.0 scenarios. In: 2016 49th Hawaii International Conference on System Sciences (HICSS). [S.l.: s.n.], 2016. p. 3928–3937. ISSN 1530-1605. Citado na página 9.
- JAIN, A.; FLYNN, P.; ROSS, A. Handbook of. Biometrics. New York: Springer, 2007. Citado 2 vezes nas páginas 2 e 3.

Jähne, B., Haubecker, H., Computer Vision and Applications, Academic Press, 2000

MARCHESAN, Ricardo. Brasil é campeão de ações trabalhistas no mundo? Dados são inconclusivos. Disponível em: <<https://noticias.uol.com.br/confere/ultimas-noticias/2017/06/27/>>. Acesso em: 16 mai. 2020.

MARENGONI, Maurício; STRINGHINI, Stringhini. Tutorial: Introdução à visão computacional usando opencv. Revista de Informática Teórica e Aplicada, v. 16, n. 1, p. 125-160, 2009.

MARQUES FILHO, Ogê; VIEIRA NETO, Hugo. Processamento Digital de Imagens, Rio de Janeiro: Brasport, 1999. ISBN 8574520098.

RODRIGUES, Karla Bertolasce Frauches; SANTOS, Nadson Gutemberg Gomes dos. As consequências legais pelo não uso do equipamento de proteção individual no ambiente de trabalho: uma breve análise a luz do ordenamento jurídico brasileiro. Disponível em: <<https://ambitojuridico.com.br/edicoes/revista-167/as-consequencias-legais-pelo-nao-uso-do-equipamento-de-protecao-individual-no-ambiente-de-trabalho-uma-breve-analise-a-luz-do-ordenamento-juridico-brasileiro>>. Acesso em: 16 mai. 2020.

SANTOS, P. V. S. et al. Aplicação de normas regulamentadoras de segurança do trabalho em obras de pequeno porte. Trabalho de Conclusão de Curso. Universidade Federal de Uberlândia. Uberlândia. 2018.

Silva, V. A. (2008). Comparação entre técnicas de reconhecimento de faces para controle de acesso a computadores. Universidade Católica Dom Bosco.

SRIVASTAVA, S.; BHARDWAJ, S.; BHARGAVA, S. et al. Fusion of palm-phalanges print with palmprint and dorsal hand vein. Applied Soft Computing, Elsevier, v. 47, p.12–20, 2016. Citado na página 1.

SHIN, Hoo-Chang et al. Deep Convolutional Neural Networks for Computer-Aided Detection.

S. Zhu, Face alignment by coarse-to-fine shape searching The IEEE Conference on Computer Vision and Pattern Recognition (CVPR).

[Zhang et al., 2016] Zhang, K., Zhang, Z., Li, Z., and Qiao, Y. (2016). Joint face detection and alignment using multi-task cascaded convolutional networks. CoRR, abs/1604.02878.

Z. Sun, C.H. Lin, Y.L. Lee, J.R. Shi, B.K. Tay, X. Shi, J. Appl. Phys. 87 (11) (2000) 8122.

ZWOLINKSKI, Bárbara Wolff. Análise do Uso de Equipamentos de Proteção Individual por Trabalhadores em Empresas de Curitiba e São José dos Pinhais. Monografia de Especialização. Curitiba. 2017.

SILVA, Jéssica Rodrigues da Silva. Estudo de Caso sobre a Utilização de EPI's na Construção Civil com Proposição de Melhorias. Trabalho de Conclusão de Curso. Instituto Federal de Educação, Ciência e Tecnologia da Paraíba. Cajazeiras. 2018. Disponível em: <<https://core.ac.uk/reader/429520339>>

MARTINS, Vinicius Eiji 2018. Deep Learning para Classificação de Imagens. Trabalho de Conclusão de Curso. Universidade Estadual de Londrina. Londrina. 2018. Disponível em: <http://www.uel.br/cce/dc/wp-content/uploads/Vinicius_Eiji_Martins_Preliminar.pdf>

ROSA, Ayrton Lima da. Classificação de Imagens Utilizando Aprendizado de Máquina. Trabalho de Conclusão de Curso. Universidade Federal de Santa Catarina. Florianópolis. 2019. Disponível em: <<https://repositorio.ufsc.br/bitstream/handle/123456789/197598/>>

RODRIGUES, Pedro Henrique Benigno. LASTHAUS, Alexandre. Técnicas de Visão Computacional para Classificação de Peças. Universidade Presbiteriana Mackenzie. 2021.

MIRANDA, Bruno de Souza. Algoritmos clássicos de Aprendizagem de Máquina Aplicados ao Problema do Reconhecimento de Imagens. Trabalho de Conclusão de Curso. Universidade Federal do Pampa. Alegrete. 2011. Disponível em: <<https://dspace.unipampa.edu.br/bitstream/rii/1547/1/>>

SANTOS, 2022. Sistema de Reconhecimento Facial com Base em Técnicas de Aprendizagem de Máquina. Trabalho de Conclusão de Curso. Universidade Federal do Pará. Tucuruí. 2022.

K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition," *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016, pp. 770-778, doi: 10.1109/CVPR.2016.90.

GONÇALVES, Vinicius Rocha. Sistema de Controle de Acesso utilizando Autenticação por RFID e gerenciamento por meio de Software WEB. Trabalho de Conclusão de Curso. Universidade Federal de Ouro Preto. Uberlandia. 2018.

GALHADO, Antonio Tadeu. Sistema Eletrônico de Controle de Acesso. Trabalho de Conclusão de Curso. Universidade São Francisco. Campinas. 2011. Disponível em: <<https://lyceumonline.usf.edu.br/salavirtual/documentos/2141.pdf>>

LEGAT, Matteus. Sistema de Controle de Acesso em IOT. Trabalho de Conclusão de Curso. Universidade Federal Santa Catarina. Florianópolis. 2018. Disponível em:<https://repositorio.ufsc.br/bitstream/handle/123456789/187880/TCC_CCO_UFSC___Matteus_Legat-4.pdf?sequence=1&isAllowed=y>

APÊNDICE A – CÓDIGO DO PROJETO

https://github.com/EngVignerVieira/Reconhecimento_de_Equipamento_de_Protecao_Individual_python