



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS PICOS
TECNOLOGIA EM ANÁLISE E DESENVOLVIMENTO DE SISTEMAS

MARIA CRISTIANA DE JESUS SÁ

**DETECÇÃO AUTOMÁTICA DE DISTANCIAMENTO SOCIAL EM LOCAIS
PÚBLICOS UTILIZANDO VISÃO COMPUTACIONAL E APRENDIZADO
PROFUNDO**

PICOS

2021

MARIA CRISTIANA DE JESUS SÁ

DETECÇÃO AUTOMÁTICA DE DISTANCIAMENTO SOCIAL EM LOCAIS PÚBLICOS
UTILIZANDO VISÃO COMPUTACIONAL E APRENDIZADO PROFUNDO

Trabalho apresentado à Banca Examinadora
como requisito parcial para obtenção do título
de Tecnólogo em Análise e Desenvolvimento
de Sistemas do Instituto Federal de Educação,
Ciência e Tecnologia do Piauí.

Orientador: Prof. Dr. Rafael Torres Anchiêta

PICOS

2021

FICHA CATALOGRÁFICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS PICOS
COORDENAÇÃO DE BIBLIOTECA
SERVIÇO DE PROCESSOS TÉCNICOS

S111d

Sá, Maria Cristiana de Jesus

Detecção automática de distanciamento social em locais públicos utilizando visão computacional e aprendizado profundo / Maria Cristiana de Jesus Sá. — 2021.

36 f.: il.

Monografia (Graduação em Análise e desenvolvimento de sistemas) — Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Picos, 2021.

Orientador: Prof. Dr. Rafael Torres Anchiêta.

1. Visão por computador. 2. Covid-19. 3. Distanciamento social. 4. Detecção de objetos. I. Título.

CDD: 006.37

MARIA CRISTIANA DE JESUS SÁ

DETECÇÃO AUTOMÁTICA DE DISTANCIAMENTO SOCIAL EM LOCAIS PÚBLICOS
UTILIZANDO VISÃO COMPUTACIONAL E APRENDIZADO PROFUNDO

Trabalho apresentado à Banca Examinadora
como requisito parcial para obtenção do título
de Tecnólogo em Análise e Desenvolvimento
de Sistemas do Instituto Federal de Educação,
Ciência e Tecnologia do Piauí.


Aprovado pela banca examinadora em 02/12/2021.

BANCA EXAMINADORA:




Prof. Dr. Rafael Torres Anchiêta

Instituto Federal de Educação, Ciência e Tecnologia do Piauí - IFPI



Prof. M^e. Daniel de Sousa Luz

Instituto Federal de Educação, Ciência e Tecnologia do Piauí - IFPI



Prof. Esp. Manoel Messias Pereira Medeiros

Instituto Federal de Educação, Ciência e Tecnologia do Piauí - IFPI

PICOS

2021

Dedico este trabalho a minha família.

AGRADECIMENTOS

Agradeço primeiramente a Deus que nunca me abandonou durante toda a minha jornada.

Agradeço aos meus pais por sempre me incentivarem e nunca me deixarem desistir dos meus sonhos. Ao meu querido orientador Rafael, que sempre me apoiou e incentivou desde o início do desenvolvimento deste trabalho.

Agradeço ao professor Daniel Luz pela sua disposição e ajuda durante a minha jornada acadêmica.

Ao amigo que o ifpi me deu de presente Daniel Nunes, agradeço por todo o seu apoio, incentivo e ajuda nas minhas maluquices.

Ao professor Gilberto (tio sam) por sempre acreditar no meu potencial e sempre me ajudar e aconselhar quando necessário.

A todos o meu muito obrigada.

*"TENHO EM MIM TODOS OS SONHOS DO MUNDO."
(Fernando Pessoa)*

RESUMO

O Sars-Cov-2 conhecido popularmente por covid-19 é uma doença infecciosa que se dissemina de uma forma muito rápida entre os seres humanos. Para tentar conter esse vírus, faz-se necessário tomar algumas medidas preventivas. Dentre essas medidas, destaca-se o distanciamento social, pois é uma das medidas mais eficazes que ajuda a diminuir o número de infectados pela doença. Na atualidade, diversas pesquisas estão sendo desenvolvidas na tentativa de conter tal vírus. Diante do contexto vivenciado, o presente trabalho visa o desenvolvimento de uma ferramenta para detecção automática de distanciamento social baseada em aprendizado profundo e voltada para ambientes públicos. Ademais, os resultados obtidos nas avaliações demonstraram que o algoritmo desenvolvido é eficaz na tarefa de detecção de pessoas e do distanciamento social.

Palavras-chaves: Covid-19. Distanciamento Social. Detecção de Objetos. Aprendizado Profundo. Yolo.

ABSTRACT

Sars-Cov-2 popularly known as covid-19 is an infectious disease that spreads very quickly among humans. To try to contain this virus, it is necessary to take some preventive measures. Among these measures, social distancing stands out, as it is one of the most effective measures which helps to reduce the number of people infected by the disease. Currently, several researches are being developed in an attempt to contain this virus. Given the context experienced, this work aims to develop a tool for automatic detection of social distance based on deep learning and aimed at public environments. Furthermore, the results obtained in the evaluations showed that the developed algorithm is effective in the task of detecting people and social distancing.

Keywords: Covid-19. Social distancing. detection of Objects. Deep Learning. Yolo.

LISTA DE ILUSTRAÇÕES

Figura 1 – Estrutura típica da família dos coronavírus.	15
Figura 2 – Etapas do processamento digital de imagens.	17
Figura 3 – Exemplo de objetos detectados em uma imagem	18
Figura 4 – Representação de uma CNN.	19
Figura 5 – Aplicação dos filtros de convolução	20
Figura 6 – exemplo de operação de pooling.	21
Figura 7 – Detecção de objetos com o yolo	22
Figura 8 – Arquitetura do modelo Yolo framework	22
Figura 9 – Frame de exemplo do Social Distancing Pedestrian Video.	26
Figura 10 – Frame de exemplo do Social Distancing.	27
Figura 11 – Detecção do distanciamento social usando método proposto.	28
Figura 12 – Detecção Correta.	29
Figura 13 – Distanciamento Social.	30
Figura 14 – Detecção Incorreta.	31

LISTA DE ABREVIATURAS E SIGLAS

BB	<i>Bounding Box</i>
CNN	<i>Convolutional Neural Network</i>
DL	<i>Deep Learning</i>
GPU	<i>Graphic Processing Unit</i>
IA	Inteligência Artificial
IoU	<i>Intersection Over Union</i>
MaP	<i>Mean Average Precision</i>
ML	<i>Machine Learning</i>
MLP	<i>Multi-Layer Perceptron</i>
MS	Ministério da Saúde
OMS	Organização Mundial da Saúde
PDI	Processamento Digital de Imagens
RNA	Rede Neural Artificial
R-CNN	Rede Neurais Convolucionais Baseadas em Regiões
SUS	Sistema Único de Saúde
ToF	<i>Time of Flight</i>
VC	Visão Computacional
YOLO	<i>You Only Look Once</i>

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Contextualização	12
1.2	Problema	13
1.3	Justificativa	13
1.4	Objetivos	14
1.4.1	Objetivos específicos	14
1.5	Estrutura do Trabalho	14
2	FUNDAMENTAÇÃO TEÓRICA	15
2.1	SARS-COV-2	15
2.2	PROCESSAMENTO DIGITAL DE IMAGENS	16
2.3	Deteção de Objetos	18
2.3.1	CONVOLUTIONAL NEURAL NETWORK	19
2.3.1.1	Camadas convolucionais	20
2.3.1.2	<i>Camadas de Pooling</i>	<i>21</i>
2.3.2	<i>You Only Look Once</i>	<i>21</i>
2.4	Métricas	23
2.4.1	<i>Intersection over Union</i>	<i>23</i>
2.4.2	<i>Mean Average Precision</i>	<i>23</i>
3	TRABALHOS RELACIONADOS	24
4	ABORDAGEM DESENVOLVIDA	26
4.1	Definição dos <i>benchmarks</i>	26
4.2	Deteção de distanciamento social	27
5	CONCLUSÃO	32
	REFERÊNCIAS	33

1 INTRODUÇÃO

Neste capítulo, são abordados: problemática, justificativa, objetivos e estrutura deste trabalho.

1.1 CONTEXTUALIZAÇÃO

O Processamento Digital de Imagens (PDI), é utilizado em diversas áreas como automação de veículos, análise de dados meteorológicos, detecção de doenças, entre outras. Gonzalez e Woods (2009), referem-se ao PDI como o processamento de uma imagem digital por um computador, sendo que uma imagem é composta de um número finito de elementos, com localização e valores específicos. Atualmente, estão sendo desenvolvidas diversas aplicações para a detecção de objetos em imagens e/ou em streams de vídeos, como análise de imagens médicas, rastreamento de veículos, entre outros.

Essas aplicações tornaram-se cada vez mais viáveis e precisas, graças às tecnologias de *Machine Learning (ML)*, que reduzem inúmeros erros e consequentemente o custo em relação ao tempo de processamento, por exemplo a velocidade de receber e transmitir os dados. De acordo com Steinheiser et al. (2020). ML é uma das subáreas da Inteligência Artificial (IA), que está presente em diversos campos, como, por exemplo, mineração de dados, visão computacional, dentre outros. É importante ressaltar que o conceito de ML vem da base ou do entendimento de que uma aplicação ou máquina pode aprender através dos dados adquiridos e das experiências realizadas durante seus testes, com a finalidade de identificar padrões específicos e consequentemente encontrar a solução mais adequada para resolvê-los (MITCHELL et al., 1997).

A Aprendizagem Profunda (AP) é uma das subáreas mais importantes do ML. Para Steinheiser et al. (2020) a AP tem como principal característica a abstração do sistema neural humano, onde o mesmo pode ser representado através de uma Rede Neural Artificial (RNA). Os algoritmos de AP são bastantes utilizados na detecção e diagnóstico de diversas doenças como o melanoma, glaucoma, malária. Como exemplo dessas aplicações pode-se citar os trabalhos dos seguintes autores: Claro et al. (2019), Moura et al. (2017) e Rajaraman et al. (2018). As técnicas de AP também podem ser aplicadas no controle de enfermidades contagiosas, como é o caso da covid-19.

A covid-19 é causado pelo vírus *SARS-CoV-2*, sua transmissão pode ocorrer de diversas formas, como o contato direto com outras pessoas infectadas através de pequenas gotículas da boca e do nariz, que se propagam quando os indivíduos infectados com o vírus tosse ou espirram. Essas gotas, então, se espalham pelos objetos e superfícies ao seu redor outras pessoas que tocam nesses locais e em seguida colocam as suas mãos nos olhos, nariz ou boca também

podem ser contaminadas pelo vírus (OMS, 2021).

Como meio de reduzir a propagação do vírus e diminuir os riscos de infecção, é necessário tomar algumas precauções básicas, como lavar frequentemente as mãos com detergente, fazer o uso do álcool em gel 70%, evitar tocar superfícies em locais públicos, usar máscara especialmente quando não for possível se distanciar socialmente de outras pessoas e o mais importante, manter o distanciamento social de pelo menos 1 metro de distância de outros indivíduos, mesmo que eles não pareçam estar doentes (OMS, 2021).

Diante desse contexto, o presente trabalho visa aplicar métodos computacionais para realizar detecção de distanciamento social em locais públicos.

1.2 PROBLEMA

Segundo os dados da OMS (2021), a Covid-19 é uma doença viral infecciosa que se dissemina rapidamente entre os seres humanos.

Pessoas que possuem 60 anos ou mais que portam algum tipo de doença pré existente como: problemas cardíacos, hipertensão, diabetes, obesidade entre outras, correm maior risco de desenvolvê-la de forma mais grave, no entanto, qualquer pessoa infectada pode apresentar seus sintomas de forma mais preocupante. Cerca de 80% da população que foram infectados e contraíram seus sintomas desenvolveram desde quadros de infecção respiratória leve até quadros de saúde muito grave, levando o paciente ao óbito. Para tentar amenizar esse cenário epidêmico é necessário tomar algumas medidas preventivas que são essenciais, dentre elas podemos citar: manter o distanciamento social necessário para realizar a contenção desse vírus. Apesar das orientações mantidas pelos principais órgãos de saúde visando a prevenção contra o coronavírus, não existem maneiras efetivas para saber se as pessoas estão seguindo corretamente essas orientações.

1.3 JUSTIFICATIVA

Segundo os dados da OMS (2021), desde o início da pandemia em 30 de dezembro de 2019 até 4 de outubro de 2021, foram registrados

mais de **234.809.103** casos confirmados de covid-19, incluindo **4.800.375** mortes. No Brasil a situação está cada vez mais crítica, se comparado a países com contingente populacional mais elevado como por exemplo os Estados Unidos. O número de indivíduos contagiados pelo novo coronavírus continua a crescer diariamente, foram contabilizados **21.459.117** casos confirmados e **597.723** óbitos até o momento atual.

De acordo com o MS (2021), foram investidos cerca de 72.5 bilhões de reais, para reforçar no combate ao covid-19 e fortalecer as medidas necessárias junto ao Sistema Único de Saúde (SUS), para que o mesmo possa ter uma boa estrutura física para atender toda demanda da

população nacional. Além disso, os órgãos de saúde nacionais e internacionais vêm auxiliando em estratégias para que os estados possam combater a evolução desse vírus, até que toda a população brasileira esteja totalmente imunizada, entre estas medidas podemos citar: manter o distanciamento social de pelo o menos 1 metro de distância de cada indivíduo, lavar as mãos e utilizar álcool em gel 70%, fazer o uso de máscaras principalmente em locais públicos, entres outras medidas preventivas, seguindo os protocolos de saúde de cada município ou cidade, de acordo com situação de risco das mesmas (OMS, 2021).

1.4 OBJETIVOS

Desenvolver uma solução *open source*, para fazer o acompanhamento em tempo real de distanciamento social em locais públicos a partir de ferramentas computacionais.

1.4.1 Objetivos específicos

- Desenvolver um modelo que contemple a detecção de distanciamento social;
- Avaliar o modelo desenvolvido utilizando os *benchmarks* da área;

1.5 ESTRUTURA DO TRABALHO

O presente trabalho está estruturado da seguinte maneira:

Fundamentação Teórica: é dedicada a fornecer o embasamento teórico através dos conceitos utilizados para a formulação desta monografia.

Trabalhos Relacionados: São abordadas propostas que propõem resolução do problema apresentado.

Abordagem Desenvolvida: apresentação da solução proposta e suas principais funcionalidades que serão utilizadas para a resolução do problema em questão.

Conclusão: são expostas as considerações finais deste estudo e, em seguida, propõe-se algumas melhorias para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA


Neste capítulo, são abordados os principais conceitos necessários para o entendimento do trabalho proposto. São expostas informações primordiais sobre os conceitos do *Sars-Cov-2*, Processamento Digital de Imagens, *Convolutional Neural Network (CNNs)*, Detecção de Objetos e do *You Only Look Once (YOLO)*.

2.1 SARS-COV-2

O *Sars-Cov-2* é um dos tipos de *betacoronavírus* que foi descoberto através de um exame chamado de lavagem broncoalveolar, que foi realizado em pacientes com um tipo diferente de pneumonia desconhecida na cidade Wuhan, província de Hubei na China, em dezembro de 2019. O coronavírus é uma grande família de vírus, que geralmente estão presentes em diversas espécies de animais como gados, camelos, gatos, e morcegos incluindo o homem. Porém, raramente o tipo de covid que os animais contraem podem infectar as pessoas e se disseminar para outros seres humanos (MS, 2021).

A doença causada pelo novo Coronavírus é conhecida popularmente por covid-19. Esse vírus faz parte de uma família que possui outros membros como o *Mers-CoV* e o *Sars-CoV*, porém ambos são considerados patogênicos para os seres humanos. Entretanto, o último membro da espécie o *Sars-Cov-2* é a versão mais agressiva desse agente infeccioso, podendo causar um conjunto de danos sérios ao organismo das pessoas como problemas renais, cardíacos e nervosos, além de causar alterações na coagulação sanguínea (SAUDE, 2021). A Figura 1 exibe a estrutura típica correspondente da família dos coronavírus.

Figura 1 – Estrutura típica da família dos coronavírus.



Fonte: Swapnarekha et al. (2020).

Pesquisas realizadas desde o início da pandemia, sugerem que os indivíduos infectados pela covid-19 podem ser mais contagiosos nos dois primeiros dias da infecção, antes mesmo de desenvolverem os sintomas da doença. Já as pessoas que desenvolveram sintomas mais graves

desse vírus, podem ficar infectadas por muito mais tempo do que os indivíduos que contraíram a mesma de forma mais leve. A capacidade de transmissão do *Sars-Cov-2* é enorme, mesmo as pessoas que são consideradas assintomáticas e pré-sintomáticas conseguem transmitilo de forma contínua para outros indivíduos (OMS, 2021).

Na atualidade, estão sendo desenvolvidas pesquisas na área da ciência e no campo tecnológico para contenção do vírus Sars-Cov-2, enquanto não ocorre a imunização total da população. Como medida de prevenção e na tentativa controlar a pandemia, as medidas não farmacológicas devem continuar a ser aplicadas, para evitar assim que a sua disseminação seja muito maior, diminuindo assim, o contágio de um grande número de pessoas e consequentemente reduzir sua proliferação (MS, 2021).

Enquanto o surto do novo coronavírus não passa o campo de visão computacional vem atuando com ferramentas que permitem auxiliar os profissionais de saúde na detecção da covid-19. Além disso, várias organizações estão fazendo o uso de ferramentas de IA, para fazer o monitoramento das medidas sociais preventivas no local de trabalho. Essas ferramentas usam técnicas de processamento de imagens, para obter resultados precisos no desenvolvimento de soluções (PACHECO; PEREIRA, 2018).

2.2 PROCESSAMENTO DIGITAL DE IMAGENS

Uma imagem digital pode ser definida por uma função bidimensional $f(x,y)$ onde cada ponto da imagem vai representar uma localização e valor específico como definido por Gonzalez e Woods (2009):


(...) uma imagem pode ser definida como uma função bidimensional, $f(x,y)$, em que x e y são coordenadas espaciais (plano), e a amplitude de f em qualquer par de coordenadas (x,y) é chamada de intensidade ou nível de cinza da imagem nesse ponto. Quando x,y e os valores de intensidade de f são quantidades finitas e discretas, chamamos de imagem digital.

Diante dessas informações, pode-se definir o processamento digital de imagens (PDI), como a manipulação de uma imagem por um computador, baseando-se em fórmulas matemáticas e probabilísticas para obter resultados mais precisos, sendo que cada imagem vai possuir um valor e uma localização bem específica (GONZALEZ; WOODS, 2009).

Destacam-se três processos computacionais contínuos que são: processos de nível baixo, médio e alto. Os processos de nível baixo referem-se a métodos mais primitivos realizados na etapa de pré-processamento, utilizados para o melhoramento das imagens. É caracterizado pelo fato das entradas e saídas nesse tipo de processo serem imagens. O processo de nível médio envolve a etapa de segmentação, representação e descrição das características envolvidas nesse modelo. Esse processo possui métodos cujas entradas são imagens e as saídas são características específicas extraídas das mesmas. Por fim, no processo de nível mais alto serão desenvolvidos

métodos para o reconhecimento e a interpretação das características extraídas na etapa de representação e descrição (GONZALEZ; WOODS, 2009). A Figura 2 demonstra todos os passos fundamentais para realizar o processamento digital de imagens.

Figura 2 – Etapas do processamento digital de imagens.



Fonte: Próprio Autor (2021).

O primeiro passo desse processamento é a aquisição das imagens, que consiste nos meios pelos quais as imagens foram adquiridas. Nessa fase, o redimensionamento das imagens pode ser usado, por exemplo, para obter um melhor resultado nas etapas posteriores.

Após a aquisição das imagens é realizado o pré-processamento. Essa é a primeira etapa do PDI, utilizado para a remoção dos ruídos, realce de contraste e melhoramento das imagens. Posterior à etapa de pré-processamento é realizada a segmentação das imagens. Nessa etapa serão removidas das imagens apenas as Regiões de interesse (ROI).

Em seguida, serão realizadas a representação e descrição. Nessa fase, os objetos constituintes serão representados e descritos de forma adequada para o processamento das informações e realização da classificação dos objetos constituintes. Por fim, será realizado o processo de reconhecimento e interpretação das características extraídas na etapa de representação e descrição. Nessa etapa, será realizada a classificação dos objetos, dando sentido às características extraídas das imagens.


O PDI é utilizado para realizar a manipulação de uma grande quantidade de dados multidimensionais. Nessa área destacam-se várias formas de atuação como o campo de Visão Computacional (VC). A VC compreende uma área da Inteligência Artificial voltada para as

máquinas, que ensinam a interpretar imagens ou um grande conjunto de dados não estruturados através do PDI, para realizar tarefas como detecção e classificação de objetos. Seu principal objetivo é auxiliar os computadores a identificar e processar as informações de forma semelhante ao seres humanos, ensinando suas máquinas a reconhecer os diferentes objetos vistos através de inúmeros dispositivos (ALMEIDA et al., 2019).

2.3 DETECÇÃO DE OBJETOS

A detecção de objetos em imagem é considerada como uma tarefa de VC, que tem como finalidade localizar instâncias de objetos de uma determinada classe em uma imagem digital (SILVA et al., 2018). A classificação de objetos pode ser vista como uma tarefa de mapear uma imagem através de um conjunto de classes. Para tanto, é necessário atribuir pontuações para cada categoria, no qual as pontuações devem ser altas para as categorias corretas e baixas para as incorretas (MARIM, 2019). A Figura 3 demonstra um exemplo de detecção de objetos.

Figura 3 – Exemplo de objetos detectados em uma imagem



Fonte: Próprio Autor (2021).

A detecção de objetos em imagens consiste basicamente em duas tarefas bem definidas: a classificação e a localização. A classificação está associada diretamente a uma classe de objetos em particular, já a localização consiste basicamente nas coordenadas dos pontos que delimitam um retângulo alinhado aos eixos de x e y do objeto na imagem, tal retângulo é denominado de *Bounding Box (BB)* ou caixa delimitadora (MARIM, 2019).

Os sistemas de detecção de objetos podem ser considerados como uma função f que mapeia uma imagem digital I em um conjunto de localização L , dado um modelo M (SILVA et

al., 2018). Assim, pode-se representá-los através da Equação 2.1:

$$L = f(I, M) \quad (2.1)$$

Portanto, uma BB pode ser definida como um vetor b que tem como principal característica indicar a localização das coordenadas dos eixos x e y , a largura (w) e a altura (h) do retângulo onde o objeto encontra-se. Para cada localização de objetos detectados pelo sistema é atribuído um valor único, que indica a confiabilidade dessas técnicas e de que os BB descrevam corretamente a qual classe o objeto detectado pertence (SILVA et al., 2018).


Existem diferentes modelos de algoritmos de DL para VC e detecção de objetos. A maioria dos métodos são baseados nas Redes Neurais Convolucionais (CNNs), e suas diversas variações como: As Redes Neurais Convolucionais Baseadas em Regiões (R-CNN), incluindo sua família de técnicas com a Fast R-CNN e a Faster R-CNN, o YOLO, entre outras abordagens.

2.3.1 CONVOLUTIONAL NEURAL NETWORK

As redes neurais, desde o seu surgimento, promoveram um grande avanço no aprendizado de máquina sendo consideradas a razão por trás do aprendizado profundo. As redes neurais como as CNNs provaram ser particularmente bem sucedidas no trabalho com dados de imagens e, desde que foram usadas na competição da ImageNet, em 2012, têm sido pioneiras na pesquisa e na indústria ao lidar com a tarefa de reconhecimento de imagens (SHARMA, 2018).

Uma CNN pode ser considerada com uma variação de uma *Multi-Layer Perceptron* (MLP), baseada no processamento de dados do córtex visual dos seres humanos. De maneira geral, os processos tradicionais de VC serão capazes de aplicar filtros visuais para processar os dados, mantendo a relação de vizinhança entre os pixels da imagem ao longo do processamento da rede (VARGAS; PAES; VASCONCELOS, 2016).

Figura 4 – Representação de uma CNN.



Fonte: Silva (2018)

As CNNs são provavelmente o modelo de rede profunda mais conhecido e utilizado atualmente. O que caracteriza esse tipo de rede é sua composição que é baseada em **camadas**

convolucionais, que processam as entradas considerando os campos receptivos locais. Adicionalmente inclui operações conhecidas como *pooling*, que são responsáveis por reduzir a dimensionalidade espacial das imagens (PONTI; COSTA, 2018).


De forma mais objetiva as CNNs são algoritmos de DL que podem captar uma imagem de entrada e atribuir valores (pesos aprendidos) a mesma, sendo capaz de diferenciar um dos outros. O pré-processamento requerido pela CNN é muito menor se comparado com outros algoritmos de classificação. Além disso, nos métodos mais primitivos os filtros são aplicados de forma manual, por outro lado, com o treinamento adequado as CNNs são capazes aprender características através dos filtros (ACADEMY, 2021). A seguir, são abordados os conceitos necessários para o entendimento das camadas de convolução e *pooling*.

2.3.1.1 Camadas convolucionais

As camadas convolucionais são composta de diversos filtros denominados de *kernels*, que são empregados em cada imagem de entrada da rede. Cada kernel formam um mapa de características, que ressaltam determinada particularidade na imagem, como por exemplo o contorno dos objetos presentes. A principal função dessa camada é a extração de características de baixo nível da imagem, através das operações de convolução, que constituem representações computacionais das imagens em forma de matrizes (MARIM, 2019).

A convolução é um tipo de operação linear considerada essencial para definição de uma CNN, isto significa que para ser uma CNN é necessário que a rede tenha pelo menos em uma de suas camadas uma operação de convolução (FARIA, 2018). O processo de convolução é apresentado na Figura 5.

Figura 5 – Aplicação dos filtros de convolução



Fonte: FARIA (2018)

Na figura acima pode-se observar que a matriz de entrada possui dimensões 5×5


e o filtro utilizado para fazer essa operação tem dimensões 3×3 , denominado de filtro *edge* que é muito utilizado para detectar bordas nas imagens. A aplicação desses filtros em uma CNN tem como propósito detectar características específicas nos dados de entrada da rede, dessa forma podemos aplicar diferentes valores nos filtros e assim produzir diferentes mapas característica para um mesmo tipo de dado de entrada (imagens/vídeos) (FARIA, 2018).

2.3.1.2 Camadas de Pooling

Outra camada muito importante e que comumente é utilizadas após a camada de convolução é a camada de agrupamento ou pooling.

A função dessa camada é reduzir a dimensionalidade dos dados na rede. Existem diversas funções para a camada de pooling, como *max-pooling*, *avarege-pooling*, *global-avegere-pooling*. No entanto, a mais utilizada é a função de *max-pooling*. A Figura 6 mostra a aplicação da função de *max-pooling* no mapa de features.

Figura 6 – exemplo de operação de pooling.



Fonte: FARIA (2018)

observa-se na figura acima que a saída da camada convolucional é composta de uma matriz de dimensão 6×4 , que após a aplicação da camada de *pooling* resultará apenas em uma camada com saída 3×2 .


Ao longo desse processo, as características mais significativas permanecem enquanto as demais se perdem, dessa maneira haverá uma redução muito significativa no número de atributos da rede, consequentemente ocorrerá uma redução muito considerável nos parâmetros de entrada da rede (FARIA, 2018). Essa redução é muito importante não só por questão de agilidade, mas também para realizar o treinamento da rede.

2.3.2 You Only Look Once

Desenvolvido por Joseph Redmon, Santoh Divvalas, Ross Girshick e Ali Farhadi o *You Only Look Once* (Yolo) é considerado um sistema de detecção de objetos em tempo real

de última geração (REDMON et al., 2016). Sua estrutura é formada por uma rede neural convolucional (CNN) que pode realizar previsões simultâneas de várias caixas delimitadoras com probabilidades de conter classes de objetos (CAO et al., 2019). A Figura 7 mostra uma ilustração do funcionamento desse modelo.

Figura 7 – Detecção de objetos com o yolo




Fonte: Hou et al. (2020)

Diferentemente dos algoritmos convencionais de detecção de objetos, o Yolo consegue processar 45 frames por segundo. O mesmo consegue detectar os objetos de uma imagem de uma única passada (*single pass*) por meio de uma CNN. Em cada um de seus quadros o Yolo consegue classificar mais de uma classe de objetos, tornando-se assim um dos detectores mais rápidos e precisos nesse tipo de tarefa (REDMON et al., 2016).

Além disso, sua estrutura consegue dividir a imagem inteira em grades, cada grade pode conter mais de uma caixa delimitadora com localização e valores específicos. A detecção e a classificação destes objetos é aplicada individualmente para cada grade da imagem. Além disso, cada grade também é associada a um limiar que indica um limite de confiança para cada detecção (SHARMA, 2018). A Figura 8 apresenta a arquitetura do modelo yolo.

Figura 8 – Arquitetura do modelo Yolo framework



Fonte: Redmon et al. (2016)

2.4 MÉTRICAS

Nesta seção serão apresentadas algumas das principais métricas utilizadas para medir a precisão dos algoritmos de detecção e classificação de objetos.

2.4.1 *Intersection over Union*

A *Intersection over Union (IoU)* ou interseção sobre união é uma métrica de avaliação utilizada para medir a qualidade dos algoritmos de detecção de objetos em um conjunto de dados específico (CAO et al., 2019). Essa métrica é definida pela razão entre a área de interseção (x) e área de união (y), conforme apresentado pela Equação 2.2.

$$IoU = \frac{x}{y} \quad (2.2)$$

Essa métrica é extremamente útil para determinar se uma detecção possui sobreposição o suficiente para corresponder a um objeto pertencente a um conjunto de dados rotulados (PONTI; COSTA, 2018).

2.4.2 *Mean Average Precision*

O *Mean Average Precision (MAP)* é uma métrica utilizada para medir a excelência dos algoritmos de detecção de objetos. Esse critério leva em consideração as detecções corretas, as detecções erradas e a falta de detecções em todos os conjuntos de testes de uma determinada base de dados. Seu cálculo é realizado através das medidas de *precision* e *recall* (SILVA et al., 2018).

3 TRABALHOS RELACIONADOS

Neste capítulo, são apresentadas algumas propostas que utilizaram diferentes conceitos de detecção de objetos e diferentes técnicas de aprendizagem profunda para realizarem a detecção automática de distanciamento social.

Rahim, Maqbool e Rana (2021) propuseram uma solução para trabalhar com o distanciamento social em ambientes com pouca luz. A estrutura proposta utiliza o modelo You Only Look Once (YOLO) na sua quarta versão para realizar a detecção de objetos em tempo real, sendo que esse modelo foi treinado no conjunto de dados ExDark (LOH; CHAN, 2019) que foca especialmente em ambientes com pouca luminosidade. Para monitorar as medidas de distanciamento social e as violações, uma câmera Time of Flight (Tof) é utilizada a uma distância fixa. Basicamente, essa câmera é um sensor que consegue determinar as distâncias entre os objetos a partir da imissão de luz dos mesmos. O distanciamento social foi calculado levando em consideração duas métricas a velocidade e a precisão. O modelo proposto atingiu um resultado em ambientes com pouca luz, de 97.84% na métrica MaP e erro absoluto médio de 1.01 cm para o distanciamento social.

Ahmed et al. (2021) propuseram em sua abordagem uma estrutura de monitoramento de distanciamento social baseada em aprendizagem profunda para rastrear a distância social entre as pessoas. Essa estrutura utiliza o modelo pré-treinado YoloV3 para realizar a detecção entre as pessoas em sequências de vídeos. Além disso, a metodologia de transferência de aprendizagem é implementada para aumentar o desempenho do modelo. Com a finalidade de calcular a distância social entre as pessoas detectadas foi utilizada a distância euclidiana. Para estimar as violações de distanciamento social é estabelecido um limite entre a distância física e o valor do pixel. Esse limite é utilizado para avaliar se as pessoas estão ou não ultrapassando essa barreira de distanciamento social pré-estabelecida. Para testar a eficácia do modelo foram utilizadas diferentes sequências de vídeos, os resultados obtidos foram promissores atingindo uma precisão de 98% e 92% sem e com transferência de aprendizagem.

Hou et al. (2020) desenvolveram em seu trabalho um método para detecção de distanciamento social utilizando aprendizado profundo. Para desenvolver essa proposta foram utilizados conceitos e aplicações de uma CNN profunda e de métodos de visão computacional. Inicialmente, foi utilizada uma rede de detecção de objetos de código aberto baseada no YoloV3 para detectar os pedestres nos quadros de vídeo. A partir dessas detecções, foi considerada apenas a classe pessoa, as demais classes foram ignoradas para implementação desse modelo. Para realizar a captura dos vídeos, foi utilizada uma câmera de ângulo fixo, esses quadros de vídeos obtidos pela câmera são transformados em uma visão bidimensional de cima para baixo para uma estimativa mais precisa da medição da distância, assumindo que os pedestres estão caminhando em um mesmo plano. Portanto, o par de pedestres que está abaixo da distância

mínima aceitável é marcado com um quadro e uma linha vermelha e o restante é marcado com um quadro verde. O método proposto foi validado por um conjunto de vídeos capturados de uma câmera pública que mostra pedestres caminhando na rua. Os resultados dessa proposta demonstram que o método proposto é capaz de detectar as medidas de distanciamento social entre as pessoas.

Ramadass, Arunachalam e Sagayasree (2020) propuseram um algoritmo de aprendizado profundo para avaliar a distância social em locais públicos através de drones. O sistema proposto utiliza um drone para inspecionar o processo de distanciamento social entre as pessoas em ambientes públicos. Uma câmera acoplada no mesmo executa o método de detecção de objetos utilizando o YoloV3. O sistema exposto se utiliza de um conjunto de dados customizado e rotulado com imagens de distanciamento social. Esse dataset foi dividido em 75% para o treinamento do modelo e 25% para realizar os testes de precisão respectivamente.

4 ABORDAGEM DESENVOLVIDA

Neste capítulo detalhamos um método para identificação de pessoas e detecção do distanciamento social entre elas. Para tanto, organizou-se este capítulo em duas seções: definições de *benchmarks* e implementação do método de detecção do distanciamento social. Na Seção 4.1, os principais *datasets* utilizados na literatura são introduzidos, enquanto na Seção 4.2, o método para detecção de distanciamento social é detalhado.

4.1 DEFINIÇÃO DOS *BENCHMARKS*

Com a finalidade de validar e testar o modelo desenvolvido, foram utilizados dois conjuntos de dados disponibilizados através da plataforma Kaggle¹ o *Social Distancing Pedestrian Video*² e o *Social Distancing*³.

O *Social Distancing Pedestrian Video* é um *dataset* que em sua composição possui um único vídeo com 30 segundos de duração, com imagens capturadas de uma câmera de segurança de um local público. Essa base de dados acabou se tornando muito útil para quem deseja analisar os parâmetros dos algoritmos de detecção de distanciamento social.

Figura 9 – Frame de exemplo do Social Distancing Pedestrian Video.



Fonte: Social Distancing Pedestrian Video.

Por outro lado, o *Social Distancing* contém mais amostras que o anterior, pois possui um total de dois vídeos, cada um com uma duração de 30 segundos.

¹ <<https://www.kaggle.com/>>

² <<https://www.kaggle.com/jayitabhattacharyya/social-distance>>

³ <<https://www.kaggle.com/didiruh/social-distancing>>

Figura 10 – Frame de exemplo do Social Distancing.



Fonte: Social Distancing.

Embora os vídeos sejam curtos, eles são bastante utilizados em competições do **Kaggle**. Além disso, nesta área os trabalhos relacionados utilizam seus próprios vídeos. Isso dificulta a comparação entre métodos de detecção de distanciamento social. Dessa forma, gravaram-se alguns vídeos tanto na cidade de Picos quanto na cidade de Monsenhor Hipólito, para avaliação do método de distanciamento social.

4.2 DETECÇÃO DE DISTANCIAMENTO SOCIAL

Para realizar a implementação do modelo, utilizou-se o *framework Yolo* na sua terceira versão. Ele é um sistema de detecção de objetos que faz uso de uma rede neural profunda pré-treinada para realizar a detecção de forma ágil e rápida. Esse modelo é treinado em imagens completas da base COCO⁴, sendo que seu tipo de treinamento otimiza diretamente o desempenho do modelo (REDMON et al., 2016). Sua estrutura se utiliza de uma rede neural pré-treinada denominada de *Darknet* (REDMON, 2013–2016).

A *Darknet* é uma rede neural profunda de código aberto desenvolvida na linguagem de programação C e CUDA, possuindo camadas convolucionais, filtros, camadas totalmente conectadas, funções de ativação, com suporte de uso de GPU (*Graphic Processing Unit*). As camadas convolucionais iniciais dessa estrutura são responsáveis pela extração dos mapas de características da imagem, já as camadas totalmente conectadas ficam responsáveis por prover as probabilidades e as coordenadas de saída da rede (FIGUEIREDO; SILVA, 2021).

Para a implementação do método de detecção de pessoas e de distanciamento social, foi utilizada a biblioteca de programação de código aberto *OpenCV*. Essa biblioteca é muito

⁴ <<https://cocodataset.org/>>

utilizada para trabalhar com detecção de objetos em imagens e *streams* de vídeos. Em conjunto com a mesma, foi utilizada a linguagem de programação Python que é muito usada em projetos de visão computacional por possuir diversas bibliotecas disponíveis.

Para a detecção das pessoas nos *streams* de vídeos, foi considerado apenas a classe pessoas do *dataset* COCO. Esse *dataset* possui um conjunto de dados de 80 objetos pré-treinados, seu formato geralmente é interpretado automaticamente por bibliotecas que fazem a utilização de conceitos de redes neurais, como é o caso do *framework* Yolo. Em seguida, foi calculada a distância entre todos os pares de pessoas detectadas no vídeo. Para calcular as medidas de distanciamento social, utilizou-se a distância euclidiana que é uma métrica muito usada para calcular a distância entre dois pontos distintos, nesse caso entre todas as pessoas detectadas em um *frame*. A Equação 4.1 apresenta matematicamente a distância euclidiana.

$$D = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.1)$$

Com base nessa distância, é feita a verificação se duas pessoas estão a 50 *pixels* de distância umas das outras. Pois essa quantidade de *pixels* equivale a distância de 1,5m que é a determinada pelo Ministério da Saúde⁵ cumprindo assim o distanciamento social estabelecido pelo principal órgão de saúde. A Figura 11 mostra um exemplo de detecção de pessoas e do distanciamento social entre eles. Como pode-se ver, as pessoas que estão marcadas com um retângulo verde, estão cumprindo o distanciamento de 1,5m, enquanto aquelas que estão marcadas com um retângulo vermelho, não estão.

Figura 11 – Detecção do distanciamento social usando método proposto.



Fonte: Próprio Autor (2021).

Além disso, foram realizadas experiências com vídeos pilotos entre duas pessoas com

⁵ <<https://www.gov.br/saude/pt-br/coronavirus/como-se-proteger>>

uma distância máxima de um $1,5m$ entre ambas, como observado nas Figuras 12 e 13. Esses experimentos foram realizados para testar o desempenho do modelo em diferentes cenários.


É possível observar que, o algoritmo se comportou de maneira adequada nos diferentes ambientes propostos, conseguindo detectar o distanciamento social de forma aproveitável em ambas as situações.

Figura 12 – Detecção Correta.



Fonte: Próprio Autor (2021).

Figura 13 – Distanciamento Social.



Fonte: Próprio Autor (2021).

No entanto, com uma distância mínima considerável entre os pares de pessoas detectadas, o algoritmo se comportou de forma inadequada, já que o mesmo não conseguiu detectar a distância social entre as pessoas de forma correta. Isso pode ocorrer por diversos fatores como a distância entre a câmera e o cenário proposto, a calibração da câmera entre outros fatores. A Figura 14 demonstra essa aplicabilidade.

Figura 14 – Detecção Incorreta.



Fonte: Próprio Autor (2021).

Na figura acima é possível observar que, o detector de distanciamento social não detectou a distância social entre as pessoas de forma correta. Ambas as BB estão na cor verde e o correto seria caixas delimitadoras na cor vermelha, já que ambos os indivíduos estão muito próximos uns dos outros, descumprindo assim o distanciamento social pré-estabelecido pelos principais órgãos de saúde.

5 CONCLUSÃO

A pandemia da Covid-19, provocada pelo novo coronavírus, trouxe e ainda traz vários problemas para a população em todo o mundo. Tais problemas são: estresse, ansiedade, sintomas depressivos, insônia em profissionais da saúde, entre outros (SPOORTHY; PRATAPA; MAHANT, 2020).

De acordo com a Organização Mundial da Saúde (OMS), o uso de máscaras e o distanciamento social são maneiras de evitar o contágio e a propagação do vírus. Partindo desse ponto, esta monografia apresentou uma abordagem baseada nas áreas de visão computacional e aprendizado de máquina para a detecção do distanciamento social entre pessoas em *frames* de vídeos. A estratégia desenvolvida fez uso do YOLO V3. Além disso, usou-se o sistema pré-treinado na base de dados COCO para realizar a detecção de pessoas. A partir do sistema pré-treinado, implementou-se um método para calcular a distância entre duas pessoas a partir da distância dos *pixels* entre as pessoas identificadas. O método desenvolvido foi avaliado em dois *datasets* publicamente disponíveis que contêm vídeos de até 30s. Ademais, realizou-se um experimento piloto em vídeos com apenas duas pessoas a fim de analisar o método de detecção de distanciamento social. A partir desses experimentos, verificou-se que o método obteve um bom desempenho nos *datasets* públicos. No entanto, no experimento piloto os resultados não foram satisfatórios.

Outra limitação da estratégia desenvolvida é a detecção de pessoas pelo YOLO. Uma vez que utilizou-se o YOLO treinado na base COCO, e ela só possui imagens em ambientes claros, ou seja, o modelo treinado não é capaz de identificar objetos em ambientes com baixa luminosidade, prejudicando a detecção de distanciamento social em ambientes com essas características.

Como trabalhos futuros pretende-se: (i) treinar o YOLO na base ExDark, que possui imagens em ambientes com baixa luminosidade, a fim de melhorar a detecção do distanciamento social em tais ambientes e (ii) investigar medidas mais robustas para detectar a distância entre dois objetos.

REFERÊNCIAS

- ACADEMY, D. S. **Introdução as Redes Neurais Convolucionais**. 2021. Disponível em: <<https://www.deeplearningbook.com.br/introducao-as-redes-neurais-convolucionais/>>. Acesso em: 25 abril. 2021. Citado na página 20.
- AHMED, I. et al. A deep learning-based social distance monitoring framework for covid-19. **Sustainable Cities and Society**, Elsevier, v. 65, p. 102571, 2021. Citado na página 24.
- ALMEIDA, C. C. d. et al. **Identificação e classificação de imagens usando rede neural convolucional e "machine learning": implementação em sistema embarcado**. [sn], 2019. Citado na página 18.
- CAO, C.-Y. et al. Investigation of a promoted you only look once algorithm and its application in traffic flow monitoring. **Applied Sciences**, Multidisciplinary Digital Publishing Institute, v. 9, n. 17, p. 3619, 2019. Citado 2 vezes nas páginas 22 e 23.
- CLARO, M. et al. **An hybrid feature space from texture information and transfer learning for glaucoma classification**. **Journal of Visual Communication and Image Representation**, Elsevier, v. 64, p. 102597, 2019. Citado na página 12.
- FARIA, E. d. Redes neurais convolucionais e máquinas de aprendizado extremo aplicadas ao mercado financeiro brasileiro. **Programa de Pós-graduação em Engenharia Civil, COPPE, da Universidade Federal do Rio de Janeiro**, 2018. Citado 2 vezes nas páginas 20 e 21.
- FIGUEIREDO, E. B.; SILVA, E. P. da. Combate ao covid19: Detecção em tempo real de indivíduos sem máscara em ambiente escolar por meio de deep learning. In: SBC. **Anais do XV Brazilian e-Science Workshop**. [S.l.], 2021. p. 113–120. Citado na página 27.
- GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. [S.l.]: Pearson Educación, 2009. Citado 3 vezes nas páginas 12, 16 e 17.
- HOU, Y. C. et al. Social distancing detection with deep learning model. In: IEEE. **2020 8th International Conference on Information Technology and Multimedia (ICIMU)**. [S.l.], 2020. p. 334–338. Citado 2 vezes nas páginas 22 e 24.
- LOH, Y. P.; CHAN, C. S. Getting to know low-light images with the exclusively dark dataset. **Computer Vision and Image Understanding**, Elsevier, v. 178, p. 30–42, 2019. Citado na página 24.
- MARIM, Y. V. R. **DETECÇÃO DE OBJETOS: ESTUDO E APLICAÇÃO DA ARQUITETURA R-CNN**. 2019. Citado 2 vezes nas páginas 18 e 20.
- MITCHELL, T. M. et al. **Machine learning**. McGraw-hill New York, 1997. Citado na página 12.
- MOURA, N. et al. **Proposta de um Descritor Híbrido para Aprimoramento da Identificação Automática de Melanoma**. In: SBC. **Anais do XVII Workshop de Informática Médica**. [S.l.], 2017. Citado na página 12.
- MS. **O QUE VOCÊ PRECISA SABER**. 2021. Disponível em: <<https://www.gov.br/saude/pt-br/pagina-inicial/#>>. Acesso em: 09 abril. 2021. Citado 3 vezes nas páginas 13, 15 e 16.

OMS. **Coronavirus disease (COVID-19) pandemic**. 2021. Disponível em: <<https://www.who.int/>>. Acesso em: 03 abril. 2021. Citado 3 vezes nas páginas 13, 14 e 16.

PACHECO, C. A. R.; PEREIRA, N. S. **Deep learning conceitos e utilização nas diversas Áreas do conhecimento**. *Revista Ada Lovelace*, v. 2, p. 34–49, 2018. Citado na página 16.

PONTI, M. A.; COSTA, G. B. P. D. **Como funciona o deep learning**. *arXiv preprint arXiv:1806.07908*, 2018. Citado 2 vezes nas páginas 20 e 23.

RAHIM, A.; MAQBOOL, A.; RANA, T. Monitoring social distancing under various low light conditions with deep learning and a single motionless time of flight camera. *Plos one*, Public Library of Science San Francisco, CA USA, v. 16, n. 2, p. e0247440, 2021. Citado na página 24.

RAJARAMAN, S. et al. **Pre-trained convolutional neural networks as feature extractors toward improved malaria parasite detection in thin blood smear images**. *PeerJ*, PeerJ Inc., v. 6, p. e4568, 2018. Citado na página 12.

RAMADASS, L.; ARUNACHALAM, S.; SAGAYASREE, Z. Applying deep learning algorithm to maintain social distance in public place through drone technology. *International Journal of Pervasive Computing and Communications*, Emerald Publishing Limited, 2020. Citado na página 25.

REDMON, J. **Darknet: Open Source Neural Networks in C**. 2013–2016. <<http://pjreddie.com/darknet/>>. Citado na página 27.

REDMON, J. et al. You only look once: Unified, real-time object detection. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2016. p. 779–788. Citado 2 vezes nas páginas 22 e 27.

SAUDE, V. **As diferenças e semelhanças entre outros coronavírus e o Sars-CoV-2**. 2021. Disponível em: <<https://saude.abril.com.br/medicina/as-diferencas-e-semelhancas-entre-o-sars-cov-2-e-outros-coronavirus/>>. Acesso em: 30 de abril. 2021. Citado na página 15.

SHARMA, P. A practical guide to object detection using the popular yolo framework—part iii. *Analytics Vidhya*, 2018. Citado 2 vezes nas páginas 19 e 22.

SILVA, G. R. et al. Detecção de objetos em imagens utilizando técnicas de aprendizagem profunda. Florianópolis, SC, 2018. Citado 3 vezes nas páginas 18, 19 e 23.


SILVA, R. E. V. d. Um estudo comparativo entre redes neurais convolucionais para a classificação de imagens. 2018. Citado na página 19.

SPOORTHY, M. S.; PRATAPA, S. K.; MAHANT, S. Mental health problems faced by healthcare workers due to the covid-19 pandemic—a review. *Asian journal of psychiatry*, Elsevier, v. 51, p. 102119, 2020. Citado na página 32.

STEINHEISER, P. W. et al. **Estudo do desempenho da detecção de objetos em exames de AgNOR**. Florianópolis, SC, 2020. Citado na página 12.

SWAPNAREKHA, H. et al. **Role of intelligent computing in COVID-19 prognosis: A state-of-the-art review**. *Chaos, Solitons & Fractals*, v. 138, p. 109947, 2020. ISSN 0960-0779. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0960077920303465>>. Citado na página 15.

VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: SN. **Proceedings of the xxix conference on graphics, patterns and images**. [S.l.], 2016. v. 1, n. 4. Citado na página 19.



INSTITUTO FEDERAL DE
EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
PIAUI

CURSO DE ANÁLISE E DESENVOLVIMENTO DE SISTEMAS

Maria Cristiana de Jesus Sá

TÍTULO: Detecção automática de distanciamento social em locais públicos utilizando visão computacional e aprendizado profundo

PICOS
2021

DETECÇÃO AUTOMÁTICA DE DISTÂNCIAMENTO SOCIAL EM LOCAIS PÚBLICOS UTILIZANDO VISÃO COMPUTACIONAL E APRENDIZADO PROFUNDO

DETECÇÃO AUTOMÁTICA DE DISTÂNCIAMENTO SOCIAL EM LOCAIS PÚBLICOS UTILIZANDO VISÃO COMPUTACIONAL E APRENDIZADO PROFUNDO

CURSO DE ANÁLISE E DESENVOLVIMENTO DE SISTEMAS

Maria Cristiana de Jesus Sá

TÍTULO: Detecção automática de distanciamento social em locais públicos utilizando visão computacional e aprendizado profundo