

TÉCNICAS PARA ESTIMAR A TAXA DE OCUPAÇÃO EM AMBIENTES INDOOR: UMA  
APLICAÇÃO EM SALA DE AULA

TECHNIQUES TO ESTIMATE THE OCCUPANCY RATE IN INDOOR ENVIRONMENTS: A  
CLASSROOM APPLICATION

João Pedro Milagres de Santana<sup>1, i</sup>

André Luis dos Santos<sup>2, ii</sup>

Caio Vinícius Ribeiro da Silva<sup>3, iii</sup>

Douglas da Serra Ogata<sup>4, iv</sup>

Data de submissão: (15/09/2022) Data de aprovação: (30/01/2023)

## RESUMO

Estimar a ocupação em ambientes fechados é um tópico muito estudado na área de *Smart Building* e pode ser utilizado para diversos fins, como garantir maior eficiência energética do ambiente e aumentar o conforto dos ocupantes. Durante o cenário pandêmico causado pela Covid-19, limitar a ocupação em ambientes fechados foi um dos principais fatores para evitar a proliferação do vírus e essa foi a maior motivação para a realização desse trabalho. O objetivo foi estudar quais técnicas são utilizadas para estimar a ocupação em ambientes fechados e construir dois dispositivos IoT distintos entre si, um que utiliza um algoritmo de aprendizado de máquina para prever a ocupação do ambiente em função de suas condições ambientais, e o outro que faz a inferência na ocupação do ambiente em função das requisições de sondagem dos aparelhos celulares. Ambas as aplicações foram feitas em um ambiente escolar e os resultados demonstraram que os protótipos cumprem o papel que lhes são propostos, apesar de exigirem melhorias para uma aplicação mais precisa.

**Palavras-chave:** edifícios inteligentes; internet das coisas; redes sem fio.

## ABSTRACT

Estimating indoor environment occupancy is a highly studied topic in the Smart Building area and can be used for various purposes, such as ensuring a greater energetic efficiency in the environment and increasing occupant's comfort. During the pandemic scenario caused by Covid-19, limiting the occupation in closed environments was one of the main factors to prevent the virus proliferation, and this was the greatest motivation for carrying out this paper. The aim is to study which techniques are used to estimate the occupancy in closed environments and then to build two IoT devices distinct from each other, one which uses a machine learning algorithm to predict the environment's occupancy based on its environmental conditions, and the other one that makes the inference in the occupation of

<sup>1</sup> Pós-Graduado em Internet das Coisas na Faculdade SENAI de Tecnologia "Mariano Ferraz". E-mail: jpedro.santana@outlook.com

<sup>2</sup> Docente da Faculdade SENAI de Tecnologia "Mariano Ferraz". E-mail: andre.lsantos@sp.senai.br

<sup>3</sup> Docente da Faculdade SENAI de Tecnologia "Mariano Ferraz". E-mail: caio.silva@sp.senai.br

<sup>4</sup> Docente da Faculdade SENAI de Tecnologia "Mariano Ferraz". E-mail: douglas.ogata@sp.senai.br

the environment in function of the probe requests of smartphones. Both solutions were applied in a school environment, and the results presented that the applications fulfill the role they are proposed to, despite requiring improvements for a more accurate application.

**Keywords:** smart buildings; internet of things; wireless.

## 1 INTRODUÇÃO

Ambientes com acesso controlado permitem, com maior facilidade, que seja estimada sua taxa ocupação se comparados com aqueles que não possuem esse tipo de acesso. Isso fica ainda mais difícil quando esses ambientes apresentam um grande fluxo de pessoas, como leitos de hospitais, praças de alimentação, supermercados e, analisando o transporte público, tanto em estações quanto no interior de ônibus e metrô.

O controle na ocupação de ambientes fechados é um assunto bastante recorrente na área de *Smart Buildings* que, segundo Vilela (2020), é a combinação de automação com aplicações de aprendizado de máquina em edifícios residenciais e comerciais. O controle na ocupação nesses ambientes é importante na identificação de padrões no interior do edifício, garantindo maior conforto e segurança para as pessoas e proporcionando maior suporte para tomadas de decisões em situações de emergências (SAHA, et al., 2019). Ainda, de acordo com Saha et al. (2019) também explica que uma característica para manter o conforto das pessoas dentro do edifício é por meio de mecanismos que garantam uma boa qualidade do ar em seu interior, e que estimar a ocupação em um ambiente também é importante para identificar intrusos ou atividades suspeitas.

O que é altamente estudado nesse campo de estudo é a busca de uma maior eficiência energética a partir do controle de sistemas de Aquecimento, Ventilação e Ar-Condicionado (AVAC) em função da quantidade de pessoas presente em um ambiente. Um exemplo disso pode ser visto no estudo de Brooks, et al. (2014) que obteve um ganho energético de 37% com o monitoramento de variáveis ambientais (temperatura, umidade e CO<sub>2</sub>) para o controle de sistemas AVAC em um prédio comercial no campus da Universidade da Flórida.

O surgimento da pandemia causada pela COVID-19 trouxe à tona o debate sobre o que são serviços essenciais e quais tipos de estabelecimentos podem funcionar conforme normas especiais relacionadas a redução de sua taxa de ocupação, essas normas foram estabelecidas por cada estado e município. Um exemplo pode ser visto na Figura 1 referente às normas de restrição para o setor de Serviços conforme o Plano São Paulo para o combate a pandemia do coronavírus.

Figura 1 – Regras para o setor de Serviços

SERVIÇOS	
<b>Fase 1</b>	<ul style="list-style-type: none"> <li>• Atividade não permitida.</li> </ul>
<b>Fase 2</b>	<ul style="list-style-type: none"> <li>• Capacidade 40% limitada</li> <li>• Horário reduzido (8 horas): Após as 6h e antes das 20h</li> <li>• Adoção dos protocolos geral e setorial específicos</li> </ul>
<b>Fase 3</b>	<ul style="list-style-type: none"> <li>• Capacidade 40% limitada</li> <li>• Horário reduzido (10 horas): Após as 6h e antes das 20h</li> <li>• Adoção dos protocolos geral e setorial específicos</li> </ul>
<b>Fase 4</b>	<ul style="list-style-type: none"> <li>• Capacidade 60% limitada</li> <li>• Horário reduzido (12 horas)</li> <li>• Adoção dos protocolos geral e setorial específicos</li> </ul>

Fonte: GOVERNO (2022)

Outro fator preocupante em relação a COVID-19 está relacionado com as diversas linhagens de variantes que surgiram nos últimos dois anos, cada variante possui algumas características diferentes da linhagem original do vírus, como maior variabilidade de transmissão ou até mesmo na letalidade do vírus em si, e as variantes mais preocupantes são mapeadas como *Variant of Concern* (VOC) (WORLD HEALTH ORGANIZATION, 2022). Uma VOC que causou muito impacto no Brasil foi a P.1, que posteriormente recebeu o nome de *Gamma*, essa variante esteve presente em muitos estados brasileiros durante uma alta demanda do sistema de saúde durante a última quinzena de fevereiro de 2021, gerando aumento nas taxas de ocupação de leitos gerais e unidades de terapia intensiva (UTI) até o seu limite, fazendo com que muitas pessoas ficassem sem atendimentos tanto na rede pública quanto privada (MARQUITTI, et al., 2021).

Este trabalho tem como objetivo estudar formas de estimar a taxa de ocupação em ambientes fechados, de forma a auxiliar uma melhor tomada de decisão e contribuir para evitar a proliferação descontrolada do vírus e/ou outras das aplicações descritas anteriormente. Foram desenvolvidos dois dispositivos de baixo custo, aplicando duas técnicas diferentes, buscando estimar a ocupação de uma sala de aula. A primeira técnica utilizada é por meio da coleta de variáveis ambientais para estimar a ocupação na sala de aula, e a segunda é a partir da requisição de sondagem dos aparelhos celulares com a finalidade de estimar quantas pessoas estão presentes no local. Após feita toda a aplicação e análise dos dados, são identificadas as vantagens e desvantagens de cada dispositivo quando comparados entre si, e se eles podem ser aplicados em outros tipos de ambientes.

O restante do trabalho está organizado da seguinte forma. Na seção 2 apresenta uma revisão da bibliografia relacionada a estimativa de ocupação em edifícios inteligentes. A seção 3 tem como principal assunto o Protocolo de Comunicação IEEE 802.11, o intuito é mostrar o seu funcionamento, principalmente para a contagem de pessoas utilizando redes wi-fi. Na seção 4, é demonstrado o desenvolvimento dos dois modelos criados e aplicados em uma sala

de aula. Depois, na seção seguinte, são discutidos os resultados e posteriormente as considerações finais.

## 2 DETECÇÃO DA OCUPAÇÃO EM AMBIENTES FECHADOS

Para detecção da ocupação de ambiente fechados, destacam-se, na literatura, as abordagens através de câmera, visão infravermelha, redes sem fio e sensores ambientes.

### 2.1 Câmera

Determinar a ocupação por meio de câmeras é uma alternativa cara, porém muito eficiente, visto que é possível aplicar diferentes métodos de medição para se alcançar diversos resultados com uma alta precisão, como a quantidade de pessoas, a posição onde elas se encontram e até mesmo identificar os indivíduos presentes (AHMAD, et al., 2018).

A utilização de câmeras também pode ser usada como auxílio na validação de variáveis para algoritmos supervisionados. Um exemplo pode ser visto no estudo de Jiang, et al. (2016) que utilizou duas câmeras para monitorar a entrada e saída das pessoas em um escritório. Já no estudo de Canadeto e Feldheim (2016) foi utilizada uma câmera digital no interior do local de estudo para se ter o número exato de ocupantes e fazer a validação com o seu modelo de classificação supervisionada.

A principal desvantagem na utilização desse método está relacionada com questões de privacidade em relação aos usuários. Esse método também possui um custo maior em relação a outras abordagens, e é uma alternativa muito dependente da iluminação do local.

### 2.2 PIR

Um sensor *Passive Infra-Red* (PIR) é um dispositivo que consegue detectar radiações infravermelha emitidos por humanos quando estão nas proximidades do sensor (VILELA, 2020). As principais aplicações utilizando esse sensor se dão no controle automático de iluminação. E esse tipo de sensor possui como principal característica o seu baixo custo de aquisição, baixo consumo de energia e tem uma grande facilidade de implementação e de operação em aplicações em tempo real (PRIYADARSHINI; MEHRA, 2015).

Vilela (2020) explica que a maior desvantagem nesse tipo de sensor se dá por ele sofrer de medições “falso negativas”. Esse tipo de leitura está relacionado com as características do sensor que apenas reconhece o movimento da pessoa, ou seja, se um ocupante estiver estático ele não será reconhecido pelo sensor. Caso muitas pessoas estejam juntas, esse sensor não conseguirá identificar exatamente a quantidade de pessoas, mostrando que um sensor PIR é mais indicado para determinar se um ambiente está ocupado, e não determinar quantas pessoas estão presentes (JIANG, et al., 2016).

### 2.3 Wi-Fi

Nos dias atuais, com o grande avanço da tecnologia os aparelhos celulares fazem parte da vida de todo ser humano, são nesses aparelhos que as pessoas fazem diversas tarefas do dia a dia, como o pagamento de contas, comunicação com outras pessoas, e diversas formas de entretenimento. A utilização do método wi-fi se torna viável pois praticamente todo edifício comercial já possui uma infraestrutura pronta para a aplicação desse método (ZOU, et al., 2017). Na contagem de pessoas por essa técnica, assume-se que cada dispositivo celular

equivale a uma pessoa, e esses dispositivos podem ser identificados pelo seu endereço MAC ou pela *Received Signal Strength Indicator* (RSSI) (SUN; ZHAO; ZHOU, 2020).

As limitações dessa abordagem estão relacionadas principalmente com a imprecisão dos dados caso um usuário não esteja portando um aparelho celular, ou que ele possua mais de um aparelho consigo. A opção pela utilização de redes 4G ao invés da rede Wi-Fi também é um problema, e com o avanço da tecnologia 5G os ocupantes de um ambiente fechado possivelmente vão tender a não utilizar a rede wi-fi disponível (SUN; ZHAO; ZHOU, 2020).

Outro ponto de atenção é que por questões de preservar a privacidade dos usuários, as empresas desenvolvedoras de sistemas operacionais estão implementando uma funcionalidade de randomizar o endereço MAC dos dispositivos enquanto eles não estão associados com nenhum ponto de acesso (VANHOEF, et al., 2016).

## 2.4 Sensores ambientais

Uma técnica muito aplicada para se estimar a ocupação em um ambiente é por meio da utilização de sensores que façam a medição de variáveis ambientais, como temperatura, umidade relativa, luminosidade e a concentração de dióxido de carbono (CO<sub>2</sub>) no ar.

A concentração de CO<sub>2</sub> é a variável que mais está relacionada com a presença ou não de pessoas em um local, visto que humanos constantemente exalam esse gás no processo de respiração (SZCZUREK; MACIEJEWSKA; PIETRUCHA, 2017). A maior vantagem desse sensor é que a medição é feita de forma não intrusiva, porém o principal ponto negativo é o seu baixo desempenho para aplicações em tempo real devido a lenta velocidade que os gases levam para se misturarem. Outros problemas podem afetar na leitura do sensor, como a sua imprecisão, aberturas repentinas de portas e janelas, a posição do sensor e interferências causadas pelo funcionamento dos sistemas de ventilação (SZCZUREK; MACIEJEWSKA; PIETRUCHA, 2017). Para lidar com esses problemas, é possível utilizar de modelos estatísticos com técnicas de aprendizado de máquina para estimar a ocupação em um ambiente fechado (ZURAIMI, 2017).

A umidade relativa do ar é o segundo parâmetro que mais está associado com a ocupação de um local. No estudo de Canadeto e Feldheim (2016) foi observado constantemente um padrão entre as curvas de concentração de CO<sub>2</sub> e umidade relativa, o que faz sentido pois a água também faz parte do processo de respiração humana.

Das variáveis mencionadas, luminosidade e temperatura são as que menos estão relacionadas com a ocupação de um ambiente. Dong e Andrews (2009) explicam que há uma variação mínima de temperatura em um ambiente interno sem janelas, e que grandes alterações de temperatura (1 °C) em um curto período de tempo (10 minutos) estão relacionadas com atividades que demandam maior quantidade de energia, como a inicialização de sistemas AVAC ou concentração de um grande número de pessoas.

No geral sensores ambientais possuem um baixo custo de aquisição e são fáceis de implementar, sua utilização é muito eficiente para identificar a ocupação de pessoas em um ambiente, porém por serem passíveis a ruídos e interferências externas que influenciam em sua medição, demonstram limitações para estimar a quantidade de pessoas que se encontram em um local.

### 3 PROTOCOLO IEEE 802.11

Atualmente as *Wireless Local Area Network* (WLAN) são redes sem fio que facilitam o acesso à internet em locais públicos, residenciais e privados. Essas redes possuem diversos tipos de padrões, como as redes de telefonia celular (como o GSM), o Bluetooth (IEEE 802.15) e a mais popular de todas, o wifi (IEEE 802.11) (CARISSIMI; ROCHOL; GRANVILLE, 2009).


O padrão IEEE 802.11 foi desenvolvido pelo Instituto de Engenheiros Elétricos e Eletrônicos (IEEE) e ficou popularmente conhecido como wifi, tendo como principal proposta conectar em uma mesma rede local diversos dispositivos sem fio, como celulares, impressoras, notebooks, televisões, entre outros (OLIVEIRA, 2017).

Há diversos padrões apresentados para o protocolo 802.11, como as versões (a/b/g/n/c) e, dependendo de sua versão, a frequência em que o protocolo opera pode ser de 2,4 GHz ou 5 GHz (OLIVEIRA, 2017). De acordo com Loureiro, et al. (2014) a diferença entre os padrões IEEE 802.11a, 802.11b, 802.11g, 802.11n e 802.11c se dá principalmente pela velocidade máxima de transmissão e no seu tipo de sinalização.

A frequência de 2,4 GHz possui 14 canais, dependendo do país de origem. No Brasil, o canal 14 não existe, conforme Loureiro, et al. (2014), e normalmente os dispositivos IoT apenas suportam a frequência de 2,4 GHz com 11 canais de comunicação nas versões “b” e “g” do protocolo (OLIVEIRA, 2017). Os canais apresentam sobreposição de sua frequência com uma largura de banda de 22 MHz, apenas os canais 1, 6, 11 e 14 não se sobrepõem, de acordo com Loureiro, et al. (2014), dessa forma esses canais são os mais recomendados para uso. A Figura 2 apresenta um exemplo a respeito da sobreposição dos canais no padrão IEEE 802.11g.

O principal componente para a comunicação em redes wifi é conhecido como conjunto básico de serviço (BSS) que pode conter um ou mais dispositivos sem fio e a presença de uma estação base central chamada de *Access Point* (AP) (KUROSE; ROSS, 2013). Esse padrão de comunicação é conhecido como infraestrutura fixa, justamente pela presença de um AP, que tem a finalidade de concentrar toda a comunicação na rede, ou seja, ele identifica o destinatário e repassa a comunicação, conforme Oliveira (2017), isso garante a interligação da rede wifi com redes cabeadas e outras redes sem fio de forma simultânea, possibilitando que dispositivos móveis fiquem interligados em uma infraestrutura de rede fixa, formando um sistema de distribuição (CARISSIMI; ROCHOL; GRANVILLE, 2009).

Figura 2 – Sobreposição dos Canais no Padrão IEEE 802.11g



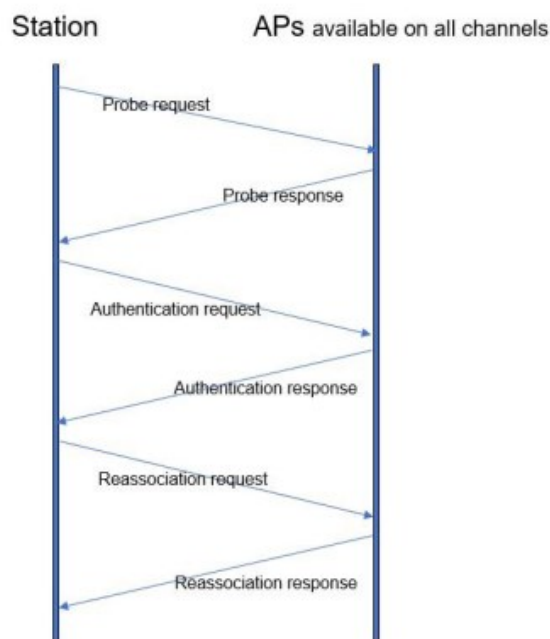
Fonte: Loureiro et al. (2014, p.39)

Em uma rede de infraestrutura fixa, para que um dispositivo possa enviar e receber dados, é necessário que ele se associe a um AP. Cada AP possui um nome próprio, conhecido como *Service Set Identifier* (SSID) e deve ser configurado em um dos 11 canais permitidos, lembrando que no Brasil recomenda-se a utilização dos canais 1, 6 e 11. O dispositivo sem fio por sua vez faz a varredura desses 11 canais na procura de quadros de sinalização que são

enviados periodicamente pelo AP, esses quadros incluem o seu SSID e endereço MAC (do inglês *Media Access Control*), que é um identificador único de 6 bytes do ponto de acesso. Após a varredura de possíveis APs a serem associados, o usuário pode escolher um deles para finalizar a autenticação, que pode exigir informações como nome de usuário e senha, ou até mesmo nenhuma solicitação (redes abertas) (KUROSE; ROSS, 2013; CARISSIMI; ROCHOL; GRANVILLE, 2009). Os autores Kurose e Ross (2013) mencionam que esse processo de varredura dos canais e a espera dos quadros de autenticação dos pontos de acesso é chamado de varredura passiva. A varredura ativa é quando um dispositivo sem fio envia requisições de sondagem que será recebido pelos APs dentro de sua área de alcance, estes por sua vez enviam um quadro de resposta indicando a sua presença, após isso o dispositivo pode escolher com qual ponto de acesso disponível ele quer se associar, esse processo pode ser visto na Figura 3.

Uma requisição de sondagem contém o endereço MAC do dispositivo sem fio que está fazendo a verificação de possíveis APs em suas imediações (HIDAYAT; TERABE; YAGINUMA, 2020). Essas requisições são enviadas em múltiplos canais e sua frequência varia de acordo com o fabricante do dispositivo e sistema operacional (LI, et al., 2020).

Figura 3 – Etapas de conexão em uma varredura ativa



Fonte: Li, et al., (2020, p. 4)

A IEEE distribui os endereços MAC de forma única para cada fabricante conhecida como *Organizationally Unique Identifier* (OUI), essa identificação é feita pelos primeiros 3 bytes do endereço.

A captura das requisições de sondagem pode ser feita com a utilização de um adaptador de rede no modo monitor, isso permite que o tráfego entre o ponto de acesso e os dispositivos seja monitorado e que o endereço MAC do transmissor seja obtido (SUN, et al., 2017; LI, et al., 2020). Como o endereço MAC do dispositivo transmissor é único e o seu fabricante pode ser identificado, é possível deduzir qual o tipo de equipamento o dispositivo

é, como um celular, ou seja, a identificação de uma pessoa em um ambiente fechado consiste em inferir que um telefone móvel foi identificado nesse local.

## 4 DESENVOLVIMENTO

Foram construídos dois protótipos, um deles baseado em sensores ambientais e outro em redes sem fio. Estes foram instalados em salas de uma instituição de ensino e as informações coletadas foram analisadas.


### 4.1 Protótipo 1 – sensores ambientais

O primeiro protótipo consiste em utilizar sensores capazes de mensurar dados do ambiente em conjunto com o ESP32. O ESP32 é um microcontrolador muito utilizado para o desenvolvimento de aplicações IoT, pois possui diversos recursos de conectividade, como wifi e Bluetooth integrado, além de possuir diversos pinos de entrada e saída em uma única placa (BERTOLETI, 2019). É possível encontrar diversos modelos de kits contendo esse microcontrolador e, neste projeto, foi utilizado o modelo Wemos Lolin ESP32 OLED. Nele foram conectados os sensores DHT22 e CCS811.

O sensor DHT22 é capaz de medir a temperatura e umidade relativa do ar. Segundo o datasheet do fabricante, a faixa de medição de temperatura vai de  $-40^{\circ}\text{C}$  até  $80^{\circ}\text{C}$  e a de umidade vai de 0 até 100%, com precisão de  $0,5^{\circ}\text{C}$  e 2%, respectivamente, sendo uma ótima opção de custo-benefício.

Para medir a concentração de  $\text{CO}_2$ , foi utilizado o sensor CCS811 que é muito utilizado para monitoramento da qualidade do ar. Conforme o datasheet do fabricante, a saída correspondente a análise de  $\text{CO}_2$  varia entre 400 ppm e 8192 ppm. O desenvolvimento da aplicação foi feito utilizando a IDE Arduino, que é bastante popular entre estudantes e entusiastas de microeletrônica. A Figura 4 mostra esquemático do protótipo com a ligação dos dois sensores.

Figura 4 – Protótipo 1 - Sensores Ambientais



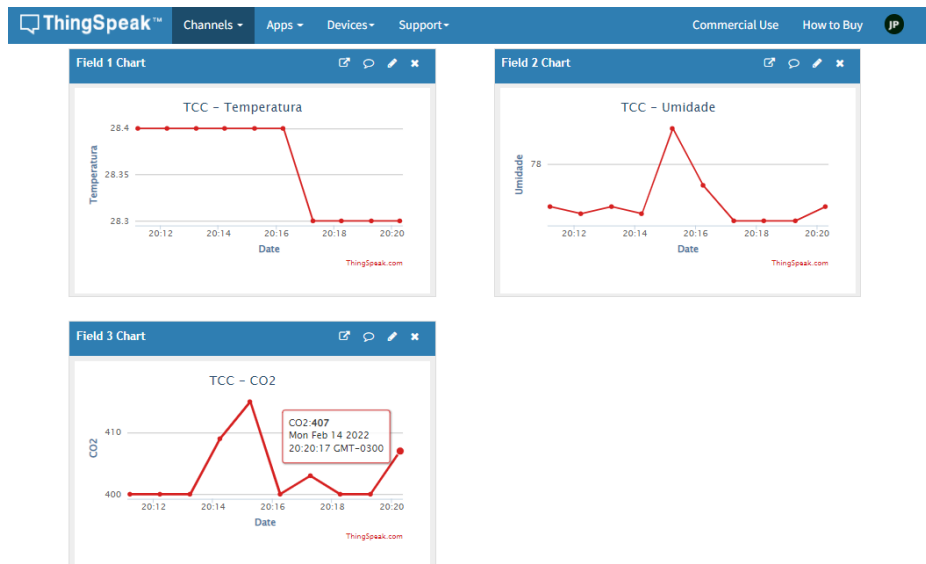
Fonte: Elaborado pelo autor (2022)

Os dados dos sensores são lidos e enviados periodicamente para o *ThingSpeak*, que é um serviço em nuvem que possibilita o registro e visualização gráfica de dados enviados por



dispositivos IoT em tempo real (OLIVEIRA, 2017; THINGSPEAK, 2022). A plataforma também possui muitos outros recursos que agregam valor na gestão e monitoramento remoto das aplicações.

Figura 5 – Visualização dos dados no ThingSpeak



Fonte: Elaborado pelo autor (2021)

Após o envio dos dados durante a fase de coleta, será extraído um arquivo em formato csv da própria plataforma, e a partir disso serão feitas as análises estatísticas e a criação do modelo de predição.

## 4.2 Protótipo 2 – redes sem fio

O protótipo 2 foi construído utilizando o Raspberry Pi modelo 3B, que possui 1 GB de memória RAM, processador de 1,2 GHz de 64 bits, 4 entradas USB, 40 pinos de entrada e saída, saída HDMI e wifi e Bluetooth inclusos. Oliveira (2017) menciona que uma grande vantagem do Raspberry Pi é de possuir o sistema Linux incluso, pois esse sistema operacional possui disponibilidade para diversos ambientes de desenvolvimento, sistemas de banco de dados e protocolos de rede, se tornando uma poderosa ferramenta para aplicações IoT de diversos segmentos.

Pela interface de rede nativa do Raspberry Pi não suportar o modo monitor, foi utilizado o adaptador wifi D-Link DWA 131 Nano para esse propósito.

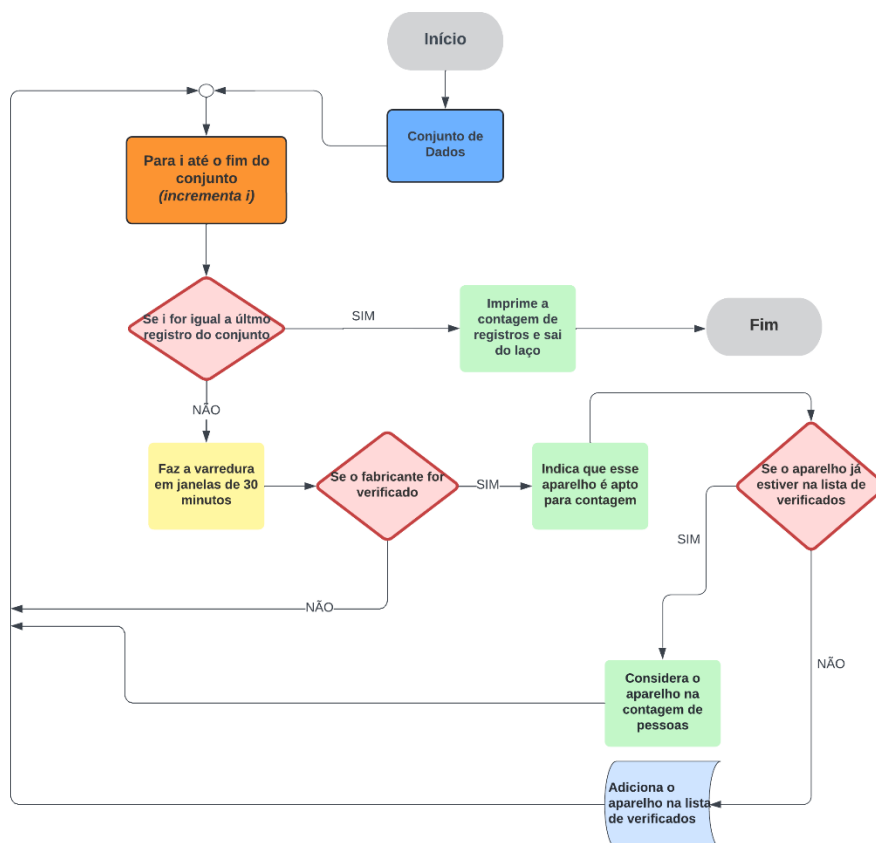
Com a interface de rede no modo monitor, a captura das requisições de sondagem é feita utilizando o analisador de protocolo de rede TShark, que permite capturar pacotes de rede através de linha de comando e aplicações de filtros para personalizar o tipo de captura desejada (CUNCHE, 2013; WIRESHARK, 2021). O TShark possui nativamente um recurso que permite a decodificação do endereço MAC do dispositivo para o seu devido fabricante, isso é feito a partir da integração da ferramenta com a base de dados de fabricante do Wireshark (do inglês, Wireshark Database Manufacturer), esse recurso permite economizar esforços, pois evita o desenvolvimento de scripts para desvendar o fabricante.

Durante a etapa de coleta dos dados, foi desenvolvido um script bash que utiliza o Tshark para gerar um arquivo binário pcapng a cada hora, esses arquivos posteriormente são convertidos para formato csv e usados para as análises estatísticas e tratamento dos dados.

Em sua pesquisa, Nunes (2019) utilizou dados sobre o mercado brasileiro de telefones celulares para estabelecer uma lista de fabricantes a serem considerados durante a análise dos dados e descartar aqueles que não se enquadram. Para esse trabalho será utilizada a mesma abordagem, considerando as principais empresas que produziram telefones celulares durante todo o ano de 2021 (STATCOUNTER, 2021). Esses fabricantes são utilizados para validar os aparelhos celulares verificados durante o algoritmo de contagem, detalhado na Figura 6.

O algoritmo de contagem faz a varredura de todo o conjunto de dados em janelas de 30 minutos, em cada iteração no laço de repetição ele verifica se o fabricante do aparelho está na lista de fabricantes de aparelhos celulares validados para a contagem. Caso esse aparelho tenha um fabricante válido, o algoritmo faz uma outra verificação que tem o objetivo de checar se o aparelho já foi detectado alguma outra vez dentro da janela de tempo, e em caso positivo, esse aparelho é considerado como uma pessoa nesse intervalo de tempo.

Figura 6 – Algoritmo de contagem



Fonte: Elaborado pelo autor (2022)

### 4.3 Custo do projeto

Ambas as aplicações possuem um baixo custo de aquisição, o item mais custoso de se adquirir foi o Raspberry Pi, que custou quase a metade do valor total de ambos os protótipos. O detalhamento do investimento feito em cada item pode ser visto no Quadro 1.

Quadro 1 – Investimento total do Projeto

MAPEAMENTO DE AQUISIÇÕES (USD)				
N	PRODUTO	ORÇAMENTO	ORÇAMENTO	CUSTO
		APLICAÇÃO 1	APLICAÇÃO 2	Custo da aquisição
1	Sensor de Qualidade do Ar - CO2 e TVOC - CCS811	\$ 20,74	-	\$ 20,74
2	Módulo DHT22 - Sensor de Temperatura	\$ 7,50	-	\$ 7,50
3	ESP32	\$ 15,07	-	\$ 15,07
4	Fonte para Raspberry Pi	-	\$ 6,21	\$ 6,21
5	Adaptador D-Link DWA 131 Nano	-	\$ 17,80	\$ 17,80
6	Raspberry Pi 3 - Modelo B	-	\$ 52,09	\$ 52,09
	<b>TOTAL</b>	\$ 43,31	\$ 76,10	<b>\$ 119,41</b>

Fonte: Elaborado pelo autor

A representação esquemática de ambos os protótipos é bem similar. A proposta é ter um controlador como ponto central da aplicação e que seja capaz de fazer a leitura dos dados com as ferramentas de software ou sensores adequados, e que posteriormente gerem uma saída para que seja analisada.

### 4.4 Detalhamento da implementação

Para estimar a ocupação de um ambiente fechado, os dois protótipos foram aplicados em uma instituição de ensino. A princípio foi decidido deixar os aparelhos operando durante uma sala de preparação de aula durante os dias 18 a 23 de março com o intuito de entender o comportamento dos protótipos e, se preciso, realizar ajustes necessários antes da aplicação prática. Essas constatações e eventuais ajustes são detalhados posteriormente nas seções de pré análise de cada protótipo.

A coleta de dados foi feita em uma sala de aula de 7,79 x 8,00 m com capacidade de ocupação máxima de 20 pessoas, a anotação real da ocupação desse ambiente foi feita entre os dias 16 e 21 de maio de 2022. Durante esse período foi solicitado que os professores anotassem a ocupação da sala de aula a cada 30 minutos. Essas anotações posteriormente foram adicionadas no conjunto de dados de ambos os protótipos para a análise dos resultados.

## 5 ANÁLISE DOS RESULTADOS


Os dados foram analisados utilizando a ferramenta *Google Colaboratory* em conjunto com a linguagem Python e suas diversas bibliotecas utilizadas para análise de dados.

### 5.1 Pré-análise: redes sem fio

Para facilitar na análise e com o intuito de identificar padrões, os dados foram analisados dividindo cada dia em quatro períodos de seis horas, que são: madrugada, manhã,

tarde e noite. O primeiro ponto interessante observado foi que durante a madrugada dos dias 18, 19 e 21 de março e durante todo o domingo dia 20 foram contabilizados registros de pessoas por meio das requisições de sondagem dos aparelhos celulares, o que não deveria ocorrer pois após às 23h não há mais tráfego de pessoas na instituição de ensino, assim como no domingo. Um exemplo pode ser visto na Figura 7.


Figura 7 – Contagem de pessoas nos dias 18 e 19 de março



Fonte: Elaborado pelo autor (2022)

Essas contabilizações provavelmente são de pessoas que estão nos arredores da instituição, ou até mesmo de edificações vizinhas. Para fazer essa verificação buscou-se observar a potência de sinal recebida (RSSI) para todos os aparelhos monitorados durante esse período, conforme exemplificado na Figura 8.


Figura 8 – RSSI dos aparelhos monitorados nos dias 19 e 20 de março



Fonte: Elaborado pelo autor (2022)

O RSSI para os dias mencionados variou entre -72 até -96 dBm e com isso pareceu razoável estabelecer um intervalo de corte para aceitar para contagem apenas aparelhos com RSSI acima de -72 dBm. Esse filtro eliminou com sucesso todos os registros que apareceram de madrugada e aos domingos, além de apresentar uma notável diferença na contagem com e sem filtro durante o dia, como apresentado na Figura 9.

Figura 9 – Contagem de pessoas com e sem filtro na tarde do dia 19 de março



Fonte: Elaborado pelo autor (2022)

Utilizar ou não o filtro por RSSI foi um grande dilema para esse trabalho, uma contagem sem o filtro acaba considerando muitos aparelhos, porém com o filtro pode acabar não considerando dados confiáveis para a análise, essa decisão foi tomada durante a análise final do modelo.

## 5.2 Análise: redes sem fio

Durante a análise dos dados coletados foram encontradas diversas dificuldades na observação das amostras. A primeira é definir o filtro ideal de RSSI dos dados, dependendo do limite de corte muitos dados se perdem ou são considerados na contagem, devido a esse problema foi adotado a consideração de todos os dados com RSSI acima de -85 dBm.

Outro problema foi não ter dados suficientes para todos os períodos de coleta, a maior parte dos dados se concentraram nos períodos da tarde e noite e como todos os horários de aula são diferentes entre si, foram considerados para a análise apenas os registros que tiveram a ocupação real anotada, ou seja, para esse conjunto de dados não foi feito nenhum processo de imputação ou estimativa dos dados reais.


O terceiro desafio na análise foi a dificuldade em estimar um valor preciso entre os dados observados com a contagem real de pessoas no ambiente, dessa forma foi adotada uma estratégia de discretizar os dados em intervalos de ocupação. A discretização consiste em transformar um atributo numérico em categórico em função de algum intervalo estabelecido no atributo, essa técnica é útil pois acaba reduzindo a quantidade de atributos, facilitando a análise dos dados (CASTRO; FERRARI, 2016). Tanto a contagem real de pessoas quanto a observada foram discretizadas da seguinte forma:

- de 0 a 5 pessoas foi considerado o valor **Vazio**;
- entre 6 e 10 pessoas, ocupação **Média**;
- entre 11 e 15 pessoas, ocupação **Alta**;
- Acima de 16 pessoas foi considerado que a sala está **Cheia**.

Mesmo discretizando as variáveis ainda se observaram um grande desbalanceamento dos dados quando comparamos a ocupação real com a observada. Um exemplo pode ser visto na Figura 10 que ilustra um comparativo entre as duas observações. É possível notar que o Raspberry Pi considerou aproximadamente 3600 registros indicando ocupação Cheia da sala, porém esse cenário não foi observado nenhuma vez na coleta real da ocupação. Há outras salas no entorno do ambiente de aplicação, e também salas com ocupação contínua que muito

provavelmente foram considerados na contagem. Esse cenário também pode ser levado em consideração quando observamos o status de ocupação Vazio da sala de aula, em que foram contabilizados 83 registros de ocupação vazia contra 2321 observações reais.

**Figura 10 – Contagem Ocupação Prevista x Real**



Fonte: Elaborado pelo autor (2022)

A métrica utilizada para avaliar o protótipo foi calcular a acurácia, que corresponde a taxa de acerto do modelo (FACELI, et al., 2021). De acordo com Castro e Ferrari (2016) as métricas de desempenho podem ser separadas nas categorias de problemas binários (envolvendo duas classes) ou problemas multiclasse (envolvendo três ou mais classes), essa última que se enquadra com a categorização dos dados desse trabalho.

A acurácia em modelos multiclasse pode ser obtida a partir da matriz de confusão das classes, na Tabela 1, Castro e Ferrari (2016, p.164) explicam que:

O elemento  $C_{11}$  indica a quantidade de objetos da classe 1 que foram classificados como pertencentes à classe 1;  $C_{12}$  indica a quantidade de objetos da classe 1 que foram incorretamente classificados como pertencentes à classe 2; e assim por diante. Portanto, um bom classificador deve apresentar números maiores na diagonal principal e números pequenos, idealmente zero, fora dela.

**Tabela 1 – Matriz de Confusão para Múltiplas Classes**

		Classe predita			
		Classe 1	Classe 2	...	Classe n
Classe original	Classe 1	$C_{11}$	$C_{12}$	...	$C_{1n}$
	Classe 2	$C_{21}$	$C_{22}$	...	$C_{2n}$
	...	...	...	...	...
	Classe n	$C_{n1}$	$C_{n2}$	...	$C_{nn}$

Fonte: Castro; Ferrari, (2016, p. 164)

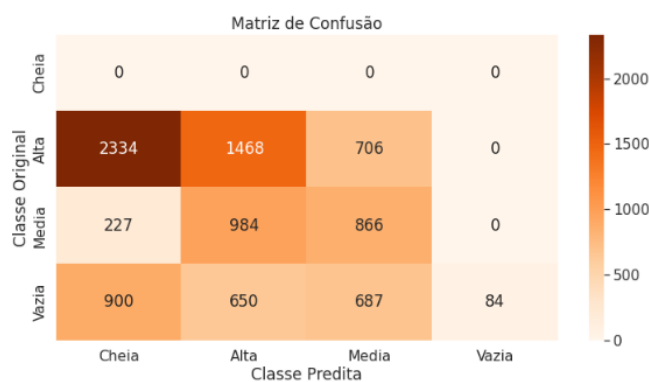
Castro e Ferrari (2016) ainda exemplificam que o cálculo da acurácia para modelos multiclasse é calculada a partir da matriz de confusão como visto na Equação 1, basicamente

consiste na soma da diagonal principal, dividido pela somatória de todos os valores da matriz. Quanto mais próximo de 1 for o resultado, maior será a acurácia do modelo.

$$ACC = \frac{\sum_{i=1}^n C_{ii}}{\sum_{i=1}^n \sum_{j=1}^n C_{ij}} \quad (1)$$

Retornando para a análise do protótipo, foi calculada a matriz de confusão e acurácia do modelo, conforme a Figura 11, observando a diagonal principal com o restante da matriz, é possível ver que os dados obtidos ficaram realmente aquém do ideal. Foi obtido uma acurácia de 27% do modelo, o que não é satisfatório para inferir a taxa ocupação real da sala de aula, indicando que possíveis ajustes ainda devem ser feitos para aumentar a confiabilidade do modelo.

Figura 11 – Matriz de Confusão do Modelo



Fonte: Elaborado pelo autor (2022)

### 5.3 Pré-análise: sensores ambientais

A princípio os dados de temperatura, umidade relativa do ar e concentração de CO<sub>2</sub> estavam sendo enviadas a cada minuto para o *Thingspeak*, gerando uma enorme carga de dados, dificultando na visualização e análise. Outro ponto de destaque foi que algumas vezes o sensor CCS811 apresentava picos anormais na concentração de CO<sub>2</sub> e demorava um tempo até se estabilizar, o que pode ser causado pela aproximação indevida de algum ocupante no sensor ou pela influência da movimentação de ar causada por sistemas de ventilação (JIANG, et. al., 2016).

Os dados eram sempre enviados de forma bruta a cada minuto e toda leitura prévia não era utilizada, então um procedimento para minimizar ruídos na medição foi fazer com que o protótipo calculasse as variáveis ambientais médias durante uma janela de tempo de 5 minutos. Esse intervalo de tempo foi escolhido para as variáveis ambientais se estabilizarem e pelo fato de as anotações da ocupação não estarem sendo feitas de forma instantânea. Após a medição durante esses 5 minutos, os dados eram enviados para o *Thingspeak*.

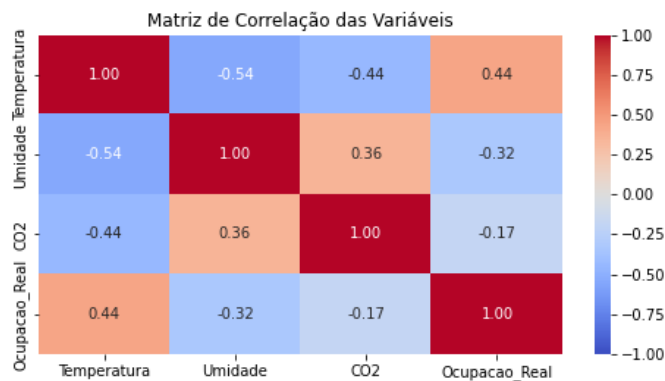
### 5.4 Análise: sensores ambientais

Para a análise dos dados desse protótipo, foi adotado o mesmo procedimento descrito anteriormente, foram imputados manualmente a ocupação real do ambiente para determinado intervalo de tempo, e os registros que não tiveram a ocupação anotada foram

removidos da base de dados. O conjunto de dados finais totalizou 451 registros para análise e criação de um modelo de predição.

Durante a análise exploratória, foi verificada uma baixa correlação das variáveis em função da ocupação do ambiente. A Umidade e concentração de CO<sub>2</sub> apresentam uma leve correlação negativa, enquanto Temperatura foi o único fator que apresentou uma correlação positiva com a ocupação da sala, porém não muito significativa conforme visto na Figura 12.


**Figura 12 – Matriz de Correlação das Variáveis**



Fonte: Elaborado pelo autor (2022)

Além da matriz de correlação, foi plotado um gráfico de dispersão, Figura 13, para visualizar melhor a linearidade das variáveis. Tendo em vista a baixa correlação observada, um modelo baseado em Regressão Linear talvez não seja o mais ideal para esse protótipo.

**Figura 13 – Dispersão das Variáveis**




Fonte: Elaborado pelo autor (2022)

Prosseguindo com a transformação dos dados, foi utilizado a mesma estratégia de discretização das variáveis do protótipo anterior e para esse conjunto de dados foi verificado um bom balanceamento no número de registros discretizados conforme mostra a Figura 14. A ausência do status Cheio da sala de aula não está presente nesse modelo de predição, pois em nenhum momento foram contabilizadas uma ocupação do ambiente acima de 15 pessoas.




Figura 14 – Contagem Ocupação Discretizada



Fonte: Elaborado pelo autor (2022)

Para a criação do modelo de predição foi adotado o algoritmo *K-Nearest Neighbor* (KNN) que é um dos modelos de predição mais simples, ele basicamente exige noções de distância para classificar corretamente os dados (GRUS, 2021). Esse algoritmo tenta fazer a predição de uma variável alvo com base em um número K de classes próximas do alvo, de acordo com Faceli, et al. (2021), dependendo do valor de K escolhido a classificação pode sofrer alterações, sendo, portanto, um dos principais desafios para esse algoritmo. Faceli, et al. (2021) ilustram esse cenário na Figura 15 em que a classificação de uma variável alvo pode ser considerada como classe “doente” caso o valor de K seja 3, porém se o valor de K for 5, uma classe “saudável” será considerada.

Figura 15 – Classificação KNN




Fonte: Faceli et al. (2021, p.56)

Como estimativa de desempenho do modelo foi utilizada a técnica de validação cruzada em k-pastas (do inglês, K-Fold Cross Validation). Essa técnica separa os dados em um número K de subconjuntos, em que K-1 desses subconjuntos são utilizados para treinamento e o conjunto restante para teste do modelo, esse processo é repetido para todos os subconjuntos e a média e desvio padrão do desempenho é adotado como métrica de qualidade (CASTRO; FERRARI; 2016). Conforme Castro e Ferrari (2016) a utilização de 10

pastas é bastante usual para estimar o desempenho do modelo conforme Figura 16, dessa forma, esse valor foi adotado no modelo final desse trabalho.

**Figura 16 – K-Fold Cross Validation, K=10**



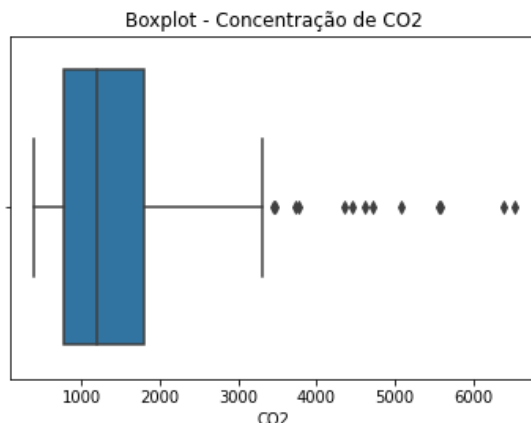
Fonte: Castro; Ferrari (2016, p.158)

Para o modelo final foram considerados como 5 o número de vizinhos mais próximos e o valor de 10 pastas para a validação cruzada. O resultado foi uma acurácia de 46,84% com desvio padrão de 11,96%, um resultado melhor que o do protótipo 1, porém ainda assim não pode ser levado em consideração de um modelo confiável.

Uma tentativa de melhorar a acurácia do modelo foi plotar um boxplot da concentração de CO<sub>2</sub>, apresentado na Figura 17, e remover os outliers da análise. Nesse gráfico é possível verificar que a maior concentração dos valores de CO<sub>2</sub> estão entre 777 até 1800 ppm, com mediana em torno de 1200 ppm, também é observado que alguns valores tiveram medição que fogem do padrão do restante, são os registros acima de 3500 ppm, esses registros foram removidos para mais uma aplicação do algoritmo KNN seguindo os mesmos parâmetros da aplicação anterior.

A quantidade de dados finais do conjunto de dados foi reduzida para 440 registros, mesmo assim apresentou uma acurácia média levemente pior que a aplicação anterior apesar do desvio padrão também ser um pouco menor (45,23% +/- 11,70%).

**Figura 17 – Boxplot CO<sub>2</sub>**



Fonte: Elaborada pelo autor (2022)

## 6 CONCLUSÃO

Estimar a ocupação de um ambiente fechado se mostrou uma tarefa desafiadora e com diversas ressalvas para melhorar a confiabilidade dos modelos.

Para o protótipo baseado em Redes sem Fio a principal complicação foi decidir ou não aplicar um filtro de leituras baseado no RSSI das requisições de sondagem, isso pode ser um indício que talvez esse protótipo seja mais adequado para ambientes com dimensões maiores do que o aplicado, já que o raio de captura aparenta ser bem elevado. Outro ponto de atenção para essa aplicação é que ela acaba sendo suscetível a falhas caso uma pessoa esteja portando mais de um aparelho celular, ou até memos nenhum (SUN; ZHAO; ZHOU, 2020). Há também a randomização de endereços MAC que alguns fabricantes acabam adotando, o que também pode afetar na identificação do dispositivo na contagem de pessoas (VANHOEF et al., 2016). Seria interessante um estudo mais profundo para identificar os reais impactos que esse processo tem sobre o modelo final. Uma sugestão de trabalhos futuros é aplicar esse protótipo em um ambiente maior, também seria interessante identificar possíveis estratégias de filtro que podem ser aplicados para limitar a leitura dentro de uma área física de interesse, há alguns trabalhos nesse sentido como o de Yoshida e Taniguchi (2015) que utilizaram 4 protótipos semelhantes em um ambiente fechado e próximos a um AP e com isso estudar uma correlação de RSSI em função da ocupação.

O modelo baseado na predição da ocupação de um ambiente baseado nas variáveis ambientais demonstrou um resultado melhor quando comparado com o protótipo anterior. Esse tipo de aplicação é mais ideal em ambientes cuja a ocupação não seja muito alta, pois conforme o número de pessoas aumenta, os sensores de CO<sub>2</sub> tendem a apresentar maior variação de erro e suas medições podem sofrer diretamente com interferências externas e ruídos, necessitando de um controle e cuidado maior no posicionamento do sensor e na abertura de portas e janelas (SUN; ZHAO; ZHOU, 2020; SZCZUREK; MACIEJEWSKA; PIETRUCHA, 2017), um exemplo claro dessa imprecisão foi na figura 18, em que o momento que a concentração de CO<sub>2</sub> era mais elevada foi o mesmo em que a ocupação da sala estava com status de Vazia, isso pode ter sido causado por diversos fatores, como aproximação indevida ao sensor, má ventilação do ambiente, demora na concentração dos gases ou até mesmo imprecisão do sensor. Uma sugestão de trabalhos futuros é manter essa aplicação em um ambiente com os mesmos moldes de capacidade de ocupação e dimensões, porém utilizando uma maior quantidade de dados para serem utilizados como treinamento e teste do modelo, isso também pode ser feito em conjunto com mais de um sensor em diferentes pontos do ambiente, outra sugestão é aplicar outros tipos de algoritmos para estimar o desempenho do modelo, nesse trabalho foi utilizado o KNN, porém há diversos outros que podem ser explorados.

Em ambos os protótipos foi necessário um trabalho de transformação dos dados numéricos em categóricos para classificar a ocupação da sala, essa estratégia pareceu ser a mais ideal em função da quantidade de dados disponíveis. A anotação da ocupação real na sala de aula foi um ponto crítico nesse trabalho, houve uma certa dificuldade em manter as anotações de forma constante e padronizadas, gerando indisponibilidade dos dados em certos horários, mas que não gerou grandes implicações na análise final dos modelos. Infelizmente os resultados alcançados nesse trabalho não apresentaram uma alta acurácia no desempenho final, porém mostrou que ambos os protótipos ainda possuem pontos a serem desenvolvidos já descritos anteriormente para apresentarem um resultado mais preciso.

## REFERÊNCIAS

AHMAD, J. et al. **Occupancy detection in non-residential buildings: a survey and novel privacy preserved occupancy monitoring solution.** [S.l.: s.n.], 2018, p. 1-17.

BERTOLETI, P. **Projetos com ESP32 e lora.** São Paulo: NCB, 2019.

BROOKS, J. et al. An experimental investigation of occupancy-based energy-efficient control of commercial building indoor climate. *In: 53ª IEEE CONFERENCE ON DECISION AND CONTROL. Anais [...].* USA: Los Angeles, 2014, p. 5680-5685.

CANDANEDO, L. M.; FELDHEIM, V. Accurate occupancy detection of an office room from light, temperature, humidity and CO<sup>2</sup> measurements using statistical learning models. **Energy and Buildings**, v. 112, p. 28-39, jan. 2016.

CARISSIMI, A. S.; ROCHOL, J.; GRANVILLE, L. Z. **Redes de computadores.** Porto Alegre: Bookman, 2009.

CASTRO, L. N.; FERRARI, D. G. **Introdução à mineração de dados: conceitos básicos, algoritmos e aplicações.** São Paulo: Saraiva, 2016.

CUNCHE, M. I know your MAC address: targeted tracking of individual using wi-fi. **Journal of Computer Virology and Hacking Techniques**, v. 10, n. 4, p. 219 - 227, nov. 2014.

DONG, B.; ANDREWS, B. **Sensor-based occupancy behavioral pattern recognition for energy and comfort management in intelligent buildings.** [S.l.: s.n.], 2009, p. 1444-1451.

FACELI, K. et al. **Inteligência Artificial: uma abordagem de aprendizado de máquina.** Rio de Janeiro: LCT, 2021.

GOVERNO DO ESTADO DE SÃO PAULO. **Retomada consciente.** 2022. Disponível em: <https://www.saopaulo.sp.gov.br/planosp/>. Acesso em: 30 mar. 2021.

GRUS, J. **Data science do zero.** Rio de Janeiro: Alta Books, 2021.

HIDAYAT, A.; TERABE, S.; YAGINUMA, H. Estimating bus passenger volume based on a wi-fi scanner survey. **Transportation Research Interdisciplinary Perspectives**, v. 6, p. 1-8, jul. 2020.

JIANG, C. et al. **Indoor occupancy estimation from carbon dioxide concentration.** [S.l.: s.n.], p. 1-11, 20 jul. 2016.

KUROSE, J.; ROSS, K. W. **Redes de computadores e a internet: uma abordagem top-down.** São Paulo: Pearson, 2013.

- LI, Y. et al. A case study of wifi sniffing performance evaluation. **IEEE Access**, v. 8, p. 129224-129235, 2020.
- LOUREIRO, C. A. H. et al. **Redes de Computadores III: níveis de enlace e físico**. Porto Alegre: Bookman, 2014.
- MARQUITTI, F. M. D. et al. Brazil in the face of new SARS-CoV-2 variants: emergencies and challenges in public health. **Revista Brasileira de Epidemiologia**, v. 24, e210022, 2021.
- NUNES, E. H. M. **Estimativa da ocupação utilizando sensoriamento wi-fi de telefones móveis: uma aplicação no transporte público urbano de passageiros por ônibus**. 2019. Dissertação (Mestrado em Engenharia de Transportes) – Faculdade de Engenharia, Universidade de São Paulo, 2019.
- OLIVEIRA, S. de. **Internet das coisas com ESP8266, Arduino e Raspberry Pi**. São Paulo: Novatec, 2017.
- PRIYADARSHINI, R.; MEHRA, R. M. Quantitative review of occupancy detection technologies. **Journals Pub**, v. 1, p. 1-19, 2015.
- SAHA, H. et al. Occupancy sensing in buildings: a review of data analytics approaches. **Energy and Buildings**, v. 188 -189, p. 278-285, abr. 2019.
- STATCOUNTER. **Mobile vendor market share Brazil**. 2022. Disponível em: <https://gs.statcounter.com/vendor-market-share/mobile/brazil/2021>. Acesso em: 28 fev. 2022.
- SUN, K.; ZHAO, Q.; ZOU, J. A review of building occupancy measurement systems. **Energy and Buildings**, v. 216, p. 1-13, jun. 2020.
- SUN, L. et al. Mobile device passive localization based on IEEE 802.11 probe request frames. **Mobile Information Systems**, v. 2017, p. 1-10, 2017.
- SZCZUREK, A.; MACIEJEWSKA, M.; PIETRUCHA, T. Occupancy determination based on time series of CO2 concentration, temperature and relative humidity. **Energy and Buildings**, v. 147, p. 142 - 154, jul. 2017.
- THINGSPEAK. **ThingSpeak para projetos de IoT**. 2022. Disponível em: <https://thingspeak.com/>. Acesso em: 28 fev. 2022.
- VANHOEF, M. et al. Why MAC address randomization is not enough: an analysis of wi-fi network discovery mechanisms. *In: ASIA CCS '16: ACM ASIA CONFERENCE ON COMPUTER AND COMMUNICATIONS SECURITY*. **Anais [...]**. China: ACM, 2016, p. 413-424.

VILELA, D. B. **Detecção da ocupação de um ambiente a partir de dados de sensores utilizando rede neural artmap fuzzy**. 2020. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2020.

WORLD HEALTH ORGANIZATION. **Tracking sars-cov-2 variants**. 2022. Disponível em: <https://www.who.int/health-topics/typhoid/tracking-SARS-CoV-2-variants>. Acesso em: 28 fev. 2022.

WIRESHARK. **Sobre o Wireshark**. Disponível em: <https://www.wireshark.org/>. Acesso em: 28 fev. 2022.

YOSHIDA, T.; TANIGUCHI, Y. **Estimating the number of people using existing wifi access point in indoor environment**. [S.l.: s.n.], p. 46-53, 2015.

ZOU, H. et al. WinLight: A WiFi-based occupancy-driven lighting control system for smart building. **Energy and Buildings**, v. 158, p. 924-938, 2017.

ZURAIMI, M. S. et al. Predicting occupancy counts using physical and statistical CO<sub>2</sub> based modeling methodologies. **Building and Environment**, v. 123, p. 517-528, out. 2017.

## SOBRE O(S)AUTOR(ES)

### <sup>i</sup> JOÃO PEDRO MILAGRES DE SANTANA



Possui graduação em Tecnologia em Construção de Edifícios pela Faculdade de Tecnologia de São Paulo (2018), é graduando em Ciência de Dados pela Universidade Virtual do Estado de São Paulo e Pós-graduado em Internet das Coisas pela Faculdade SENAI Mariano Ferraz (2022). Atualmente é Assistente de TI na Capitale Energia, atuando com suporte ao ERP Protheus, sendo responsável pela melhoria contínua dos processos, desenvolvimento de rotinas, integrações e migrações de release dentro do sistema.

<https://orcid.org/0009-0001-4920-806X>

### <sup>ii</sup> ANDRÉ LUIS DOS SANTOS



Possui graduação em Engenharia Mecatrônica pela Universidade Paulista (2001), mestrado em Engenharia Mecânica pela Universidade de São Paulo (2016) e atualmente é docente na Faculdade de Tecnologia SENAI Mariano Ferraz. Tem experiência na área de automação industrial e desenvolvimento de software, com ênfase em Linguagens de Programação, atuando principalmente nos seguintes temas: processamento de sinais, tomografia por impedância elétrica, redes de comunicação e microcontroladores.

<https://orcid.org/0000-0001-6627-3886>

<http://lattes.cnpq.br/1891985094962230>

**iii CAIO VINÍCIUS RIBEIRO DA SILVA**

É Eletricista de Manutenção pela Escola SENAI “Humberto Reis Costa”, Técnico em Mecatrônica pela Escola Técnica Estadual Getúlio Vargas (2008), graduação em Tecnologia em Eletrônica Industrial pela Faculdade de Tecnologia SENAI Anchieta (2012), graduação em Teologia pela Universidade Presbiteriana Mackenzie (2015), Especialista em Automação Industrial pela Faculdade SENAI de Tecnologia Mecatrônica (2017), Especialista em Inovação e Competitividade Industrial pela Faculdade SENAI “Theobaldo de Nigris” (2021). Tem experiência na área de Internet das Coisas, Inteligência Artificial, Aprendizado de Máquina e Engenharia Eletrônica, com ênfase em Projetos de Automação e Sistemas Microcontrolados. É professor e Coordenador de Estágios na Escola e Faculdade de Tecnologia SENAI Mariano Ferraz.

<https://orcid.org/0000-0002-9421-2471>

<https://lattes.cnpq.br/3169061864059378>

**iv DOUGLAS DA SERRA OGATA**

Possui graduação em Engenharia de Automação e Controle pela Universidade Paulista - UNIP (2002), e Especialização em Automação e Controle pela Faculdade de Tecnologia SENAI “Mariano Ferraz” (2015). Aluno de mestrado do Programa de Pós-graduação em Engenharia Mecânica da Escola Politécnica da USP com tema voltado à Indústria 4.0. Tem experiência na área de Automação Industrial e Mecatrônica.

<https://orcid.org/0000-0001-9203-0466>