

Redes neurais: transformando um *smart campus* por meio do monitoramento de pessoas com e sem mobilidade reduzida

Neural networks: transforming a smart campus through the monitoring of people with and without reduced mobility

Engenharia de Controle e Automação

Victor Inácio de Oliveira (pro14724@cefsa.edu.br)

Doutor em Engenharia de Automação e Controle pela Universidade de São Paulo (USP) e professor da Faculdade Engenheiro Salvador Arena e da Universidade Presbiteriana Mackenzie

Ricardo Janes (ricardo.janes@mackenzie.br)

Doutor em Engenharia Elétrica pela Universidade de São Paulo (USP) e professor da Faculdade de Engenharia Industrial (FEI) e da Universidade Presbiteriana Mackenzie

Rogério Issamu Yamamoto (pro15804@cefsa.edu.br)

Doutor em Engenharia Mecânica pela Universidade de São Paulo e professor da Faculdade Engenheiro Salvador Arena e da Universidade Presbiteriana Mackenzie

Nilson Yukihiro Tamashiro (pro5827@cefsa.edu.br)

Mestre em Engenharia Biomédica pela Universidade de Mogi das Cruzes (UMC) e professor da Faculdade Engenheiro Salvador Arena e da Universidade São Judas Tadeu (USJT)

Bruno Luis Soares de Lima (bruno.lima@mackenzie.br)

Doutor em Engenharia Elétrica pela Universidade de São Paulo (USP) e professor da Universidade Presbiteriana Mackenzie

Matheus Santana Ferreira (matheus.k.santanaferreira@gmail.com)

Bacharel em Engenharia Elétrica pela Universidade Presbiteriana Mackenzie

FTT Journal of Engineering and Business

- SÃO BERNARDO DO CAMPO, SP JUN. 2025
- ISSN 2525-8729

Submissão: 10 dez. 2024 Aceitação: 28 maio 2025

Sistema de avaliação: às cegas dupla (double blind review)

FACULDADE ENGENHEIRO SALVADOR ARENA, p. 96 - 117

FTT JOURNAL
of Engineering and Business



FACULDADE
ENGENHEIRO
SALVADOR ARENA

Resumo

O presente trabalho tem como objetivo desenvolver um sistema de monitoramento capaz de identificar pessoas com e sem mobilidade reduzida, destacando aquelas que utilizam dispositivos para auxiliar na movimentação como cadeira de rodas e muletas, gerando um mapa de calor que auxilia no entendimento do fluxo de pessoas dentro do campus da Universidade Presbiteriana Mackenzie. O modelo foi desenvolvido com a arquitetura de visão computacional YOLOv8 a partir de um *dataset* de imagens montado com imagens de licença CC 4.0. Toda a etapa de aprendizado foi executada em ambiente do *google colab* e, posteriormente, o processamento foi realizado por um Raspberry Pi 4 e uma câmera HD. Os resultados demonstraram que o modelo utilizado foi capaz de detectar todas as classes com indicadores satisfatórios de desempenho, gerando mapas de calor e possibilitando o envio de notificações caso pessoas com mobilidade reduzida necessitassem de auxílio para se locomover no campus.

Palavras-chave: Rede Neural. Análise de Dados. Visão Computacional. Fluxo de Pessoas

Abstract

This study aims to develop a monitoring system capable of identifying people with and without reduced mobility, with emphasis on individuals using mobility assistance devices such as wheelchairs and crutches, generating a heat map that helps in understanding the flow of people within the campus of Universidade Presbiteriana Mackenzie. The model was developed using the YOLOv8 computer vision architecture based on a dataset of images compiled from CC 4.0 licensed images. The entire learning phase was executed in a Google Colab environment, and the subsequent processing was carried out using a Raspberry Pi 4 and an HD camera. The results demonstrated that the model used was able to detect all classes with satisfactory performance indicators, generating heat maps and allowing notifications to be sent, if individuals with reduced mobility needed assistance to move around the campus.

Keywords: Neural Network. Data Analysis. Computer Vision. People Flow

Introdução

Com a evidente ascensão de políticas para ampliar e democratizar o acesso ao ensino superior no Brasil, como o Plano de Ensino Nacional (PEN), que visa aumentar o número de jovens entre 18 e 24 anos matriculados em alguma instituição de ensino superior em 50% até 2024, de acordo com a Lei nº 13.005, de 25 de junho de 2014 (Brasil, 2014), é de se esperar que o fluxo de pessoas em um campus universitário consequentemente cresça também, em um contexto de uma sociedade cada vez mais conectada a múltiplos dispositivos e mais adepta do auxílio de redes neurais e da inteligência artificial.

O cálculo do fluxo de pessoas em um campus universitário sem o uso da inteligência artificial e das redes neurais envolve métodos tradicionais de contagem e análise. Por exemplo, contagem manual, sensores de movimento, cartões de acesso e registros de presença, pesquisas e questionários. Por meio da inteligência artificial e da análise de dados avançada pode-se aprimorar a precisão no monitoramento do fluxo de pessoas, identificando padrões e tendências, prevendo o futuro e assim tornando a gestão do campus mais eficiente e eficaz.

O tema de *Smart Campus* é uma derivação de uma temática maior e mais abrangente, o de *Smart Grids* ou *Smart Cities*, que tem por objetivo a melhoria da qualidade de vida das pessoas por meio da implantação de sistemas de inteligência artificial. O tema incorpora uma série de tecnologias de informação e de comunicação para monitorar, controlar e otimizar recursos em contextos variados. As ideias iniciais acerca dele surgiram no final do século 20, impulsionadas pelo progresso nas tecnologias de telecomunicações e computação. Já no século 21, o tema ganhou mais força devido à alta demanda de dados gerados diariamente e da necessidade de um meio para utilizá-los de alguma forma. (Dong et al., 2016).

Dito isto, um maior número de pessoas em um campus universitário aumenta em consequência de diferentes demandas no que diz respeito aos recursos da instituição de ensino; no caso deste projeto, trata-se de análise de acesso igualitário para a transposição dos entraves que representam as barreiras para a efetiva participação de pessoas nos vários âmbitos da vida social, como a mobilidade reduzida, sendo temporária ou crônica. Este trabalho contribui no sentido de oferecer auxílio às diferentes vertentes de monitoramento e ampliar as aplicações de seus benefícios em um contexto mais amplo. Assim, o objetivo deste projeto é elaborar uma rede neural auxiliada por câmeras capaz de monitorar e consequentemente gerar relatórios e produzir *forecasts* a respeito do fluxo de pessoas ao longo do dia, além das demandas de acessibilidade de pessoas com mobilidade reduzida em um campus universitário.

Revisão de Literatura

Smart Campus

Em um contexto de integração com a tecnologia, pode-se definir um *smart campus* como uma “infraestrutura inteligente onde sensores e atuadores colaboram para coletar informações e interagir com máquinas, ferramentas e usuários em um campus universitário” (Fraga-Lamas *et al*, 2019). Assim, uma vez que o conceito de um *Smart Campus* é derivado do conceito de *Smart Cities*, é visto de tal maneira que seu objeto passa a ser considerado como uma cidade, compartilhando, em grande parte, os mesmos problemas de uma cidade convencional, (Bandeira; Neto, 2022).

Conceito de acessibilidade e inclusão


A acessibilidade consiste na ideia de possibilitar a inclusão de um indivíduo com qualquer tipo de deficiência na participação ativa no uso de produtos, serviços e informações, tendo como objetivo principal promover oportunidade de igualdade, segurança e autonomia na execução de qualquer atividade. (Decreto nº 6.949, 2009).

Rede neural artificial

Segundo Haykin (2009), pode-se definir uma rede neural da seguinte maneira: “Uma rede neural é um processador, maciçamente e paralelamente distribuído, constituído de unidades de processamento simples, que têm propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso.” (HAYKIN, 2009)


A arquitetura da rede neural consiste em uma interface capaz de emular a maneira como um cérebro realiza tarefas ou uma função de interesse; sua implementação se dá a partir de componentes eletrônicos ou simulações em um computador, e seu desempenho depende diretamente de uma interligação de células denominadas “neurônios” ou “unidades de processamento” (Haykin, 2009). Nas figuras 1 e 2 podemos comparar as semelhanças entre os neurônios de um cérebro humano e os de uma rede neural, respectivamente.

Figura 1 - Célula Pirâmidal de um Cérebro Humano e Neurônio Artificial



Fonte: Haykin (2009)

Figura 2 - Neurônio Artificial



Fonte: Haykin (2009)

Sendo ‘ ω ’ o valor de um peso sináptico; ‘ x ’ os valores de entrada; ‘ y ’ os valores de saída; ‘ b ’ os valores de bias, que alteram a liquidez da somatória de ativação, mudando se ela for positiva ou negativa.

Assim, baseado no modelo da figura 2, pode-se descrever o modelo matemático de um neurônio artificial por meio das seguintes equações 1 e 2.

$$v_k = \sum_{j=0}^m \omega_{kj} x_j \quad (\text{equação 1})$$

$$y = \varphi(v_k) \quad (\text{equação 2})$$

Onde 'j' é a entrada de sinapse conectada ao neurônio k multiplicada pelo peso sináptico ω .

Para tomar suas decisões, uma rede neural leva em consideração um fator denominado peso sináptico, que consiste em números positivos ou negativos que aumentam o fator de decisão de uma rede neural por meio dos neurônios que enviam e dos neurônios que recebem a informação; assim, quanto maior o peso sináptico, mais certeza (ou crença) uma rede neural tem a respeito de uma decisão. (Roque, 2024)

Rede neural convolucional

Uma rede neural convolucional ou *Convolutional Neural Network* (CNN) consiste em uma arquitetura de rede neural profunda utilizada para reconhecimento e agrupamento de imagens, podendo identificar, por exemplo, rostos e objetos dentro de cenas.

Sua composição consiste em camadas de dois estágios de processamento, sendo o primeiro deles a camada convolucional, que extrai as informações de entradas, e uma camada de *pool*, que mantém as informações mais importantes baseadas nos mapas de características determinadas; em uma etapa seguinte, uma Rede Perceptron de Multicamadas (MLP) é utilizada para analisar as informações, agora abstratas, e transformá-las em modelos preditivos capazes de detectar os objetos nas imagens. Portanto, a CNN não enxerga uma imagem como os humanos, mas sim, como um conjunto de textos que indicam coordenadas dentro de um *grid*.

Classificação de imagem

No âmbito de uma CNN, a classificação de imagem tem por objetivo prever qual objeto está nela contido; a ação de identificar o objeto e atribuir a ele uma classe é chamada localização.

Para prever qual objeto pertence a determinada classe, uma CNN utiliza um conceito conhecido como *bouding box* (Caixa Delimitadora), que é responsável por definir quais são os limites que compõem a estrutura de um objeto, isto é, seu início e seu fim, podendo, dessa forma comparar a imagem amostrada com um *dataset* de características, apresentando no final uma porcentagem que indica a confiabilidade da classificação executada. (Redmon, J. 2018)

Uma CNN pode ser treinada para possuir caráter multiclasse, sendo assim capaz de reconhecer múltiplos objetos diferentes simultaneamente (Redmon, J. 2018).


Modelo de classificação de imagens Yolo

Dentre as redes neurais mais utilizadas para a classificação de imagem, a YOLO (*You Only Look Once*) possui o maior(melhor) desempenho quando comparada às demais. (Ultralytics, 2024).

A YOLO consiste em uma CNN *open source* de detecção de objetos e segmentação em tempo real. Seu maior(melhor) desempenho ocorre porque, como seu próprio nome indica, a YOLO realiza múltiplas classificações por meio de uma única visualização da imagem, conseguindo assim gerar diversas caixas delimitadoras, exigindo menor poder de processamento e menor tempo de execução. (Ultralytics, 2024)

Na figura 3, podemos notar como a arquitetura YOLO se sobressai em relação a outros modelos no quesito de classificação de imagem.

Figura 3 - Desempenho do YOLOv8 comparado a versões anteriores em relação a parâmetros reconhecidos e tempo de latência respectivamente.



Fonte: Ultralytics (2024).

Algoritmo de previsão

No que diz respeito à previsão relacionada ao fluxo de pessoas, há metodologias amplamente difundidas, como a clusterização, um método de aprendizado não supervisionado, utilizado para identificar padrões de comportamento em grandes bases de dados, sendo vista como um meio de segmentação que organiza dados em subconjuntos os quais compartilham padrões e propriedades similares, no caso deste trabalho, de tempo e quantidade de indivíduos.


Metodologia

O funcionamento se inicia a partir de uma câmera HD que coleta as imagens em um determinado local do campus da Universidade Presbiteriana Mackenzie; esta câmera, por sua vez, está conectada a um Raspberry Pi 4 que atua sendo o centro de todas as operações; as classes de pessoas com e sem mobilidade reduzida são detectadas e, na sequência, separadas em dois grupos distintos com uma ação diferente para cada um deles.

Para as pessoas com mobilidade reduzida, a informação de sua presença é enviada para os responsáveis a fim de melhorar sua experiência de deslocamento, como por exemplo, acionar os carros de deslocamento interno para realizar a locomoção dessas pessoas entre um ponto e outro da faculdade, ou então, segurar o elevador para que elas possam ter prioridade no uso desse equipamento. Já para as pessoas sem mobilidade reduzida é realizada uma contagem que tem por finalidade gerar um mapa de calor a respeito do fluxo de pessoas na região e definir a melhor rota para deslocamento no campus.

A visualização desta arquitetura está na figura 4:

Figura 4 - Arquitetura do projeto



Fonte: elaboração dos autores (2024).

Para o pleno funcionamento, a seguinte arquitetura foi elaborada:

Aquisição de informações via câmeras

Foi utilizada uma câmera HD conectada ao *Raspberry*.

Armazenamento dos dados

O grande volume de dados gerados requer que um banco de dados seja utilizado para armazenar as informações coletadas no tópico 3.1 antes de serem enviados para a plataforma de gerenciamento pela lógica de processamento. O *DynamoDB* e o *Firebase* foram utilizados.

Plataformas de processamento

Todas as etapas do treinamento foram realizadas no ambiente do *Google Colab*, que oferece acesso gratuito a recursos de computação, incluindo *Graphic Processing Units (GPUs)*, que no contexto dessa plataforma, é realizado por meio de máquinas virtuais dedicadas destinadas a atender as demandas de aprendizagem de uma CNN. A GPU dedicada do *Google Colab* é uma Tesla V100 da Nvidia. Quanto à análise dos dados coletados, o ambiente do *Posit Cloud* foi utilizado para elaborar gráficos e modelos matemáticos preditivos. O desempenho dos modelos foi avaliado a partir da curva ROC (*Receiver Operating Characteristic*) e de parâmetros de acurácia como o erro médio quadrático.

Aprendizagem da rede neural

Para realizar o aprendizado de uma rede neural utilizando a arquitetura YOLO diversas etapas menores foram realizadas.

Criação de um dataset

A primeira etapa do processo foi criar um *dataset* com todas as imagens que foram utilizadas durante o treinamento, as quais devem estar acompanhadas de arquivos de extensão txt, que possuem anotações com coordenadas cartesianas indicando a posição de uma caixa delimitadora que contém o objeto de interesse na imagem.

As imagens podem ser obtidas em *datasets online*; neste projeto, os datasets foram obtidos nos sites *Roboflow* e *Open Images Dataset*, e possuem uma licença CC BY 4.0, que concede ao usuário liberdade para “copiar e redistribuir o material em qualquer suporte ou formato para qualquer fim, mesmo que comercial; remixar, transformar, e criar a partir do material para qualquer fim, mesmo que comercial.”. (Creative Commons, 2024). As fotos do *dataset* foram separadas em dois grupos: *train*, que possui o maior volume de imagens e é responsável pelo treinamento em si e *valid*, que é responsável por validar o treinamento e verificar qual porcentagem de certeza a CNN possui a respeito de determinado objeto.

Importação da biblioteca

Uma vez definidos e agrupados em um *dataset* único, a arquitetura YOLOv8 da *ultralytics* foi importada; o YOLOv8 possui 6 variações, sendo elas: YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l e YOLOv8x. Cada uma delas possui maior precisão de detecção que sua versão anterior, porém, conseqüentemente exige um maior processamento. O modelo YOLOv8n foi utilizado neste projeto.

Treinamento da rede neural

Com o *dataset* importado e o modelo a ser utilizado configurado iniciou-se o treinamento customizado da rede neural. Para tanto, configurações foram realizadas, como tamanho da imagem, velocidade de aprendizado e em quantas épocas o treinamento seria realizado; uma época diz respeito a uma passada completa da rede neural por todas as imagens de treino e validação disponíveis, e para que uma rede neural possa apresentar resultados satisfatórios cerca de 300 épocas são necessárias.

Quanto à pesquisa envolvendo seres humanos

A Universidade Presbiteriana Mackenzie dispõe de um Comitê de Ética em Pesquisa (CEP) que possui como atribuição fundamental “divulgar, no âmbito da UPM, normas relativas à ética em pesquisa envolvendo seres humanos e procedimentos deste Comitê” (Conselho Universitário da Universidade Presbiteriana Mackenzie, 2022). Deste modo, esta pesquisa visa estar de acordo com as normas no que diz respeito ao tratamento de dados relacionados aos que são gerados envolvendo seres humanos.

Por desenvolver processos de análise de imagem de maneira quantitativa, que independem do uso de características faciais, como parte da metodologia, foi realizada a ocultação dos rostos capturados por câmeras.

Resultados

Aprendizado de máquina

Após 300 épocas realizadas em cerca de 50 horas, os seguintes resultados foram obtidos no treinamento realizado para pessoas com muletas e cadeiras de rodas.


Quadro 1 - Resultados do aprendizado de máquina para muleta e cadeira de rodas

Classe	Precisão de Caixa Delimitadora	Recall	mAP50	mAP50-95
Muleta	0,957	0,944	0,989	0,803
Cadeira de rodas	0,933	0,979	0,992	0,896
Média	0,962	0,961	0,987	0,85

Fonte: elaboração do autor (2024).

Ao todo, cerca de 29 mil imagens foram usadas no aprendizado de máquina, sendo 25 mil delas utilizadas para treinamento e 4 mil para validação. A rede neural conseguiu apresentar resultados excelentes em ambientes controlados, como é possível observar na precisão da caixa delimitadora e no mAP50, mas sua confiabilidade é ligeiramente afetada devido ao *overfitting*, isto é, uma situação na qual a rede neural se adaptou excessivamente à base de dados, o que resultou em uma pequena queda de desempenho para imagens que não compõem a base de dados. No entanto, a confiabilidade apresentada ainda é alta o suficiente para garantir a aplicação do projeto. As métricas de desempenho podem ser visualizadas na figura 5.

Figura 5: Resultados do aprendizado de máquina.



Fonte: elaboração do autor (2024).

Na linha de cima, podemos visualizar todos os parâmetros de treinamento, enquanto na linha de baixo, vemos os valores de validação. É possível notar que à medida que o número de épocas aumentou, o erro da caixa delimitadora diminuiu em *box_loss*, juntamente também com o erro de classe, enquanto as métricas de *precision* e *recall* aumentaram, resultados estes que eram esperados nesse método de aprendizado. Os resultados positivos puderam ser observados tanto na etapa de treinamento quanto na de validação.

Uma vez que a rede neural foi treinada corretamente, uma segunda etapa conhecida como transferência de conhecimento foi efetuada; isso ocorre quando um treinamento é realizado a partir de pesos já treinados anteriormente. O objetivo desta etapa foi criar uma rede neural capaz de compreender que tanto pessoas com muletas quanto indivíduos com cadeira de rodas possuem mobilidade reduzida, compilando-se duas classes em apenas uma, sendo indiferente do ponto de vista


analítico se essa redução foi causada por cadeira de rodas ou por muletas. Além disso, devido a limitações de hardware, tanto o pré-processamento quanto o processamento em tempo real são beneficiados ao se tratar de apenas uma classe. Assim, as figuras 6 e 7 contêm os resultados de detecção da rede neural no ambiente do *colab*.

Figura 6 : resultados de detecção de pessoas com mobilidade reduzida devido a cadeira de rodas com 91% de precisão.



Fonte: Open Images Dataset, modificadas pelos autores (2024).

Figura 7 - Resultados de detecção de pessoa com mobilidade reduzida com 88% de precisão.




Fonte: Open Images Dataset, modificadas pelos autores (2024).

Levando em consideração as questões de ética anteriormente citadas, no que diz respeito a testes realizados na Universidade Presbiteriana Mackenzie, todas as imagens foram borradas na etapa de pré-

processamento por meio da opção *blur* presente no YOLO; a figura 8 exemplifica como as imagens são visualizadas na GUI (*Graphic User Interface*):

Figura 8 - Detecção realizada entre os prédios 5 e 6 da Universidade Presbiteriana Mackenzie.



Fonte: elaboração dos autores (2024).

Também devido à capacidade limitada de processamento do hardware e do modelo YOLO8vs adotado, é possível notar que há uma distância máxima de detecção para qualquer uma das classes; logo, pessoas mais ao fundo da imagem tendem a não terem sua imagem borrada; no entanto, elas ainda permanecem irreconhecíveis.

Monitoramento via Raspberry

Uma vez que a rede neural foi treinada e testada, ela foi utilizada para o formato NCNN, que consiste em uma biblioteca de interferência de redes neurais para alto desempenho em dispositivos móveis, possibilitando que modelos de aprendizados possam ser executados de maneira mais rápida e eficaz em dispositivos com menor poder de processamento. O objetivo dessa portabilidade foi poder executar a detecção das classes a partir de um *Raspberry Pi 4* com as seguintes características de processamento:

- Processador: Broadcom BCM2711, Quad core Cortex-A72 (ARM v8) 64-bit SoC @ 1.8GHz
- Memória RAM: 4GB LPDDR4-3200 SDRAM

Assim, os testes passaram a ser realizados com monitoramento em tempo real utilizando a unidade de processamento do *Raspberry*; todas as informações coletadas são enviadas ao SQLite em formato de uma planilha relacional, que contém as seguintes colunas:

- ID
- Classe
- Timestamp
- Contagem

De modo que toda vez que a Rede Neural detecta qualquer uma das duas classes, uma linha é adicionada no banco de dados, que poderá ser utilizada posteriormente; além disso, o *Raspberry* gera o mapa de calor de pessoas nesta etapa.


A câmera HD foi instalada no laboratório de Engenharia Elétrica e coletou os dados por uma semana; todos os valores armazenados foram enviados ao banco de dados *DynamoDB*. A figura 9 demonstra como os dados foram armazenados, e a figura 10 mostra como a imagem processada é visualizada pelo usuário.

Figura 9 - Valores armazenados no *DynamoDB*

☐	<i>Id (Número)</i>	<i>class</i>	<i>person_count</i>	<i>timestamp</i>
☐	151	person	9	2024-10-31 20:08:44.461149-03:00
☐	145	person	1	2024-10-31 19:59:07.467830-03:00
☐	142	person	0	2024-10-31 19:58:54.178280-03:00
☐	139	person	19	2024-10-31 19:56:45.574661-03:00
☐	138	person	19	2024-10-31 19:56:45.450302-03:00
☐	135	person	12	2024-10-31 19:52:13.737556-03:00
☐	132	person	19	2024-10-31 19:56:45.326227-03:00

Fonte: elaboração dos autores (2024).

Figura 10 - Exemplo de Detecções Realizadas.




Fonte: elaboração dos autores (2024).

Pode-se notar na figura 10 que a rede neural aplica um *blur* no corpo inteiro de todas as pessoas detectadas; além disso, atribui um ID único para auxílio da contagem de pessoas e também conta o número de pessoas que passaram pelo local.

Análise dos dados obtidos

Ao todo, foram detectadas 1600 pessoas ao longo de quatro dias, sendo eles: segunda-feira, terça-feira, quinta-feira e sexta-feira. Os valores obtidos foram analisados em linguagem R por meio da plataforma *Posit Cloud*. A análise foi obtida por meio de agrupamentos de *cluster*, onde inicialmente o método do cotovelo (*elbow method*) foi utilizado para determinar qual seria o número ideal de *clusters* de acordo com o volume de dados; o método consiste em calcular as distâncias quadradas dentro dos *clusters* até o momento em que elas se estabilizam. A figura 11 mostra a curva calculada.


Figura 11 - Elbow Method



Fonte: elaboração dos autores (2024).

É possível observar que a partir de dois *clusters* a curva apresenta uma desaceleração significativa, especialmente partindo de quatro *clusters*, demonstrando que a partir deste ponto o aumento de *clusters* tem pouca influência nos resultados. Na sequência, um agrupamento foi gerado utilizando $k = 4$, sendo k o número de *clusters* utilizados. A segmentação foi feita utilizando-se os dias da semana e as horas do dia como variáveis nos eixos y e x respectivamente. Os *clusters* foram gerados a partir de 40 amostras aleatórias da base de dados; com dessa forma, os resultados da figura 12 foram obtidos.

Figura 12 - Segmentação dos dados por clusters




Fonte: elaboração dos autores (2024).

O Cluster 1 é identificado pela cor vermelha e aparece em várias horas do dia para todos os dias da semana. O de número 2 é representado pela cor verde e aparece em algumas horas específicas em diferentes dias. O terceiro aparece na cor azul, com uma distribuição própria de dias e horas. O Cluster 4 é mostrado em roxo e apresenta um padrão distinto. Por meio dessa análise, é possível concluir que a hora do dia tem impacto significativo no fluxo de pessoas no local. Essa distribuição sugere que há quatro padrões distintos de lotação na base de dados, mostrando uma segmentação clara neste quesito e possibilitando análises mais aprofundadas sobre o tráfego de pessoas.

Para averiguar se a hipótese de que diferentes horários no dia influenciam no fluxo de pessoas, um dendrograma de clusterização hierárquica foi gerado.

Figura 13 - Dendrograma de clusterização hierárquica



Fonte: elaboração dos autores (2024).


A visualização indica que, em níveis iniciais de fusão, os pontos de dados parecem ser agrupados de maneira lógica com base na similaridade temporal (dia da semana e hora do dia). À medida que a altura do dendrograma aumenta, as observações de grupos mais amplos se fundem, sugerindo que esses agrupamentos representam padrões distintos de comportamento ao longo do tempo.

Com a segmentação bem definida e condizente com a realidade, foi possível elaborar um modelo capaz de calcular a probabilidade de haver ao menos 15 pessoas nos corredores do laboratório em todas as horas do dia e, além disso, de construir um gráfico com um mapa de calor do número de IDs únicos detectados durante os dias.

Assim, o dendrograma sugere que a clusterização hierárquica dos dados resulta em 4 grupos bem definidos, cada um com padrões distintos de presença ao longo do tempo, podendo representar

diferentes comportamentos ou características temporais, como variações na presença de pessoas ou atividades ao longo da semana e do dia.


Figura 14 - Probabilidade de presença de pessoas com base na hora e dia da semana



Fonte: elaboração dos autores (2024).

É possível observar que o gráfico reflete um padrão de presença mais acentuado nos últimos dias da semana, ao final da noite, o que condiz com o comportamento ocasionado pelo final do horário acadêmico, enquanto nos demais dias da semana apresenta-se um comportamento mais homogêneo de distribuição. Outro gráfico gerado foi o de um mapa de calor mostrando a contagem de pessoas únicas em determinadas horas do dia.


Figura 15 - Mapa de calor de contagem de pessoas



Fonte: elaboração dos autores (2024).

Por fim, tendo em vista averiguar a precisão do modelo adotado, uma curva ROC foi gerada, sendo esta uma ferramenta de classificação binária entre a taxa de verdadeiros positivos e a taxa de verdadeiros negativos que são plotadas nos eixos Y e X respectivamente.


Figura 16 - Curva ROC do modelo de predição.



Fonte: elaboração dos autores (2024).

Nota-se que a curva sobe rapidamente do ponto (0,0) até o ponto (1,1), demonstrando uma boa eficácia na classificação de observações dada a distância entre a curva e a linha diagonal. Ao analisarmos o valor AUC (Área Sob a Curva), obtemos um valor de 0,938, ou aproximadamente 93,8% de chance de classificar corretamente uma instância positiva em comparação com uma negativa. Outro fator importante para a avaliação do modelo foi a acurácia de 80%, adequada para as condições observadas, mas que pode ser melhorada à medida que a base de dados também aumenta. Dito isto, é importante ressaltar que durante todo o período de coleta de dados nenhuma pessoa com mobilidade reduzida foi detectada; no entanto, a rede neural é capaz de detectar com precisão as pessoas nessas condições, conforme demonstra a figura 17, que foi realizada em um ambiente controlado devido à falta de amostras no ambiente real.

Figura 17 – Detecção de mobilidade reduzida em ambiente controlado




Fonte: elaboração dos autores (2024).

É possível observar que o modelo reconhece duas pessoas e, além disso, reconhece uma pessoa com mobilidade reduzida simultaneamente, gerando três caixas delimitadoras.

Interface gráfica de usuário

Para realizar a interação entre os dados coletados e os usuários que a querem acessar, um aplicativo foi desenvolvido na interface *Flutterflow*, um site que possibilita a criação *low-code* de aplicativos para celulares e computadores.


Figura 18 - Tela inicial do aplicativo desenvolvido em *Flutterflow*



Fonte: elaboração dos autores (2024).

Para que o aplicativo pudesse ler corretamente os valores registrados no *DynamoDB*, uma rotina foi criada no AWS Lambda para extrair todos os valores armazenados em formato *.json*. Na sequência, uma API (*Application Programming Interface*), criada no AWS API Gateway, automatiza o processo de extração; a URL da API gerada foi inserida no *flutterflow* e é executada por meio de uma *API Call*, atualizando a base periodicamente. Por fim, ações condicionais permitem que os valores sejam atualizados toda vez que um timer interno seja zerado dentro do aplicativo e possibilitando notificações de pessoas com mobilidade reduzida. A figura 19 exemplifica o que é visto pelo usuário.

Figura 19 – Dados apresentados aos usuários.



Fonte: elaboração dos autores (2024)

Considerações finais

É possível determinar que o modelo adotado é capaz de reconhecer com alto grau de precisão as classes de pessoas e pessoas com mobilidade reduzida em tempo real, armazenando instantaneamente todos os dados coletados em um banco *NoSQL* e possibilitando a predição do fluxo de pessoas baseada em diferentes horários e dias por meio de análise detalhada dos dados, viabilizando a visualização de mapas de calor, padrões temporais e notificações de assistência para pessoas com mobilidade reduzida.

No entanto, é importante salientar como a limitação de hardware influencia negativamente a solução como um todo; ao se considerar fatores como escalabilidade, o *Raspberry 4* não consegue atender a demanda de maneira eficaz; isso ocorre devido ao seu processamento de memória RAM, que impede que ele detecte pessoas em quantidades acima de 30 Ids únicos simultaneamente, sendo, neste caso, necessária uma GPU dedicada apenas para a detecção das pessoas no campus, possibilitando o maior aproveitamento da arquitetura aqui proposta.

Ademais, uma vez que a arquitetura não depende de etapas adicionais, é notável o seu potencial de escalabilidade para todo o campus da Universidade Presbiteriana Mackenzie, visto que o modelo adotado demonstrou uma alta taxa de acurácia, reforçando sua capacidade de contribuir significativamente com insights valiosos a respeito dos padrões de comportamento dos estudantes bem como da presença de pessoas com necessidades especiais. Para trabalhos futuros, recomenda-se o foco na escalabilidade do projeto, focando em capacidade de processamento e entrega de informações aos usuários por meio do monitoramento em tempo real e em larga escala do campus, possibilitando maiores insights e aplicando

um maior volume de dados, sendo possível acrescentar, por exemplo, variáveis de diferentes locais no campus, horários de aulas e grades de horários para cada curso a fim de aumentar a precisão das previsões.

Referências

- ALVES, G. Detecção de Objetos com YOLO – Uma abordagem moderna. Disponível em: <https://iaexpert.academy/2020/10/13/deteccao-de-objetos-com-yolo-uma-abordagem-moderna>. Acesso em: 20 abr. 2024.
- BERTAGLIA, R. Acessibilidade: exemplos, tipos e como se enquadrar às normas?, 2022. Disponível em: <https://www.handtalk.me/br/blog/acessibilidade-exemplos/>. Acesso em: 4 out. 2023.
- BRASIL. LEI Nº 13.005, de 25 de junho de 2014. Aprova o Plano Nacional de Educação - PNE e dá outras providências. **Diário Oficial da União** - Brasília, DF, p. 1, 26 jun. 2014. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2014/lei/l13005.htm. Acesso em: 4 out. 2023.
- BRASIL. Decreto nº 6.949, de 25 de agosto de 2009. Decreta a Convenção Internacional sobre os Direitos das Pessoas com Deficiência e seu Protocolo Facultativo. **Diário Oficial da União** - Brasília, DF, p. 3, 26 ago. 2009. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2014/lei/l13005.htm. Acesso em: 21 abr. 2024.
- CHUA, L. O.; ROSKA, T. The CNN paradigm. **IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications**, v. 40, n. 3, p. 147-156, mar. 1993. doi: 10.1109/81.222795.
- CONSELHO NACIONAL DO MINISTÉRIO PÚBLICO. Acessibilidade. Disponível em: <https://www.cnmp.mp.br/portal/acessibilidade>. Acesso em: 20 abr. 2024.
- CONSELHO UNIVERSITÁRIO DA UNIVERSIDADE PRESBITERIANA MACKENZIE (CONSU). Resolução re-consu-014/2022 de 01 dezembro de 2022. Disponível em: https://www.mackenzie.br/fileadmin/ARQUIVOS/Public/1-mackenzie/universidade/pro-reitoria/pesquisa-e-pos-graduacao/coordenadoria-de-pesquisa/comites-de-etica-em-pesquisa/2018/humanos/Res_CONSU_014_2022_-_Alteracao_do_Regimento_do_Comite_de_Etica_em_Pesquisa_Envolvendo_Seres_Humanos_CONSU_473_M7_Republic_Assinada-3.pdf.
- DIRETORIA DE ESTATÍSTICAS EDUCACIONAIS. **Censo da Educação Superior 2021** Notas Estatísticas. Disponível em: https://download.inep.gov.br/publicacoes/institucionais/estatisticas_e_indicadores/notas_estatisticas_censo_da_educacao_superior_2021.pdf. Acesso em: 4 out. 2023.
- EDUCAÇÃO, S. Acesso ao ensino superior no Brasil: veja um panorama geral! Blog Saraiva Educação, 2020. Disponível em: <https://blog.saraivaeducacao.com.br/acesso-ao-ensino-superior/>. Acesso em: 4 out. 2023.
- FACELI, K.; LORENA, A. C.; GAMA, J.; et al. **Inteligência Artificial** - Uma Abordagem de Aprendizado de Máquina. Rio de Janeiro: Grupo GEN, 2021. E-book. ISBN 9788521637509. Disponível em: <https://app.minhabiblioteca.com.br/#/books/9788521637509/>. Acesso em: 20 abr. 2024.
- FERRAZ, Junior. Educação superior no Brasil é historicamente limitada e necessita de políticas públicas de acesso, 2021. Disponível em: <https://jornal.usp.br/atualidades/formacao-na-educacao-superior-nao-podeprescindir-de-politica-de-ciencia-tecnologia-e-inovacao/>. Acesso em: 4 out. 2023.
- FRAGA-LAMAS, P.; CELAYA-ECHARRI, M.; LOPEZ-ITURRI, P.; CASTEDO, L.; et al. Design and Experimental Validation of a LoRaWAN Fog Computing Based Architecture for IoT Enabled Smart Campus Applications. **Sensors**, 2019, 19, 3287. Acesso em: 17 abr. 2024.
- GIRSHICK, R. et al. Region-Based Convolutional Networks for Accurate Object Detection and Segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 38, n. 1, p. 142-158, 1 jan. 2016. doi: 10.1109/TPAMI.2015.2437384.

HAYKIN, S. **Redes Neurais**: Princípios e Prática. Porto Alegre, RS: Grupo A, 2007. E-book. ISBN 9788577800865. Disponível em: <https://app.minhabiblioteca.com.br/#/books/9788577800865/>. Acesso em: 10 fev. 2024.

MINISTÉRIO DA EDUCAÇÃO. Plano Nacional de Educação - PNE. Disponível em: <https://pne.mec.gov.br/>. Acesso em: 4 out. 2023.

MIRANDA, A. et al. Usando Redes Neurais Artificiais e Regressão Logística na Predição da Hepatite A. Disponível em: <https://www.scielo.org/pdf/rbepid/v8n2/04.pdf>. Acesso em: 9 nov. 2023.

REDMON, J. et al. You only look once: Unified, real-time object detection. 2016 **IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**, 2016. Acesso em: 20 abr. 2024.

ROQUE, A. Psicologia Conexionista: do neurônio biológico ao neurônio das redes neurais artificiais. Disponível em: <http://sisne.org/Disciplinas/PosGrad/PsicoConex/aula3.pdf>. Acesso em: 18 abr. 2024.

ULTRALYTICS. **Guia**: Raspberry Pi para YOLO. Disponível em: <https://docs.ultralytics.com/pt/guides/raspberry-pi/>. Acesso em: 14 out. 2024.

ULTRALYTICS. **Guia**: Desfoque de Objetos com YOLO. Disponível em: <https://docs.ultralytics.com/guides/object-blurring/?h=blur>. Acesso em: 14 out. 2024.

VINA, A. YOLOv8 Turns One: Um ano de avanços e inovações. Disponível em: <https://www.ultralytics.com/pt/blog/ultralytics-yolov8-turns-one-a-year-of-breakthroughs-and-innovations>. Acesso em: 30 abr. 2024.