



UNIVERSIDADE FEDERAL DO PARÁ
NÚCLEO DE DESENVOLVIMENTO AMAZÔNICO EM ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA

ANTÔNIO CARLOS PEREIRA DE SOUSA JÚNIOR

**Sistema Embarcado Baseado em Lógica Fuzzy para Análise da Qualidade
do Ar em Ambientes Internos**

Dissertação

Tucuruí
2025



UNIVERSIDADE FEDERAL DO PARÁ
NÚCLEO DE DESENVOLVIMENTO AMAZÔNICO EM ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA

ANTÔNIO CARLOS PEREIRA DE SOUSA JÚNIOR

Sistema Embarcado Baseado em Lógica Fuzzy para Análise da Qualidade do Ar em Ambientes Internos

Dissertação de Mestrado apresentado ao Programa De Pós-Graduação Em Computação Aplicada. Núcleo De Desenvolvimento Amazônico Em Engenharia. Universidade Federal do Pará. Área de Concentração: Computação Aplicada
Orientador: Prof. Dr. Elton Rafael Alves

Tucuruí
2025

Banca Examinadora

Orientador:

Prof. Dr. Elton Rafael Alves
Programa De Pós-Graduação em Computação Aplicada - UFPA

Membro 1:

Dr. Adam Dreyton Ferreira dos Santos
Programa de Pós-Graduação em Computação Aplicada - UFPA

Membro 2:

Dr. Haroldo Gomes Barroso Filho
Programa de Pós-Graduação em Engenharia Elétrica - UFMA

Membro 3:

Dr. Warley Muricy Valente Júnior
Programa de Pós-Graduação em Ciências Forenses - UNIFESSPA

RESUMO

A crescente preocupação com a qualidade do ar em ambientes internos tem impulsionado o desenvolvimento de soluções inteligentes para seu monitoramento e controle. Esta dissertação apresenta um sistema baseado em lógica *fuzzy* para avaliação do conforto ambiental em salas de aula, considerando variáveis como umidade, temperatura, monóxido de carbono (CO) e dióxido de carbono (CO₂), cujos dados são obtidos por sensores conectados a uma plataforma embarcada. A saída do sistema *fuzzy* é uma variável denominada “Conforto”, inspirada nos princípios do índice de qualidade do ar (AQI), utilizada para acionar um umidificador por meio de um servomotor, ajustando automaticamente os níveis de umidade de forma proporcional às condições do ambiente. O sistema foi implementado com uso do Arduino para controle físico e *Python* para processamento dos dados em tempo real, sendo comparado a um controlador tradicional *proporcional-integral-derivativo* (PID). Os resultados mostraram que, em comparação ao controlador PID, a abordagem *fuzzy* apresentou menor variabilidade diante das mudanças do ambiente interno, realizando ajustes mais suaves e consistentes no controle da umidade. Esse comportamento resultou em melhor desempenho geral e maior eficiência energética. Esses achados reforçam o potencial da lógica *fuzzy* como alternativa eficaz e confiável para aplicações em monitoramento contínuo da qualidade do ar em ambientes *indoors*.

Palavras-chave: Lógica Fuzzy, Qualidade do Ar Interno, Sistema Embarcado.

ABSTRACT

The growing concern about indoor air quality has driven the development of smart solutions for its monitoring and control. This dissertation presents a fuzzy logic-based system for evaluating environmental comfort in classrooms, considering environmental variables such as humidity, temperature, carbon monoxide (CO), and carbon dioxide (CO₂). Data for these variables are acquired by sensors connected to an embedded platform. The fuzzy system's output is a variable called "Comfort", inspired by the principles of the Air Quality Index (AQI), used to activate a humidifier via a servomotor, automatically adjusting humidity levels proportionally to ambient conditions. The system was implemented using Arduino for physical control and Python for real-time data processing, and its performance was compared to that of a traditional proportional-integral-derivative (*PID*) controller. The results showed that, in comparison with the *PID* controller, the fuzzy approach exhibited lower variability in response to changes in the indoor environment, performing smoother and more consistent adjustments in humidity control. This behavior led to improved overall performance and greater energy efficiency. These findings highlight the potential of fuzzy logic as an effective and reliable alternative for continuous indoor air quality monitoring applications.

Keywords: Fuzzy Logic, Indoor Air Quality, Embedded System

LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo de variável linguística	20
Figura 2 – Comparativo entre a Lógica Clássica e a Lógica Fuzzy.	21
Figura 3 – Funções de pertinência para a variável temperatura.	23
Figura 4 – Exemplos de funções de pertinência.	24
Figura 5 – Máquina de Inferência <i>Fuzzy</i>	25
Figura 6 – Etapas do processo de metodologia.	46
Figura 7 – Fluxograma representativo do projeto de avaliação da qualidade do ar.	48
Figura 8 – Arduino Uno.	51
Figura 9 – Sensor DHT11.	52
Figura 10 – Servomotor modelo SG90 utilizado no controle do umidificador.	53
Figura 11 – Sensor MQ-9.	54
Figura 12 – Sensor MQ-135.	55
Figura 13 – Gráfico de Pertinência da Temperatura.	59
Figura 14 – Gráfico de Pertinência da Umidade.	60
Figura 15 – Gráfico de Pertinência do CO ₂	61
Figura 16 – Gráfico de Pertinência do Monóxido de Carbono (CO).	62
Figura 17 – Gráfico de Pertinência do Conforto.	63
Figura 18 – Esquema de prototipagem do sistema, destacando conexões entre sensores e Arduino.	64
Figura 19 – Esquema do Sistema de Monitoramento.	67
Figura 20 – Sistema embarcado posicionado no ambiente.	67
Figura 21 – Diagrama do Fluxo de Dados.	69
Figura 22 – Interface do dashboard desenvolvido com Streamlit.	71
Figura 23 – Diagrama do processo ETL.	72
Figura 24 – Umidificador utilizado como atuador no sistema.	73
Figura 25 – Umidificador acoplado ao servomotor.	73
Figura 26 – Lógica de acionamento do umidificador	74
Figura 27 – Variação da temperatura na sala vazia ao longo do tempo.	84
Figura 28 – Distribuição da temperatura na sala vazia.	85
Figura 29 – Gráfico de linhas da temperatura na sala cheia.	85
Figura 30 – Evolução da temperatura ao durante a coleta.	86
Figura 31 – Distribuição da temperatura durante o teste	87
Figura 32 – Variação da temperatura durante o teste	88
Figura 33 – Gráfico de linhas da umidade na sala vazia.	88
Figura 34 – Gráfico de bloxpot da umidade na sala vazia.	89
Figura 35 – Gráfico de linhas da umidade na sala cheia.	90
Figura 36 – Gráfico de boxplot da umidade na sala cheia.	90

Figura 37 – Gráfico de violino da umidade na sala cheia.	91
Figura 38 – Evolução da umidade ao longo do tempo durante os testes.	92
Figura 39 – Distribuição da umidade durante os testes, com destaque para a mediana e os pontos isolados.	92
Figura 40 – Evolução da umidade ao longo do tempo durante os testes.	93
Figura 41 – Gráfico de violino da umidade na sala cheia.	93
Figura 42 – Evolução da umidade ao longo do tempo durante os testes.	94
Figura 43 – Distribuição dos valores de sinal analógico de CO na sala vazia	95
Figura 44 – Distribuição dos valores de CO na sala cheia representada pelo gráfico de violino.	95
Figura 45 – Evolução da concentração de CO ao longo do tempo durante os testes. . . .	96
Figura 46 – Distribuição da concentração de CO	97
Figura 47 – Evolução da concentração de CO ao longo do tempo durante os testes. . . .	98
Figura 48 – Evolução da concentração de CO ao longo do tempo durante os testes. . . .	98
Figura 49 – Distribuição dos valores de CO ₂ na sala vazia.	99
Figura 50 – Distribuição dos valores de CO ₂ na sala cheia.	100
Figura 51 – Evolução da concentração de CO ₂ ao longo do tempo durante os testes. . . .	100
Figura 52 – Distribuição da concentração de CO ₂ durante os testes, com destaque para a mediana e os pontos isolados.	101
Figura 53 – Evolução da concentração de CO ₂ ao longo do tempo durante os testes. . . .	101
Figura 54 – Evolução da concentração de CO ₂ ao longo do tempo durante os testes. . . .	102
Figura 55 – Variação da variável conforto ao longo do teste, conforme a saída do sistema fuzzy.	103
Figura 56 – Variação da variável conforto ao longo do teste, conforme a saída do sistema fuzzy.	104
Figura 57 – Variação da variável conforto ao longo do teste, conforme a saída do sistema fuzzy.	105
Figura 58 – Comparação do ambiente antes e depois da implementação do umidificador. . . .	106
Figura 59 – Variação da variável conforto ao longo do teste, conforme a saída dos sistemas fuzzy e PID.	107

LISTA DE TABELAS

Tabela 1 – Fatores que influenciam a qualidade do ar interior	32
Tabela 2 – Resumo dos trabalhos relacionados com ênfase nos autores, ferramentas e contribuições	42
Tabela 3 – Classificação da temperatura para lógica <i>fuzzy</i>	58
Tabela 4 – Classificação da umidade relativa para lógica <i>fuzzy</i>	59
Tabela 5 – Classificação da concentração de dióxido de carbono (CO ₂) para lógica <i>fuzzy</i>	60
Tabela 6 – Classificação da concentração de monóxido de carbono (CO) para lógica <i>fuzzy</i>	61
Tabela 7 – Classificação da variável conforto para lógica <i>fuzzy</i>	62
Tabela 8 – Resumo das fases de coleta: período, tempo médio diário e número médio de amostras	78
Tabela 9 – Tabela de coleta de dados	79
Tabela 10 – Tabela de Coleta de Dados em Sala Cheia (Novembro e Dezembro de 2024)	81
Tabela 11 – Datas dos Testes com Umidificador (Abril e Maio de 2025)	83
Tabela 12 – Datas dos Testes com Umidificador (Maio de 2025)	84
Tabela 13 – Comparativo das métricas estatísticas antes e depois da ativação do umidificador	106
Tabela 14 – Comparação dos indicadores quantitativos entre os sistemas Fuzzy e PID	108

LISTA DE ABREVIATURAS E SIGLAS

ASHRAE	American Society of Heating, Refrigerating and Air-Conditioning Engineers
AVC	Acidente Vascular Cerebral
CO	Monóxido de Carbono
CO ₂	Dióxido de Carbono
FLC	Controlador Lógico Fuzzy
GCP	Google Cloud Platform
HVAC	Sistema de Aquecimento, Ventilação e Ar-Condicionado
IQA	Índice de Qualidade do Ar
IoT	Internet das Coisas
NO ₂	Dióxido de Nitrogênio
O ₃	Ozônio
OMS	Organização Mundial da Saúde
PID	Proporcional, Integral e Derivativo
PM	Material Particulado
PMV	Predicted Mean Vote
ppm	Partes por Milhão
SBRF	Sistemas Baseados em Regras Fuzzy
VOCs	Compostos Orgânicos Voláteis
WSN	Redes de Sensores Sem Fio

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Contextualização do Problema	12
1.2	Justificativa	15
1.3	Objetivos	17
1.3.1	Objetivo Geral	17
1.3.2	Objetivos Específicos	17
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Lógica <i>Fuzzy</i>	19
2.1.1	Conjuntos <i>Fuzzy</i>	20
2.1.2	Propriedades da Lógica <i>Fuzzy</i>	22
2.1.3	Variáveis Linguísticas e Funções de Pertinência	22
2.1.4	Inferência <i>Fuzzy</i>	24
2.1.5	Fuzzificação	26
2.1.6	Regras de Inferência na Lógica <i>Fuzzy</i>	27
2.1.7	Defuzzificação	28
2.1.8	Gestão da Incerteza	28
2.1.9	Sistema de Inferência <i>Fuzzy</i>	30
2.2	Qualidade do Ar	31
2.2.1	Um Desafio Invisível à Saúde Humana	31
2.2.2	Qualidade do Ar em Ambientes Internos	31
2.2.3	Monóxido de Carbono	34
2.2.4	Dióxido de Carbono	35
2.2.5	Temperatura do Ar	35
2.2.6	Umidade do Ar	36
2.2.7	Conforto Térmico	37
2.3	Controlador Proporcional–Integral–Derivativo	38
3	TRABALHOS RELACIONADOS	40
4	METODOLOGIA	46
4.1	Sistema Proposto	48
4.2	Ferramentas Utilizadas	49
4.2.1	<i>Python</i>	50
4.2.2	<i>Arduino</i>	51
4.2.3	DHT11	52
4.2.4	SG90	53
4.2.5	MQ-9	53
4.2.6	MQ-135	54
4.3	Variáveis Utilizadas	55

4.3.1	Temperatura	55
4.3.2	Umidade	56
4.3.3	Monóxido de Carbono	56
4.3.4	Dióxido de Carbono	57
4.3.5	Escolha das Variáveis	57
4.4	Modelagem das Variáveis de Lógica Fuzzy	57
4.4.1	Função de Pertinência para Temperatura	58
4.4.2	Função de Pertinência para Umidade	58
4.4.3	Função de Pertinência para Dióxido de Carbono (CO ₂)	60
4.4.4	Função de Pertinência para Monóxido de Carbono (CO)	61
4.4.5	Função de Pertinência para Conforto	62
4.5	Programação das Regras Fuzzy	63
4.6	Extração de Dados	66
4.7	Transformação de Dados	68
4.8	Carga de Dados	69
4.9	Visualização de Dados	70
4.10	Umidificador como Atuador do Sistema	73
4.11	Equações para Análise de Comparação	74
4.12	Comparação entre os Controladores Fuzzy e PID	76
5	RESULTADOS	78
5.1	Coletas de Dados	79
5.1.1	Primeira Fase de Coletas	79
5.1.2	Segunda Fase de Coletas (Aplicação dos Conjuntos Fuzzy)	80
5.1.3	Calibração dos Sensores	81
5.1.4	Terceira Fase de Coletas	83
5.1.5	Quarta Fase de Coletas	83
5.1.6	Análise da Temperatura	84
5.1.7	Análise da Umidade	88
5.1.8	Análise do CO	94
5.1.9	Análise do CO ₂	99
5.2	Conforto com <i>Fuzzy</i>	102
5.3	Análise Quantitativa do Desempenho do Sistema	105
5.4	Análise Quantitativa entre os Controladores <i>Fuzzy</i> e PID	107
6	CONSIDERAÇÕES FINAIS	109
	REFERÊNCIAS	111

1 INTRODUÇÃO

A qualidade do ar sempre esteve intrinsecamente ligada ao progresso humano, especialmente durante os períodos de urbanização e industrialização. A Revolução Industrial marcou o início de desafios significativos relacionados à poluição atmosférica, evidenciando os impactos adversos do uso intensivo de combustíveis fósseis, como o carvão, sobre a saúde pública e o meio ambiente (BRIMBLECOMBE, 1987). Esse período trouxe à tona não apenas uma degradação ambiental inédita, mas também um aumento considerável na morbidade e mortalidade relacionadas a doenças respiratórias e cardiovasculares.

Eventos históricos como o “Grande Smog de Londres” e o “Nevoeiro Tóxico de 1952” se tornaram símbolos dos perigos associados à poluição do ar (DAVIS, 2002). Esses episódios destacaram como a industrialização descontrolada e o crescimento urbano contribuíram para a deterioração da qualidade do ar, trazendo implicações sociais, econômicas e de saúde pública que se refletem até os dias atuais. Estudos de Schwartz (1994) corroboram que a urbanização, aliada ao crescimento populacional, intensificou os impactos ambientais, promovendo a formação de ilhas de calor e elevando as concentrações de poluentes em áreas densamente habitadas.

O Grande *Smog* de Londres de 1952 durou cinco dias e matou até 12.000 pessoas. O *smog* se desenvolveu principalmente devido à queima extensiva de carvão com alto teor de enxofre. Os efeitos na saúde foram imediatos e duradouros, com um estudo recente revelando uma maior probabilidade de desenvolvimento de asma infantil em indivíduos expostos ao Grande Smog enquanto no útero ou durante o primeiro ano de vida. (POLIVKA, 2018, p. 4)

O reconhecimento da gravidade da poluição atmosférica levou à formulação de políticas regulatórias significativas, como o *Clean Air Act* de 1970 nos Estados Unidos. Essa legislação estabeleceu padrões nacionais de qualidade do ar e concedeu à Agência de Proteção Ambiental (EPA) autoridade para regular as emissões de poluentes, visando proteger a saúde pública e o meio ambiente. Estudos recentes indicam que a implementação dessas políticas resultou em melhorias substanciais na qualidade do ar e na saúde pública.

Por exemplo, a análise de Isen, Rossin-Slater e Walker (2017) demonstra que a redução da poluição do ar, decorrente do *Clean Air Act*, teve efeitos positivos de longo prazo no mercado de trabalho, aumentando a renda e a empregabilidade de indivíduos expostos a menores níveis de poluição durante a infância. Essas iniciativas estabeleceram bases para que países em todo o mundo implementassem regulamentações voltadas ao controle de emissões, priorizando a proteção da saúde pública.

Apesar disso, no Brasil e no mundo, a situação da poluição atmosférica continua sendo uma preocupação crescente. Segundo a Organização Mundial da Saúde (OMS), cerca de 90% da população mundial respira ar poluído, e a poluição do ar é responsável por mais de 7 milhões de mortes prematuras anualmente (WORLD HEALTH ORGANIZATION, 2020b). No

Brasil, as grandes cidades enfrentam níveis elevados de poluentes, especialmente em áreas com intensa concentração de veículos e atividades industriais. Estima-se que mais de 100 mil brasileiros morram anualmente devido a problemas relacionados à poluição do ar, como doenças respiratórias, cardiovasculares e cânceres; Além disso, a poluição atmosférica no país está associada a problemas como o aumento de doenças alérgicas e complicações em pessoas com condições pré-existentes, como asma e bronquite (BRASIL, 2020).

Em algumas das cidades mais poluídas do Brasil, como São Paulo e Rio de Janeiro, as concentrações de material particulado ($PM_{2,5}$) frequentemente ultrapassam os limites estabelecidos pela OMS (WORLD HEALTH ORGANIZATION, 2020b). Estudos também mostram que o ar poluído afeta desproporcionalmente as populações mais vulneráveis, como crianças, idosos e pessoas com comorbidades. A desigualdade social no acesso a ambientes saudáveis agrava ainda mais a situação, pois as áreas mais pobres geralmente estão localizadas em regiões com maior concentração de poluição e menor cobertura de espaços verdes.

Essa realidade mundial e nacional reforça a urgência de ações para reduzir as emissões de poluentes e promover políticas públicas eficazes, além da conscientização da população sobre a importância da qualidade do ar para a saúde e bem-estar. A busca por soluções sustentáveis, como a transição para fontes de energia renováveis e a implementação de transportes mais limpos, são passos essenciais para mitigar os impactos da poluição atmosférica e melhorar a qualidade de vida das gerações futuras.

A mitigação dos impactos da poluição atmosférica exige mais do que políticas regulatórias: é necessária a implementação de sistemas eficazes de monitoramento ambiental. A capacidade de medir e avaliar a qualidade do ar em tempo real permite não apenas identificar fontes de emissão, mas também desenvolver estratégias mais precisas e eficientes para reduzir os níveis de poluentes. Nesse contexto, a integração de tecnologias como sensores inteligentes e microcontroladores oferece uma abordagem promissora para monitorar e controlar a poluição em ambientes urbanos.

Portanto, compreender os impactos da poluição do ar na saúde humana e desenvolver soluções tecnológicas para monitorá-la e mitigá-la são passos essenciais para proteger a saúde pública. Diversas abordagens tecnológicas têm o potencial de contribuir para esse objetivo, incluindo sistemas baseados em sensores inteligentes, plataformas de microcontroladores e métodos computacionais, como a lógica *fuzzy*. Projetos que integram essas tecnologias oferecem alternativas promissoras para enfrentar os desafios impostos pela poluição atmosférica, possibilitando estratégias mais eficazes e acessíveis de monitoramento e controle.

1.1 Contextualização do Problema

A poluição do ar é amplamente reconhecida como um dos principais fatores de risco para a saúde humana, sendo responsável por uma parcela significativa da morbimortalidade global. A

Organização Mundial da Saúde (OMS) alerta que a grande maioria da população mundial respira ar que excede os limites de qualidade recomendados, evidenciando a gravidade e a abrangência desse problema (WORLD HEALTH ORGANIZATION, 2022). Esse cenário ressalta a urgência de medidas eficazes para monitorar e mitigar os impactos da poluição atmosférica.

Diversos estudos epidemiológicos demonstram uma forte correlação entre a exposição a poluentes atmosféricos e o desenvolvimento de doenças crônicas. A inalação de material particulado fino (PM_{2.5}), por exemplo, está associada a processos inflamatórios que aumentam o risco de eventos cardiovasculares, como infarto do miocárdio e acidentes vasculares cerebrais (PAHO, 2022).

No sistema respiratório, a exposição prolongada a poluentes como dióxido de nitrogênio (NO₂) e ozônio (O₃) contribui para a exacerbação de condições como asma, doença pulmonar obstrutiva crônica e redução permanente da função pulmonar (JORNAL BRASILEIRO DE PNEUMOLOGIA, 2018). Esses efeitos adversos são mais pronunciados em populações vulneráveis, como crianças, idosos e indivíduos com condições pré-existentes, que enfrentam riscos ampliados à saúde (PAHO, 2018).

Além disso, a OMS destaca que a poluição do ar é um fator determinante para doenças crônicas não transmissíveis, contribuindo para 24% das mortes por doenças cardíacas, 25% por acidentes vasculares cerebrais, 43% por doença pulmonar obstrutiva crônica e 29% por câncer de pulmão (PAHO, 2018). Esses dados refletem a dimensão do impacto da poluição atmosférica na saúde pública e enfatizam a necessidade de abordagens integradas para seu controle.

A poluição atmosférica encontra-se presente nos mais diferentes cenários ao longo dos últimos 250 anos, desde que a Revolução Industrial acelerou o processo de emissão de poluentes que, até então, estava limitado ao uso doméstico de combustíveis vegetais e minerais e às emissões vulcânicas intermitentes. Hoje, aproximadamente 50% da população do planeta vivem em cidades e aglomerados urbanos e estão expostas a níveis progressivamente maiores de poluentes do ar. (ARBEX et al., 2012)

O monóxido de carbono (CO) e o dióxido de carbono (CO₂) são poluentes atmosféricos amplamente estudados devido aos seus impactos significativos no meio ambiente e na saúde humana. O CO é um gás incolor, inodoro e extremamente tóxico, formado principalmente pela combustão incompleta de combustíveis fósseis, como gasolina e carvão, além da queima de biomassa. A exposição ao CO interfere no transporte de oxigênio no sangue, pois ele se liga irreversivelmente à hemoglobina, resultando em hipóxia, uma condição que afeta os tecidos do corpo (PENNEY, 2000). As consequências incluem danos neurológicos, problemas cardiovasculares e, em casos graves, morte (GOLDBERG; BURNETT; BAILAR, 2001).

A exposição ao CO interfere no transporte de oxigênio no sangue, pois ele se liga irreversivelmente à hemoglobina, resultando em hipóxia, uma condição que afeta os tecidos do corpo. As consequências incluem danos neurológicos, problemas cardiovasculares e, em casos graves, morte. Estudos indicam que

o CO possui uma afinidade pela hemoglobina cerca de 220 vezes maior que a do oxigênio, comprometendo significativamente o transporte de oxigênio aos tecidos. Além disso, o CO pode ligar-se à mioglobina no músculo cardíaco, alterando a contratilidade muscular e levando ao desenvolvimento de arritmias ou isquemia miocárdica. Portanto, a exposição ao CO pode resultar em hipóxia tecidual, danos neurológicos e cardiovasculares, e, em casos graves, levar à morte. (ORFãO, 2011)

Esse problema é particularmente preocupante em áreas urbanas, onde o tráfego veicular é uma das principais fontes de emissão de CO. Estudos indicam que mesmo exposições moderadas podem causar sintomas como tonturas, fadiga e dores de cabeça, enquanto exposições prolongadas em ambientes mal ventilados podem levar a complicações severas (RAUB et al., 2000). Além disso, populações vulneráveis, como crianças, idosos e pessoas com doenças crônicas, apresentam maior suscetibilidade aos efeitos do CO (SMITH; WOODWARD; CAMPBELL-LENDRUM, 2009). Essas observações reforçam a necessidade de regulamentações para mitigar suas emissões, especialmente em grandes cidades.

Esses eventos climáticos exacerbam doenças respiratórias e cardiovasculares, além de comprometerem a segurança alimentar e hídrica. Por exemplo, incêndios florestais, intensificados pelas mudanças climáticas, aumentam as emissões de CO e CO₂, além de material particulado, criando um ciclo que agrava ainda mais a qualidade do ar e seus impactos na saúde pública (RAUB et al., 2000). Além disso, a interação entre o CO₂ e outros poluentes citados, como o (PM_{2.5}) e o (O₃), intensifica os efeitos adversos para a saúde (SMITH; WOODWARD; CAMPBELL-LENDRUM, 2009).

As emissões de CO₂ de origem fóssil aumentaram 64% entre 1990 e 2019, contribuindo significativamente para o aquecimento global e seus impactos na saúde humana. O dióxido de carbono, principal responsável pelo efeito estufa antropogênico, acumula-se na atmosfera devido à queima de combustíveis fósseis, mudanças no uso da terra e desmatamento. Esse aumento resulta em efeitos diretos e indiretos na saúde pública, como o agravamento de doenças respiratórias e cardiovasculares causadas por ondas de calor mais intensas e frequentes. Além disso, a elevação nos níveis de CO₂ está associada a eventos climáticos extremos, como inundações e secas, que comprometem a segurança alimentar e a disponibilidade de água potável em várias regiões do mundo. (WATTS et al., 2018)

Além de seu impacto ambiental, o CO₂ afeta indiretamente a qualidade do ar ao acelerar reações químicas que resultam em ozônio troposférico, um poluente associado a doenças respiratórias, como asma e bronquite (PENNEY, 2000). Essas interações reforçam a complexidade dos efeitos dos poluentes e a necessidade de estratégias integradas para combatê-los, considerando tanto os aspectos de saúde quanto os impactos ambientais.

Outro aspecto relevante é a qualidade do ar em ambientes internos, também chamados de *indoors*. A maior parte do tempo das pessoas é passada em espaços fechados onde a ventilação costuma ser insuficiente. Nesses ambientes, fontes internas como móveis, produtos químicos e processos de combustão contribuem para o acúmulo de poluentes como dióxido de carbono,

material particulado fino e compostos orgânicos voláteis. Diversos estudos multicêntricos indicam que a exposição a esses poluentes dentro de ambientes fechados está associada a prejuízos no desempenho cognitivo, incluindo aumento no tempo de resposta e redução na produtividade em tarefas que exigem atenção e raciocínio, mesmo quando os níveis de poluição são considerados moderados (LAURENT et al., 2021). Tais evidências ressaltam a importância de se garantir uma boa qualidade do ar interior para promover tanto o bem-estar quanto a eficiência das pessoas em suas atividades diárias.

Além disso, ambientes escolares e residenciais que apresentam condições de umidade e mofo representam um risco elevado à saúde, especialmente para crianças. Pesquisas recentes, como a conduzida por Groot et al. (2024), mostram que a exposição a essas condições está associada ao aumento da incidência de infecções respiratórias em crianças, especialmente em locais onde a umidade visível é mais presente. Esses fatores ambientais contribuem para o surgimento e agravamento de doenças respiratórias, evidenciando a necessidade de medidas adequadas para controlar a umidade, evitar o desenvolvimento de mofo e melhorar a ventilação desses espaços. Assim, a manutenção da qualidade do ar em ambientes internos é fundamental para prevenir problemas respiratórios e promover um ambiente saudável para os ocupantes (OKAFOR; ADEWALE; MUSA, 2023).

1.2 Justificativa

A melhoria da qualidade do ar exige uma abordagem integrada, que combine políticas públicas e tecnologias de monitoramento contínuo baseadas em sensores, além da adoção de fontes de energia renovável, visando reduzir os impactos dos poluentes sobre a saúde pública e o meio ambiente (WATTS et al., 2018). Na região amazônica, esse desafio é ampliado por fatores ambientais e socioeconômicos locais, como a alta umidade e a presença de aerossóis e partículas finas, que, ao interagirem com poluentes gerados por atividades humanas, intensificam problemas respiratórios na população (SILVA; OLIVEIRA, 2021).

Os incêndios que queimaram 2,4 milhões de hectares na Amazônia entre junho e agosto de 2024 emitiram 31,5 milhões de toneladas de CO₂ equivalente. É quase o que a Noruega emite por ano (32,5 milhões de toneladas de CO₂ equivalente). Comparado com o mesmo período de 2023, o aumento das emissões foi de 60% (IPAM, 2024)

A queima de biomassa, como madeira e carvão vegetal, é uma prática comum nas áreas rurais da Amazônia e contribui significativamente para a emissão de poluentes como CO, CO₂ e material particulado, agravando a qualidade do ar (OLIVEIRA; SOUZA, 2019). As queimadas, amplamente empregadas na limpeza de terrenos para agricultura, intensificam os impactos ambientais e à saúde (SOUZA; LIMA, 2022). No Sudeste do Pará, cidades como São

Félix do Xingu têm registrado níveis alarmantes de poluição atmosférica, impulsionados pelo desmatamento e pelo número elevado de focos de incêndio, com mais de 1.800 em apenas sete dias de setembro de 2024, segundo dados do INPE (INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS, 2024). Essa situação afeta diretamente a saúde da população, sobretudo de grupos mais vulneráveis, como crianças, idosos e pessoas com doenças respiratórias (INSTITUTO DE PESQUISA AMBIENTAL DA AMAZÔNIA, 2024).

A escassez de infraestrutura e tecnologias adequadas para o monitoramento da qualidade do ar nas áreas urbanas e rurais da Amazônia dificulta a obtenção de dados precisos e compromete a adoção de medidas preventivas, especialmente em comunidades remotas (BRITO; COSTA, 2023). A ausência de informações em tempo real expõe a população a riscos de doenças respiratórias e cardiovasculares (MARTINS; ALMEIDA, 2022), reforçando a necessidade de soluções acessíveis e adaptadas à realidade local. Nesse contexto, o uso de sensores de baixo custo, integrados a plataformas como o Arduino e técnicas de inteligência computacional, surge como uma alternativa viável para o monitoramento eficiente da qualidade do ar na região.

Sistemas de monitoramento com coleta de dados em tempo real, adaptados às condições específicas da Amazônia, oferecem suporte essencial para a tomada de decisões rápidas e eficazes (ALMEIDA; PEREIRA, 2021). A integração desses sistemas com sensores de poluentes é especialmente eficiente em áreas de difícil acesso, onde a infraestrutura convencional é limitada.

Iniciativas como o aplicativo Selva, desenvolvido pela Universidade do Estado do Amazonas, exemplificam esse potencial ao fornecer informações sobre queimadas e qualidade do ar para orientar ações da população e das autoridades (Portal Amazônia, 2023). A adoção de tecnologias acessíveis e inovadoras promove não apenas a melhoria da saúde pública, mas também contribui para o desenvolvimento sustentável e a preservação ambiental da região (FERREIRA; COSTA, 2023).

Diante dos impactos causados pela degradação da qualidade do ar, como o aumento de doenças respiratórias, cardiovasculares e desequilíbrios ambientais, torna-se essencial buscar soluções eficazes para o monitoramento contínuo e a mitigação da poluição. A tecnologia tem desempenhado um papel central nesse cenário, oferecendo ferramentas inovadoras para enfrentar esse desafio global.

Revisões recentes confirmam que tanto a exposição aguda quanto prolongada à poluição atmosférica estão associadas a uma maior mortalidade e morbidade cardiovascular, incluindo AVCs, doenças isquêmicas e hipertensão (BONT et al., 2022). Ao mesmo tempo, avanços tecnológicos em sensores inteligentes e microcontroladores viabilizam sistemas de monitoramento em tempo real com potencial para reduzir os efeitos da poluição em ambientes urbanos (KUMAR; SKOULODIS; BELL, 2015).

Nesse cenário, a combinação de sensores ambientais com sistemas embarcados baseados em plataformas como o Arduino representa uma alternativa acessível e eficaz para o monitora-

mento da qualidade do ar. Sistemas embarcados permitem integração com diversos sensores para medir parâmetros ambientais, como concentração de gases, material particulado, temperatura e umidade, favorecendo a coleta de dados em tempo real e em ambientes variados.

A lógica fuzzy destaca-se por sua menor complexidade, alta interpretabilidade e habilidade para lidar com incertezas e dados imprecisos típicos de medições ambientais (ZADEH, 1994). Além disso, permite adaptação e expansão gradual do sistema sem exigir grandes volumes de dados para treinamento, ao contrário de técnicas como redes neurais, tornando-a ideal para sistemas embarcados. Integrada a algoritmos de processamento e controle, a lógica fuzzy possibilita o desenvolvimento de sistemas inteligentes para otimizar a ventilação e filtragem do ar em ambientes internos, equilibrando qualidade do ar, conforto térmico e consumo energético, conforme demonstrado em aplicações práticas, como controladores de ar condicionado (SOUZA et al., 2016).

Complementando essas perspectivas, este trabalho apresenta uma abordagem própria, com particularidades na metodologia e na prototipagem do sistema embarcado, que serão detalhadas posteriormente. A integração de tecnologias acessíveis, como plataformas de hardware de baixo custo e técnicas avançadas de processamento de dados, revela grande potencial para soluções inovadoras no monitoramento da qualidade do ar. Ainda assim, há necessidade de aprofundar a investigação sobre a coleta de dados e a implementação clara de métodos de inteligência computacional. Nesse contexto, este estudo combina a versatilidade do Arduino com a lógica fuzzy para propor uma solução prática e eficiente para o monitoramento e a melhoria da qualidade do ar.

1.3 Objetivos

1.3.1 Objetivo Geral

Desenvolver um sistema embarcado inteligente para o gerenciamento da qualidade do ar em ambientes internos, capaz de monitorar, analisar e otimizar parâmetros ambientais, com o propósito de promover condições mais saudáveis e sustentáveis.

1.3.2 Objetivos Específicos

- Analisar detalhadamente as variáveis que afetam a qualidade do ar em ambientes internos, identificando os fatores determinantes e as suas interações;
- Definir funções de pertinência precisas e adequadas para o processo de fuzzificação, assegurando que a solução proposta atenda às características e exigências específicas do ambiente estudado;

- Desenvolver e implementar as funções de lógica difusa em um protótipo de sistema embarcado, realizando experimentos em condições reais e avaliando o desempenho por meio de métricas quantitativas, além de uma análise qualitativa dos resultados obtidos;
- Comparar o desempenho do sistema baseado em lógica fuzzy com um sistema de controle conhecido, como o PID (Proporcional, Integral e Derivativo), a fim de avaliar cada método no controle da qualidade do ar em ambiente interno.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os fundamentos teóricos e tecnológicos que sustentam o desenvolvimento deste projeto, com ênfase na lógica fuzzy e seu papel no monitoramento da qualidade do ar em ambientes internos. A lógica fuzzy, proposta por Zadeh (1965), é uma ferramenta poderosa para lidar com incertezas e modelar sistemas complexos. Sua abordagem permite a utilização de variáveis linguísticas, funções de pertinência e regras *SE-ENTÃO* para interpretar e classificar dados ambientais dinâmicos, oferecendo uma solução robusta para desafios relacionados à análise de multi parâmetros.

Logo, neste contexto, o capítulo explora o estado da arte na aplicação da lógica fuzzy ao monitoramento ambiental, abordando os principais conceitos que a fundamentam e destacando sua relevância em sistemas de tomada de decisão. Também será discutida a integração da lógica fuzzy com sistemas embarcados, como o Arduíno, que permitem a coleta e processamento de dados em tempo real. Essa abordagem tecnológica oferece uma solução acessível e eficiente para regiões como a Amazônia, onde a variabilidade ambiental e as características locais exigem metodologias adaptadas e inovadoras.

2.1 Lógica *Fuzzy*

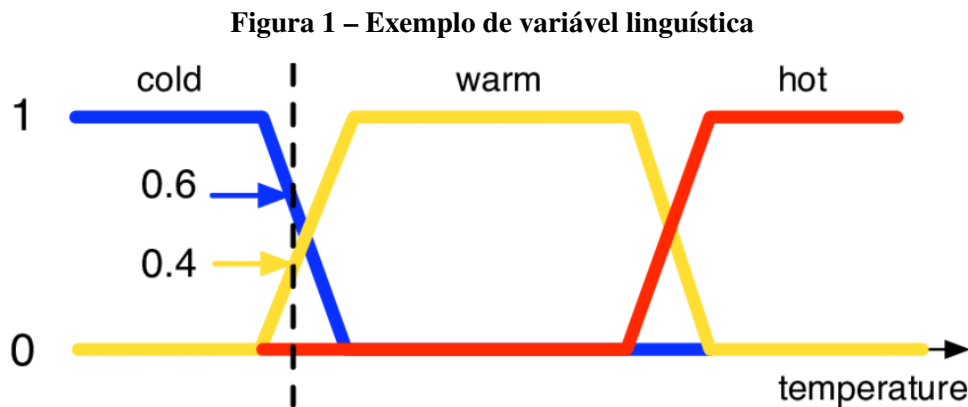
Elaborada por Zadeh (1965), a lógica difusa oferece uma maneira flexível e intuitiva de lidar com a incerteza e a imprecisão, características frequentemente presentes em sistemas do mundo real, como o monitoramento da qualidade do ar. Imagine a dificuldade de definir com exatidão o que é uma “boa” qualidade do ar. A Lógica *Fuzzy* permite que conceitos como este, que não possuem limites rigidamente definidos, sejam representados e manipulados de forma computacional.

Diferentemente da lógica booleana tradicional, que opera com valores binários “verdadeiro”(1) ou “falso”(0), a Lógica *Fuzzy* permite que um elemento pertença a um conjunto com um certo grau de pertinência, variando de 0 a 1. Essa característica permite modelar nuances e transições graduais, como a variação da qualidade do ar de “ruim” para “boa”, passando por estados intermediários.

Um conceito fundamental na Lógica *Fuzzy* é o de variável linguística. Uma variável linguística descreve uma característica por meio de termos da linguagem natural, como “temperatura”, “umidade” ou “concentração de poluentes”. Cada variável linguística é composta por termos fuzzy, que são rótulos que expressam diferentes estados da variável, como “frio”, “ameno” e “quente” para a variável “temperatura”.

Para cada termo *fuzzy*, define-se uma função de pertinência, que mapeia os valores numéricos da variável em graus de pertinência no intervalo [0, 1]. A função de pertinência determina o quanto um valor numérico pertence a um determinado conjunto *fuzzy*. Por exemplo,

uma temperatura de 20°C pode pertencer ao conjunto “frio” com grau de pertinência 0.2, ao conjunto “ameno” com grau 0.8 e ao conjunto “quente” com grau 0.1.



Fonte: Adaptado de Förster (2024).

O processo de inferência *fuzzy* combina as regras *fuzzy* com os graus de pertinência das variáveis de entrada para determinar a saída do sistema. A regra *fuzzy* então será ativada com esse grau de pertinência, e o sistema poderá decidir ligar o ventilador em uma velocidade proporcional a esse valor. A defuzzificação converte o resultado da inferência *fuzzy*, que é um conjunto *fuzzy*, em um valor numérico preciso que pode ser usado para controlar um atuador, como a velocidade do ventilador.

Em resumo, a lógica *fuzzy* oferece uma estrutura poderosa para modelar sistemas complexos com incerteza e imprecisão. Sua capacidade de lidar com informações vagas e representar o conhecimento de forma intuitiva a torna uma ferramenta valiosa para diversas aplicações, incluindo o monitoramento e controle da qualidade do ar, que é apresentado neste estudo.

2.1.1 Conjuntos Fuzzy

Na teoria clássica de conjuntos, a pertinência de um elemento a um conjunto é definida de forma binária: o elemento pertence ou não pertence ao conjunto. Essa relação dicotômica é formalizada pela função característica, que assume valor 1 para elementos pertencentes ao conjunto e 0 para elementos não pertencentes, conforme descrito por Zimmermann (2011). Formalmente, para um conjunto A dentro de um universo U , a função característica $f_A(x)$ é definida Equação 2.1:

$$f_A(x) = \begin{cases} 1, & \text{se e somente se } x \in A, \\ 0, & \text{se e somente se } x \notin A. \end{cases} \quad (2.1)$$

No entanto, essa abordagem binária, expressa na Equação 2.1, se mostra inadequada para modelar muitos conceitos do mundo real, que se caracterizam por imprecisão e gradualidade.

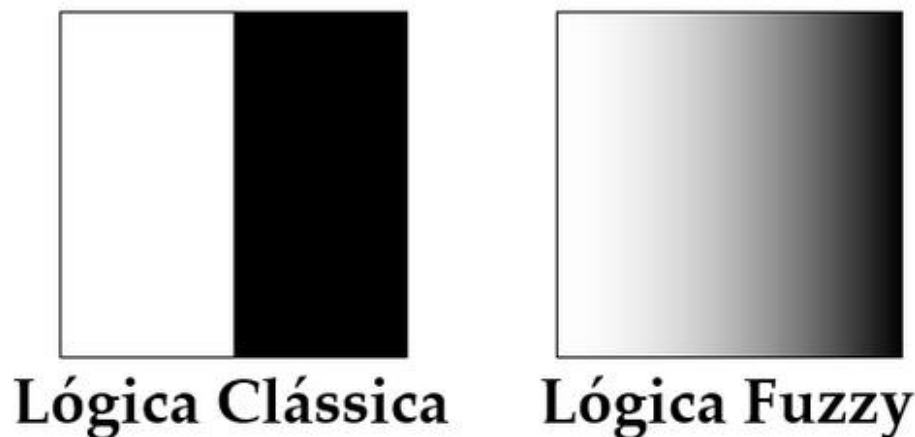
A lógica *fuzzy* oferece uma alternativa para lidar com essa limitação, expandindo a noção de pertinência por meio da introdução de conjuntos *fuzzy* (ZADEH, 1965). Nessa abordagem, a pertinência de um elemento a um conjunto é gradual, variando continuamente entre 0 e 1. Essa gradualidade é formalizada pela função de pertinência, que generaliza a função característica da teoria clássica, permitindo que um elemento pertença a múltiplos conjuntos *fuzzy* com diferentes graus de pertinência. Zadeh (1965) sugeriu uma generalização da função característica, permitindo que esta adote valores no intervalo $[0, 1]$ e seja representada por meio de pares ordenados da Equação 2.2:

$$A = \{\mu_A(x)/x \mid x \in U\}, \quad (2.2)$$

onde A representa o conjunto fuzzy, x a variável de interesse, U o universo de discurso e $\mu_A(x)$ o grau de pertinência de x no conjunto A . Conforme expresso na Equação 2.2, um elemento pode fazer parte de diversos conjuntos fuzzy, cada um com sua própria medida de pertinência.

A Figura 2 ilustra a distinção entre a lógica clássica e a lógica *fuzzy*. Enquanto a lógica clássica define fronteiras nítidas entre as classes, a lógica *fuzzy* permite uma transição suave entre os estados, como destacado por Pedrycz e Gomide (2007). Na imagem, observa-se que a lógica *fuzzy* acomoda a existência de tons de cinza entre o preto e o branco, representando a gradualidade inerente a muitos fenômenos.

Figura 2 – Comparativo entre a Lógica Clássica e a Lógica Fuzzy.



Fonte: Adaptado de Junior (2015).

O conceito de grau de pertinência, como definido por Dubois e Prade (1980), permite quantificar a incerteza e a imprecisão associadas à pertinência de um elemento a um conjunto. Na lógica clássica, um elemento pertence 0% ou 100% a um conjunto. Na lógica *fuzzy*, o grau de pertinência pode assumir qualquer valor entre 0% e 100%, refletindo a natureza gradual de muitos conceitos. Essa capacidade de representar a gradualidade e a imprecisão, como argumentado por Ross (2010), torna os conjuntos *fuzzy* uma ferramenta poderosa para modelar sistemas complexos

e lidar com informações vagas, como as encontradas em problemas de monitoramento e controle da qualidade do ar.

2.1.2 Propriedades da Lógica *Fuzzy*

A lógica *fuzzy*, com suas diversas propriedades, emerge como uma ferramenta essencial para enfrentar os desafios inerentes à incerteza e imprecisão que permeiam os sistemas do mundo real (ZADEH, 1965).

- I. **Gradualidade:** Enquanto a lógica booleana tradicional se restringe a valores binários - verdadeiro ou falso - a lógica *fuzzy* permite uma representação mais refinada da realidade. Por meio de conjuntos *fuzzy*, a gradualidade é introduzida, permitindo que os elementos tenham diferentes graus de pertinência, uma manifestação mais precisa da incerteza inerente aos fenômenos observados.
- II. **Tolerância à Ambiguidade:** Uma das principais forças da lógica *fuzzy* é sua capacidade de lidar com ambiguidades de forma eficaz. Ela oferece uma estrutura para formalizar e manipular termos vagos e imprecisos, tornando-se uma ferramenta poderosa em cenários onde a precisão absoluta é difícil de alcançar.
- III. **Flexibilidade:** Uma característica distintiva da lógica *fuzzy* é sua flexibilidade inerente. Essa flexibilidade permite que os usuários definam conjuntos *fuzzy* e regras de inferência de acordo com as nuances específicas de um problema. Essa adaptabilidade torna a lógica *fuzzy* aplicável em uma ampla gama de domínios e situações.
- IV. **Capacidade de Raciocínio Aproximado:** A lógica *fuzzy* capacita o raciocínio aproximado, refletindo a maneira como os seres humanos tomam decisões na vida real, onde a incerteza e a ambiguidade são predominantes. Isso permite que conclusões sejam alcançadas com base em informações imprecisas e parciais.
- V. **Interpretabilidade:** Além disso, uma característica essencial da lógica *fuzzy* é sua interpretabilidade. Os resultados gerados por sistemas *fuzzy* são facilmente compreendidos e interpretados por humanos, facilitando a comunicação e a tomada de decisões em ambientes complexos e incertos.

Essas propriedades combinadas conferem à lógica *fuzzy* uma versatilidade única e a torna uma ferramenta indispensável na modelagem e análise de sistemas complexos em ambientes imprecisos e incertos.


2.1.3 Variáveis Linguísticas e Funções de Pertinência

A lógica *fuzzy* se destaca pela capacidade de lidar com informações imprecisas e subjetivas, frequentemente expressas em linguagem natural (ZADEH, 1975). Para isso, ela introduz o

conceito de *variáveis linguísticas*, que são variáveis cujos valores são palavras ou termos linguísticos, em vez de números. Essas variáveis permitem representar conceitos vagos e qualitativos, como “temperatura alta”, “velocidade baixa” ou “qualidade do ar boa”, de forma matemática (ZADEH, 1975).

Cada variável linguística é composta por um conjunto de termos *fuzzy*, que são rótulos que descrevem diferentes estados ou condições da variável. Por exemplo, a variável linguística “temperatura” pode ter os termos *fuzzy* “fria”, “amena” e “quente”. A Figura 3 ilustra um exemplo de variáveis linguísticas e funções de pertinência no contexto da temperatura.

Figura 3 – Funções de pertinência para a variável temperatura.



Fonte: Adaptado de Gonçalves (2007).

Para cada termo *fuzzy*, define-se uma *função de pertinência*, que mapeia os valores numéricos da variável em graus de pertinência no intervalo $[0, 1]$ (KLIR; YUAN, 1995). A função de pertinência indica o quanto um valor numérico pertence a um determinado conjunto *fuzzy*. Por exemplo, uma temperatura de 22°C pode pertencer ao conjunto “fria” com grau de pertinência 0.1, ao conjunto “amena” com grau 0.7 e ao conjunto “quente” com grau 0.2.

As variáveis linguísticas desempenham um papel fundamental na lógica *fuzzy*, pois permitem representar o conhecimento de forma mais natural e intuitiva, aproximando-se do raciocínio humano (ZADEH, 1973). Elas capturam a imprecisão inerente à linguagem natural e permitem que sistemas computacionais lidem com informações vagas e subjetivas.

Formalmente, uma variável linguística é definida pela quintupla

$$(X, T(X), U, G, M)$$

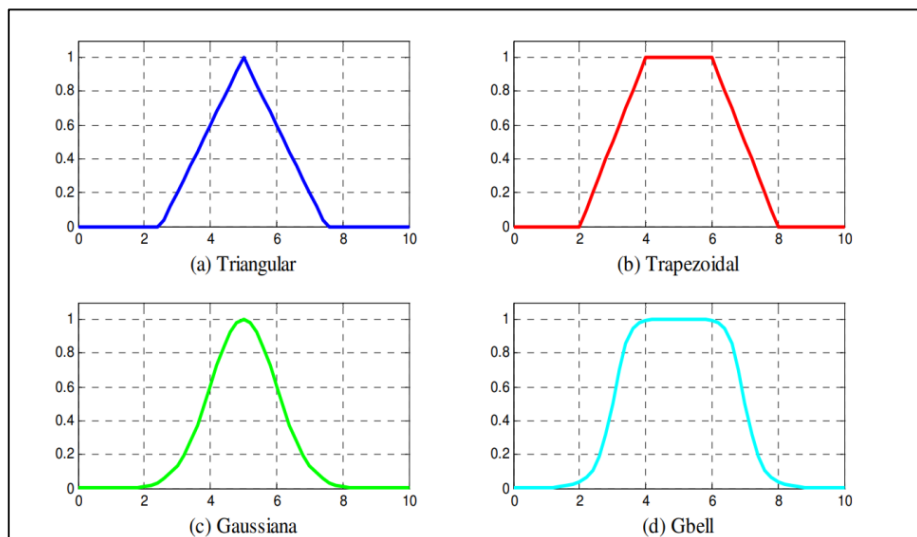
(ZADEH, 1975), onde:

- X : é o nome da variável linguística (ex: “temperatura”).

- $T(X)$: é o conjunto de termos *fuzzy* da variável (ex: {"fria", "amena", "quente"}).
- U : é o universo de discurso da variável (ex: o conjunto de todas as temperaturas possíveis).
- G : é a regra sintática para gerar os termos *fuzzy*.
- M : é a regra semântica que associa cada termo *fuzzy* a um conjunto *fuzzy* em U .

As funções de pertinência podem assumir diversas formas, como triangular, trapezoidal, gaussiana, sigmoidal, entre outras (ROSS, 2010). A escolha da forma da função depende da natureza da variável, do conhecimento do especialista e do contexto da aplicação. A Figura 4 apresenta exemplos de diferentes tipos de funções de pertinência.

Figura 4 – Exemplos de funções de pertinência.



Fonte: Martinez (2010).

Funções de pertinência triangulares e trapezoidais são frequentemente utilizadas por sua simplicidade e capacidade de representar a maioria dos comportamentos de variáveis em um determinado intervalo (YEN; LANGARI, 1999). No entanto, a escolha da função de pertinência mais adequada deve ser feita com base em uma análise criteriosa do problema em questão.

Em resumo, as variáveis linguísticas e as funções de pertinência são elementos essenciais da lógica *fuzzy*, permitindo a representação de informações imprecisas e subjetivas de forma matemática. Essa capacidade de lidar com a incerteza e a vagueza torna a lógica *fuzzy* uma ferramenta poderosa para modelar sistemas complexos e desenvolver soluções inovadoras em diversas áreas, incluindo o monitoramento e controle da qualidade do ar.

2.1.4 Inferência *Fuzzy*

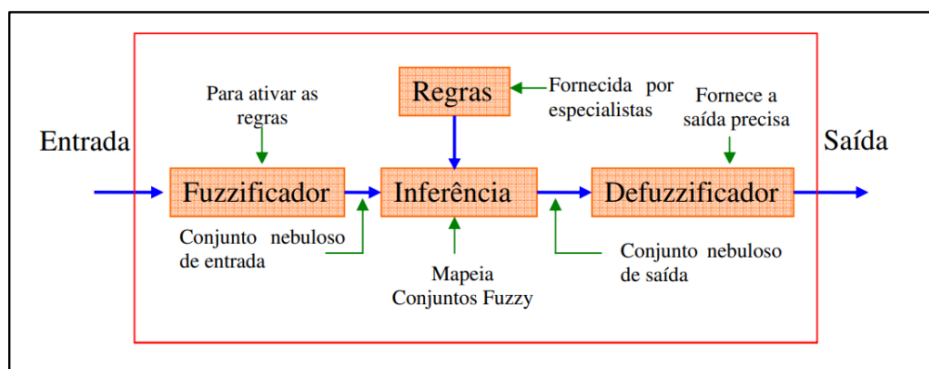
A inferência *fuzzy*, um dos pilares da lógica *fuzzy*, destaca-se como um mecanismo poderoso para modelar o raciocínio humano aproximado e lidar com a imprecisão inerente

a muitos problemas do mundo real (ZADEH, 1973). Diferentemente dos sistemas lógicos tradicionais, que se baseiam em verdades absolutas e fronteiras nítidas entre conjuntos, a inferência *fuzzy* permite a representação de gradualidade e incerteza, aproximando-se da forma como os humanos interpretam e processam informações. No cerne da inferência *fuzzy* está o conceito de regras *fuzzy*, expressas na forma “SE-ENTÃO”, que relacionam variáveis linguísticas por meio de conectivos *fuzzy*, como “E”, “OU” e “NÃO” (KLIR; YUAN, 1995). Essas regras capturam o conhecimento especializado e as relações complexas entre as variáveis, permitindo que o sistema tome decisões mesmo em situações com informações incompletas ou imprecisas.

O processo de inferência *fuzzy* se inicia com a fuzzificação das variáveis de entrada, ou seja, a conversão de valores numéricos *crisp* em conjuntos *fuzzy*. Essa conversão é realizada por meio de funções de pertinência, que atribuem graus de pertinência a cada valor em relação aos conjuntos *fuzzy* definidos (ROSS, 2010). Em seguida, o sistema avalia as regras *fuzzy*, determinando o grau de ativação de cada regra com base nos graus de pertinência das variáveis de entrada. A próxima etapa é a implicação, que determina a contribuição de cada regra para a saída *fuzzy*. Essa contribuição é calculada com base no grau de ativação da regra e na função de pertinência do consequente da regra. As contribuições de todas as regras são então agregadas para obter a saída *fuzzy* final.

A Figura 5 ilustra as etapas do processo de inferência *fuzzy*, desde a fuzzificação das entradas até a defuzzificação da saída. Cada bloco na figura representa um componente do sistema de inferência, e as setas indicam o fluxo de informações entre os componentes.

Figura 5 – Máquina de Inferência *Fuzzy*.



Fonte: Martínez (2010).

Por fim, a defuzzificação converte a saída *fuzzy* em um valor numérico *crisp* (valor absoluto, preciso e exato), que pode ser utilizado para controlar um atuador ou tomar uma decisão (LEE, 1990). Existem diversos métodos de defuzzificação, cada um com suas características e aplicações. Alguns dos métodos mais comuns, como descrito por (KLIR; YUAN, 1995), incluem:

- **Método do Centro de Gravidade:** Calcula o centro de gravidade da área delimitada pela

função de pertinência da saída *fuzzy*.

- **Método da Média dos Máximos:** Calcula a média dos valores que possuem o maior grau de pertinência na saída *fuzzy*.
- **Método do Máximo dos Máximos:** Seleciona o valor com o maior grau de pertinência na saída *fuzzy*.

As vantagens da inferência *fuzzy* incluem a capacidade de lidar com incerteza e imprecisão, permitindo que o sistema opere de forma robusta em situações complexas que serão enfatizadas a seguir, além da flexibilidade e adaptabilidade, facilitando a incorporação de novo conhecimento e a adaptação a diferentes cenários.

Outro ponto importante é a interpretabilidade, uma vez que as regras *fuzzy* são fáceis de entender e permitem que o conhecimento do especialista seja explicitamente representado. Em suma, a inferência *fuzzy* se destaca como uma abordagem poderosa para modelar sistemas complexos e lidar com a imprecisão inerente a muitos problemas do mundo real. Sua flexibilidade, interpretabilidade e capacidade de lidar com incerteza a tornam uma ferramenta valiosa para o desenvolvimento de sistemas inteligentes e a tomada de decisão em diversas áreas, incluindo o monitoramento e controle da qualidade do ar.

A inferência *fuzzy* tem sido aplicada com sucesso em uma variedade de áreas, incluindo controle de processos, diagnóstico médico, reconhecimento de padrões e tomada de decisão. No contexto do monitoramento da qualidade do ar, a inferência *fuzzy* pode ser utilizada para modelar a dispersão de poluentes, controlar sistemas de ventilação, prever a qualidade do ar e avaliar o impacto de diferentes fontes de poluição, auxiliando na tomada de decisão para mitigar os efeitos da poluição.

2.1.5 Fuzzificação

Na teoria da lógica *fuzzy*, a fuzzificação desempenha um papel essencial ao converter variáveis de entrada claras e definidas em conjuntos *fuzzy*, o que possibilita uma modelagem mais precisa e flexível da incerteza e imprecisão inerentes aos sistemas do mundo real (KLIR; YUAN, 1995).

O processo de fuzzificação envolve a atribuição de graus de pertinência a variáveis de entrada com relação aos conjuntos *fuzzy* relevantes. Por exemplo, em um sistema de controle de temperatura de uma sala, a temperatura ambiente é fuzzificada em conjuntos *fuzzy* como “fria”, “morna” e “quente”, com diferentes graus de pertinência atribuídos a cada conjunto, dependendo da temperatura medida. Esses graus de pertinência capturam a incerteza associada à variável de entrada e permitem que ela seja tratada de forma mais precisa e flexível em sistemas baseados em lógica *fuzzy* (ZADEH, 1965).

Existem várias abordagens para realizar a fuzzificação, incluindo métodos baseados em funções de pertinência triangular, trapezoidal, gaussianas, entre outras. Cada método possui suas próprias características e é escolhido com base no contexto específico do problema e nas preferências do projetista do sistema *fuzzy* (JANG; SUN; MIZUTANI, 1997).

O processo de fuzzificação envolve não apenas a conversão das variáveis de entrada em conjuntos *fuzzy*, mas também a aplicação das regras de inferências estabelecidas na caixa de inferência do sistema *fuzzy*. A caixa de inferência é responsável por combinar as variáveis de entrada fuzzificadas de acordo com as regras estabelecidas, a fim de produzir uma saída *fuzzy* que representa a resposta do sistema (JANG; SUN; MIZUTANI, 1997). As regras de inferência, por sua vez, são declarações lógicas que definem como as variáveis de entrada influenciam a saída do sistema.

Essas regras capturam o conhecimento e a experiência do especialista no domínio do problema e são cruciais para o funcionamento eficaz do sistema *fuzzy* (ZADEH, 1965). Em resumo, o processo de fuzzificação é essencial para a operação eficaz de sistemas baseados em lógica *fuzzy*, permitindo que variáveis de entrada imprecisas sejam adequadamente representadas e manipuladas para a tomada de decisões inteligentes e adaptativas.

2.1.6 Regras de Inferência na Lógica *Fuzzy*

As regras de inferência na lógica *fuzzy* desempenham um papel crucial na determinação do comportamento do sistema e na tomada de decisões com base nas variáveis de entrada fuzzificadas (JANG; SUN; MIZUTANI, 1997). Segundo Jang, Sun e Mizutani (1997), as regras de inferência geralmente seguem uma estrutura condicional, onde as variáveis de entrada e saída são relacionadas por meio de proposições lógicas. Por exemplo, uma regra de inferência típica pode ser expressa como: “Se X é A e Y é B, então Z é C”, onde X e Y são variáveis de entrada fuzzificadas, A e B são conjuntos *fuzzy* associados a essas variáveis, e Z é a variável de saída com seu conjunto *fuzzy* correspondente C.

Essas regras capturam o conhecimento e a experiência do especialista no domínio do problema, fornecendo um conjunto de diretrizes para o sistema *fuzzy* seguir (ZADEH, 1965). Existem diferentes métodos para determinar as regras de inferência em um sistema *fuzzy*, incluindo abordagens baseadas em lógica difusa, aprendizado de máquina e heurísticas. A escolha do método depende do contexto específico do problema, da disponibilidade de dados e do conhecimento do especialista no domínio.

Conforme Mamdani e Assilian (1975) destacam, é importante ressaltar que a qualidade das regras de inferência é crucial para o desempenho e a eficácia do sistema *fuzzy*. Regras bem definidas e cuidadosamente projetadas podem levar a decisões mais precisas e resultados mais confiáveis, enquanto regras imprecisas ou mal formuladas podem levar a comportamentos indesejados ou resultados inadequados. Em outras palavras, como enfatizado por Zadeh (1994),

as regras de inferência são um componente fundamental dos sistemas baseados em lógica *fuzzy*, que orientam o processo de tomada de decisões e influenciam diretamente o comportamento do sistema. Sua formulação e seleção adequada são essenciais para garantir um desempenho eficaz e confiável do sistema em uma variedade de cenários e aplicações.

2.1.7 Defuzzificação

Na lógica *fuzzy*, o processo de defuzzificação é uma etapa essencial para converter as saídas *fuzzy* do sistema em valores nítidos ou ações compreensíveis e utilizáveis. Esta etapa ocorre após a inferência *fuzzy*, na qual as variáveis de entrada fuzzificadas são combinadas de acordo com as regras estabelecidas para produzir uma saída *fuzzy*. A defuzzificação visa, portanto, trazer clareza e precisão ao resultado do sistema *fuzzy*, permitindo que sejam tomadas decisões fundamentadas com base nas informações imprecisas e incertas (JANG; SUN; MIZUTANI, 1997).

Existem várias técnicas de defuzzificação disponíveis, cada uma com suas próprias abordagens e aplicações. Uma das técnicas mais comuns é o método do centro de gravidade, onde o valor nítido é calculado como o ponto central da área sob a curva da função de pertinência agregada dos conjuntos *fuzzy* de saída. Este método é amplamente utilizado devido à sua simplicidade e capacidade de fornecer resultados robustos em uma variedade de cenários. Outras técnicas incluem o método do máximo, que seleciona o valor nítido como o ponto de máximo da função de pertinência agregada, e o método da média ponderada, que calcula uma média ponderada dos valores nítidos associados a cada conjunto *fuzzy* de saída (ZADEH, 1965).

Além disso, é importante destacar que a escolha da técnica de defuzzificação adequada depende do contexto específico do problema e das características das saídas *fuzzy* envolvidas. Algumas situações podem exigir uma abordagem mais simples e direta, enquanto outras podem se beneficiar de uma análise mais sofisticada e ponderada. Portanto, a seleção cuidadosa da técnica de defuzzificação é crucial para garantir que as saídas *fuzzy* sejam adequadamente interpretadas e utilizadas para tomar decisões informadas e eficazes (MAMDANI; ASSILIAN, 1975).

De maneira sucinta, o processo de defuzzificação desempenha um papel vital na lógica *fuzzy*, fornecendo uma ponte entre as saídas *fuzzy* do sistema e as ações ou valores nítidos que orientam o comportamento do sistema no mundo real. Sua aplicação requer uma compreensão cuidadosa das técnicas disponíveis e das necessidades específicas do problema em questão, visando sempre proporcionar resultados claros e relevantes para o contexto em que são aplicados.

2.1.8 Gestão da Incerteza

Além das características já mencionadas, a lógica *fuzzy*, emerge como uma ferramenta poderosa para lidar com a incerteza inerente aos sistemas de monitoramento e controle. Ao

contrário da lógica booleana tradicional, que se baseia em valores binários de “verdadeiro” ou “falso”, a lógica *fuzzy* permite a representação de graus de pertinência intermediários, refletindo a natureza gradual e imprecisa de muitos fenômenos do mundo real, assim, assimilando um menor nível de complexidade.

À medida que a complexidade de um sistema aumenta, nossa capacidade de fazer afirmações precisas e significativas sobre seu comportamento diminui até que um limite é atingido além do qual a precisão e a significância (ou relevância) se tornam quase características mutuamente exclusivas. (ZADEH, 1965)

No contexto da qualidade do ar, a incerteza se manifesta em diversas dimensões. As medições de concentração de poluentes, por exemplo, são frequentemente afetadas por ruídos, interferências e limitações dos sensores. Além disso, os próprios padrões de qualidade do ar são definidos com base em faixas de valores e termos linguísticos vagos, como “bom”, “moderado” e “ruim”, que desafiam a representação precisa da lógica clássica.

Com sua capacidade de modelar a imprecisão, a lógica difusa oferece uma abordagem mais flexível e robusta para lidar com essas incertezas. Como descrito por Ross (2010): “A lógica *fuzzy* permite que os termos linguísticos sejam traduzidos em funções de pertinência, que quantificam o grau em que um determinado valor numérico pertence a um conjunto *fuzzy*”. Essa tradução de conceitos vagos em representações matemáticas permite que os sistemas de controle operem de forma mais eficiente em situações complexas e com informações incompletas.

A literatura reconhece a importância da lógica *fuzzy* na gestão da incerteza em diversas áreas, incluindo o monitoramento ambiental. Como por exemplo para Dubois e Prade (1980), em sua obra sobre conjuntos *fuzzy*, destacam que: “A incerteza pode ser vista como uma falta de informação precisa sobre os valores de variáveis, os parâmetros de um modelo ou o estado de um sistema”. A lógica difusa, portanto, fornece mecanismos para representar e processar essa falta de precisão, permitindo que os sistemas tomem decisões mais robustas e eficazes.

A aplicação da lógica *fuzzy* no controle da qualidade do ar pode abranger diversas áreas, desde a otimização de sistemas de ventilação até a previsão da dispersão de poluentes. A capacidade da ferramenta de lógica difusa integrar o conhecimento especialista expresso em regras linguísticas, com dados numéricos a torna particularmente adequada para lidar com a complexidade dos sistemas ambientais.

Em outras palavras, é possível afirmar que a lógica *fuzzy* se destaca como uma ferramenta valiosa para modelar e gerenciar a incerteza no monitoramento da qualidade do ar, pois a sua flexibilidade e a capacidade de lidar com informações vagas e a habilidade de integrar conhecimento especialista a tornam uma abordagem promissora para o desenvolvimento de sistemas de controle mais robustos, eficientes e adaptáveis às incertezas inerentes aos fenômenos ambientais.

2.1.9 Sistema de Inferência *Fuzzy*

O sistema de inferência *fuzzy* é portanto, considerado o componente central da parte teórica da lógica *fuzzy*, ele proporciona um arcabouço matemático para modelar o raciocínio humano aproximado, permitindo que sistemas computacionais lidem com informações imprecisas e incertas, características inerentes aos problemas de monitoramento e controle da qualidade do ar, como é o caso deste trabalho. A inferência *fuzzy*, como definida por Lee (1990), consiste no mapeamento de um espaço de entrada para um espaço de saída utilizando a lógica *fuzzy*.

Esse mapeamento se baseia em um conjunto de regras *fuzzy* e funções de pertinência que traduzem o conhecimento especialista e as nuances do problema em questão. A base de conhecimento de um sistema de inferência *fuzzy* compreende a base de dados e a base de regras. A base de dados define as variáveis linguísticas e seus respectivos termos *fuzzy*, cada um associado a uma função de pertinência que estabelece um mapeamento entre os valores numéricos e os graus de pertinência. A base de regras, por sua vez, contém as regras *fuzzy* que governam o comportamento do sistema, estabelecendo relações entre as variáveis de entrada e as variáveis de saída.

O mecanismo de inferência *fuzzy* é o responsável por aplicar as regras *fuzzy* aos valores de entrada fuzzificados. Para tal, ele se utiliza de operadores *fuzzy*, como a conjunção (“E”), a disjunção (“OU”) e a negação (“NÃO”), para combinar as evidências e inferir conclusões. Esses operadores são formalmente definidos como funções que generalizam os operadores lógicos clássicos para o domínio dos graus de pertinência, conforme explanado por Klir e Yuan (1995). A literatura apresenta uma variedade de sistemas de inferência *fuzzy*, cada um com suas peculiaridades e domínios de aplicação.

O sistema de inferência *Mamdani* (que é utilizado neste trabalho), um dos mais difundidos, caracteriza-se pela utilização do mínimo para a conjunção e do máximo para a disjunção. Em contraste, se tem o sistema de inferência *Sugeno*, por exemplo, que emprega uma função linear para representar a parte consequente das regras, o que contribui para uma maior eficiência computacional. A escolha do sistema de inferência adequado depende das especificidades do problema e dos requisitos de desempenho.

Finalmente, é possível definir que o processo de inferência *fuzzy*, em sua generalidade, envolve as seguintes etapas: fuzzificação dos valores de entrada, aplicação das regras *fuzzy*, implicação para determinar a contribuição de cada regra, agregação das contribuições para obter a saída *fuzzy* final e, por fim, defuzzificação para converter a saída *fuzzy* em um valor *crisp* conforme já representado na Figura 5.

Em suma, o sistema de inferência *fuzzy* constitui uma ferramenta poderosa para a modelagem e gestão da incerteza em sistemas complexos, como os encontrados no monitoramento e controle da qualidade do ar. Sua flexibilidade, aliada à capacidade de lidar com informações imprecisas e de integrar conhecimento especialista, torna-o uma abordagem promissora para o

desenvolvimento de sistemas de controle mais robustos, eficientes e adaptáveis às complexidades e incertezas do mundo real.

2.2 Qualidade do Ar

2.2.1 Um Desafio Invisível à Saúde Humana

A qualidade do ar interno, frequentemente negligenciada, desempenha um papel fundamental na saúde e no bem-estar das pessoas que ocupam ambientes fechados, como residências, escritórios e escolas (SPENGLER; SAMET, 1994). A poluição do ar nesses ambientes pode ser originada de uma variedade de fontes, incluindo materiais de construção, produtos de limpeza, mobiliário, equipamentos eletrônicos e sistemas de ventilação inadequados (WOLKOFF et al., 2006). A presença de poluentes no ar interno pode causar irritação nos olhos, nariz e garganta, dores de cabeça, fadiga, problemas respiratórios e até mesmo contribuir para o desenvolvimento de doenças mais graves (SAMET; SPENGLER; MITCHELL, 2000) (POPE C. ARDEN et al., 2002).

A qualidade do ar interior é um determinante importante da saúde, do conforto e da produtividade dos ocupantes do edifício. A má qualidade do ar interior pode causar uma série de problemas de saúde, incluindo dores de cabeça, fadiga, irritação dos olhos, nariz e garganta, e aumento da gravidade dos sintomas de asma. (SEPPÄNEN; FISK; MENDELL, 2006)

Para avaliar a qualidade do ar interno, utiliza-se o Índice de Qualidade do Ar (IQA), ele agrega as concentrações de diferentes poluentes em um único valor, permitindo classificar a qualidade do ar e informar sobre os riscos à saúde (US Environmental Protection Agency, 2012). No entanto, a complexidade da poluição do ar interno e a interação entre diferentes poluentes tornam a avaliação da qualidade do ar um desafio (KLEPEIS et al., 2001).

A poluição do ar interno é um problema que exige atenção e conscientização. A falta de informação sobre os riscos e a dificuldade de implementar medidas eficazes de controle contribuem para a persistência desse problema (MUDARRI, 2004). É fundamental adotar medidas para reduzir a exposição aos poluentes em ambientes internos, como aumentar a ventilação, controlar as fontes de poluição e utilizar materiais de construção e produtos de limpeza mais seguros.

2.2.2 Qualidade do Ar em Ambientes Internos

O ser humano passa grande parte da vida em ambientes fechados, em locais como: residências, escritórios, escolas, hospitais; e, muitas vezes, desconhece os impactos que a qualidade do ar nesses espaços exerce sobre a saúde e o bem-estar (SPENGLER; SAMET, 1994). A poluição do ar interno, invisível e silenciosa, pode comprometer a saúde respiratória, agravar

alergias, reduzir a produtividade e afetar significativamente a qualidade de vida (FANGER, 1988). Diferentes fontes de poluição, como materiais de construção, produtos de limpeza, mobiliário e equipamentos eletrônicos, podem emitir VOCs, material particulado e outros poluentes que deterioram a qualidade do ar interno (WOLKOFF et al., 2006).

A World Health Organization (2010) estima que a poluição do ar em ambientes internos seja responsável por milhões de mortes e doenças respiratórias a cada ano. A exposição a altos níveis de poluentes em espaços fechados pode causar irritação nos olhos, nariz e garganta, dores de cabeça, fadiga e problemas respiratórios, como asma e bronquite (SAMET; SPENGLER; MITCHELL, 2000). Em casos mais graves, a poluição do ar interno pode contribuir para o desenvolvimento de doenças cardíacas, câncer e outros problemas de saúde (POPE C. ARDEN et al., 2002). Além disso, crianças, idosos e pessoas com problemas respiratórios pré-existentes são particularmente vulneráveis aos efeitos da poluição do ar interno (BERNSTEIN et al., 2008).

Diante desses desafios, surge a necessidade de ferramentas eficazes para monitorar e avaliar a qualidade do ar em ambientes internos. Nesse contexto, destaca-se o Índice de Qualidade do Ar Interior (IAQ), uma métrica projetada para avaliar as condições do ar em espaços fechados, como residências, escritórios, escolas e hospitais. Focado na poluição do ar externo, o IAQ oferece uma avaliação abrangente da qualidade do ar em locais confinados, onde as pessoas passam a maior parte do tempo. Essa métrica considera a concentração de diferentes poluentes e as condições ambientais, permitindo identificar potenciais riscos à saúde e orientar a implementação de medidas corretivas (SEPPÄNEN; FISK; MENDELL, 2006).

Adicionalmente, o IAQ considera a interação entre diversos fatores que influenciam a qualidade do ar interno. Esses elementos, apresentados na Tabela 1, fornecem uma perspectiva abrangente e embasada sobre as condições ambientais em espaços fechados.

Tabela 1 – Fatores que influenciam a qualidade do ar interior

Fator	Descrição
Poluentes	Material particulado (MP), compostos orgânicos voláteis (VOCs), dióxido de carbono (CO ₂), monóxido de carbono (CO), ozônio (O ₃), dióxido de nitrogênio (NO ₂) e dióxido de enxofre (SO ₂) (WOLKOFF et al., 2006).
Temperatura	A temperatura do ar afeta o conforto térmico e a concentração de poluentes (ZHANG; YOSHINO; HASEGAWA, 2007).
Umidade	A umidade relativa do ar influencia o crescimento de microrganismos e a sensação térmica (FANGER, 1988).
Ventilação	A ventilação adequada é essencial para renovar o ar e remover poluentes (SUNDELL, 2011).

Fonte: O Autor (2025).

O IAQ se divide em alguns grupos de valores para quantificar a qualidade do ar, variando

entre 0 e 300 (Instituto Ar, 2024). Valores mais elevados indicam maiores níveis de poluição atmosférica e, conseqüentemente, maior risco à saúde da população. Para facilitar a interpretação e a gestão da qualidade do ar, o índice é dividido em cinco categorias: “Boa” (0–50), “Regular” (51–100), “Inadequada” (101–199), “Ruim” (200–299) e “Péssima” (acima de 300). Cada categoria reflete diferentes níveis de impacto à saúde, desde condições satisfatórias até cenários com riscos severos para toda a população. No entanto, para a aplicação em modelos de lógica *fuzzy*, os valores do IQA são frequentemente padronizados em escalas de 0 a 1 ou de 0 a 100, permitindo uma integração mais eficiente com funções de pertinência e facilitando a análise computacional.

Basicamente, o cálculo do IAQ baseia-se na medição das concentrações de diferentes poluentes, integrando essas informações em um índice único que reflete a qualidade geral do ar. Existem alguns métodos para determinar o IAQ, sendo que a escolha do método depende das variáveis consideradas e dos objetivos da análise. Um dos métodos amplamente utilizados é o proposto por Chen, Zhang e Xie (2009), que combina lógica *fuzzy* para agregar as variáveis envolvidas e calcular o índice de qualidade do ar. Este método inicia com a definição de funções de pertinência *fuzzy* para cada variável de entrada.

Essas funções mapeiam os valores numéricos das variáveis em graus de pertinência a conjuntos *fuzzy*, que representam a qualidade do ar em relação àquela variável. Por exemplo, a variável CO₂ pode ser mapeada em conjuntos *fuzzy* como “baixo”, “médio” e “alto”, e a função de pertinência determina o grau de pertinência de uma dada concentração de CO₂ a cada um desses conjuntos. A construção dessas funções de pertinência requer conhecimento especializado e pode ser baseada em dados experimentais, normas e recomendações de especialistas de organizações como a ASHRAE (American Society of Heating, Refrigerating and Air-Conditioning Engineers) e a OMS.

Em seguida, o método utiliza uma matriz de comparação par a par para determinar os pesos relativos de cada variável na composição do IAQ. Essa matriz é construída com base em julgamentos de especialistas ou em dados de pesquisas que indicam a importância relativa de cada variável para a qualidade do ar interno. A análise hierárquica permite decompor o problema da qualidade do ar em seus componentes principais e estabelecer uma hierarquia de importância entre eles, facilitando a compreensão das interações e a definição dos pesos de cada variável.

Com as funções de pertinência e os pesos das variáveis definidos, o método calcula o IAQ utilizando a seguinte Equação 2.3:

$$IAQ = \sum_{i=1}^n w_i \cdot \mu_i(x_i), \quad (2.3)$$

onde:

- *IAQ*: é o Índice de Qualidade do Ar Interior;

- n : é o número de variáveis consideradas;
- w_i : é o peso da i -ésima variável;
- $\mu_i(x_i)$: é o grau de pertinência da i -ésima variável ao seu conjunto fuzzy correspondente.

O Índice de Qualidade do Ar (IAQ) calculado por esse método é um valor numérico que representa a qualidade geral do ar interno. Valores mais altos indicam uma qualidade do ar superior, enquanto valores mais baixos indicam condições menos favoráveis. É fundamental destacar que o IAQ é um índice relativo, o que significa que ele permite a comparação da qualidade do ar entre diferentes ambientes ou em um mesmo ambiente ao longo do tempo.

A interpretação do IAQ deve levar em consideração o contexto específico da avaliação, bem como os valores de referência para cada variável envolvida, portanto, o IAQ é considerado uma ferramenta valiosa tanto para avaliar quanto para melhorar a qualidade do ar em ambientes fechados, permitindo a identificação dos principais fatores que impactam a qualidade do ar.

Além disso, ele auxilia na tomada de decisões para criar ambientes mais saudáveis e confortáveis. A aplicação de lógica fuzzy no cálculo do IAQ permite lidar com a imprecisão e a subjetividade inerentes à avaliação da qualidade do ar, tornando o índice mais robusto e representativo da percepção humana, o que aumenta sua utilidade na gestão e monitoramento das condições ambientais.

2.2.3 Monóxido de Carbono

O monóxido de carbono (CO), um gás incolor, inodoro e insípido, representa uma ameaça silenciosa em ambientes internos (World Health Organization, 2010). Ele é gerado pela combustão incompleta de combustíveis fósseis e materiais orgânicos, podendo se acumular em espaços com ventilação inadequada. Entre as principais fontes de CO estão aquecedores a gás, lareiras, fogões a lenha e veículos em garagens anexas. Além disso, a fumaça do cigarro (SEPPÄNEN; SATERI; PALONEN, 1997), o uso de fogões a lenha e carvão para cozinhar (BRAGA et al., 2007) e equipamentos movidos a gasolina, como geradores e cortadores de grama, também contribuem para a sua presença em ambientes internos.

A toxicidade do CO decorre de sua elevada afinidade pela hemoglobina, formando carboxihemoglobina e reduzindo significativamente a capacidade de transporte de oxigênio no sangue (PROCKOP; CHICHKOVA, 2003). Esse processo leva à hipóxia, comprometendo órgãos vitais como o cérebro e o coração. Os sintomas da intoxicação variam conforme a concentração e o tempo de exposição, podendo incluir dores de cabeça, tontura, náuseas e, em casos mais graves, perda de consciência e morte (POPE C. ARDEN et al., 2002).

A presença de CO em ambientes internos exige atenção redobrada, especialmente em regiões do Brasil suscetíveis a queimadas, onde a fumaça pode se infiltrar em residências e outros espaços fechados, mesmo a grandes distâncias (BRAGA et al., 2007). A conscientização sobre os

riscos do CO, aliada a práticas como a ventilação adequada e o controle de fontes de combustão, é essencial para minimizar os riscos à saúde. Em caso de suspeita de intoxicação, é fundamental sair imediatamente do ambiente contaminado, buscar ar fresco e procurar assistência médica.

2.2.4 Dióxido de Carbono

O dióxido de carbono (CO₂) é um gás sem cor e sem odor, amplamente presente na atmosfera e essencial para processos naturais, como a fotossíntese. No entanto, em ambientes internos, sua concentração pode se elevar significativamente, principalmente em locais com ventilação deficiente e grande ocupação humana (SEPPÄNEN; FISK; MENDELL, 2006). Embora não seja considerado tóxico em concentrações baixas, o acúmulo excessivo pode impactar o bem-estar, a saúde e o desempenho cognitivo (SATISH et al., 2012).

A principal fonte de CO₂ em espaços fechados é a respiração humana, pois o gás é eliminado continuamente pelo metabolismo celular (FANGER, 1988). Além disso, equipamentos de combustão, como sistemas de aquecimento movidos a combustíveis fósseis, também podem contribuir para o aumento dos níveis desse gás. A exposição prolongada a concentrações elevadas pode causar sintomas como sonolência, dor de cabeça e dificuldade de concentração, reduzindo a capacidade de raciocínio e produtividade (WARGOCKI et al., 2000). Em situações extremas, a saturação do ambiente com CO₂ pode levar à redução do oxigênio disponível, representando um risco grave à saúde.

O controle da ventilação é um fator essencial para manter os níveis de CO₂ dentro de limites seguros, principalmente em locais com alta densidade de pessoas, como salas de aula, escritórios e espaços de reunião. Pesquisas indicam que quando a concentração do gás ultrapassa 1000 ppm, há uma percepção negativa da qualidade do ar e aumento da sensação de desconforto (FISCHER et al., 2007). Dessa forma, estratégias eficazes de ventilação, naturais ou mecânicas, são fundamentais para garantir um ambiente saudável e confortável para os ocupantes.

2.2.5 Temperatura do Ar

A temperatura do ar em ambientes internos exerce uma influência multifacetada na qualidade do ar, no conforto térmico dos ocupantes e, conseqüentemente, na saúde e na produtividade. Manter a temperatura em níveis adequados é crucial para promover ambientes saudáveis e propícios ao bem-estar, visto que temperaturas extremas, tanto frias quanto quentes, podem causar desconforto, estresse e afetar as funções cognitivas, impactando negativamente a saúde mental e física dos indivíduos (LAN et al., 2011).

Para Zhang, Yoshino e Hasegawa (2007), a temperatura do ar interno é um fator dinâmico, influenciado por diversas variáveis interdependentes, incluindo a temperatura externa, a incidência solar, as características da edificação (isolamento térmico, materiais de construção), a quantidade de pessoas no ambiente e a presença de equipamentos que geram calor. Além

disso, a temperatura do ar interfere na concentração de poluentes e na percepção da qualidade do ar, criando um complexo sistema de interações que demandam atenção no projeto e gestão de ambientes internos.

A temperatura é uma variável crucial para o conforto humano, para Mendell e Heath (2006), a faixa considerada ideal fica entre 18°C e 25°C, contudo, uma temperatura até 29°C ainda é considerável moderada. Já as temperaturas elevadas podem agravar os efeitos da poluição do ar interno, aumentando a volatilidade de VOCs e acelerando a degradação de materiais que liberam poluentes, como demonstrado por Seppänen, Säteri e Palonen (1997) em seu estudo de sobre emissões de formaldeído em materiais de construção.

O calor também pode intensificar a formação de O₃ em ambientes com equipamentos eletrônicos, como fotocopiadoras e impressoras a laser (WESCHLER, 2007). Essa interação entre temperatura e emissões de poluentes ressalta a importância de se considerar esses fatores de forma integrada na busca por ambientes internos saudáveis.

Temperaturas extremamente baixas não serão consideradas, pois estão fora do escopo do presente estudo. No entanto, Fanger (1988) destaca que temperaturas muito baixas podem reduzir a ventilação natural, favorecendo a acumulação de poluentes e aumentando o risco de condensação e proliferação de mofo, o que pode resultar em problemas respiratórios e alérgicos para os ocupantes. Dessa forma, a manutenção de uma temperatura adequada é fundamental para prevenir impactos negativos na qualidade do ar interno e na saúde dos indivíduos.

A busca por um ambiente interno saudável e confortável requer uma abordagem holística que leve em consideração a interação entre a temperatura do ar, a qualidade do ar e o conforto térmico dos ocupantes. A implementação de estratégias de controle da temperatura, como a utilização de sistemas de climatização e ventilação eficientes, o isolamento térmico adequado e o monitoramento da temperatura em tempo real, são essenciais para alcançar esse objetivo.

2.2.6 Umidade do Ar

A umidade relativa do ar, definida como a quantidade de vapor de água presente no ar em relação à quantidade máxima que o ar pode conter a uma determinada temperatura, desempenha um papel crucial na qualidade do ar interno e no conforto dos ocupantes. Manter a umidade em níveis adequados é essencial para evitar problemas de saúde, proliferação de microrganismos e danos aos materiais de construção (ZHANG; YOSHINO; HASEGAWA, 2007). A umidade do ar interno é influenciada por diversos fatores, incluindo a umidade externa, a ventilação, a presença de fontes de vapor d'água (como chuveiros, cozinhas e plantas), as características da edificação e o número de ocupantes.

A umidade interage com outros parâmetros da qualidade do ar interno, como a temperatura e a concentração de poluentes, afetando o conforto e a saúde dos indivíduos. Em excesso, ela pode criar um ambiente propício para a proliferação de ácaros, fungos e bactérias, que podem

causar alergias, irritações respiratórias e infecções (FANGER, 1988). O mofo, em particular, libera esporos no ar que podem desencadear crises asmáticas e outros problemas respiratórios, especialmente em pessoas sensíveis. Além disso, a umidade elevada pode acelerar a degradação de materiais de construção, como madeira, gesso e papel de parede, causando danos e prejuízos às edificações além de dispositivos eletrônicos.

Por outro lado, a umidade muito baixa também pode ser prejudicial à saúde, causando ressecamento das vias respiratórias, irritação nos olhos e na pele, e aumentando a susceptibilidade a infecções (SUNDELL, 2011). O ar seco também pode contribuir para o aumento da carga eletrostática e a dispersão de partículas em suspensão no ar, o que pode agravar os sintomas de alergias e problemas respiratórios.

Para garantir a qualidade do ar interno e o conforto dos ocupantes, é essencial manter a umidade relativa do ar em níveis adequados, idealmente entre 40% e 60% (ANSI; ASHRAE, 2017). A ventilação adequada, o uso de desumidificadores ou umidificadores e o controle das fontes de vapor d'água são medidas importantes para regular a umidade em ambientes internos. É fundamental monitorar a umidade do ar e adotar medidas corretivas sempre que necessário, visando a criação de ambientes internos mais saudáveis e confortáveis.

2.2.7 Conforto Térmico

De acordo com ANSI e ASHRAE (2017), o conforto térmico é um conceito essencial na ciência da edificação e na saúde ocupacional, indo além da simples ausência de desconforto térmico. Ele representa um estado de satisfação com o ambiente térmico, no qual o indivíduo experimenta bem-estar e equilíbrio com o meio. Alcançar esse estado implica atender tanto às necessidades fisiológicas quanto às psicológicas, levando em consideração a complexa interação entre o corpo humano e o ambiente térmico.

A avaliação do conforto térmico permite, a partir de diversas variáveis ambientais e individuais, classificar a sensação térmica do indivíduo dentro de um determinado espaço. Esse conceito pode ser relacionado ao AQI, pois ambos fornecem parâmetros objetivos para mensurar a percepção ambiental e seus impactos sobre a saúde e o bem-estar. Assim, compreender e gerenciar o conforto térmico é fundamental para a criação de ambientes internos saudáveis e adequados às necessidades humanas.

O conforto térmico, um fenômeno subjetivo e multifatorial, é influenciada por uma série de variáveis ambientais e individuais (TANABE; NISHIHARA; HANEDA, 2009). Dentre os fatores ambientais, destacam-se a temperatura do ar, a umidade relativa, a velocidade do ar e a temperatura radiante das superfícies circundantes. Fatores individuais, como o metabolismo, a vestimenta e as preferências pessoais, também desempenham um papel importante na percepção do conforto térmico. A interação entre temperatura e qualidade do ar é um fator crucial no conforto térmico. Temperaturas elevadas podem aumentar a Quantidade de VOCs, provenientes

de materiais de construção, mobiliário e produtos de limpeza, intensificando a exposição dos ocupantes a esses poluentes (WOLKOFF, 1998). Por outro lado, temperaturas baixas podem comprometer a eficiência da ventilação, reduzindo a taxa de renovação do ar e aumentando a concentração de poluentes internos.

A umidade relativa também desempenha um papel essencial nessa dinâmica. A umidade excessiva favorece o crescimento de ácaros, fungos e bactérias, que podem causar alergias, irritações respiratórias e infecções (SUNDELL, 2011). Por outro lado, a umidade muito baixa pode provocar ressecamento das vias respiratórias, aumentando a suscetibilidade a infecções e favorecendo a dispersão de partículas e alérgenos no ar.

Portanto, a busca pelo equilíbrio entre temperatura, umidade e ventilação é essencial para garantir um ambiente interno saudável e confortável. Medidas como monitoramento contínuo das condições ambientais, escolha adequada de materiais de construção e mobiliário, e a implementação de sistemas eficientes de climatização e ventilação podem contribuir significativamente para a qualidade do ambiente e o bem-estar dos ocupantes.

2.3 Controlador Proporcional–Integral–Derivativo

O controlador Proporcional–Integral–Derivativo (PID) é uma das técnicas de controle automático mais difundidas na engenharia e automação industrial, amplamente aplicado em sistemas que exigem regulação precisa de variáveis físicas, como temperatura, pressão, umidade e velocidade.

Suas origens remontam a sistemas de direção automática para navios, desenvolvidos por Sperry (1911), e tiveram seu primeiro tratamento teórico formal com os estudos de Minorsky (1922), que observaram a ação de timoneiros no ajuste de rumos de embarcações. Minorsky percebeu que o controle eficaz não depende apenas do erro instantâneo, mas também de erros passados e da taxa de variação do erro, estabelecendo assim a base conceitual do PID.

Posteriormente, avanços na industrialização e na automação permitiram a aplicação prática do PID em processos industriais, com registros de patentes e métodos de sintonia desenvolvidos por Callender e Stevenson (1939) e Ziegler e Nichols (1942), consolidando o PID como um dos pilares do controle clássico. Essa evolução histórica demonstra a confiabilidade e robustez do controlador, que se mantém relevante até os dias atuais devido à sua simplicidade matemática e eficácia comprovada em múltiplos contextos.

A lei de controle do PID em tempo contínuo é expressa pela Equação 2.4:

$$u(t) = K_p e(t) + K_i \int_0^t e(\tau) d\tau + K_d \frac{de(t)}{dt}, \quad (2.4)$$

onde $u(t)$ representa a variável de controle aplicada ao sistema, $e(t)$ é o erro entre o valor de referência (*set-point*) e a variável de processo medida, e K_p , K_i e K_d correspondem aos ganhos

proporcional, integral e derivativo, respectivamente. Esta formulação permite que o controlador combine respostas imediatas, acumulativas e antecipatórias, ajustando a saída do sistema de forma contínua e dinâmica.

O termo proporcional (P) atua diretamente sobre o erro instantâneo, fornecendo uma resposta imediata e proporcional ao desvio observado. Já o termo integral (I) acumula os erros ao longo do tempo, garantindo que o *set-point* seja alcançado com precisão, eliminando desvios residuais em regime estacionário. Por sua vez, o termo derivativo (D) avalia a taxa de variação do erro, atuando de forma antecipatória para reduzir oscilações, amortecer respostas indesejadas e melhorar a previsibilidade do sistema, principalmente durante transientes e perturbações externas.

Para aplicação prática em sistemas digitais e microcontroladores, a forma discreta do PID é necessária, conforme apresentado na Equação 2.5:

$$u[k] = K_p e[k] + K_i T_s \sum_{i=0}^k e[i] + K_d \frac{e[k] - e[k-1]}{T_s}, \quad (2.5)$$

onde T_s representa o intervalo de amostragem. Nesse contexto, o termo integral é calculado pela soma acumulada dos erros ao longo das amostras, enquanto o termo derivativo utiliza diferenças finitas entre valores consecutivos do erro. Essa abordagem preserva a eficácia do PID contínuo, permitindo implementação digital com baixo custo computacional, alta confiabilidade e compatibilidade com sistemas embarcados.

3 TRABALHOS RELACIONADOS

Para fundamentar o desenvolvimento do sistema proposto, realizou-se uma revisão dos trabalhos mais relevantes relacionados ao monitoramento e controle da qualidade do ar utilizando técnicas baseadas em lógica *fuzzy* e sistemas embarcados. A literatura atual apresenta diversas abordagens que combinam sensores ambientais, algoritmos inteligentes e plataformas de hardware de baixo custo para otimizar o conforto térmico, a qualidade do ar e a eficiência energética em diferentes ambientes.

Mudholkar e Patil (2019) propuseram a implementação de um controlador *fuzzy* otimizado por algoritmo genético (*GAFLC*) voltado ao controle de sistemas de ar-condicionado do tipo split, utilizando o índice *PMV* (*Predicted Mean Vote*) de Fanger como métrica para avaliar o conforto térmico. A abordagem combina lógica fuzzy e algoritmos genéticos para ajustar automaticamente parâmetros como temperatura e umidade, buscando manter o conforto de forma adaptativa e eficiente. A validação do sistema foi realizada por meio de simulações no *MATLAB/Simulink*, bem como testes em hardware com o microcontrolador *ATmega 328*.

Os resultados demonstraram que o controlador conseguiu manter o índice *PMV* dentro dos limites recomendados, evidenciando sua viabilidade na otimização de sistemas *HVAC* (aquecimento, ventilação e ar-condicionado). Este trabalho se insere em um campo crescente de pesquisas que exploram o uso de inteligência artificial aplicada ao controle ambiental, incluindo técnicas como redes neurais, algoritmos genéticos e lógica *fuzzy*.

No estudo de Bushnag (2022), foi desenvolvido um sistema inteligente de monitoramento da qualidade do ar e controle climático para ambientes internos, com base em lógica *fuzzy*. O sistema visa integrar o controle de temperatura, umidade e qualidade do ar, otimizando a atuação de dispositivos como ventiladores e condicionadores de ar. A lógica *fuzzy* é utilizada para lidar com a incerteza e variabilidade das condições ambientais, permitindo ajustes em tempo real com base nos dados coletados.

O sistema utiliza sensores para monitorar continuamente poluentes atmosféricos (como CO_2 e compostos orgânicos voláteis) e variáveis ambientais. A validação incluiu simulações e testes experimentais, demonstrando que o controlador *fuzzy* é eficaz em manter padrões adequados de conforto e qualidade do ar.

Liu (2021) desenvolveu um sistema inteligente para controle da qualidade do ar em estufas agrícolas, utilizando o microcontrolador *NodeMCU*. O sistema realiza a leitura contínua de variáveis como temperatura, umidade e concentração de CO_2 , visando garantir condições ideais para o cultivo. Seu diferencial está na integração com a Internet das Coisas (*IoT*), permitindo o envio de dados para a nuvem via *ThingSpeak*, com acesso remoto por dispositivos móveis.

Além do monitoramento em tempo real, o sistema realiza ajustes automáticos em equipamentos como ventiladores e desumidificadores quando os níveis de CO_2 ou umidade se tornam

inadequados. Também inclui alertas para notificar os usuários sobre variações ambientais críticas, contribuindo para a eficiência e segurança na produção agrícola.

Em Saini, Dutta e Marques (2022), os autores propuseram o *Adaptive Dynamic Fuzzy Inference System Tree (ADFIST)*, um modelo adaptativo baseado em árvore de inferência fuzzy dinâmica para previsão da qualidade do ar em ambientes internos. O sistema utiliza sensores conectados por *IoT* para medir poluentes como PM_{10} , $PM_{2,5}$, CO_2 , CO , NO_2 e $tVOC$, permitindo o monitoramento contínuo e a tomada de decisão automatizada.

A base de conhecimento *fuzzy* neste estudo foi otimizada por técnicas de meta-heurística, como enxame de partículas, com o objetivo de aprimorar a acurácia do sistema. Os resultados experimentais indicaram excelente desempenho preditivo, com potencial de aplicação em ambientes diversos, como residências, escritórios e indústrias.

Em outro projeto, Widhiada et al. (2019) desenvolveram um sistema de controle híbrido *Fuzzy-PID* (Proporcional-Integral-Derivativo) para regular a temperatura e a umidade em incubadoras neonatais. O sistema visa garantir condições ambientais estáveis para recém-nascidos prematuros, combinando a lógica *fuzzy* com o controle PID tradicional para responder rapidamente a variações ambientais. A implementação foi feita com o microcontrolador *Arduino Mega 2560*, permitindo o ajuste dinâmico dos parâmetros de controle conforme a taxa de erro. Os testes revelaram que o controlador *Fuzzy-PID* apresentou desempenho superior ao PID convencional, garantindo estabilidade e resposta mais precisa.

Dionova et al. (2020) apresentaram um sistema de monitoramento e controle da qualidade do ar baseado em um controlador lógico *fuzzy* (FLC), com o objetivo de calcular o Índice de Qualidade do Ar Interno Ambiental (*EIAQI*). Este índice é dividido em quatro níveis (excelente, bom, ruim e pior), orientando a atuação automática de exaustores, ventiladores e alarmes. Sensores de baixo custo (MQ-135, MQ-7, MQ-9) foram utilizados para detectar gases como CO , CO_2 , NO_2 , O_3 , e partículas $PM_{2,5}$, além de parâmetros como temperatura e umidade. Os testes demonstraram resposta eficiente do sistema a mudanças ambientais, com impactos positivos sobre a saúde e o conforto dos ocupantes.

Em Pierre et al. (2023), foi apresentado um sistema que combina (*IoT*) e lógica *fuzzy* para monitoramento inteligente em salões públicos durante a pandemia de COVID-19. O modelo proposto integra sensores de temperatura, umidade, concentração de CO_2 e ocupação do ambiente, processando essas variáveis em tempo real por meio de regras difusas capazes de identificar situações de risco relacionadas à propagação do vírus.

A arquitetura inclui módulos de conectividade *IoT* e um controlador difuso responsável por gerar alertas e acionar respostas automáticas, como ajuste de ventilação e restrição de acesso. Os resultados obtidos mostraram que a solução é eficiente para apoiar a tomada de decisão em ambientes coletivos, oferecendo uma alternativa de baixo custo e fácil escalabilidade para cenários que demandam monitoramento contínuo da qualidade do ar e segurança sanitária.

Na pesquisa de Colella, Rossi e Bianchi (2022), foi implementado um Sistema de Inferência *Fuzzy* (*FIS*) para monitoramento da qualidade do ar em salas cirúrgicas, com foco na prevenção de infecções no local cirúrgico. O sistema avalia variáveis como temperatura, umidade, partículas suspensas e CO₂, ajustando dinamicamente a ventilação conforme os riscos identificados. Testes em ambiente hospitalar real demonstraram que o *FIS* é capaz de identificar variações críticas e promover ações corretivas eficazes, reduzindo o risco de contaminação e promovendo maior segurança nos procedimentos médicos.

Wahid et al. (2019) propuseram uma abordagem híbrida que combina o Algoritmo dos Vaga-lumes (*Firefly Algorithm*, *FA*) com o Algoritmo Genético (*Genetic Algorithm*, *GA*) para a otimização do consumo energético em edifícios inteligentes. Sensores de qualidade do ar, temperatura e umidade alimentam um sistema baseado em lógica *fuzzy*, que realiza ajustes automáticos nos sistemas de iluminação, ventilação e aquecimento.

A combinação dos métodos *FA* e *GA* resultou em uma maior eficiência energética, com reduções expressivas no consumo sem comprometer o conforto dos ocupantes. Os resultados obtidos indicam que essa abordagem híbrida supera os sistemas de controle convencionais em termos de tempo de resposta e economia de energia.

Por fim, Ly et al. (2019) desenvolveram um modelo de previsão para concentrações de NO₂ e CO em áreas urbanas, utilizando um sistema de inferência *fuzzy* adaptativo otimizado com Recozimento simulado e otimização por enxame de partículas. O sistema utilizou dados de sensores de gás e variáveis meteorológicas para prever, com alta acurácia, a poluição atmosférica horária. A análise de sensibilidade destacou os sensores de NO₂ e hidrocarbonetos não metânicos como os mais influentes. O modelo demonstrou ser eficaz para aplicação em áreas urbanas densamente povoadas, contribuindo para o planejamento de estratégias voltadas à melhoria da qualidade do ar.

A Tabela 2 apresenta de forma organizada as ferramentas utilizadas, os resultados obtidos e as principais contribuições dos trabalhos citados, com o objetivo de facilitar a análise comparativa entre as abordagens. Ressalta-se que o último trabalho listado corresponde ao presente estudo, permitindo, assim, a contextualização de suas contribuições em relação às propostas previamente desenvolvidas.

Tabela 2 – Resumo dos trabalhos relacionados com ênfase nos autores, ferramentas e contribuições

Autor	Ferramentas	Resultados e Contribuições
Mudholkar e Patil (2019)	Controlador fuzzy otimizado por algoritmo genético (GAFLC), índice PMV, MATLAB/Simulink, microcontrolador ATmega 328	Controlador eficaz para sistemas de ar-condicionado split; mantém conforto térmico dentro dos limites recomendados; validação por simulação e hardware; contribui para otimização adaptativa de sistemas HVAC.

Bushnag (2022)	Sistema de monitoramento e controle climático baseado em lógica fuzzy, sensores de poluentes (CO ₂ , VOCs)	Sistema dinâmico e preciso para controle integrado de qualidade do ar, temperatura e umidade; validação via simulações e testes; mantém parâmetros ideais em tempo real para ambientes fechados.
Liu (2021)	Sistema inteligente com NodeMCU, sensores para temperatura, umidade e CO ₂ , integração IoT via ThingSpeak	Monitoramento remoto e em tempo real da qualidade do ar em estufas agrícolas; controle automático de ventilação e dispositivos; sistema de alerta para variações ambientais; promove saúde das plantas e eficiência agrícola.
Saini, Dutta e Marques (2022)	Sistema adaptativo ADFIST (árvore de inferência fuzzy dinâmica), sensores IoT, otimização global e por enxame de partículas	Previsão precisa da concentração de poluentes internos; sistema adaptativo aplicável a múltiplos ambientes; integração IoT para monitoramento contínuo; contribuição para ambientes internos mais seguros e saudáveis.
Widhiada et al. (2019)	Controlador híbrido Fuzzy-PID, microcontrolador Arduino Mega 2560	Controle eficaz da temperatura e umidade em incubadoras infantis; desempenho superior ao PID tradicional; resposta rápida e precisa às variações ambientais; importante para saúde de bebês prematuros.
Dionova et al. (2020)	Controlador lógico fuzzy (FLC), sensores MQ-135, MQ-7, MQ-9, sistema de ventilação com exaustores e sprinklers	Sistema para monitoramento e controle da qualidade do ar interno; classifica poluentes e ajusta ventilação automaticamente; melhora conforto térmico e saúde dos ocupantes; uso de sensores de baixo custo.
Pierre et al. (2023)	Internet das Coisas (IoT), Sistema de Inferência Fuzzy, sensores ambientais (temperatura, umidade, CO ₂ , ocupação)	Monitoramento inteligente em salões públicos durante a pandemia de COVID-19; identificação em tempo real de riscos de contaminação; acionamento automático de respostas como ajuste de ventilação e controle de acesso; alternativa de baixo custo e escalável para ambientes coletivos.

Colella, Rossi e Bianchi (2022)	Sistema de Inferência <i>Fuzzy</i> (FIS), sensores de alta precisão para temperatura, umidade, partículas e CO ₂	Avaliação da qualidade do ar em salas cirúrgicas; prevenção de infecções; ajusta ventilação para condições ideais; reduz contaminação do ar e riscos de infecção; validado em ambiente real.
Wahid et al. (2019)	Abordagem híbrida com algoritmos Firefly (FA), genético (GA), controladores fuzzy, sensores ambientais	Otimização do consumo energético em edifícios inteligentes; sistema ajusta ventilação, iluminação e aquecimento; maior eficiência energética sem comprometer conforto; supera controladores tradicionais.
Ly et al. (2019)	Modelo ANFIS otimizado por Simulated Annealing (SA) e Particle Swarm Optimization (PSO), sensores multisensores	Previsão precisa das concentrações de NO ₂ e CO em áreas urbanas; modelo sensível a variáveis meteorológicas e sensores específicos; apoio para estratégias de controle da poluição do ar causada pelo tráfego em ambientes urbanos.
O Autor (2025)	Lógica <i>fuzzy</i> com implementação de extração, transformação e carregamento de dados, além de análise comparativa com o controle proporcional–integral–derivativo (PID).	Classificação da qualidade do ar interno em tempo real, com acionamento automático de um umidificador, visando à melhoria das condições ambientais no ambiente monitorado.

Fonte: O Autor (2025)

Assim como os trabalhos previamente mencionados, este estudo tem como objetivo aprimorar a qualidade do ar, promovendo ambientes internos mais confortáveis e saudáveis, considerando os diferentes contextos apresentados. A metodologia adotada baseia-se principalmente na utilização da lógica *fuzzy* para alcançar esses objetivos. Embora haja variações na quantidade de regras empregadas entre os estudos, com alguns utilizando um número maior e outros optando por um conjunto mais reduzido, todos compartilham o procedimento de normalização dos valores nítidos por meio da defuzzificação da máquina de inferência.

Este trabalho, no entanto, apresenta algumas diferenças significativas em relação às metodologias tradicionais. Toda a implementação computacional da lógica difusa, incluindo o software e os códigos-fonte, está incorporada diretamente no dispositivo embarcado, em contraste com os estudos que realizam o processamento em computadores externos. Com isso, a

execução e a análise em tempo real dos dados captados pelos sensores ocorrem diretamente no microcontrolador Arduino, conforme será detalhado adiante.

Os testes foram conduzidos exclusivamente em uma sala de aula, durante diferentes estações do ano, o que confere uma importante especificidade aos resultados, especialmente diante da presença significativa de pessoas no ambiente. A coleta, o armazenamento e o processamento dos dados seguem a metodologia de extração, transformação e carregamento (ETL), amplamente empregada na engenharia de dados, assegurando organização e confiabilidade das informações.

Dessa forma, os dados são adquiridos diretamente pelo sistema embarcado, armazenados em um repositório online e, posteriormente, transformados para gerar análises numéricas e visuais detalhadas com base na lógica *fuzzy*. O sistema também incorpora o controle de um umidificador, cuja atuação é determinada pela variável de saída *Conforto* gerada pelo sistema *fuzzy*, possibilitando a avaliação do impacto desse recurso na melhoria da qualidade do ar e no bem-estar geral do ambiente. Destaca-se que, embora o umidificador atue diretamente sobre a umidade relativa, sua utilização também provocou influência indireta sobre outras variáveis ambientais monitoradas, evidenciando uma resposta ambiental integrada decorrente da atuação do sistema.

Além disso, o presente trabalho realiza uma comparação com o método Proporcional–Integral–Derivativo (PID), amplamente utilizado em sistemas de controle. A análise comparativa reforça a eficácia da abordagem baseada em lógica *fuzzy*, evidenciando suas vantagens em termos de adaptação e resposta às variações ambientais, quando comparada a uma técnica convencional amplamente consolidada.

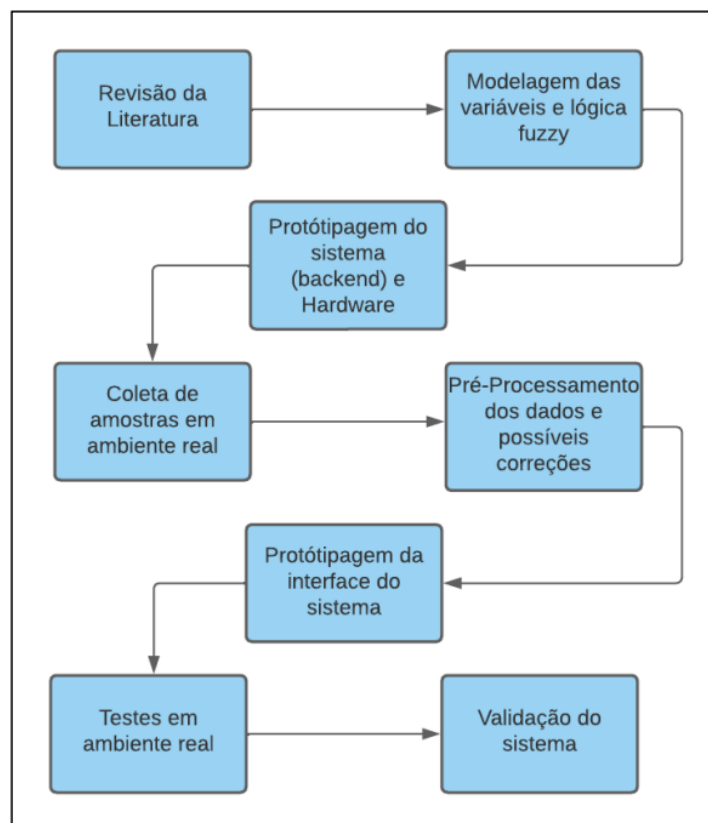
4 METODOLOGIA

Para solucionar o problema de maneira eficaz, foram adotadas as recomendações metodológicas apresentadas por Prodanov e Freitas (2013). Dessa forma, definiu-se que a pesquisa seguiria uma abordagem explicativa, uma vez que se concentra na criação de modelos, experimentos e soluções voltadas para a melhoria da qualidade do ar em ambientes internos. Em outras palavras, trata-se de uma pesquisa baseada em métodos empíricos, na qual a aplicação e validação da tecnologia e dos métodos propostos constituem a base principal para a construção da solução, sendo esta desenvolvida por meio de aplicações práticas.

No contexto dessa linha de pesquisa, foi implementado o método científico do tipo experimental. A escolha desse método deve-se ao fato de que foram realizadas coletas de variáveis associadas à qualidade do ar, com o objetivo de viabilizar a formulação de uma resposta fundamentada para a problemática em questão.

Consequentemente, é importante destacar que fatores como a especificidade de cada caso, as características do ambiente estudado, as condições climáticas predominantes e outras variáveis não passíveis de controle exerceram influência significativa sobre o desenvolvimento e os resultados da pesquisa. Com base nessas definições, elaborou-se um fluxograma, apresentado na Figura 6, cujo objetivo é identificar as etapas do processo até a fase de validação do sistema.

Figura 6 – Etapas do processo de metodologia.



Fonte: O Autor (2025)

Na etapa de revisão de literatura, realizou-se uma pesquisa minuciosa de trabalhos semelhantes ou com objetivos equivalentes. Foram definidos diversos parâmetros relacionados à melhoria da qualidade do ar por meio da lógica difusa, tais como os métodos utilizados, as variáveis analisadas, os dispositivos de interface, os microcontroladores empregados, os sensores adotados e a usabilidade em diferentes locais para a aplicação do método.

Em seguida, iniciou-se a fase de modelagem das variáveis segundo a lógica difusa. Nesse estágio, as variáveis previamente selecionadas com base no estudo foram incorporadas a um modelo que as utilizava como entradas para um sistema fuzzy, cuja saída consistia na resposta para a melhoria do ambiente. Inicialmente, o atuador escolhido para influenciar positivamente na qualidade do ar foi um aparelho umidificador de ar.

Na terceira etapa, foram desenvolvidos os dispositivos de hardware responsáveis pela coleta de dados do ambiente. Para isso, sensores selecionados conforme as variáveis escolhidas foram conectados a um microcontrolador, permitindo o envio e o tratamento adequado das informações sobre a qualidade do ar para as etapas subsequentes de pré-processamento e análise. Em seguida, ocorreu a implementação do software back-end do sistema, englobando os processamentos, o armazenamento e todas as lógicas adotadas pelo método, além da programação do microcontrolador integrado aos sensores. O próximo passo consistiu na primeira fase de coleta de amostras das variáveis selecionadas em um ambiente real.

Para esta etapa, foram utilizados os componentes de hardware e software desenvolvidos anteriormente, permitindo a observação do comportamento dos dados e possibilitando a realização de análises para obter saídas voltadas à melhoria da qualidade do ar em um ambiente de testes. Os dados coletados passaram por um pré-processamento, no qual foram corrigidos possíveis erros e inconsistências provenientes da fase de coleta. Esse procedimento foi essencial para evitar problemas durante as análises aprofundadas baseadas na lógica difusa.

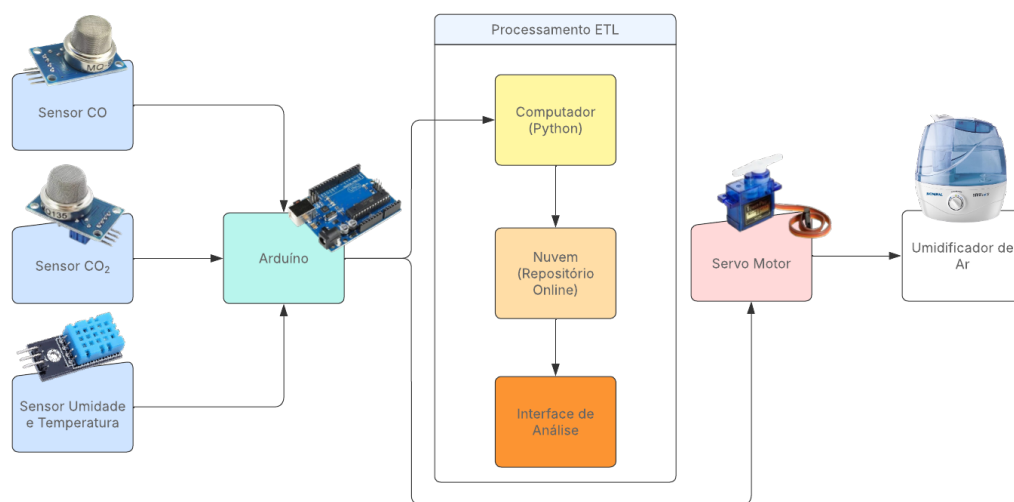
Nesta fase, além do desenvolvimento da interface do sistema para monitoramento pelos usuários, foi implementado um umidificador de ar controlado pela variável “conforto”. A variável “conforto”, resultante da combinação das variáveis de entrada (umidade, CO₂, CO e temperatura) e das regras de inferência fuzzy, foi utilizada para ajustar automaticamente o funcionamento do umidificador, visando melhorar a umidade do ar conforme necessário. Essa abordagem permitiu uma atuação mais precisa do umidificador, garantindo que a umidade fosse ajustada de acordo com as condições ambientais detectadas pelo sistema.

Esperava-se que, ao melhorar a umidade do ar de forma controlada, houvesse um impacto indireto nas outras variáveis ambientais, como a concentração de CO₂, CO e a temperatura. A umidificação adequada poderia influenciar positivamente na dispersão de poluentes e na percepção térmica do ambiente, contribuindo para um aumento geral no nível de conforto. A análise desses efeitos foi fundamental para avaliar a eficácia do sistema proposto e para entender como a interação entre as variáveis ambientais afetava o conforto dos ocupantes.

4.1 Sistema Proposto

A Figura 7 apresenta o fluxograma que representa o funcionamento geral do projeto. O fluxograma ilustra o fluxo de dados, desde a coleta por sensores específicos, como os de CO, CO₂, umidade e temperatura, passando pelo microcontrolador (*Arduino*), até o processamento ETL. Este processamento ocorre tanto no computador, onde são realizadas as transformações e análises em Python, quanto em um repositório na nuvem, que armazena os dados para análise posterior. Finalmente, uma interface de análise é responsável por exibir os resultados de maneira acessível ao usuário.

Figura 7 – Fluxograma representativo do projeto de avaliação da qualidade do ar.



Fonte: O Autor (2025)

O diagrama apresenta as variáveis ambientais coletadas por sensores, que são umidade, temperatura, CO e CO₂, representadas nos quadros em azul, os quais fornecem os dados de entrada para o sistema. Essas variáveis são processadas por meio de regras *fuzzy* que avaliam a situação do ambiente quanto ao conforto. A lógica do sistema foi projetada para lidar com a imprecisão típica dos dados ambientais, permitindo que o modelo ofereça respostas graduais e condizentes com diferentes cenários reais. O penúltimo quadro do fluxograma representa o atuador do sistema, responsável por controlar automaticamente o funcionamento do umidificador, mostrado no último quadro, por meio de um servo motor que ajusta seu nível de atuação conforme a necessidade.

O modelo *fuzzy* foi estruturado com a definição de variáveis de entrada. A temperatura, medida em graus Celsius (°C), é um parâmetro fundamental para avaliar o conforto térmico dos ocupantes. A umidade, expressa em percentual (%) de umidade relativa do ar, impacta tanto a sensação de conforto quanto a potencial formação de fungos e bactérias. As concentrações de CO₂ e CO foram medidas em partes por milhão (ppm), servindo como indicadores importantes para a ventilação e a qualidade geral do ar.

Para cada uma dessas variáveis, foram estabelecidas funções de pertinência com base em critérios definidos pela literatura. Essas funções permitem categorizar as variáveis em faixas como “Baixo”, “Moderado” e “Alto”, oferecendo uma representação detalhada das condições ambientais.

Além das variáveis de entrada, o modelo inclui regras *fuzzy* que combinam essas variáveis para determinar o nível de conforto ambiental. As regras foram formuladas com base em conhecimento especializado e práticas recomendadas para ambientes internos. Por exemplo, uma regra pode estipular que se a temperatura for “Quente” e a umidade for “Alta”, o conforto ambiental será classificado como “Ruim”.

A variável de saída, conforto ambiental, será definida com base no *IAQ*, considerando a combinação das variáveis de entrada para fornecer uma avaliação geral do ambiente. Vale destacar que o sistema fuzzy, com seus código e execução, estão completamente embutidos no Arduino, sendo representados pelo quadro verde na estrutura do diagrama apresentado na Figura 7.

A coleta de dados foi realizada em uma sala de aula ao longo de um mês, em dois períodos do ano, considerando diferentes condições de ocupação, incluindo momentos em que a sala estava vazia e momentos em que estava ocupada. Essa abordagem permite capturar como as condições ambientais variam com o uso do espaço. Sensores calibrados foram utilizados para medir temperatura, umidade, CO₂ e CO. A calibração dos sensores é fundamental para garantir a precisão das medições. Os dados foram registrados em intervalos regulares durante o período de coleta e os sensores foram posicionados de maneira a representar adequadamente as condições da sala.

Os dados foram armazenados em um repositório que é atualizado remotamente a cada coleta de dados, utilizando um fluxo de dados ETL (quadro de processamento ETL na Figura 7) e serão analisados na seção de Resultados. Isso incluiu a verificação da integridade dos dados e a formatação adequada. As análises do serão realizadas posteriormente, com base nos dados obtidos, utilizando o modelo *fuzzy* desenvolvido.

Cada variável será classificada conforme as funções de pertinência e combinada através das regras *fuzzy* para determinar o nível de conforto. A análise detalhada dos dados coletados e a validação do modelo *fuzzy* serão conduzidas em etapas futuras. Através da análise dos dados reais, serão realizados ajustes no modelo e calibradas as funções de pertinência e regras, com o objetivo de melhorar a precisão e a aplicabilidade do modelo para a avaliação da qualidade do ar.

4.2 Ferramentas Utilizadas

As principais ferramentas que fazem parte do projeto serão descritas a seguir, quaisquer dados, resultados, funções ou conclusões deste trabalho em algum momento teve contato direto

com alguma destes elementos.

4.2.1 *Python*

Python, uma linguagem de programação de alto nível criada por Guido van Rossum no final da década de 1980, rapidamente se tornou uma das ferramentas mais populares e versáteis do mundo tecnológico (ROSSUM, 1991). Sua sintaxe clara e concisa, inspirada na linguagem natural, a torna acessível tanto para iniciantes quanto para programadores experientes. A versatilidade do *Python* o torna uma escolha ideal para diversas áreas, desde o desenvolvimento *web* até a ciência de dados e a inteligência artificial. Para a Python Software Foundation (2023), a crescente popularidade de *Python* se deve à sua comunidade ativa, que contribui para o desenvolvimento de novas ferramentas e recursos, e à sua capacidade de se adaptar a diferentes plataformas e sistemas operacionais.

Para o desenvolvimento deste projeto, diversas bibliotecas do ecossistema *Python* foram utilizadas, permitindo lidar com diferentes aspectos do fluxo de trabalho, desde a coleta e manipulação dos dados até a sua análise e armazenamento. A seguir, detalhamos as principais bibliotecas utilizadas e suas finalidades:


- ***Pandas***: Biblioteca poderosa para manipulação e análise de dados, usada para carregar, processar e formatar os dados coletados.
- ***PySerial***: Usada para estabelecer a comunicação entre o microcontrolador (*Arduino*) e o computador através de portas seriais.
- ***Pytz***: Permite o gerenciamento de fusos horários, garantindo que os dados sejam coletados com marcas de tempo corretas.
- ***Time***: Utilizada para funções relacionadas ao tempo, como pausas (*sleep*) e medições temporais.
- ***Re (Regular Expressions)***: Usada para processar e validar dados textuais com padrões específicos.
- ***Datetime***: Empregada para manipulação e formatação de datas e horários.
- ***CSV***: Biblioteca padrão para leitura e escrita de arquivos no formato CSV, facilitando o armazenamento e a troca de dados tabulares.
- ***Os***: Utilizada para interagir com o sistema operacional, como acessar diretórios e arquivos.
- ***Oauth2client.service_account***: Ferramenta essencial para autenticação e acesso seguro a *APIs*, como o Google *Sheets*, onde os dados foram armazenados.

Essas bibliotecas, combinadas com o modelo *fuzzy* descrito anteriormente, permitiram desenvolver uma solução robusta e eficiente para a avaliação da qualidade do ar em ambientes internos.

4.2.2 *Arduino*

O *Arduino*, apresentado na Figura 8, é uma plataforma de hardware de código aberto que foi fundamental no desenvolvimento do projeto, sendo responsável por gerenciar todo o processo de captura de dados dos sensores, processamento da lógica *fuzzy* e envio das informações para o computador via comunicação *serial USB*. Nesse projeto, foi utilizada a biblioteca *Fuzzy.h* para implementar a lógica *fuzzy*, que permitiu realizar decisões baseadas em regras linguísticas sobre os dados dos sensores.

Figura 8 – Arduino Uno.



Fonte: Olhar Digital (2024)

A biblioteca *DHT.h* foi utilizada para interagir com o sensor de temperatura e umidade, permitindo a captura dos dados ambientais em tempo real. A biblioteca *math.h* foi empregada para realizar cálculos logarítmicos, necessários para o ajuste dos valores medidos. A lógica *fuzzy* foi implementada diretamente no *Arduino* utilizando a biblioteca *fuzzy.h*, responsável por realizar a inferência e a defuzzificação dos dados capturados, possibilitando o controle eficiente das variáveis ambientais do sistema.

Com essas bibliotecas, o *Arduino* processa os dados recebidos dos sensores em tempo real, executando a lógica *fuzzy* para determinar as ações a serem tomadas. Em seguida, os dados processados são enviados ao computador através de uma interface *serial USB*, permitindo que os resultados sejam visualizados ou armazenados para análise posterior (CC, 2023).


O uso do *Arduino* em projetos como este tem se mostrado uma solução eficiente e acessível, com sua ampla gama de bibliotecas e a facilidade de integração com diferentes sensores e sistemas. Banzi (2010) afirma que a sua flexibilidade torna o *Arduino* uma escolha

popular para prototipagem rápida e desenvolvimento de sistemas de controle baseados em sensores, como é o caso demonstrado neste projeto.

4.2.3 DHT11

No projeto em questão, o sensor DHT11 representado na Figura 9 foi conectado ao *Arduino* para coletar dados de temperatura e umidade do ambiente. O DHT11 é um sensor eletrônico de baixo custo e fácil de utilizar, amplamente empregado em projetos com microcontroladores como o *Arduíno*. Especializado na medição de temperatura e umidade relativa do ar, o DHT11 oferece uma solução prática e precisa para diversas aplicações, como sistemas de monitoramento ambiental e automação residencial. Sua interface simples, com apenas três pinos, facilita a integração em circuitos diversos, tornando-o uma escolha popular entre os entusiastas da eletrônica e *makers*.

Figura 9 – Sensor DHT11.



Fonte: Robocore (2017)


A versatilidade do sensor DHT11 se deve à sua capacidade de fornecer dados precisos sobre as condições climáticas locais. Ao combinar um termistor e um sensor capacitivo, o DHT11 é capaz de medir a temperatura em graus Celsius e a umidade relativa do ar em porcentagem (AOSONG ELECTRONICS, 2015). Essas informações coletadas foram essenciais para o controle e monitoramento das condições ambientais no projeto, permitindo uma resposta eficiente e dinâmica do sistema. Além disso, a existência de diversas bibliotecas e exemplos de código disponíveis online, como a biblioteca DHT da Adafruit Industries (2023), facilita o desenvolvimento de projetos com o DHT11.

4.2.4 SG90

No projeto em questão, o servomotor modelo SG90, representado na Figura 10, foi utilizado para controlar mecanicamente o atuador do sistema, responsável por ajustar a intensidade do umidificador. O SG90 é um servo motor micro, amplamente utilizado em projetos com microcontroladores como o Arduino devido ao seu baixo custo, tamanho compacto e facilidade de integração.

Este componente permite o posicionamento preciso do eixo por meio de sinais *PWM* (*Pulse Width Modulation*), oferecendo torque suficiente e resposta rápida para garantir o ajuste dinâmico do umidificador conforme a lógica *fuzzy* determina o nível de conforto do ambiente.

Figura 10 – Servomotor modelo SG90 utilizado no controle do umidificador.



Fonte: Robocore (2025)

A utilização do SG90 no sistema permite que o microcontrolador execute comandos precisos para alterar a posição do atuador, possibilitando ajustes automáticos do fluxo de umidade liberado no ambiente. Essa capacidade é fundamental para a implementação da lógica de controle que visa otimizar o conforto no espaço monitorado, garantindo eficiência e responsividade ao sistema.


4.2.5 MQ-9

Também foi utilizado o sensor de gás MQ-9 (Figura 11) que foi conectado ao Arduino e foi responsável pela coleta de dados relacionados à concentração de monóxido de carbono (CO). O MQ-9 é um componente eletrônico semiconductor amplamente utilizado para detectar gases inflamáveis e tóxicos, como o CO, além de outros gases como metano, propano e butano.

Sua alta sensibilidade e baixo custo o tornam ideal para aplicações em sistemas de segurança, monitoramento ambiental e controle industrial. Quando exposto ao gás, a resistência elétrica do sensor varia proporcionalmente à concentração do mesmo, permitindo a detecção e quantificação dos gases presentes no ambiente.

Uma das principais aplicações do MQ-9 é em sistemas de detecção de gás em ambientes domésticos. Kim e Lee (2018) desenvolveram um sistema de baixo custo baseado no MQ-9 para detectar vazamentos de gás em residências, demonstrando a eficácia do sensor em ambientes reais. A versatilidade do MQ-9 se destaca pela sua capacidade de detectar uma ampla gama de gases, o que o torna uma escolha popular em sistemas de monitoramento ambiental e de segurança.

Figura 11 – Sensor MQ-9.



Fonte: HAOYU Electronics (2018)

A calibração do sensor MQ-9 é um processo fundamental para garantir a precisão das leituras (PIERCE; YANTASEE, 2012).


4.2.6 MQ-135

No projeto, o sensor de gás MQ-135 semelhante a modelo da Figura 12, foi conectado ao Arduino e utilizado para medir a concentração de dióxido de carbono (CO_2) no ambiente. Esse sensor semicondutor é amplamente empregado na detecção de gases tóxicos no ar devido à sua sensibilidade e baixo custo. Seu funcionamento baseia-se na variação da resistência elétrica de um material semicondutor poroso, geralmente óxido de estanho (SnO_2), quando exposto a diferentes gases. A adsorção de moléculas de gás na superfície do material altera sua condutividade elétrica, modificando assim a resistência entre dois eletrodos. Essa variação na resistência é proporcional à concentração do gás, permitindo sua quantificação de forma eficiente.

O MQ-135 é especialmente sensível a gases como amônia, dióxido de carbono, benzeno e óxido nítrico, possuindo faixas de detecção que variam de acordo com o gás específico. Essa característica torna-o uma ferramenta valiosa para monitorar a qualidade do ar em ambientes internos e externos, como residências, indústrias e sistemas de ventilação. Entretanto, a calibração

regular do sensor é essencial para garantir a precisão das medições. Fatores como temperatura, umidade e a presença de outros gases e partículas podem influenciar significativamente sua resposta.

Figura 12 – Sensor MQ-135.



Fonte: Rajguru Electronics (2018)

Além disso, a seletividade do MQ-135 pode ser limitada, o que significa que ele pode responder de maneira similar a diferentes gases, dificultando a identificação individual de cada composto em misturas complexas. Para mitigar essa limitação, técnicas de processamento de sinal e algoritmos de aprendizado de máquina podem ser empregados para aprimorar a precisão e a seletividade do sensor. A combinação do MQ-135 com outros sensores, aliada ao uso de modelos matemáticos mais sofisticados, permite a criação de sistemas de monitoramento de gases mais robustos e confiáveis (KIM; LEE, 2018).

4.3 Variáveis Utilizadas

A qualidade do ar em ambientes internos desempenha um papel crucial na saúde e no bem-estar dos ocupantes de edifícios. A exposição a poluentes atmosféricos em ambientes fechados tem sido associada a diversos problemas de saúde, incluindo doenças respiratórias, alergias, irritações nos olhos e na pele, além de impactos no sistema cardiovascular e nervoso central (DOCKERY et al., 2019) (WORLD HEALTH ORGANIZATION, 2020a).

4.3.1 Temperatura

A temperatura é uma variável crucial em ambientes internos, influenciando diretamente o conforto dos ocupantes e o desempenho de processos fisiológicos e tecnológicos. Estudos

indicam que a temperatura interna ideal deve estar entre 20°C e 24°C, variando conforme o tipo de atividade e a ocupação do espaço (ASHRAE, 2017). O controle e monitoramento preciso da temperatura são essenciais para garantir que as condições ambientais atendam às necessidades dos indivíduos, promovendo não apenas conforto, mas também saúde e bem-estar.

Para medir a temperatura de forma eficiente e acessível, foi utilizado o sensor DHT11, amplamente disponível e de baixo custo. Como já mencionado na Seção 4.2.3, esse sensor de temperatura e umidade foi escolhido por ser compacto e de fácil instalação, oferecendo uma solução prática e precisa para sistemas de monitoramento da qualidade do ar.

Com seu baixo custo e desempenho confiável, o DHT11 se destaca como uma opção ideal para a coleta de dados em projetos de qualidade do ar. Além disso, é importante ressaltar que a temperatura ideal é um fator-chave em sistemas HVAC (aquecimento, ventilação e ar condicionado), que ajustam a climatização do ambiente de acordo com as preferências dos usuários (CIBSE, 2015).

4.3.2 Umidade

A umidade é uma variável essencial para a manutenção de um ambiente saudável, impactando diretamente a qualidade do ar e o bem-estar dos ocupantes. Sua concentração afeta a prevenção de doenças respiratórias, a proliferação de fungos e o conforto térmico (ASHRAE, 2017). Os níveis ideais de umidade relativa em ambientes internos variam entre 30% e 60%, dependendo da estação e das atividades realizadas (ASHRAE, 2017).

Para monitoramento eficiente, foi utilizado o sensor DHT11, que permite a medição precisa da umidade em tempo real, possibilitando ajustes automáticos em sistemas de ventilação ou desumidificação (CIBSE, 2015). A combinação de baixo custo e alta precisão desses sensores contribui para o controle eficaz da qualidade do ar.

4.3.3 Monóxido de Carbono

O monóxido de carbono (CO) conforme descrito na Seção 2.2.3 é um gás incolor, inodoro e tóxico, gerado pela queima incompleta de materiais orgânicos. Sua presença em ambientes internos pode representar riscos à saúde, ao comprometer o transporte de oxigênio no sangue (ENVIRONMENTAL PROTECTION AGENCY, 2020b). Devido à sua alta confiabilidade e custo acessível, sensores de CO são amplamente utilizados para monitorar níveis perigosos deste gás em ambientes fechados.

No projeto, o sensor MQ-9 (Seção 4.2.5) foi utilizado para medir a concentração de CO, permitindo a detecção precoce de riscos. A medição contínua do CO é essencial para garantir a segurança dos ocupantes, viabilizando ações preventivas, como ventilação adequada (ENVIRONMENTAL PROTECTION AGENCY, 2020b).

4.3.4 Dióxido de Carbono

O dióxido de carbono (CO_2) é um gás natural presente na atmosfera, cuja concentração interna é um importante indicador da eficiência da ventilação de um ambiente. Embora o CO_2 não seja tóxico em concentrações típicas, níveis elevados podem prejudicar o conforto e a produtividade dos ocupantes, levando a sintomas como fadiga, dores de cabeça e dificuldades de concentração entre outros problemas já citados na Seção 2.2.4. A escolha do CO_2 como variável de monitoramento é justificada não apenas pela sua relevância para a qualidade do ar, mas também pela facilidade com que pode ser medido com sensores de baixo custo e alta precisão.

Neste projeto, o sensor MQ-135 foi utilizado para coletar os dados de CO_2 , devido à sua capacidade de detectar com precisão a concentração deste gás em ambientes internos. O monitoramento contínuo do CO_2 é amplamente utilizado como um indicador da ventilação do ambiente. Concentrações elevadas de CO_2 sinalizam a necessidade de aumentar a circulação de ar, o que pode ser alcançado por meio de sistemas de ventilação mecânica ou natural (ENVIRONMENTAL PROTECTION AGENCY, 2020a). A capacidade de medir o CO_2 de forma eficaz e econômica contribui para a manutenção de um ambiente saudável, assegurando que os níveis de oxigênio permaneçam adequados para os ocupantes.

4.3.5 Escolha das Variáveis

As variáveis mencionadas: temperatura, umidade, CO, e CO_2 , foram selecionadas com base em sua relevância para a saúde e o conforto dos ocupantes, bem como pela facilidade de medição e confiabilidade proporcionada pelos sensores de baixo custo e pequeno porte. Embora outras variáveis possam ser igualmente importantes, como a concentração de partículas finas ($\text{PM}_{2.5}$), a medição de gases específicos ou de compostos orgânicos voláteis (*VOCs*), os sensores para essas variáveis tendem a ser mais caros ou apresentar limitações quanto à precisão em ambientes de baixo custo.

Portanto, a escolha dessas variáveis foi motivada pela necessidade de garantir uma coleta de dados confiável sem comprometer os custos do sistema. O baixo preço e a acessibilidade dos sensores de temperatura, umidade, CO e CO_2 tornam essas variáveis particularmente adequadas para sistemas de monitoramento de qualidade do ar, permitindo que sejam amplamente aplicadas em diferentes tipos de ambientes internos com alta eficiência e precisão.

4.4 Modelagem das Variáveis de Lógica Fuzzy

Nesta seção, são apresentadas as variáveis de temperatura, umidade, CO_2 e CO, juntamente com suas respectivas funções de pertinência, que foram utilizadas no sistema fuzzy deste projeto para as etapas de teste. Estas variáveis são fundamentais para avaliar a qualidade

do ar em ambientes internos, uma vez que influenciam diretamente o conforto e a saúde dos ocupantes. Para a modelagem da qualidade do ar, utilizou-se um sistema de inferência fuzzy, conforme descrito por (BRAINVENDRA, 2020), que integra dados e diretrizes de especialistas da OMS e da EPA. Esse sistema oferece uma abordagem adaptativa, considerando incertezas e variabilidades nos dados ambientais, o que permite uma avaliação mais precisa e confiável da qualidade do ar interior.

4.4.1 Função de Pertinência para Temperatura

A temperatura é uma variável crucial para o conforto humano, sendo classificada em três categorias distintas para o propósito de lógica difusa neste projeto. A faixa considerada ideal, entre 18°C e 25°C, é designada como “Boa”, por proporcionar condições térmicas adequadas para os ocupantes (MENDELL; HEATH, 2006). Temperaturas abaixo de 15°C são classificadas como “Frio”, podendo causar desconforto e, em exposições prolongadas, até problemas de saúde, como hipotermia (FISK, 2017).

Vale destacar que, embora valores próximos de 20°C estejam dentro da faixa ideal, ainda podem ser percebidos como frios por algumas pessoas, dependendo de fatores individuais e contextuais. Já as temperaturas superiores a 28°C são classificadas como “Calor”, onde o desconforto aumenta significativamente e pode levar a sérios riscos à saúde, como desidratação, exaustão pelo calor e até insolação, especialmente em exposições prolongadas (WHO, 2009). Essa separação por faixas é apresentada na Tabela 3.

Tabela 3 – Classificação da temperatura para lógica fuzzy.

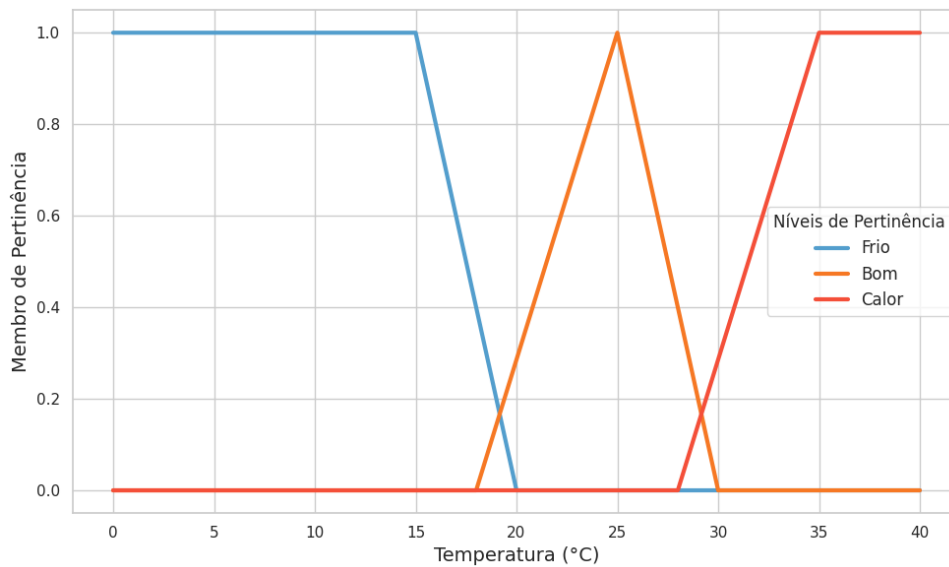
Classificação	Faixa de Temperatura
Frio	Abaixo de 20°C
Boa	Entre 18°C e 30°C
Calor	Acima de 28°C

Fonte: O Autor (2025)

Vale ressaltar que, embora as faixas de temperatura adotadas neste trabalho estejam alinhadas com as definições apresentadas na literatura especializada, esses valores podem variar de especialista para especialista (sendo observado durante pesquisa literária), dado que as percepções de conforto térmico e os riscos à saúde podem ser influenciados por diferentes fatores, como características individuais e contextos ambientais. A Figura 13 ilustra as faixas de valores para temperatura, refletindo estas categorias.

4.4.2 Função de Pertinência para Umidade

A umidade relativa do ar é um fator essencial para o conforto humano e o bem-estar geral. Para o propósito de lógica difusa neste projeto, a umidade foi classificada em três faixas distintas. A faixa considerada ideal, entre 40% e 70%, é classificada como “Boa”, proporcionando um

Figura 13 – Gráfico de Pertinência da Temperatura.

Fonte: O Autor (2025)

ambiente agradável e confortável para os ocupantes. Quando a umidade está dentro dessa faixa, a sensação térmica é mais equilibrada, promovendo bem-estar (MENDELL; HEATH, 2006).

Faixas de umidade entre 30% e 50% são designadas como “Baixa”, podendo ocasionar desconforto, especialmente em climas mais quentes, devido à falta de umidade no ar (FISK et al., 2017). Já a umidade entre 60% e 100% é considerada “Elevada”, o que pode resultar em sensação de abafamento, desconforto e até mesmo riscos à saúde em níveis muito elevados, como no caso de umidade excessiva (KOWALSKI, 2012). Essa classificação por faixas se estabelece conforme a Tabela 4.

Tabela 4 – Classificação da umidade relativa para lógica fuzzy.


Classificação	Faixa de Umidade Relativa
Baixa	Entre 0% e 40%
Boa	Entre 30% e 70%
Elevada	Entre 60% e 100%

Fonte: O Autor (2025)

Vale destacar, assim como na temperatura, que as faixas de umidade consideradas neste trabalho foram adaptadas com base na literatura especializada, porém, a percepção de nível de umidade pode variar conforme analisado de especialista para especialista, condições ambientais e as características individuais de cada pessoa, logo os valores apresentados seguem uma base comum utilizada por autores especialistas já mencionado anteriormente.

A Figura 14 ilustra essas categorias de umidade, refletindo as faixas de valores adotadas para o monitoramento do conforto térmico e saúde.

Figura 14 – Gráfico de Pertinência da Umidade.



Fonte: O Autor (2025)

4.4.3 Função de Pertinência para Dióxido de Carbono (CO₂)

A concentração de dióxido de carbono (CO₂) no ar está diretamente relacionada à qualidade da ventilação do ambiente. Níveis entre 0 e 800 ppm indicam uma qualidade de ar “bom”, sugerindo que o ambiente está bem ventilado (FISK et al., 2017). Quando as concentrações variam de 600 ppm a 1000 ppm, a qualidade do ar é classificada como “alto”, indicando uma ventilação intermediária (KOWALSKI, 2012). Por fim, concentrações entre 1200 ppm e 2000 ppm indicam um ambiente “perigo”, onde a ventilação é insuficiente e pode comprometer a saúde dos ocupantes (MENDELL; HEATH, 2006).


A Tabela 5 apresenta a classificação das faixas de concentração de CO₂ para a lógica *fuzzy*, proporcionando uma base para a definição de regras no sistema de controle da qualidade do ar. A Figura 15 ilustra o comportamento das funções de pertinência utilizadas para essas classificações.

Tabela 5 – Classificação da concentração de dióxido de carbono (CO₂) para lógica *fuzzy*.

Classificação	Faixa de Concentração de CO₂ (ppm)
Bom	Entre 0 e 800 ppm
Alto	Entre 600 e 1000 ppm
Perigo	Entre 1200 e 2000 ppm

Fonte: O Autor (2025)

Figura 15 – Gráfico de Pertinência do CO₂.



Fonte: O Autor (2025)

4.4.4 Função de Pertinência para Monóxido de Carbono (CO)

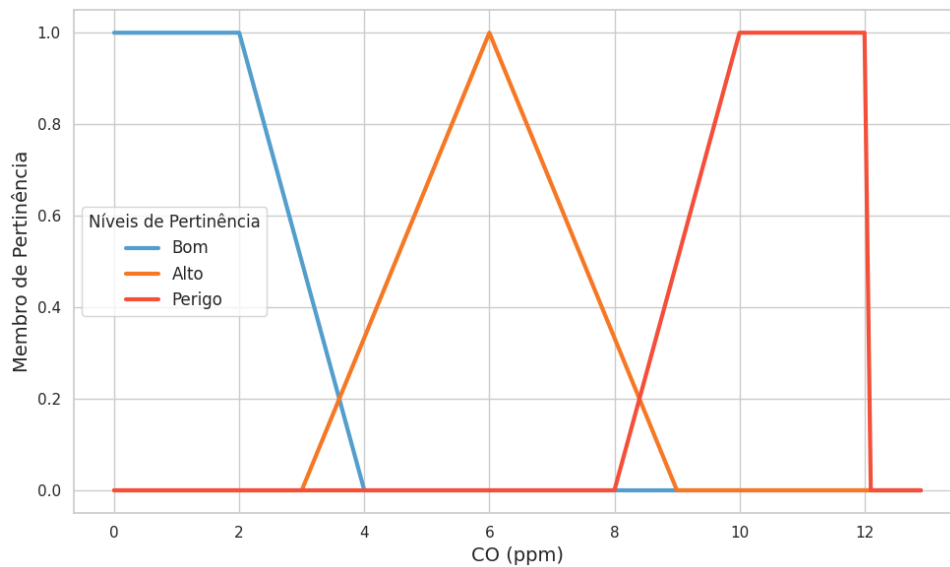
O monóxido de carbono (CO) é um gás tóxico cuja concentração no ambiente está diretamente relacionada aos riscos à saúde. Dependendo da exposição, pode variar de níveis seguros a perigosos. Concentrações entre 0 e 4 ppm são classificadas como “bom”, indicando ausência de risco significativo (WHO, 2006). Níveis entre 3 ppm e 9 ppm são considerados “alto”, sinalizando risco para indivíduos sensíveis (CARBAJAL; LEYVA; MALACARA, 2015). Por fim, concentrações entre 8 ppm e 12 ppm são classificadas como “perigo”, onde a exposição prolongada pode acarretar sérios problemas de saúde (EZZATI; KAMMEN, 2005).

A Tabela 6 apresenta a classificação das faixas de concentração de CO para a lógica *fuzzy*, facilitando a definição de regras para o controle da qualidade do ar. O comportamento das funções de pertinência que definem essas faixas pode ser visualizado no Gráfico de Pertinência da Figura 16.

Tabela 6 – Classificação da concentração de monóxido de carbono (CO) para lógica *fuzzy*.

Classificação	Faixa de Concentração de CO (ppm)
Bom	Entre 0 e 4 ppm
Alto	Entre 3 e 9 ppm
Perigo	Entre 8 e 12 ppm

Fonte: O Autor (2025)

Figura 16 – Gráfico de Pertinência do Monóxido de Carbono (CO).

Fonte: O Autor (2025)

4.4.5 Função de Pertinência para Conforto

A saída do sistema *fuzzy* é representada pela variável conforto, que resulta da combinação das variáveis de entrada (umidade, CO₂, CO e temperatura) e das regras de inferência *fuzzy* (ZADEH, 1994). No contexto do sistema, a variável conforto atua como um índice representativo das condições ambientais, aproximando-se dos conceitos de qualidade do ar interior (IAQ) e conforto térmico. Embora este índice não possa ser interpretado estritamente como IAQ ou conforto térmico, devido à necessidade de considerar outras variáveis adicionais, ele fornece uma métrica aproximada para avaliar o ambiente com base nas variáveis monitoradas.

A classificação da variável conforto é realizada por meio da inferência *fuzzy*, utilizando regras que definem como as variáveis de entrada interagem para influenciar a saída. Cada variável de entrada é quantificada em graus de pertencimento às categorias "Desconfortável", "Confortável" e "Muito Confortável" (HUANG; CHEN, 2019; MELENDEZ; SALAS; MUNOZ, 2019) conforme é apresentado na Tabela 7.

Tabela 7 – Classificação da variável conforto para lógica *fuzzy*.

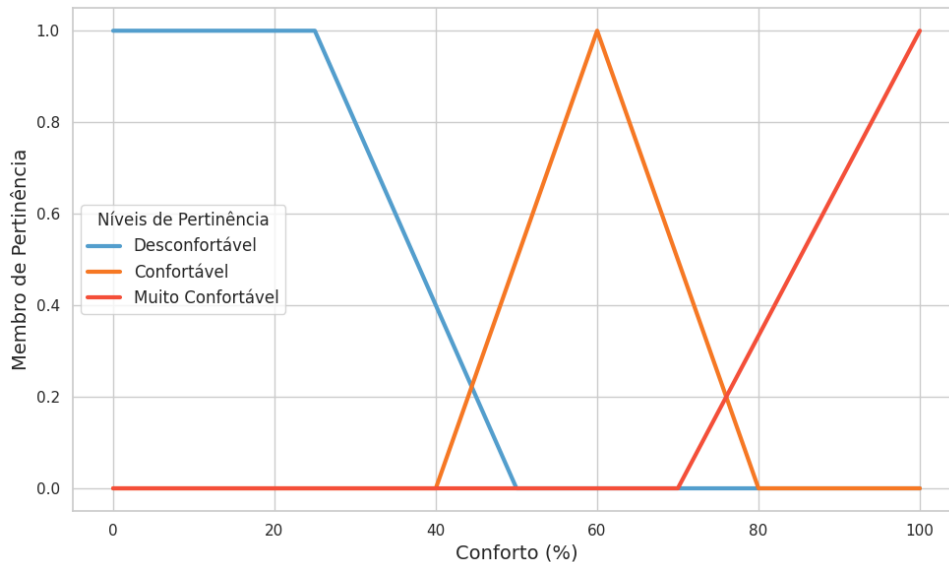
Classificação	Faixa de Valores (%)
Desconfortável	0 a 50
Confortável	40 a 80
Muito Confortável	70 a 100

Fonte: O Autor (2025)

As funções de pertinência dessas categorias são trapezoidais, conforme mostrado na Figura 17. A faixa "Desconfortável" abrange valores de 0 a 50, a categoria "Confortável" varia de

40 a 80, e a classificação "Muito Confortável" ocorre para valores acima de 70, atingindo seu pico em 100.

Figura 17 – Gráfico de Pertinência do Conforto.

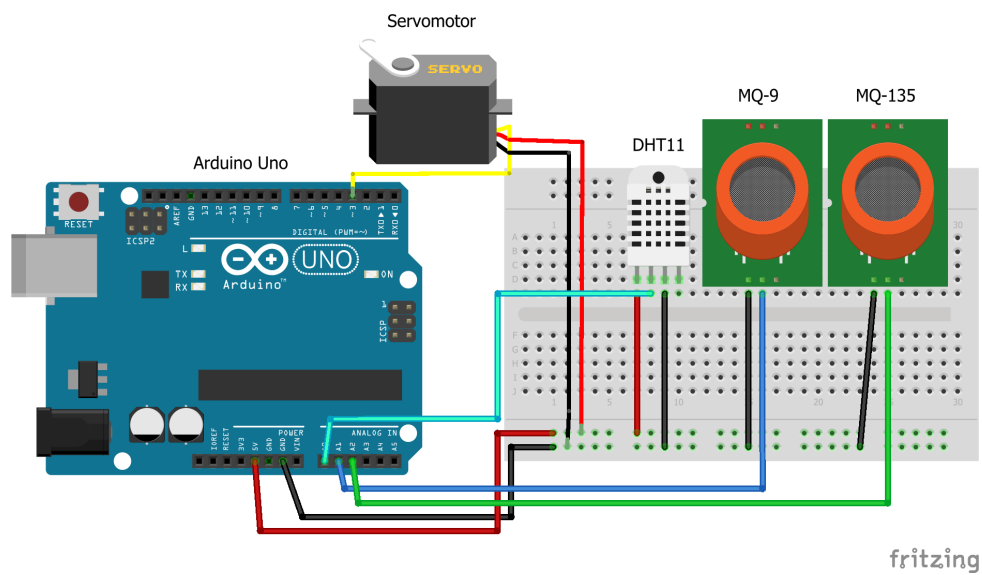


Fonte: O Autor (2025)

Além de sua função na análise ambiental, a variável conforto será usada para definir um novo parâmetro de controle: o acionamento do umidificador. Esse controle será inversamente proporcional ao nível de conforto identificado; ou seja, quanto menor o conforto, maior será a atuação do umidificador para melhorar as condições ambientais.

4.5 Programação das Regras Fuzzy

O sistema desenvolvido para monitorar e melhorar a qualidade do ar integra sensores, um microcontrolador Arduino, lógica *fuzzy* e um atuador, com o objetivo de criar um protótipo capaz de medir variáveis essenciais, como temperatura, umidade e concentrações de gases poluentes (CO e CO₂), processando essas informações para gerar um índice de conforto ambiental. A imagem da Figura 18 apresenta o esquema de prototipagem do sistema, destacando as conexões entre os sensores, o atuador e o microcontrolador Arduino.

Figura 18 – Esquema de prototipagem do sistema, destacando conexões entre sensores e Arduino.

Fonte: O Autor (2025)

A montagem do sistema inclui três sensores principais conectados ao Arduino. O sensor DHT11 é utilizado para medir temperatura e umidade relativa, sendo ligado aos pinos VCC (5V), GND e DATA do microcontrolador. O sensor MQ-135, responsável pela medição das concentrações de dióxido de carbono (CO_2), é conectado a uma entrada analógica do Arduino, assim como o sensor MQ-7, que detecta a presença de monóxido de carbono (CO). Todos os sensores foram fixados em uma protoboard, com as conexões realizadas por fios jumper, e a alimentação é fornecida diretamente pelo Arduino.

Além da coleta e processamento dos dados, o sistema também atua no controle da umidade do ambiente por meio de um servomotor acoplado a um umidificador. Esse servomotor é responsável por ajustar automaticamente o nível de operação do umidificador com base na lógica fuzzy, promovendo maior conforto e eficiência no controle ambiental.

A lógica fuzzy foi implementada no Arduino utilizando a linguagem C++ com o auxílio da biblioteca *fuzzy.h*. O código, carregado diretamente no microcontrolador, processa as variáveis de entrada do sistema, que incluem temperatura, umidade, CO e CO_2 . A variável de saída gerada é o índice de conforto (Seção 4.4.5).

O sistema foi configurado com um total de 81 regras fuzzy, abrangendo todas as combinações possíveis das variáveis de entrada. As regras foram formuladas para refletir as interações complexas entre temperatura, umidade, CO e CO_2 , garantindo uma avaliação robusta e precisa da qualidade do ar. Para a definição das regras fuzzy, foi utilizado o método de Mamdani, que permite uma representação eficiente e interpretável das relações entre as variáveis. Exemplos de regras incluem:

- SE a temperatura é “boa” E a umidade é “boa” E o CO é “bom” E o CO_2 é “bom”,

ENTÃO o conforto é “Muito Confortável”.

- **SE** a temperatura é “calor” **E** a umidade é “baixa” **E** o CO é “perigo” **E** o CO₂ é “perigo”, **ENTÃO** o conforto é “Desconfortável”.
- **SE** a temperatura é “frio” **E** a umidade é “alta” **E** o CO é “alto” **E** o CO₂ é “alto”, **ENTÃO** o conforto é “Desconfortável”.
- **SE** a temperatura é “boa” **E** a umidade é “baixa” **E** o CO é “bom” **E** o CO₂ é “alto”, **ENTÃO** o conforto é “Confortável”.
- **SE** a temperatura é “calor” **E** a umidade é “alta” **E** o CO é “alto” **E** o CO₂ é “bom”, **ENTÃO** o conforto é “Confortável”.
- **SE** a temperatura é “frio” **E** a umidade é “boa” **E** o CO é “bom” **E** o CO₂ é “bom”, **ENTÃO** o conforto é “Confortável”.
- **SE** a temperatura é “boa” **E** a umidade é “alta” **E** o CO é “perigo” **E** o CO₂ é “perigo”, **ENTÃO** o conforto é “Desconfortável”.
- **SE** a temperatura é “frio” **E** a umidade é “baixa” **E** o CO é “bom” **E** o CO₂ é “alto”, **ENTÃO** o conforto é “Desconfortável”.
- **SE** a temperatura é “calor” **E** a umidade é “boa” **E** o CO é “perigo” **E** o CO₂ é “alto”, **ENTÃO** o conforto é “Desconfortável”.
- **SE** a temperatura é “boa” **E** a umidade é “boa” **E** o CO é “alto” **E** o CO₂ é “alto”, **ENTÃO** o conforto é “Confortável”.
- As demais 71 regras são geradas pela combinação das variáveis de entrada, com base nos conjuntos fuzzy definidos e utilizando o método da centroide na defuzzificação.

O processamento fuzzy no implementado no Arduino é realizado em três etapas. Na fase de fuzzificação, os valores das variáveis de entrada são transformados em graus de pertinência para os conjuntos fuzzy definidos. Em seguida, as regras fuzzy são avaliadas simultaneamente, combinando os níveis de entrada para determinar os estados fuzzy de saída. Por fim, o resultado fuzzy é convertido em um valor *crisp* por meio do método do centroide, gerando o índice de conforto ambiental em uma escala de 0 a 100. Após o processamento, os dados são enviados ao computador por meio de comunicação serial.

O computador central organiza as informações em um banco de dados e apresenta os resultados em gráficos e tabelas, permitindo a análise em tempo real da qualidade do ar e do conforto do ambiente interno. Além disso, em etapas futuras o sistema pode ser expandido para emitir alertas e recomendações, como o aumento da ventilação ou o acionamento de purificadores de ar.

4.6 Extração de Dados

A etapa de extração de dados refere-se ao processo de captura das informações de origem, que, neste estudo, são provenientes dos sensores conectados ao Arduino. A coleta de dados foi realizada de forma periódica e em tempo real, com o objetivo de garantir que os dados mais recentes estivessem sempre disponíveis para análise. Durante o experimento, os dados foram extraídos a cada minuto, capturando informações sobre as condições ambientais, como temperatura, umidade e níveis de gases presentes no ar.

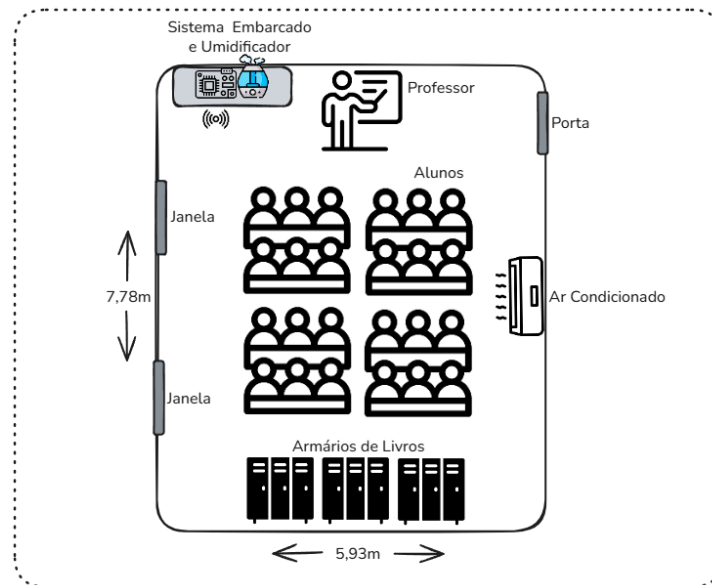
O Arduino foi responsável por gerenciar essa captura de dados, utilizando comunicação serial para transmitir as informações a um computador intermediário. A escolha do Arduino para essa tarefa se justifica pela sua capacidade de lidar com múltiplos sensores e pela facilidade de integração com diferentes módulos e dispositivos, o que proporciona uma solução econômica e eficiente para a coleta de dados em tempo real (BANZI; SHILOH, 2014).

A comunicação serial foi escolhida como o meio para transferir os dados do Arduino para o computador devido à sua simplicidade e confiabilidade. Além disso, a transmissão serial possibilitou o envio contínuo dos dados para o sistema de processamento, garantindo uma coleta precisa e ininterrupta das variáveis ambientais. Esse fluxo constante de dados é fundamental para o monitoramento em tempo real, permitindo a análise contínua e a identificação de variações na qualidade do ar. Esse processo é crucial para a detecção de problemas de poluição ou falhas nos sistemas de ventilação de um ambiente (ZHAO; WANG; CHEN, 2020).

As coletas de dados foram realizadas em uma sala de aula da Escola Municipal Eurídice Neiva Bezerra, localizada no município de São Geraldo do Araguaia. O ambiente possui dimensões aproximadas de $7,78 \times 5,93 \text{ m}^2$, sendo climatizado por ar-condicionado, o que proporciona maior controle sobre temperatura e umidade, variáveis cruciais para o estudo da qualidade do ar, uma vez que influenciam diretamente a dispersão e a concentração de poluentes. O diagrama apresenta os principais componentes utilizados, como sensores, microcontrolador e atuadores, bem como o fluxo de informações desde a coleta até o processamento e atuação.

Durante o período de coleta de dados, a sala abrigou, em média, 20 pessoas, o que representa uma condição de ocupação típica para o ambiente de ensino. A escolha deste local se deu pela sua representatividade como um espaço fechado com alta densidade de ocupação, característica comum em ambientes escolares.

A presença de um número considerável de pessoas é fundamental para avaliar o impacto da respiração humana e da atividade física na qualidade do ar interno, além de permitir analisar a eficácia dos sistemas de ventilação e climatização em manter níveis aceitáveis de poluentes. A estrutura do ambiente com o sistema desenvolvido implementado para o monitoramento da qualidade do ar nesse ambiente pode ser visualizada na Figura 19.

Figura 19 – Esquema do Sistema de Monitoramento.

Fonte: O Autor (2025)

A sala de aula, por fazer parte de uma escola municipal, é um ambiente adequado para estudos da qualidade do ar em espaços coletivos. Esse contexto permite coletar dados relevantes sobre a influência da presença humana e das condições internas, fatores importantes para a saúde e bem-estar dos ocupantes. A Figura 20 mostra o sistema embarcado em funcionamento no local de testes, demonstrando sua aplicação prática.

Figura 20 – Sistema embarcado posicionado no ambiente.

Fonte: O Autor (2025)

Adicionalmente, é importante destacar que o primeiro período de coleta coincidiu com uma época de intensa ocorrência de queimadas na região de São Geraldo do Araguaia, conforme será apresentado nos resultados no Capítulo 5. Esse fenômeno afetou diretamente os resultados do estudo, uma vez que as queimadas liberam grandes quantidades de partículas e gases tóxicos, como CO e CO₂, na atmosfera.

A presença dessas substâncias no ar exterior pode influenciar significativamente a qualidade do ar interno, mesmo em ambientes climatizados, devido à infiltração de poluentes por meio de portas, janelas e sistemas de ventilação. Como resultado, os dados coletados durante este período apresentaram variações que refletem a influência das queimadas, proporcionando uma análise que abrange tanto fontes internas de poluição, como a presença de ocupantes, quanto fontes externas, como o impacto das queimadas regionais.

4.7 Transformação de Dados

Após a extração, os dados brutos coletados necessitam passar por um processo de transformação para garantir que estejam em um formato adequado para a análise. A transformação de dados tem como objetivo preparar as informações de modo que sejam consistentes, válidas e de fácil utilização. Para isso, foi utilizada a biblioteca Python *pandas* (Seção 4.2.1), amplamente empregada em processos de manipulação de dados devido à sua eficiência na organização e análise de grandes volumes de dados (MCKINNEY, 2010).

Durante a transformação, foram realizadas diversas operações de limpeza e verificação de dados, como a remoção de valores ausentes ou duplicados, além da validação para garantir que os dados seguissem padrões predefinidos. A validação envolveu a verificação de dados válidos e a correção de inconsistências, como a detecção de valores fora do intervalo esperado ou de entradas inválidas. Também foi realizada a conversão de tipos de dados para garantir a integridade das informações, como a conversão de texto para números ou de datas para *timestamps*, de forma a manter a coerência dos dados durante a análise.

Além disso, a transformação incluiu a normalização dos dados, quando necessário, para assegurar que as variáveis estivessem em escalas compatíveis, o que facilita a análise subsequente. O processo foi automatizado para garantir uma preparação eficiente dos dados, reduzindo a necessidade de intervenção manual e minimizando a possibilidade de erros. A adoção de uma abordagem automatizada também permitiu maior consistência e reprodutibilidade nos processos de transformação, o que é essencial para garantir a confiabilidade das análises de qualidade do ar, que dependem da precisão dos dados (INMON, 2005).

4.8 Carga de Dados

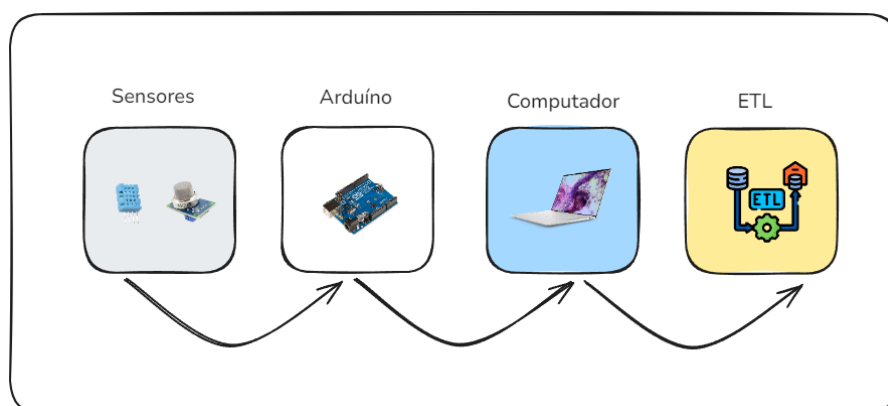
A última etapa do ETL é a carga, responsável pelo armazenamento dos dados processados em um repositório acessível para análise posterior. No contexto deste projeto, o repositório escolhido foi o Google Sheets, uma plataforma online que permite armazenar e visualizar dados em tempo real, garantindo fácil acesso remoto.

A integração com o Sheets foi realizada por meio da *API* do *Google Cloud Platform* (*GCP*), o que possibilitou a automação do carregamento dos dados, eliminando a necessidade de atualizações manuais. Esse processo aumentou a confiabilidade do sistema, garantindo que os dados estivessem sempre atualizados e prontos para análise contínua das condições da qualidade do ar.

O armazenamento em um repositório baseado na nuvem também trouxe benefícios significativos em termos de segurança e escalabilidade. A infraestrutura do Google Sheets oferece recursos de backup e redundância, assegurando a integridade dos dados mesmo em casos de falhas locais. Além disso, a facilidade de integração com outras ferramentas de análise e visualização permitiu a colaboração simultânea de diferentes usuários, tornando o processo mais eficiente e acessível.

A implementação de um pipeline ETL para monitoramento da qualidade do ar provou ser uma abordagem eficiente para coletar, processar e armazenar dados de forma estruturada. Sensores de baixo custo, conectados a um microcontrolador Arduino, capturam dados ambientais em tempo real, que, após as etapas de extração e transformação, são armazenados em um repositório online. Esse fluxo assegura a precisão dos dados e permite uma análise contínua, possibilitando respostas rápidas às variações na qualidade do ar. A Figura 21 apresenta o fluxograma do percurso dos dados até a fase de carregamento no repositório online.

Figura 21 – Diagrama do Fluxo de Dados.



Fonte: O Autor (2025)

A arquitetura do sistema desenvolvido é composta por componentes principais que atuam de forma integrada para garantir a coleta, o processamento e o armazenamento eficiente dos

dados ambientais. Cada etapa desempenha um papel fundamental no funcionamento do sistema, desde a medição das variáveis físicas até o acesso remoto aos dados transformados. A seguir, são descritos os principais elementos que compõem essa estrutura:

1. **Sensores (DHT11, MQ7, MQ135):** Responsáveis por capturar variáveis ambientais essenciais, como temperatura, umidade e níveis de poluentes atmosféricos, incluindo o CO e CO₂. O DHT11 mede temperatura e umidade, enquanto os sensores MQ7 e MQ135 detectam concentrações de CO e CO₂, respectivamente. Os dados coletados são enviados ao Arduino para processamento inicial.
2. **Arduino:** Atua como controlador central, recebendo e processando os dados dos sensores antes de transmiti-los para o próximo estágio. Ele gerencia a coleta de informações e prepara os dados para envio ao computador.
3. **Computador:** Funciona como intermediário no sistema, recebendo os dados do *Arduino* e encaminhando-os para o processo de ETL. Essa etapa permite a execução de algoritmos de processamento e análise preliminar antes do armazenamento definitivo.
4. **Processo de ETL:** Responsável pelo fluxo de dados desde a coleta até o armazenamento final. A etapa de extração ocorre em intervalos regulares, garantindo a obtenção contínua de informações. Na transformação, os dados são limpos e formatados para assegurar sua precisão e consistência. Por fim, a carga transfere os dados processados para o repositório online.
5. **Repositório Online:** Como etapa final do processo de ETL, os dados transformados são armazenados no Google *Sheets*, garantindo acesso remoto e contínuo para análise. Esse repositório proporciona segurança, versionamento e integração com ferramentas de visualização, permitindo consultas e estudos posteriores.

4.9 Visualização de Dados

A visualização de dados desempenha um papel essencial na interpretação e análise de grandes volumes de informações, especialmente quando estas são complexas e difíceis de compreender em seu formato original. Dados brutos, por si só, não fornecem insights imediatos, tornando o processo analítico mais desafiador. Ao convertê-los em representações gráficas, como gráficos, mapas e painéis interativos, torna-se possível identificar padrões, tendências e correlações de maneira mais intuitiva e acessível. No contexto do monitoramento da qualidade do ar, a visualização de dados se torna ainda mais relevante, pois permite acompanhar variações ambientais em tempo real e fornecer informações claras para a tomada de decisão.

Como a qualidade do ar afeta diretamente a saúde pública, dispor de ferramentas visuais eficazes possibilita respostas rápidas a mudanças nos níveis de poluentes. Para facilitar esse

processo, foi desenvolvido um dashboard interativo utilizando a biblioteca Streamlit. Essa abordagem permitiu a criação ágil de interfaces dinâmicas, sem a necessidade de conhecimentos avançados em desenvolvimento web, viabilizando a análise e o acompanhamento contínuo dos dados ambientais.

O dashboard desenvolvido com o Streamlit oferece uma interface de fácil interação, na qual os dados relativos à qualidade do ar são apresentados de maneira visualmente agradável e intuitiva. Por meio de gráficos interativos, tabelas dinâmicas e mapas, os usuários conseguem explorar os dados de maneira profunda, podendo, por exemplo, filtrar as informações com base em períodos específicos, regiões geográficas ou até mesmo variáveis ambientais específicas, como a concentração de poluentes no ar.

Essa interatividade não apenas facilita a análise detalhada dos dados, mas também torna o acompanhamento das condições ambientais muito mais acessível e compreensível, o que é particularmente importante quando se trata de públicos não especializados, como gestores públicos e cidadãos interessados em compreender as condições de qualidade do ar em suas localidades. A Figura 22 ilustra a interface do dashboard desenvolvido, demonstrando como os dados são apresentados de forma clara e interativa.

Figura 22 – Interface do dashboard desenvolvido com Streamlit.

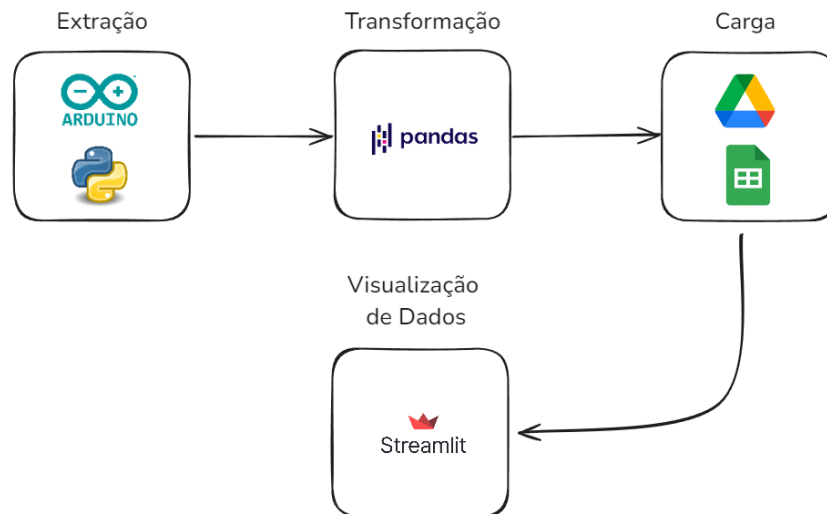


Fonte: O Autor (2025)

O diagrama apresentado na Figura 23 ilustra o fluxo do processo ETL (Extração, Transformação e Carga), que é responsável pela movimentação e preparação dos dados desde a sua coleta até a visualização final no dashboard. O processo ETL é uma etapa crucial em qualquer sistema de análise de dados, pois garante que os dados coletados, muitas vezes provenientes de diferentes fontes e com diferentes formatos, sejam integrados de forma consistente e adequada para análise. Na etapa de extração, os dados são retirados das fontes, que neste caso incluem sensores de qualidade do ar.

Em seguida, durante a transformação, os dados passam por processos de limpeza e organização, de modo que se tornem utilizáveis e coerentes para análise. Por fim, na fase de carga, os dados são armazenados em um repositório ou banco de dados adequado e disponibilizado para visualização e interpretação.

Figura 23 – Diagrama do processo ETL.



Fonte: O Autor (2025)

A visualização final no dashboard, construída com o Streamlit, reflete todo o trabalho de integração e preparação dos dados realizado ao longo do processo. O diagrama de fluxo do ETL permite compreender como os dados são coletados, transformados e, por fim, apresentados na interface do dashboard. Essa visão geral ajuda a entender a importância do Streamlit na visualização dos dados, pois é através dele que o usuário final pode interagir, explorar os resultados e realizar suas análises de forma intuitiva.

A união do processo ETL com o dashboard Streamlit resultou em uma solução prática e eficiente para o monitoramento da qualidade do ar. Enquanto o pipeline ETL garante que os dados sejam organizados e processados corretamente, o dashboard torna essas informações acessíveis de maneira interativa e visualmente clara. Essa abordagem não apenas facilita a análise detalhada dos dados, mas também possibilita um acompanhamento em tempo real, permitindo respostas rápidas a qualquer variação nas condições ambientais.

Com isso, é possível apoiar a tomada de decisões de forma mais informada e ágil, contribuindo para a gestão da qualidade do ar e a proteção da saúde pública. Além de compreender melhor o cenário atual, essa solução também auxilia na antecipação de medidas que possam mitigar os impactos da poluição do ar na população.

4.10 Umidificador como Atuador do Sistema

Com o objetivo de promover a melhoria do ambiente de testes, foi adotado como atuador um umidificador de ar convencional modelo NUA-02, conforme apresentado na Figura 24. Esse componente foi integrado ao sistema para contribuir diretamente no controle das condições do ambiente interno. Para isso, o sistema realiza leituras contínuas por meio dos sensores instalados, permitindo a aferição em tempo real da qualidade do ar.

Figura 24 – Umidificador utilizado como atuador no sistema.



Fonte: O Autor

Com base nesses dados, o microcontrolador aplica lógica *fuzzy* para determinar o acionamento do umidificador, que é controlado por um servo motor acoplado ao potenciômetro de ajuste do equipamento, conforme demonstrado na Figura 25, permitindo regular seu funcionamento de forma automatizada.

Figura 25 – Umidificador acoplado ao servomotor.



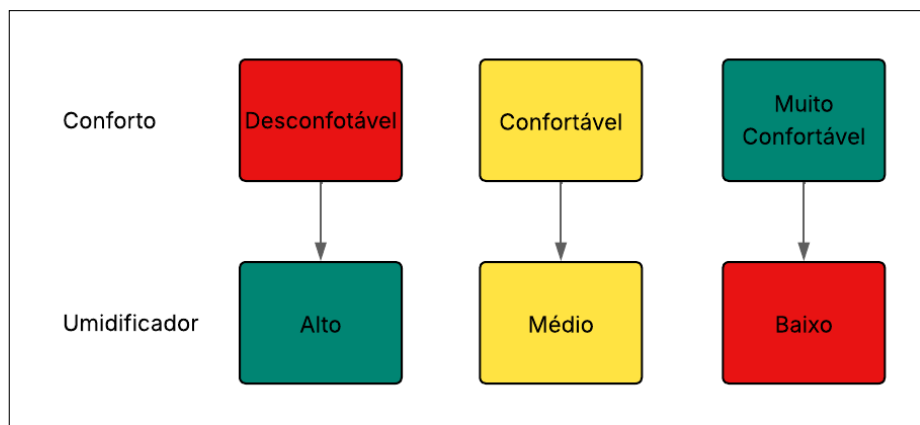
Fonte: O Autor

Essa integração permite o ajuste dinâmico das condições ambientais no espaço de testes, contribuindo para a criação de um ambiente mais controlado e confortável. A variável de saída

denominada *Conforto* (Seção 4.4.5) define três níveis de operação do sistema: “Desconfortável”, “Confortável” e “Muito Confortável”. Essa variável indica a qualidade atual do ambiente e funciona como parâmetro para avaliar o estado interno do sistema. Com base nessa avaliação, são tomadas decisões quanto à atuação do atuador, que neste caso é um umidificador controlado por servomotor.

Para isso, foi adotada uma lógica de controle inversamente proporcional ao nível de conforto identificado, em que quanto menor o conforto detectado, maior será a atuação do umidificador, e quanto maior o conforto, menor será sua intensidade. Esse modelo busca evitar acionamentos desnecessários, promovendo eficiência energética e melhor desempenho na regulação do ambiente. A Figura 26 apresenta o fluxograma que representa a lógica de funcionamento do umidificador dentro do sistema automatizado.

Figura 26 – Lógica de acionamento do umidificador



Fonte: O Autor

Nessa lógica, a atuação do umidificador ocorre por meio de um servo motor acoplado ao potenciômetro do próprio equipamento, permitindo o controle do fluxo de liberação de umidade conforme o valor da variável *Conforto*, o sistema realiza ajustes automáticos da intensidade em três níveis distintos, sendo eles alta, média e baixa, de modo que, quando o ambiente é classificado como desconfortável, a intensidade acionada é alta, quando é considerado confortável, a intensidade é média, e quando é muito confortável, a atuação se dá em nível baixo, garantindo uma resposta proporcional às condições reais do ambiente, com melhor aproveitamento energético e redução de acionamentos desnecessários.

4.11 Equações para Análise de Comparação

A análise comparativa do desempenho do sistema de controle foi conduzida por meio de métricas estatísticas que permitem compreender diferentes aspectos do comportamento dinâmico da variável de interesse (*Conforto*). Essas métricas foram selecionadas por possibilitarem a quantificação da dispersão dos dados, da extensão entre os valores extremos e da intensidade

acumulada das oscilações, de modo a fornecer uma visão sistemática sobre a estabilidade do ambiente monitorado.

A primeira métrica considerada na análise foi o desvio padrão, cuja formulação matemática é apresentada na Equação 4.1.

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2}, \quad (4.1)$$

onde x_i representa cada observação individual do conjunto de dados, μ corresponde à média aritmética dessas observações e n indica o número total de elementos considerados. O termo $(x_i - \mu)^2$ calcula o quadrado da diferença entre cada valor e a média, de modo que a soma $\sum_{i=1}^n$ acumula todas essas diferenças. A divisão pelo número de elementos e a raiz quadrada resultam em uma métrica expressa nas mesmas unidades dos dados originais, o que facilita sua interpretação prática.

Com base nessa formulação, o desvio padrão se consolida como uma das ferramentas estatísticas mais utilizadas para mensurar a variabilidade de um conjunto de dados. Ele descreve o grau de dispersão dos valores em relação à média, permitindo avaliar o quão consistente ou irregular é o comportamento do sistema ao longo do tempo. Valores mais elevados indicam maior dispersão e, conseqüentemente, maior variabilidade entre as observações, enquanto valores mais baixos refletem maior uniformidade e menor variação nos dados analisados.

Outra métrica fundamental para compreender o comportamento dos dados é a amplitude, expressa pela Equação 4.2:

$$A = x_{\text{máx}} - x_{\text{mín}}, \quad (4.2)$$

onde $x_{\text{máx}}$ representa o maior valor observado em uma série temporal, enquanto $x_{\text{mín}}$ corresponde ao menor valor registrado. A diferença entre esses dois extremos resulta em uma medida simples e direta da variação total existente nos dados, expressando a distância entre os limites mínimo e máximo alcançados pelo sistema.

A partir desta definição, a amplitude se apresenta como um recurso útil para identificar a presença de valores extremos e compreender a largura do intervalo em que os registros se distribuem. Diferentemente do desvio padrão, que considera a dispersão média em torno da média, a amplitude evidencia exclusivamente a extensão total da variação, permitindo uma análise imediata da faixa de oscilação dos dados ao longo do tempo.

Complementando as métricas de dispersão, a energia do sinal foi utilizada como um recurso analítico capaz de captar a magnitude acumulada das flutuações da variável de interesse ao longo do tempo, sendo compreendida pela Equação 4.3:

$$E = \sum_{i=1}^n x_i^2, \quad (4.3)$$

onde x_i corresponde a cada observação individual da série temporal, enquanto n indica o número total de elementos considerados. A operação de elevar cada valor ao quadrado e somar todos os elementos permite quantificar a magnitude acumulada das variações ao longo do tempo, fornecendo uma medida numérica que reflete o esforço total das flutuações da variável analisada.

Diferentemente de métricas como o desvio padrão ou a amplitude, que avaliam a dispersão ou a faixa de variação dos dados, a energia do sinal considera a intensidade global das oscilações, independentemente da direção dos desvios, fornecendo uma visão complementar às demais métricas estatísticas.

Essa característica torna a métrica especialmente útil em análises de séries temporais e processamento de sinais, permitindo identificar a magnitude total das variações, compreender a intensidade acumulada das mudanças ao longo do tempo e interpretar de forma mais completa o comportamento dinâmico do sistema, destacando a suavidade ou a agressividade das flutuações na variável de interesse.

A aplicação conjunta do desvio padrão, da amplitude e da energia proporciona um conjunto robusto de métricas que permite interpretar de maneira detalhada e a dinâmica do sistema. Cada medida aborda uma dimensão distinta da variabilidade, possibilitando compreender tanto a dispersão média quanto os extremos e a intensidade acumulada das oscilações. Dessa forma, torna-se viável realizar uma avaliação mais consistente do desempenho observado, permitindo que a análise estatística forneça subsídios sólidos para a interpretação dos resultados em contextos de monitoramento e controle do ar no ambiente interno.

4.12 Comparação entre os Controladores Fuzzy e PID

Para avaliar a eficácia da abordagem proposta, o sistema baseado em lógica *fuzzy* foi comparado a um controlador tradicional do tipo PID (Seção 2.3). O objetivo dessa análise paralela consistiu em possibilitar uma comparação direta entre os dois métodos, garantindo que ambos operassem sobre as mesmas variáveis ambientais, utilizando os mesmos sensores, microcontrolador e condições físicas. Essa abordagem permitiu estabelecer um cenário controlado, onde diferenças de desempenho poderiam ser atribuídas exclusivamente às estratégias de controle adotadas por cada sistema, sem interferências externas.

Durante os testes, ambos os controladores foram implementados simultaneamente no mesmo ambiente, realizando a monitoração em tempo real das mesmas medições. O sistema baseado em lógica *fuzzy* ajustava o umidificador conforme a avaliação contínua das variáveis ambientais, enquanto o controlador PID processava os erros em relação ao *set-point* para calcular o sinal de controle, utilizando a forma discreta apresentada na Equação 2.5. Essa configuração

permitiu acompanhar de maneira paralela o comportamento de ambos os sistemas, garantindo uma comparação direta e objetiva de suas respostas aos mesmos estímulos ambientais.

Para a implementação do PID discreto, foram definidos coeficientes ajustados a partir de testes preliminares: $K_p = 1,0$, $K_i = 0,1$ e $K_d = 0,05$. O ganho proporcional K_p determina a intensidade da reação imediata ao erro detectado, permitindo uma correção direta quando há desvio do *set-point*. O ganho integral K_i é responsável por corrigir desvios acumulados ao longo do tempo, eliminando erros persistentes e garantindo que a variável controlada se aproxime do valor desejado. Por sua vez, o ganho derivativo K_d atua sobre a taxa de variação do erro, antecipando alterações abruptas e contribuindo para uma resposta mais suave e controlada, especialmente em situações de transientes ou perturbações rápidas no ambiente.

A adoção da forma discreta do PID proporciona plena compatibilidade com microcontroladores e sistemas digitais, preservando as propriedades essenciais do controle contínuo, enquanto garante que os cálculos do sinal de controle possam ser aplicados em tempo real. Essa implementação não apenas mantém a fidelidade do comportamento do PID clássico, como também permite sua integração eficiente em plataformas embarcadas, reduzindo o tempo de processamento e o consumo de recursos computacionais, fatores críticos em aplicações práticas de automação ambiental.

Além disso, a presença do PID como referência clássica de controle oferece um padrão de comparação sólido para avaliar a performance do sistema *fuzzy*. Ao executar ambos os controladores em paralelo sob condições idênticas, é possível observar diferenças de comportamento, capacidade de lidar com variabilidade ambiental e eficiência na manutenção do conforto interno, sem recorrer a estimativas subjetivas. Dessa forma, a análise posterior dos dados será fundamentada em uma base experimental robusta, permitindo conclusões mais precisas sobre as vantagens relativas de cada abordagem.

Portanto, a implementação simultânea do controlador PID e do sistema *fuzzy* cria um ambiente experimental controlado e confiável, no qual a comparação futura entre os dois métodos poderá ser realizada de forma objetiva. Essa estratégia garante que as métricas de desempenho a serem analisadas, como variabilidade, eficiência e suavidade da resposta, reflitam exclusivamente as características inerentes de cada controlador, assegurando a validade e a consistência da análise quantitativa apresentada na seção subsequente.

5 RESULTADOS

Foram realizadas quatro fases distintas de testes ao longo dos anos de 2024 e 2025, visando analisar o desempenho do sistema de monitoramento e controle da qualidade do ar em diferentes condições ambientais e operacionais. As duas primeiras fases ocorreram em 2024. A etapa inicial foi realizada nos meses de julho e agosto, aproveitando o período de férias escolares para conduzir os testes em uma sala de aula vazia.

Esse cenário permitiu avaliar o comportamento do ambiente sem interferência humana, proporcionando uma linha de base para as medições. Logo após o retorno das aulas, nos primeiros quinze dias do segundo semestre, os testes foram repetidos com a sala ocupada por alunos, possibilitando um comparativo direto entre as condições com e sem a presença de pessoas.

O foco dessas fases iniciais foi compreender as variações ambientais causadas pela ocupação da sala, avaliando como as variáveis monitoradas pelo sistema respondem à presença humana e identificando possíveis ajustes necessários para o funcionamento do sistema. Além disso, esses testes foram essenciais para validar a estabilidade da estrutura do sistema, identificar e corrigir falhas, bem como garantir a confiabilidade do armazenamento dos dados em nuvem, evitando perdas de informações importantes.

Em 2025, foram conduzidas mais duas fases de testes, realizadas nos meses de abril e maio, com duração aproximada de um mês cada. Nessas etapas, o sistema incorporou um umidificador de ar convencional como atuador, possibilitando a avaliação prática do impacto do controle automático na melhoria das condições ambientais da sala de aula.

Além disso, foi realizada uma comparação entre a lógica fuzzy, já empregada nas fases anteriores, e o controle proporcional-integral-derivativo (PID). Essa análise teve como objetivo avaliar a eficiência, a resposta dinâmica e a adequação de cada método ao contexto específico do ambiente de testes. A Tabela 8 sintetiza as informações referentes às fases de coleta e aos testes conduzidos ao longo do estudo.

Tabela 8 – Resumo das fases de coleta: período, tempo médio diário e número médio de amostras

Fase de Coleta	Período	Tempo Médio (horas)	Número Amostras (por dia)
1 ^a	jul/2024 - ago/2024	5,5	330
2 ^a	nov/2024 - dez/2024	5,5	330
3 ^a	abr/2025 - mai/2025	5,5	330
4 ^a	mai/2025	11,5	690

Fonte: O Autor

Cada fase de coleta adotou uma frequência de amostragem de um dado por minuto, gerando aproximadamente seis horas diárias de amostras, totalizando cerca de 330 registros por dia. Exceto pela quarta fase de coleta, realizada em maio de 2025, quando o sistema operou por cerca de doze horas diárias, resultando em quase o dobro de amostras nesse período.

Ao todo, os testes cobriram um período significativo, que permitiu captar as variações sazonais e comportamentais do ambiente, proporcionando um conjunto robusto de dados para análise do desempenho do sistema em diferentes condições operacionais.

5.1 Coletas de Dados

5.1.1 Primeira Fase de Coletas

Durante a primeira fase de coleta, foram observados padrões distintos para cada tipo de teste, refletindo as condições específicas da sala nos cenários de ocupação vazia e cheia. Os dados foram registrados de forma contínua ao longo de dez dias para cada condição, conforme detalhado na Tabela 9. O principal objetivo dessa etapa inicial foi compreender o comportamento das variáveis ambientais e sua relação com a ocupação do ambiente. A análise desses dados permitiu identificar tendências e variações, proporcionando uma base para a aplicação da lógica difusa ao cenário estudado. Além disso, os resultados obtidos auxiliaram no refinamento do processo de monitoramento, garantindo que as comparações e análises subsequentes fossem conduzidas com maior precisão e embasamento.

- **Teste em Sala Vazia:** No cenário de sala vazia, os dados foram registrados ao longo de dez dias, sem a presença de ocupantes. Esse teste foi fundamental para estabelecer uma linha de base, permitindo compreender o comportamento das variáveis ambientais na ausência de interferência humana. As medições obtidas nesse período serviram como referência para avaliar as alterações que ocorrem no ambiente quando a sala está ocupada. A análise desse cenário possibilitou identificar padrões estáveis e compreender a influência de fatores externos, como ventilação natural e variações térmicas ao longo do dia.
- **Teste em Sala Cheia:** O teste em sala cheia foi conduzido durante o período regular de aulas, com uma média de vinte pessoas ocupando o ambiente. A coleta de dados ocorreu ao longo de duas semanas, possibilitando um monitoramento contínuo das condições ambientais em um espaço dinâmico e em uso real. A presença humana teve impacto direto sobre diversas variáveis do sistema, como temperatura, umidade e concentração de CO e CO₂, permitindo a identificação de padrões específicos de variação ao longo do tempo. Os insights obtidos nessa fase do experimento foram fundamentais para compreender o comportamento de cada variável em resposta à ocupação do ambiente, possibilitando ajustes e otimizações no modelo de controle ambiental do sistema.

Tabela 9 – Tabela de coleta de dados

Dia	Tipo de Teste	Data
1	Sala Vazia	23/07/2024

2	Sala Vazia	25/07/2024
3	Sala Vazia	26/07/2024
4	Sala Vazia	29/07/2024
5	Sala Vazia	30/07/2024
6	Sala Vazia	31/07/2024
7	Sala Vazia	01/08/2024
8	Sala Vazia	02/08/2024
9	Sala Vazia	05/08/2024
10	Sala Vazia	06/08/2024
1	Sala Cheia	16/08/2024
2	Sala Cheia	17/08/2024
3	Sala Cheia	18/08/2024
4	Sala Cheia	19/08/2024
5	Sala Cheia	20/08/2024
6	Sala Cheia	23/08/2024
7	Sala Cheia	24/08/2024
8	Sala Cheia	25/08/2024
9	Sala Cheia	26/08/2024
10	Sala Cheia	27/08/2024

Fonte: O Autor (2025)

Inicialmente, supôs-se que o sistema de ar condicionado seria suficiente para manter a climatização adequada da sala, independentemente da ocupação. No entanto, os dados coletados revelaram falhas no equipamento, que comprometiam a refrigeração do ambiente quando cheio de pessoas.

Após a conclusão dos testes, os resultados foram apresentados à diretoria da escola, o que levou à solicitação formal para a substituição do sistema de ar condicionado. Esse processo foi concluído após um mês, trazendo melhorias significativas para o ambiente escolar. No segundo teste, realizado em novembro, foi possível verificar os efeitos positivos dessa mudança, observando uma melhor regulação térmica da sala. Dessa forma, além de contribuir para a pesquisa, os dados coletados desempenharam um papel fundamental na otimização das condições do ambiente da escola.

5.1.2 Segunda Fase de Coletas (Aplicação dos Conjuntos Fuzzy)

A análise dos primeiros testes indicou a necessidade de aplicar a lógica fuzzy ao sistema de monitoramento do ar. Essa abordagem permite avaliar seu desempenho em condições reais, integrando fuzzificação, inferência e defuzzificação em tempo de execução no Arduino. Antes dos testes, foi realizada a calibração dos sensores para converter a voltagem gerada pelo pino do

Arduino obtida em partes por milhão (PPM), garantindo a precisão das medições. Os resultados a seguir demonstram o comportamento do sistema e as interações entre as variáveis monitoradas e as decisões fuzzy.

Os testes realizados nesta etapa ocorreram na mesma sala de aula utilizada anteriormente, porém em uma estação do ano distinta. Enquanto os primeiros testes foram conduzidos durante o verão de julho e agosto, esta nova série de experimentos foi realizada durante a última semana de novembro e o mês de dezembro de 2024. Essa mudança de período introduz condições climáticas distintas, com temperaturas razoavelmente mais baixas, típicas do final do outono e início do inverno no hemisfério sul.

Essa variação sazonal teve impacto direto nas variáveis monitoradas, especialmente devido às diferenças no comportamento térmico da sala, o que será perceptível nos resultados apresentados. A Tabela 10 apresenta as datas e o tipo de teste realizados, com foco total nos testes em sala cheia.

Tabela 10 – Tabela de Coleta de Dados em Sala Cheia (Novembro e Dezembro de 2024)

Dia	Tipo de Teste	Data
1	Sala Cheia	25/11/2024
2	Sala Cheia	26/11/2024
3	Sala Cheia	27/11/2024
4	Sala Cheia	28/11/2024
5	Sala Cheia	02/12/2024
6	Sala Cheia	03/12/2024
7	Sala Cheia	04/12/2024
8	Sala Cheia	05/12/2024
9	Sala Cheia	06/12/2024
10	Sala Cheia	09/12/2024

Fonte: O Autor (2025)

5.1.3 Calibração dos Sensores

Antes de realizar a segunda fase de testes aplicados ao sistema de monitoramento da qualidade do ar (Tabela 10), foi necessário calibrar os sensores utilizados para medir os níveis de monóxido de carbono (CO) e dióxido de carbono (CO₂) no ambiente. Para isso, foram empregados os sensores MQ-9 e MQ-135, respectivamente. A calibração foi realizada utilizando dados obtidos em condições controladas e funções matemáticas específicas fornecidas pelo fabricante dos sensores, implementadas no código do sistema.

A calibração é essencial para garantir a precisão das leituras fornecidas pelos sensores, uma vez que eles apresentam variações de comportamento dependendo de fatores como temperatura, umidade e o estado do ambiente. Nesse contexto, os seguintes parâmetros foram considerados:

- Os sensores operam em um circuito de tensão controlada.
- A resistência da carga (R_L) foi configurada em:
 - 10 k Ω para o sensor MQ-9 (CO).
 - 20 k Ω para o sensor MQ-135 (CO₂).
- As resistências em ar limpo (R_0) foram definidas como:
 - 15.824,67 Ω para o sensor MQ-9 (CO).
 - 28.714,29 Ω para o sensor MQ-135 (CO₂).

O cálculo da concentração dos gases (em partes por milhão, PPM) foi realizado aplicando-se equações fornecidas pelo fabricante, que relacionam a resistência do sensor ao nível de gás detectado. A Equação 5.1 foi utilizada para o monóxido de carbono (CO):

$$PPM_{CO} = 10^{\left(m_{CO} \cdot \log_{10}\left(\frac{R_S}{R_0}\right) + b_{CO}\right)}, \quad (5.1)$$

Onde:

- R_S representa a resistência do sensor em operação.
- R_0 é a resistência em ar limpo.
- m_{CO} e b_{CO} são coeficientes da curva característica do sensor MQ-9 para CO, com valores -0,62 e 0,89, respectivamente.

O valor de R_S é calculado a partir da tensão de saída do sensor (V_{out}) utilizando a relação entre a tensão de alimentação (V_{CC}) e a resistência de carga (R_L).

De forma análoga, a concentração de dióxido de carbono (CO₂) foi calculada utilizando a Equação 5.2:

$$PPM_{CO_2} = 10^{\left(m_{CO_2} \cdot \log_{10}\left(\frac{R_S}{R_0}\right) + b_{CO_2}\right)}, \quad (5.2)$$

onde:

- m_{CO_2} e b_{CO_2} são os coeficientes ajustados para o sensor MQ-135, com valores -3,27 e 1,984, respectivamente.
- A multiplicação por 10 reflete a sensibilidade ampliada do sensor para este gás.

O processo de calibração incluiu:

- Coleta de dados de referência em ambientes conhecidos e controlados, com concentrações de CO e CO₂ previamente estabelecidas.
- Ajuste dos coeficientes das equações com base nos dados obtidos.
- Fuzzificação das leituras para transformar os valores brutos em informações linguísticas para o sistema fuzzy.

Esse processo de calibração assegurou que os sensores operassem com precisão e confiabilidade no monitoramento das condições internas do ambiente. Com essa base estabelecida, foi possível avançar para os testes em tempo real, aplicando os modelos fuzzy para a análise e controle dos parâmetros relacionados à qualidade do ar.

5.1.4 Terceira Fase de Coletas

A partir desta fase de testes e coletas, o umidificador de ar passou a ser controlado de forma autônoma pelo sistema embarcado, utilizando-se integralmente a estrutura apresentada na Figura 18. Os experimentos foram conduzidos durante cinco dias consecutivos, na mesma sala de aula utilizada nas etapas anteriores. Durante esse período, foi possível observar um impacto positivo na atuação do sistema, uma vez que a variável “Conforto”, gerada pelo modelo baseado em lógica fuzzy, indicou uma melhora perceptível na qualidade do ar do ambiente.

A Tabela 11 apresenta as datas em que foram realizadas as coletas de dados durante o período em que o umidificador foi controlado automaticamente pelo sistema.

Tabela 11 – Datas dos Testes com Umidificador (Abril e Maio de 2025)

Dia	Tipo de Teste	Data
1	Sala Cheia	29/04/2025
2	Sala Cheia	30/04/2025
3	Sala Cheia	02/05/2025
4	Sala Cheia	06/05/2025
5	Sala Cheia	08/05/2025

Fonte: O Autor (2025).

Apesar dos resultados promissores, constatou-se a necessidade de uma nova fase de testes, com duração mais longa. O objetivo foi avaliar de forma mais aprofundada o comportamento do umidificador ao longo do tempo e verificar a estabilidade do controle automático em um período contínuo dentro do mesmo ambiente.

5.1.5 Quarta Fase de Coletas

Nesta quarta fase buscou-se aprofundar a análise do comportamento do sistema de controle automático do umidificador, considerando dois cenários distintos, sendo um com a

utilização da lógica fuzzy e outro com a aplicação do controle proporcional integral derivativo, conhecido como PID. O objetivo foi avaliar o desempenho de ambos os métodos em relação à regulação da qualidade do ar em ambiente de sala de aula.

Os experimentos foram conduzidos durante cinco datas não consecutivas, com duração aproximada de 12 horas por dia. Ao longo desse período observou-se que o sistema fuzzy apresentou desempenho mais eficiente no controle da variável "Conforto", evidenciando maior capacidade de adaptação frente às variações ambientais. A comparação direta com o método PID reforçou a positividade da abordagem fuzzy no contexto analisado.

A Tabela 12 apresenta as datas nas quais foram realizadas as coletas dessa fase de experimentação comparativa.

Tabela 12 – Datas dos Testes com Umidificador (Maio de 2025)


Dia	Tipo de Teste	Data
1	Sala Cheia	18/04/2025
2	Sala Cheia	21/04/2025
3	Sala Cheia	23/05/2025
4	Sala Cheia	24/05/2025
5	Sala Cheia	28/05/2025

Fonte: O Autor (2025).

5.1.6 Análise da Temperatura

A análise dos gráficos de temperatura da sala vazia, obtidos na primeira fase de coletas, revela aspectos importantes do comportamento térmico do ambiente. O gráfico de linha da Figura 27 mostra uma variação que começa em torno de 28°C e sobe gradualmente até cerca de 33°C. Esse aumento contínuo ao longo do tempo indica a ausência de um controle térmico eficaz, pois a temperatura não se estabiliza, sugerindo que o ambiente não possui mecanismos de regulação suficientes para manter condições estáveis.

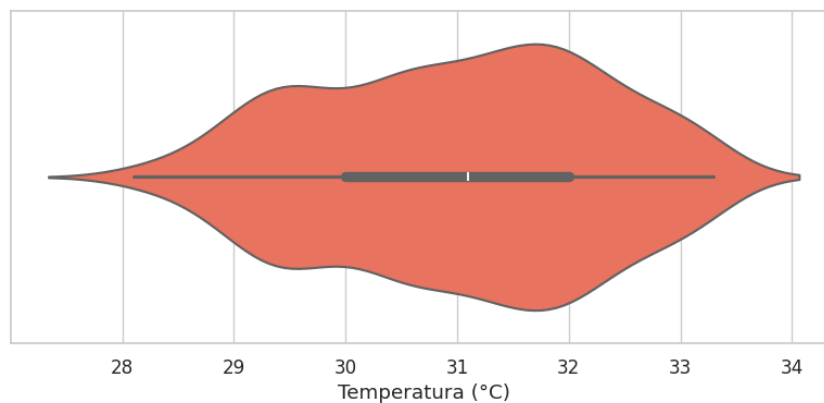
Figura 27 – Variação da temperatura na sala vazia ao longo do tempo.



Fonte: O Autor (2025)

A Figura 28 apresenta o gráfico de violino referente à temperatura no cenário de sala vazia. Observa-se que a maior parte das medições se concentra em torno de $31,6^{\circ}\text{C}$, com a forma do gráfico indicando uma distribuição contínua e densa próxima a esse valor. A ausência de dispersões extremas e a simetria da distribuição sugerem um ambiente termicamente estável, com controle eficiente da temperatura e variação mínima ao longo do período monitorado. Esses dados reforçam a confiabilidade do ambiente como referência para comparações futuras, especialmente em cenários com presença de pessoas.


Figura 28 – Distribuição da temperatura na sala vazia.



Fonte: O Autor (2025)

Na primeira fase de coletas, agora com a sala cheia, observou-se um comportamento térmico distinto em relação à sala vazia. Apesar da presença de climatização, os dados de temperatura apresentaram variações significativas. No gráfico de linhas da Figura 29, a temperatura mínima registrada foi de $30,6^{\circ}\text{C}$. Durante o período das aulas, os valores oscilaram frequentemente entre 34°C e $36,3^{\circ}\text{C}$, com picos ocorrendo de 4 a 7 vezes a cada 30 minutos. Essa instabilidade térmica pode ser atribuída à presença de pessoas no ambiente e à limitação do sistema de climatização em manter a temperatura constante.

Figura 29 – Gráfico de linhas da temperatura na sala cheia.



Fonte: O Autor (2025)


Entretanto, a distribuição também evidencia frequentes oscilações térmicas, com variações entre aproximadamente 34°C e $36,3^{\circ}\text{C}$ que ocorreram de 4 a 7 vezes a cada 30 minutos

durante o período de aula. Após o ponto de maior densidade, observa-se uma baixa na distribuição seguido por uma subida próxima aos 37°C. Essa característica sugere que, mesmo com a climatização, o calor gerado pelas pessoas presentes na sala, junto com a capacidade limitada do sistema de resfriamento, contribuiu para os aumentos pontuais na temperatura, resultando em grande variação térmica.

Esses padrões diferem bastante dos observados na sala vazia, evidenciando o impacto do número de pessoas presentes. A variação térmica e os picos mostram que a climatização, apesar de funcionar, pode não ser suficiente para manter a temperatura estável em ambientes muito ocupados. Isso indica que ajustes no sistema ou medidas complementares podem ser necessários para controlar melhor o calor gerado pela ocupação. Essas observações ressaltam a importância de considerar fatores ambientais e de ocupação ao analisar a temperatura interna.

Na segunda fase de coletas, a temperatura continuou sendo um parâmetro fundamental a ser monitorado, dado seu impacto direto no conforto e bem-estar dos alunos durante as aulas. Inicialmente, a temperatura estava próxima de 31°C. Contudo, conforme os alunos foram chegando à sala, observou-se uma tendência de queda gradual na temperatura. Esse comportamento pode ser atribuído à troca de calor entre os corpos dos alunos e o ambiente, bem como ao aumento da ventilação e da movimentação dentro da sala. A Figura 30 ilustra essa variação da temperatura ao longo do tempo, destacando a influência da presença dos alunos no ambiente.

Figura 30 – Evolução da temperatura ao durante a coleta.



Fonte: O Autor (2025)


A oscilação térmica observada evidenciou que o sistema de ar-condicionado da sala realmente não estava funcionando adequadamente durante a primeira fase de coletas, contribuindo para a sensação de desconforto térmico. Após a análise desses dados, as informações foram encaminhadas à secretaria e à direção da escola, que reconheceram a necessidade de intervenção. Como resultado, o sistema de climatização foi ajustado e passou a operar com maior eficiência, promovendo um ambiente mais confortável e propício ao aprendizado.

Após essa intervenção, a temperatura na sala passou a se estabilizar em torno de 29°C, apresentando pequenas variações. Durante a aula, à medida que os alunos saíam gradativamente, a temperatura manteve-se estável, mas apresentou uma leve queda, chegando a valores inferiores

a 28°C ao final do período. Esses comportamentos foram evidenciados por meio de gráficos de linha, que ilustram a evolução da temperatura ao longo do tempo e destacam as alterações relacionadas ao fluxo de entrada e saída dos alunos.

Na Figura 31, é possível observar a distribuição da temperatura ao longo do segundo período de testes por meio de um gráfico de boxplot. O gráfico revela que a maior parte das medições de temperatura se concentrou entre 29.4°C e 30.4°C, com a mediana situada em aproximadamente 29.7°C. Além disso, um ponto isolado abaixo de 28°C, localizado na parte final do gráfico, corresponde à temperatura registrada quando a sala já estava vazia, após a saída gradual dos alunos. Esse comportamento indica que a temperatura se estabilizou em níveis mais confortáveis para o ambiente escolar, evidenciando a influência da ocupação da sala na variação térmica.

Figura 31 – Distribuição da temperatura durante o teste

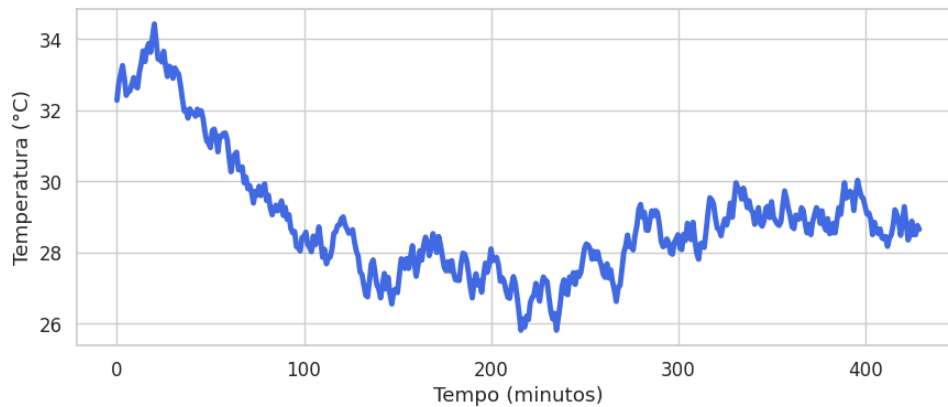


Fonte: O Autor (2025)

Na terceira e quarta fases de coletas, com a introdução do umidificador de ar como atuador no sistema, observou-se uma mudança significativa no comportamento térmico do ambiente em comparação com as fases anteriores. Nessas etapas, a temperatura passou a apresentar uma tendência de queda ao longo do tempo, conforme pode ser observado no gráfico da Figura 32, que mostra a evolução térmica durante o período de coleta.

Inicialmente, a temperatura no ambiente de teste estava próxima de 34°C. Com o funcionamento do sistema, os registros indicam uma redução gradual da temperatura, chegando a valores próximos de 26°C. Após essa queda, houve uma estabilização entre 28 e 30°C, indicando um controle mais eficaz sobre as variações térmicas.

No entanto, o aspecto mais interessante observado nessas fases está relacionado ao comportamento da variável temperatura. Embora o foco do sistema esteja no controle da umidade, os dados revelam que a atuação do umidificador também exerce influência na estabilidade térmica do ambiente. Isso se evidencia na redução gradual da temperatura e, principalmente, na sua posterior estabilização dentro de um intervalo mais confortável.

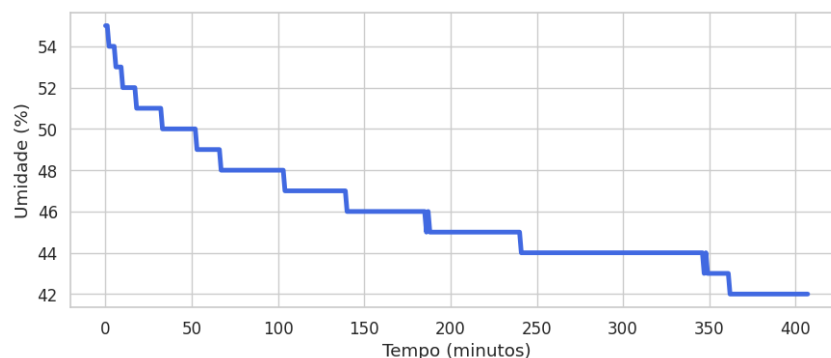
Figura 32 – Variação da temperatura durante o teste

Fonte: O Autor (2025)

Essa estabilidade térmica não apenas contribui para o conforto geral, mas também destaca a interação entre as variáveis do ambiente, sugerindo que o controle eficiente da umidade pode ter efeitos colaterais positivos sobre a temperatura. Tal constatação abre caminho para interpretações mais amplas sobre o impacto de sistemas de automação ambiental em múltiplas dimensões do conforto humano, mesmo quando o controle direto sobre certas variáveis, como a temperatura, não é o objetivo principal do sistema.

5.1.7 Análise da Umidade

Na primeira fase de coletas, a umidade da sala vazia apresentou uma queda acentuada e contínua ao longo do tempo, conforme ilustrado na Figura 33.

Figura 33 – Gráfico de linhas da umidade na sala vazia.


Fonte: O Autor (2025)

O gráfico de linhas indica que a umidade inicial era de aproximadamente 55%, e a tendência observada foi de uma diminuição quase exponencial, atingindo valores próximos a 40%. Essa redução expressiva pode ser atribuída à ausência de fontes de umidade no ambiente, à ventilação e a outros fatores que favorecem a desidratação do ar. A característica exponencial

dessa queda sugere que o ambiente tende a se estabilizar progressivamente em níveis mais baixos de umidade.

A Figura 34 apresenta o gráfico de boxplot da umidade registrada na sala vazia. Observa-se que a faixa interquartil, representada pela caixa do gráfico, varia aproximadamente entre 44% e 48%, indicando que a maior parte das medições de umidade encontra-se concentrada nesse intervalo.

Figura 34 – Gráfico de bloxpot da umidade na sala vazia.

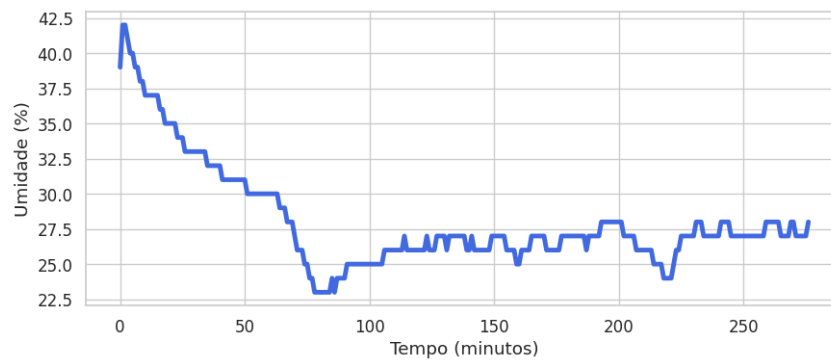


Fonte: O Autor (2025)

Há também a presença de um ponto fora da caixa, próximo a 55%, considerado um valor atípico, possivelmente relacionado a condições específicas dos instantes iniciais, conforme indicado pelo pico observado no gráfico de linhas.

A estabilidade aparente da umidade, evidenciada pela concentração dos dados em um intervalo estreito, sugere que o ambiente permaneceu em condições relativamente constantes durante a maior parte do tempo. Contudo, vale destacar que os níveis de umidade se mantiveram, em grande parte, abaixo do valor considerado ideal para o conforto térmico e a qualidade do ar, o que pode indicar a necessidade de intervenções para melhorar as condições ambientais. Além disso, o ponto de disparidade demonstra que, embora raro, o ambiente pode registrar variações significativas. Essa análise sintetiza o comportamento estatístico da variável ao longo do período e complementa a visualização temporal fornecida pelo gráfico de linhas.

A análise da umidade na sala cheia, ainda na primeira fase de testes, revela padrões distintos em relação à sala vazia. A Figura 35 mostra uma queda abrupta da umidade, iniciando em torno de 44% e atingindo rapidamente valores próximos de 20%. Após essa queda inicial, há uma recuperação gradual, estabilizando-se em torno de 27%, com variações constantes.


Figura 35 – Gráfico de linhas da umidade na sala cheia.

Fonte: O Autor (2025)

Esse comportamento pode ser atribuído à presença de cerca de 20 alunos e à maior atividade no ambiente, que influenciam diretamente a dinâmica da umidade em interação com a ventilação e outras variáveis ambientais. A análise da umidade na sala cheia revela padrões distintos quando comparados com a sala vazia. A Figura 35 demonstra um padrão de queda abrupta na umidade, começando em torno de 44% e rapidamente diminuindo para valores próximos a 20%.

Após essa queda inicial, a umidade apresenta uma melhora gradual, estabilizando-se em torno de 27%, mas com variações constantes ao longo do tempo. Esse comportamento pode ser atribuído ao aumento da atividade na sala, com a presença de aproximadamente 20 pessoas, o que pode ter influenciado a dinâmica da umidade interna. As flutuações observadas são indicativas de uma interação dinâmica entre a ventilação, a quantidade de pessoas e outras fontes de umidade ou secagem no ambiente.

A Figura 36 apresenta um gráfico de boxplot, no qual a caixa varia entre 25,4% e 27,8%, com 11 pontos de disparidade que indicam valores mais altos, variando de 30% a 42%.

Figura 36 – Gráfico de boxplot da umidade na sala cheia.


Fonte: O Autor (2025)

Esses pontos refletem momentos em que a umidade foi significativamente maior do que

a média geral. A faixa central da caixa representa a maior parte dos dados coletados, enquanto os pontos de disparidade ajudam a identificar eventos ou condições excepcionais que afetam a umidade de maneira notável.

O gráfico de violino, mostrado na Figura 37, revela uma distribuição crescente de umidade até a maior concentração em torno de 26,5%.

Figura 37 – Gráfico de violino da umidade na sala cheia.



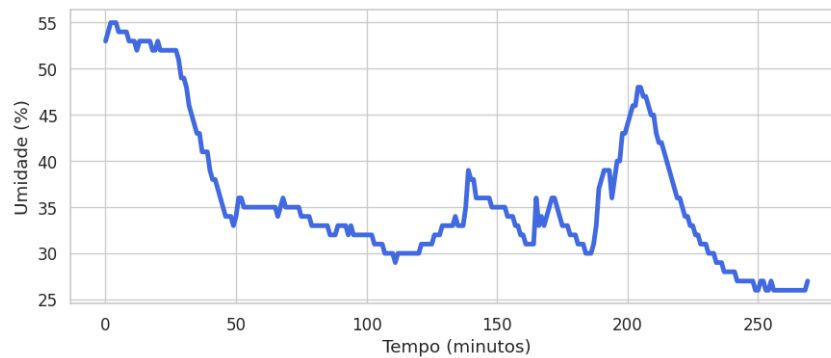
Fonte: O Autor (2025)

Após esse pico, os valores decaem, retornando a valores superiores a 40% de forma constante. O gráfico de violino proporciona uma visão detalhada da distribuição da umidade, mostrando que, apesar da concentração mais alta ser observada em torno de 26,5%, há uma dispersão considerável para valores mais elevados, indicando variações significativas na umidade ao longo do período analisado.

Em resumo, a análise da Figura 35, mostra um padrão de umidade inicial elevado que diminui abruptamente e depois estabiliza-se em torno de 27%, com variações significativas ao longo do tempo. A Figura 36 confirma a presença de pontos de disparidade, enquanto a Figura 37 destaca a distribuição da umidade e a dispersão para valores mais altos. Esses resultados refletem o impacto da presença de pessoas na dinâmica da umidade e indicam que a sala cheia apresenta variações mais amplas e constantes em comparação com a sala vazia.


Na segunda fase de coletas, representada na Figura 38, observa-se a variação da umidade ao longo do período de testes.

Inicialmente, os níveis estavam em torno de 55%. No entanto, com o início da operação do sistema de ar-condicionado, houve uma queda acentuada, com a umidade se mantendo entre 30% e 37% durante a maior parte do tempo. Esse comportamento é típico de ambientes climatizados, nos quais o ar-condicionado reduz a umidade relativa ao mesmo tempo em que resfria o ar. Ao final do teste, com a saída gradual dos alunos, a umidade caiu ainda mais, atingindo valores próximos de 25%. Esse fenômeno pode ser atribuído à menor ocupação da sala, somada à operação contínua do sistema de climatização, que continuou promovendo a remoção da umidade do ambiente.

Figura 38 – Evolução da umidade ao longo do tempo durante os testes.

Fonte: O Autor (2025)


Na Figura 39, é possível observar a distribuição dos níveis de umidade durante os testes por meio de um gráfico de boxplot.

Figura 39 – Distribuição da umidade durante os testes, com destaque para a mediana e os pontos isolados.

Fonte: O Autor (2025)

A caixa do gráfico se encontra entre 31% e 37%, indicando que a maior parte das medições permaneceu dentro desse intervalo. Além disso, há pontos isolados que ultrapassaram os 47% e 50%, representando momentos em que a umidade aumentou devido a fatores externos ou possíveis irregularidades no funcionamento do sistema de climatização. Esses valores atípicos destacam a importância de um monitoramento contínuo para garantir a estabilidade das condições ambientais.

Na terceira fase de coleta, com a adição do umidificador de ar ao sistema, foi possível observar uma mudança significativa em relação às etapas anteriores. A Figura 40 apresentará essa alteração nos níveis de umidade do ambiente ao longo de todo o período de testes.

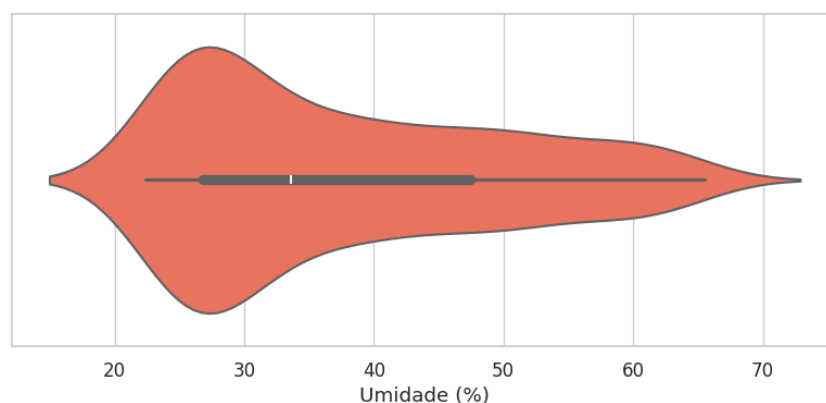
Figura 40 – Evolução da umidade ao longo do tempo durante os testes.

Fonte: O Autor (2025)

No início do teste, a umidade se encontrava abaixo de 30%, patamar considerado crítico. Após a ativação do umidificador, observou-se uma elevação constante da umidade, alcançando níveis próximos de 70%, o que é considerado ideal para o conforto ambiental. Em um primeiro momento, o problema parece ter sido solucionado. No entanto, como o tempo total da coleta foi de aproximadamente seis horas, não foi possível determinar se os níveis de umidade se estabilizariam ou se continuariam aumentando, a ponto de tornar o ambiente excessivamente úmido, semelhante a uma “sauna”.

Diante dessa incerteza, tornou-se necessário estabelecer uma nova rodada de testes com um período mais longo. O objetivo foi verificar o comportamento da variável ao longo do tempo e identificar o ponto de estabilidade, confirmando se o sistema fuzzy conseguiria manter a umidade em níveis adequados sem ultrapassar o limite necessário.

A Figura 41 apresenta o gráfico de violino correspondente à umidade durante essa terceira fase.

Figura 41 – Gráfico de violino da umidade na sala cheia.

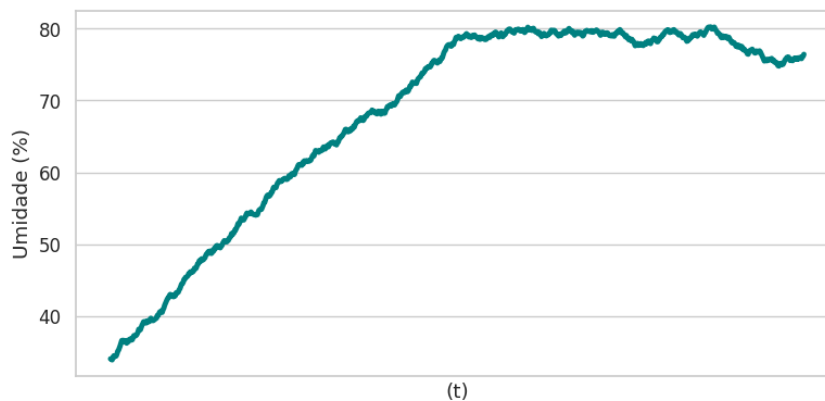
Fonte: O Autor (2025)

É possível observar que a maior concentração de dados está abaixo de 30%, o que reforça

as observações iniciais da Figura 40. Posteriormente, nota-se uma elevação dos valores, que chegam a ultrapassar 70%, evidenciando a melhoria significativa dessa variável em comparação com as fases anteriores.

Na quarta e última fase de coletas, o experimento foi estendido para aproximadamente doze horas, permitindo uma análise mais aprofundada do comportamento da umidade ao longo do tempo. A Figura 42 ilustra a variação da umidade no ambiente durante esse período.

Figura 42 – Evolução da umidade ao longo do tempo durante os testes.



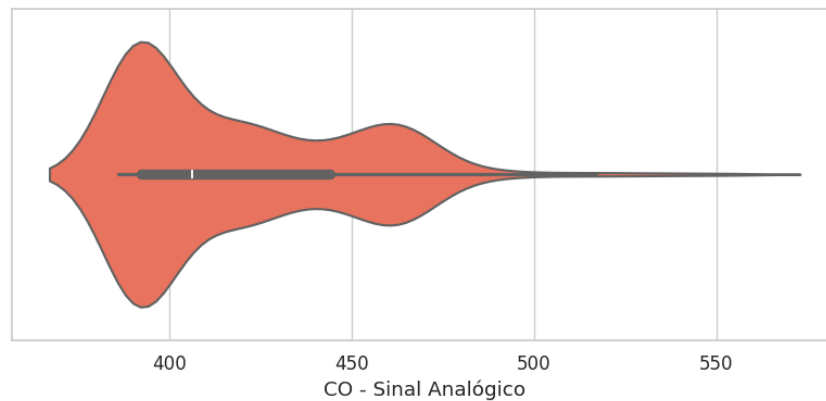
Fonte: O Autor (2025)

Nos primeiros sete horas de teste, observa-se uma elevação contínua dos níveis de umidade, resultado da atuação prolongada do umidificador. Esse crescimento constante reflete a resposta do sistema fuzzy frente aos baixos níveis iniciais, buscando alcançar o patamar de conforto ideal.

Após esse período inicial, por volta da sétima hora, nota-se uma estabilização da umidade, com valores oscilando entre 76% e 80%. Esse comportamento indica que o sistema atinge sua zona de resolução dentro desse intervalo, mantendo a umidade em um nível considerado confortável. Nesse estágio, o umidificador passa a atuar de forma menos intensa, apenas realizando ajustes pontuais para preservar a estabilidade. Assim, confirma-se a eficácia do sistema fuzzy em corrigir o problema de baixa umidade identificado nas fases anteriores, promovendo um ambiente mais adequado ao conforto dos ocupantes.

5.1.8 Análise do CO

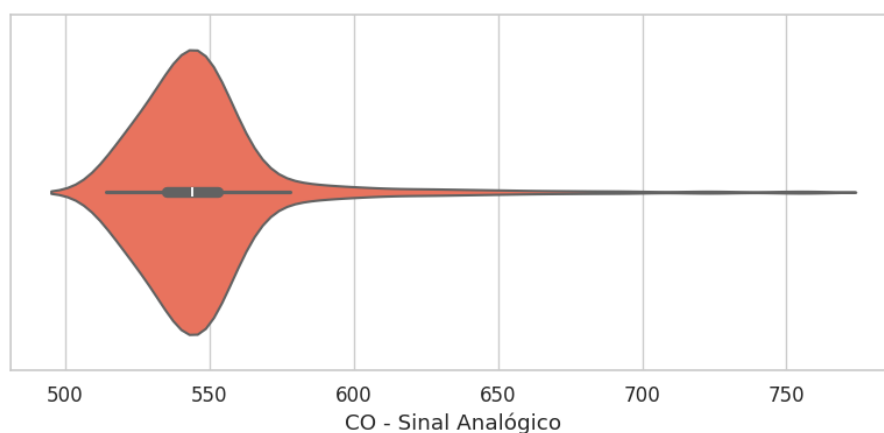
A Figura 43 apresenta o gráfico de violino referente à medição dos valores de monóxido de carbono (CO) durante a primeira fase de coleta, realizada em uma sala vazia.

Figura 43 – Distribuição dos valores de sinal analógico de CO na sala vazia

Fonte: O Autor (2025)

Os dados representados correspondem à leitura bruta do sinal captado pelo pino analógico do *Arduino*, que varia em uma escala de 0 a 1023. Nesta etapa inicial, os sensores ainda não operavam com conversão para a unidade de ppm, pois os dados coletados também foram utilizados para auxiliar na posterior calibração dos sensores para a segunda fase de experimentos. A distribuição dos valores de CO mostra uma maior concentração em torno de 490, com uma queda gradual até cerca de 460, onde a presença de valores se torna mais esparsa. Esse padrão sugere que, na ausência de pessoas no ambiente, os níveis de CO mantiveram-se relativamente estáveis e baixos ao longo do período de coleta, sem grandes variações.

Na segunda parte da primeira fase de coletas, com a sala agora ocupada por pessoas, observou-se um comportamento distinto na concentração de monóxido de carbono (CO). A Figura 44 exibe o gráfico de violino correspondente a essa condição, revelando uma concentração mais elevada dos valores de CO, com a maioria dos dados agrupando-se em torno de 540.

Figura 44 – Distribuição dos valores de CO na sala cheia representada pelo gráfico de violino.

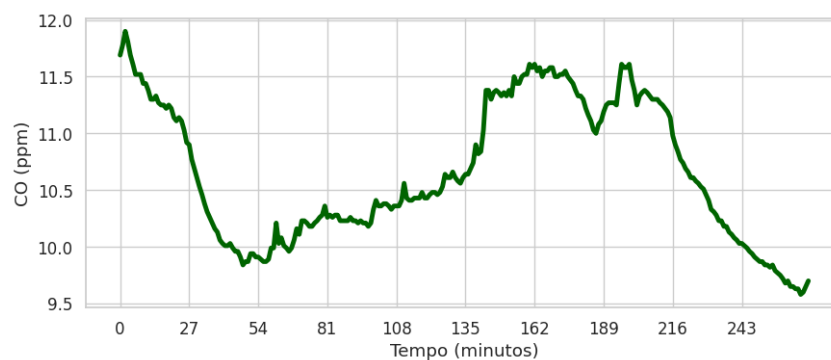
Fonte: O Autor (2025)

Esse aumento está de acordo com a expectativa de que a presença humana em ambientes fechados contribua para o acréscimo de CO no ar. As medições continuaram sendo realizadas

a cada minuto e armazenadas no repositório de dados. Embora os sensores ainda não estejam calibrados para fornecer leituras em ppm, o que impede neste momento a determinação precisa da concentração de CO, é visível um aumento nos valores registrados. Mesmo operando em escala de sinal analógico, os padrões de concentração se apresentaram mais elevados e relativamente estáveis durante o período de ocupação, em comparação com os resultados obtidos anteriormente na sala vazia.

A Figura 45 apresenta a variação da concentração de monóxido de carbono (CO) ao longo do tempo, já na segunda fase de testes.

Figura 45 – Evolução da concentração de CO ao longo do tempo durante os testes.

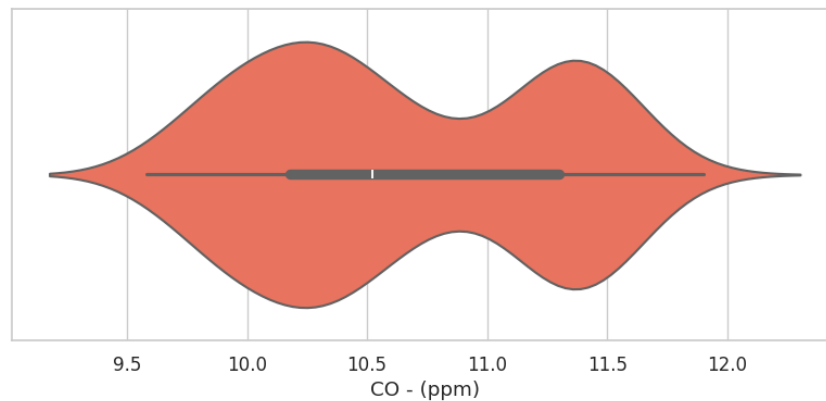


Fonte: O Autor (2025)

Nesta etapa, os sensores foram devidamente calibrados para o ambiente, possibilitando a obtenção de valores em partes por milhão (ppm). Durante o período de monitoramento, os níveis de CO oscilaram entre 12 e 9,5 ppm, revelando um padrão de comportamento característico.

Inicialmente, observou-se uma queda na concentração do gás, seguida por uma leve elevação. Ao final da coleta, os valores voltaram a cair de forma mais acentuada, o que pode estar relacionado à redução do número de alunos presentes na sala, diminuindo, assim, a emissão de CO. Esse comportamento reforça a influência direta da ocupação do ambiente sobre os níveis de concentração desse poluente.

Na Figura 46, observa-se o gráfico de boxplot que descreve a distribuição da concentração de CO durante este segundo período de testes.

Figura 46 – Distribuição da concentração de CO


Fonte: O Autor (2025)

A caixa de dados se encontra entre 10,2 e 11,3 ppm, com a linha mediana situada em torno de 10,5 ppm. Esse intervalo reflete a relativa estabilidade dos níveis de CO durante a maior parte do experimento, sugerindo que a emissão do gás manteve-se constante dentro dessa faixa.

Contudo, apesar dos níveis relativamente elevados de CO, a concentração apresentou um comportamento estável ao longo do período monitorado. A leve variação dentro da faixa observada pode ser atribuída a pequenas flutuações nos processos que geram o gás, como o fluxo de ar e a ocupação variável da sala.

Ainda assim, os valores se mantiveram bem controlados, o que indica que, mesmo com as mudanças no ambiente, a ventilação e o sistema de climatização foram eficazes em manter os níveis de CO dentro de um intervalo seguro para a saúde dos indivíduos presentes. Além disso, a linha mediana próxima de 10,5 ppm sugere que o comportamento da concentração de CO foi relativamente constante e previsível ao longo do tempo, sem grandes picos de variação. Esse padrão é desejável em ambientes internos.

Na terceira fase de coletas, marcada pela introdução do umidificador de ar acoplado ao sistema, foi possível observar mudanças significativas no comportamento do ambiente interno, conforme apresentado na Figura 47, o gráfico de linhas evidencia uma redução considerável nos níveis de monóxido de carbono (CO) em comparação com as fases anteriores, indicando um ambiente mais estável e com menor concentração do gás.

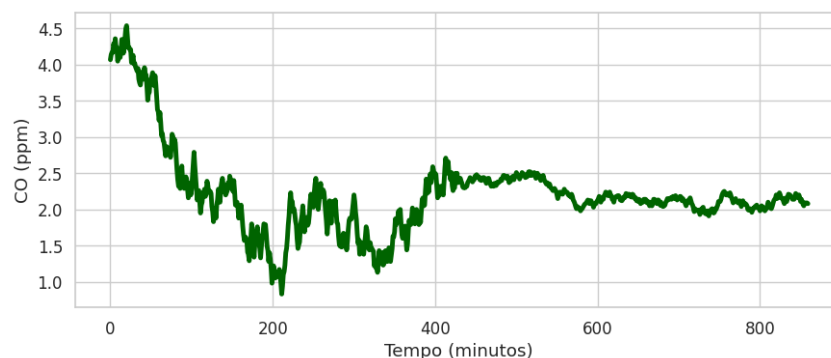
Figura 47 – Evolução da concentração de CO ao longo do tempo durante os testes.

Fonte: O Autor (2025)

Durante essa etapa, os valores de CO iniciaram-se e se mantiveram próximos de 6,0 ppm ao longo do tempo de monitoramento. Esse comportamento sugere que o aumento da umidade relativa do ar contribuiu para uma maior estabilidade na concentração de CO, reduzindo as variações bruscas que haviam sido registradas anteriormente. A umidade atua como um fator de dispersão que interfere positivamente na dinâmica dos gases presentes no ambiente, tornando o ar menos suscetível a oscilações indesejadas.

Esse cenário é especialmente desejável em ambientes internos, como salas de aula, pois promove maior conforto e segurança aos ocupantes, além de indicar que o uso do umidificador pode ser uma medida eficaz para manter a qualidade do ar em níveis adequados.

Na última fase de coletas, foi possível identificar um comportamento mais específico e refinado nos níveis de CO, conforme apresentado na Figura 48.

Figura 48 – Evolução da concentração de CO ao longo do tempo durante os testes.

Fonte: O Autor (2025)

Durante essa etapa, os dados mantiveram inicialmente um padrão semelhante ao observado na terceira fase. No entanto, a partir do momento em que a umidade relativa do ar atinge um ponto de estabilização, registra-se uma variação ainda mais reduzida na concentração de CO. Essa redução na amplitude das oscilações sugere uma melhora nos índices de qualidade do ar, mesmo que essa melhoria não tenha sido promovida de forma deliberada.

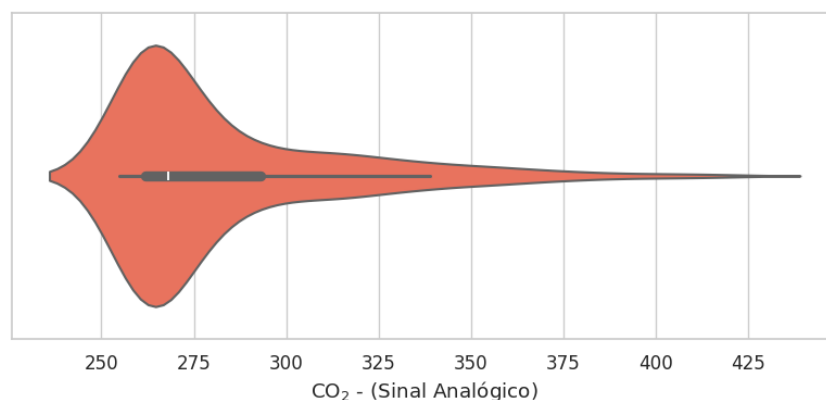
A estabilidade da umidade no ambiente pode estar relacionada a uma atenuação nas variações da concentração de CO, favorecendo um comportamento potencialmente mais constante e previsível desse gás. Tal tendência sugere que níveis controlados de umidade relativa podem contribuir para melhorar os processos de dispersão e diluição de poluentes, o que, por sua vez, tenderia a favorecer um microclima mais estável e saudável em ambientes fechados, como salas de aula. Embora não se possa afirmar uma relação direta, os dados indicam a relevância de considerar múltiplos parâmetros ambientais na busca por uma melhor qualidade do ar em ambientes internos.

5.1.9 Análise do CO₂

Na primeira fase de coletas, dedicada à observação do ambiente com a sala vazia, a variável dióxido de carbono (CO₂) apresentou comportamentos distintos em relação às demais fases. Os dados revelaram uma média do sinal analógico do sensor em torno de 260, seguida por uma tendência de decréscimo contínuo até valores próximos de 425. Essa estabilidade nos valores é considerada positiva, pois a análise digital indicou poucas variações significativas, sugerindo uma concentração de CO₂ relativamente baixa e constante durante a ausência de pessoas.

A Figura 49 ilustra essa distribuição na sala vazia, destacando a manutenção de uma faixa controlada de valores, o que reflete a inexistência de fontes relevantes de emissão de CO₂ neste cenário inicial.

Figura 49 – Distribuição dos valores de CO₂ na sala vazia.

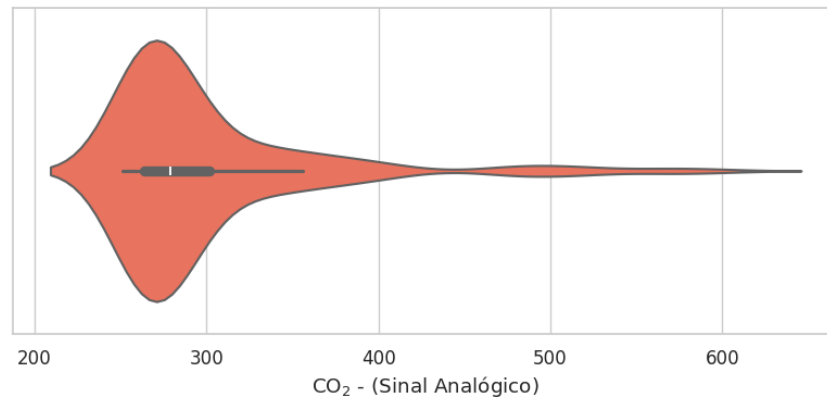


Fonte: O Autor (2025)

Ainda na primeira fase de coleta, agora durante a segunda etapa, com a sala ocupada, os dados indicaram uma média do sinal analógico associado à concentração de CO₂ em torno de 380, apresentando um aumento gradual até atingir valores próximos de 500. Essa variação é significativamente mais acentuada em comparação à observada na sala vazia, refletindo o impacto direto da presença de pessoas no ambiente, que intensifica a emissão de CO₂.

A Figura 50 ilustra, por meio de um gráfico de violino, a distribuição dos dados, destacando uma ampla dispersão entre os valores de 350 a 600, o que evidencia a maior variabilidade dos níveis de CO₂ na sala cheia.

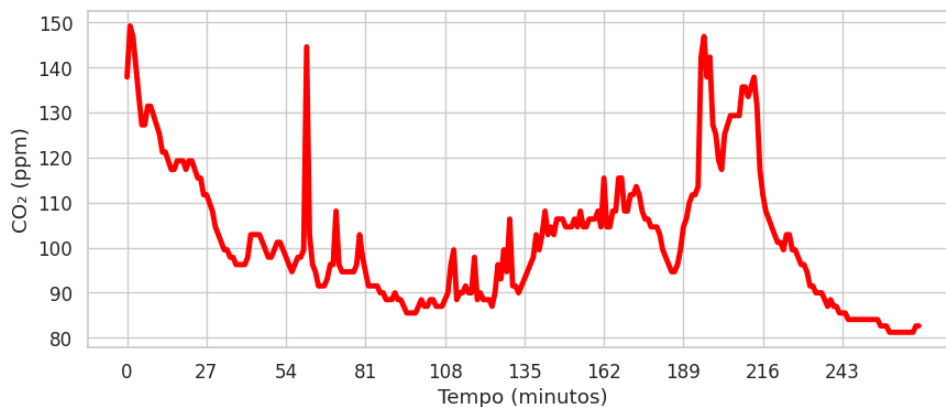
Figura 50 – Distribuição dos valores de CO₂ na sala cheia.



Fonte: O Autor (2025)

A Figura 51 apresenta um gráfico de linha que ilustra a variação da concentração de dióxido de carbono (CO₂) ao longo do tempo, durante a segunda fase dos testes. Observa-se uma oscilação marcada por sucessivos picos e uma queda acentuada no final do período de medição.

Figura 51 – Evolução da concentração de CO₂ ao longo do tempo durante os testes.

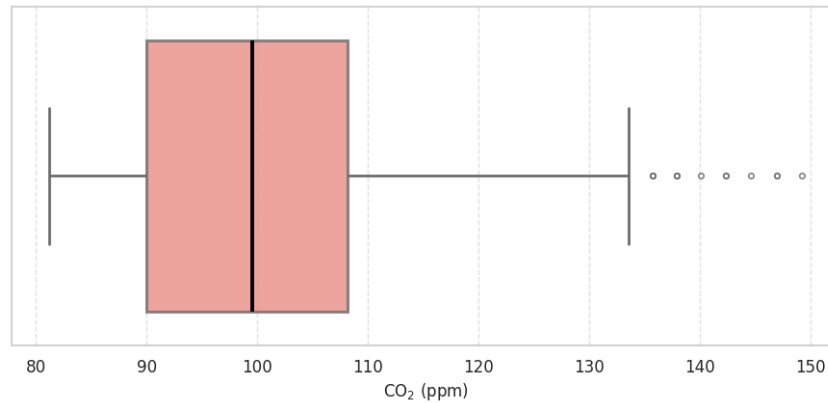


Fonte: O Autor (2025)

Essa medição foi realizada após a calibração dos sensores no ambiente e revelou um comportamento significativamente mais dinâmico em comparação com o observado para o monóxido de carbono. Durante a maior parte do tempo, os níveis de CO₂ mantiveram-se abaixo de 150 ppm, com variações frequentes entre 80 e 150 ppm, o que é característico de ambientes fechados com presença constante de pessoas, como salas de aula. Ao final da coleta, os dados indicaram um aumento gradual da concentração até atingir 150 ppm. Em seguida, foi registrada uma queda brusca para cerca de 80 ppm, o que reflete a saída dos alunos e a consequente renovação do ar no ambiente.

Adicionalmente, o gráfico de boxplot exibido na Figura 52 mostra que a caixa de dados se localiza entre 90 e 109 ppm, com a linha mediana próxima de 100 ppm.

Figura 52 – Distribuição da concentração de CO₂ durante os testes, com destaque para a mediana e os pontos isolados.

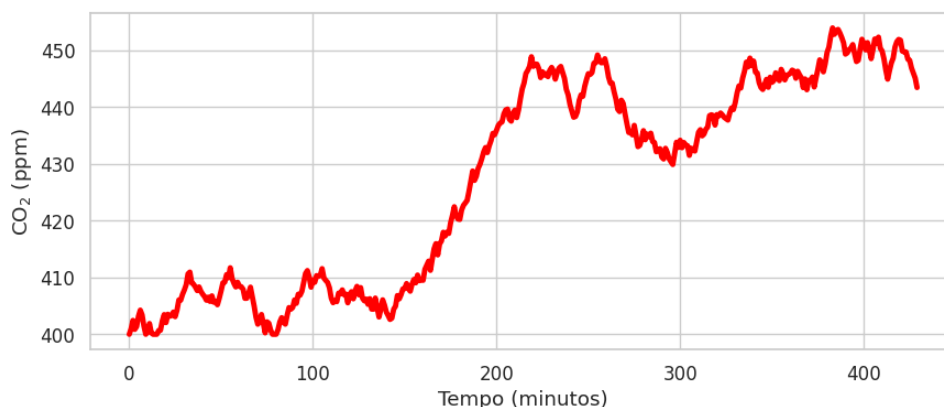


Fonte: O Autor (2025)

Os pontos isolados acima de 130 ppm e próximos de 150 ppm indicam momentos em que ocorreram picos significativos na concentração de CO₂, geralmente associados ao aumento da ocupação da sala e à pouca renovação do ar.

A Figura 53 apresenta o gráfico correspondente à concentração de CO₂ durante a terceira fase de testes. Nesta etapa, conforme descrito anteriormente, foi realizado o acoplamento do umidificador ao sistema, permitindo a análise do comportamento dos gases em um ambiente com umidade controlada.

Figura 53 – Evolução da concentração de CO₂ ao longo do tempo durante os testes.



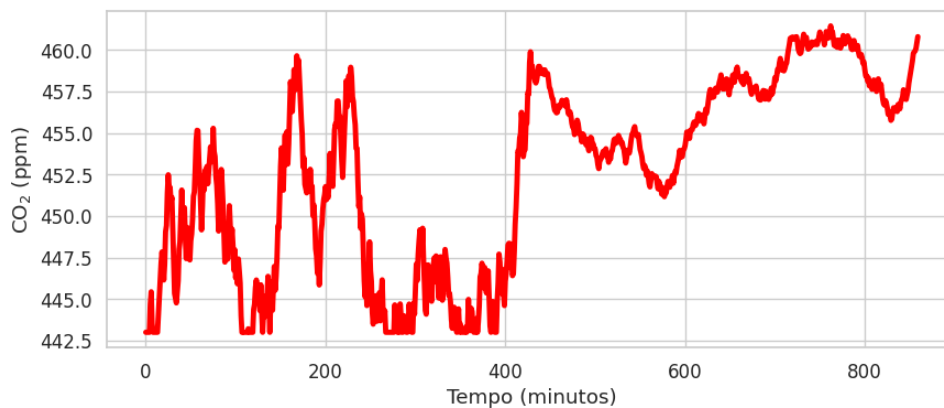
Fonte: O Autor (2025)

Observa-se que, embora haja um leve aumento nos valores de CO₂ ao longo do tempo, esse crescimento ocorre de forma atenuada e progressiva. A concentração mantém-se dentro de uma faixa relativamente estável, demonstrando baixa sensibilidade do CO₂ frente à elevação dos níveis de umidade. Esse comportamento contrasta com o observado na fase anterior, em que

ocorriam oscilações acentuadas, com picos e quedas bruscas. Dessa forma, o ambiente torna-se mais previsível e controlado, evidenciando um padrão de estabilidade associado à presença do umidificador no sistema.

Na última fase de coletas, com um tempo de aferição mais prolongado, foi possível observar um comportamento semelhante ao registrado na primeira fase de testes, conforme ilustrado na Figura 54.

Figura 54 – Evolução da concentração de CO₂ ao longo do tempo durante os testes.



Fonte: O Autor (2025)


Durante todo o período de monitoramento, os níveis de CO₂ mantiveram-se dentro de um intervalo estreito de variação, sem apresentar oscilações bruscas ou picos acentuados. Essa estabilidade indica um ambiente mais uniforme e previsível em relação às variáveis de qualidade do ar, especialmente no que se refere a alterações repentinas na concentração de dióxido de carbono. Tal comportamento sugere uma consolidação dos efeitos das adaptações implementadas nas fases anteriores, contribuindo para um controle mais eficaz do ambiente monitorado.

5.2 Conforto com *Fuzzy*

A variável conforto *fuzzy* passou a ser estimada apenas a partir da segunda fase de testes, período no qual foram definidas as funções de pertinência para cada variável de entrada e concluída a calibração dos sensores de CO e CO₂. Essa etapa foi essencial para garantir maior precisão nas medições e confiabilidade no processo de inferência *fuzzy*.

Na Figura 55, observa-se a evolução dessa variável ao longo do período monitorado. O conforto foi calculado com base na inferência e defuzzificação dos sinais analógicos obtidos pelos sensores, refletindo de forma integrada as condições ambientais do espaço analisado.

Logo após sua implementação, o sistema estimou o conforto em aproximadamente 0,6, o que corresponde a um grau de pertencimento de 60% à categoria Confortável, conforme os critérios estabelecidos na Tabela 7 e nas Funções de Pertinência apresentadas na Seção 4.4.5. Esse valor representa um ambiente razoavelmente equilibrado, embora sujeito a variações ao

Figura 55 – Variação da variável conforto ao longo do teste, conforme a saída do sistema fuzzy.

Fonte: O Autor (2025)

longo do tempo, especialmente diante do aumento na ocupação da sala e das alterações naturais nas variáveis ambientais.


Com a entrada dos alunos, observou-se uma queda acentuada no conforto, que atingiu valores inferiores a 0,4, classificando-se na faixa Confortável. A umidade também sofreu alterações, oscilando dentro da faixa inferior da categoria Boa. À medida que o ambiente se estabilizou e os sistemas de ventilação e climatização entraram em funcionamento, a variável conforto apresentou um aumento gradual, alcançando um pico acima de 0,9, situando-se na categoria Muito Confortável. Esse pico foi registrado quando as variáveis ambientais estavam total ou parcialmente dentro dos limites ideais para um ambiente saudável.

Esse estado de conforto máximo, no entanto, foi apenas momentâneo. Em seguida, houve uma nova queda, e os valores estabilizaram-se na faixa entre 0,4 e 0,5 durante a maior parte do teste. Tal comportamento evidencia a importância do monitoramento contínuo das variáveis ambientais para a manutenção de um ambiente confortável e saudável ao longo do tempo.

Durante esta fase de testes, a variável conforto apresentou variações visíveis e significativas, com oscilações frequentes entre picos e quedas, refletindo as mudanças nas condições ambientais dentro da sala. Ao final da aula, com a saída dos alunos, os valores de conforto voltaram a cair, chegando novamente a níveis inferiores a 0,4. Essa queda evidenciou a alteração nas condições internas da sala, causada pela redução no número de pessoas e pelo aumento no fluxo de saída de ar no ambiente.

Na terceira fase de teste, com a introdução do umidificador de ar no ambiente, a variável conforto passou a ser diretamente influenciada por esse fator externo. A partir desse momento, o sistema não apenas monitorava as condições ambientais, mas também atuava com o objetivo de ajustar o índice de conforto para dentro de faixas consideradas ideais. A Figura 56 apresenta o comportamento do ambiente após a inserção do umidificador de ar.

Observa-se nesta fase de coleta de dados uma tendência clara e consistente de elevação do

Figura 56 – Variação da variável conforto ao longo do teste, conforme a saída do sistema *fuzzy*.

Fonte: O Autor (2025)

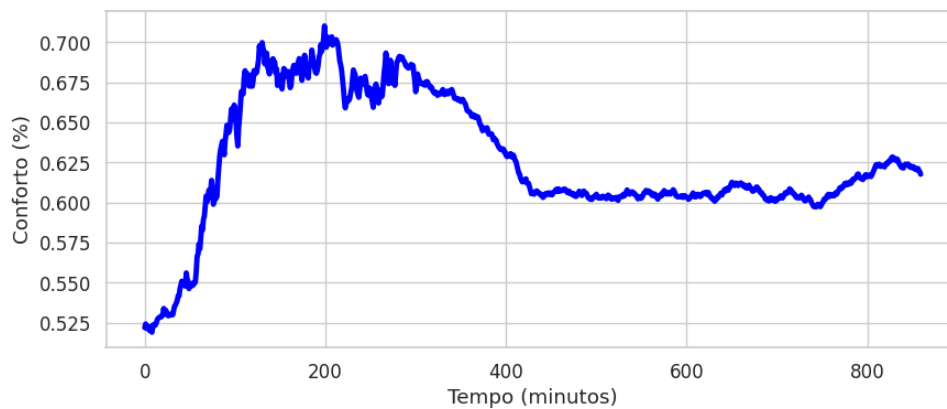
nível de conforto ambiental, o que está diretamente alinhado com os objetivos do presente estudo. Diferentemente da fase anterior, em que o índice de conforto apresentava oscilações intensas e comportamento instável, neste momento os dados revelam uma trajetória de crescimento contínuo, com significativa atenuação de picos e vales abruptos.

O valor inicial do índice de conforto se encontra em torno de 0,45, um patamar considerado abaixo do intervalo ideal para a sensação de bem-estar no ambiente. Com a ativação e operação contínua do sistema de controle, especialmente após a introdução do umidificador de ar, esse índice começa a se elevar gradualmente, demonstrando um comportamento quase linear ao longo do tempo. Essa elevação prossegue até atingir valores próximos de 0,6, momento em que se observa o início de um processo de estabilização.

Esse padrão de evolução indica que o sistema começa a responder de forma mais precisa às variações das variáveis ambientais, promovendo um ajuste contínuo que culmina na construção de um ambiente interno mais equilibrado. A redução da volatilidade do conforto e sua progressão em direção a níveis mais satisfatórios demonstram que o sistema está efetivamente desempenhando seu papel como agente regulador e otimizador das condições do ambiente interno.

Na quarta etapa das coletas, cuja duração se estende por aproximadamente doze horas, observa-se um comportamento semelhante ao padrão identificado na fase anterior. No entanto, devido ao período ampliado de monitoramento, torna-se possível analisar com maior clareza os efeitos prolongados do sistema de controle sobre a variável conforto, especialmente após a estabilização da umidade do ar no interior da sala, conforme apresentado na Figura 57.

No início do teste, o índice de conforto já se encontra em torno de 0,52, valor superior ao das fases iniciais dos testes anteriores. A partir da atuação do sistema de controle *fuzzy*, observa-se uma elevação significativa do conforto, que atinge níveis superiores a 0,70 nas primeiras três horas de operação. Em seguida, o sistema sinaliza uma tendência de estabilização e passa por

Figura 57 – Variação da variável conforto ao longo do teste, conforme a saída do sistema *fuzzy*.

Fonte: O Autor (2025)

uma leve queda gradual, até alcançar uma faixa estável em torno de 0,61, na qual permanece até o término da coleta.

Esse comportamento indica que, mesmo após o pico de conforto, o sistema mantém sua capacidade de regulação e sustenta um ambiente satisfatório ao longo do tempo. Tal desempenho comprova a eficácia do modelo de controle adotado, especialmente na manutenção de condições ambientais adequadas por períodos prolongados. A análise da variável “Conforto” reforça, portanto, a melhoria efetiva da qualidade do ar proporcionada pela atuação contínua do sistema.


5.3 Análise Quantitativa do Desempenho do Sistema

A análise dos resultados evidencia que a implementação do umidificador trouxe mudanças significativas no comportamento da variável conforto ao longo do tempo. Antes de sua introdução, o sistema apresentava níveis de conforto consideravelmente baixos e instáveis, com picos e vales pronunciados, dificultando a manutenção de condições agradáveis no ambiente. Com a ativação do umidificador, observou-se uma elevação gradual e consistente dos valores de conforto, indicando que o sistema passou a atuar de forma mais eficiente e a regular melhor o microclima interno.

A partir da avaliação do desvio padrão, foi possível quantificar a redução na variabilidade dos níveis de conforto. Os dados mostram que, antes da intervenção, a dispersão das observações era elevada, refletindo maior irregularidade no ambiente monitorado. Após a ativação do umidificador, o desvio padrão diminuiu significativamente, evidenciando que os valores passaram a se concentrar em torno de uma faixa mais controlada, com menor oscilação e maior previsibilidade. A Figura 58 ilustra claramente essa diferença, comparando o comportamento do sistema antes e depois da implementação do umidificador.

A análise da amplitude reforça esse comportamento, evidenciando mudanças mais significativas a partir do *turning point*. Antes da intervenção, a amplitude dos valores de conforto

Figura 58 – Comparação do ambiente antes e depois da implementação do umidificador.



Fonte: O Autor (2025)

era ampla, indicando que o sistema registrava extremos significativos ao longo do tempo. Com o umidificador em operação, a amplitude foi reduzida de forma expressiva, sobretudo após o *turning point*, mostrando que os níveis de conforto passaram a variar dentro de um intervalo mais estreito. Essa redução na variabilidade total demonstra que o sistema conseguiu limitar os valores extremos, promovendo maior uniformidade e estabilidade no ambiente, com as melhorias mais perceptíveis justamente nos instantes posteriores à atuação efetiva do umidificador.

A energia do sinal, por sua vez, evidencia a intensidade acumulada das flutuações. A comparação entre as duas etapas do experimento revelou uma diminuição considerável na energia após a ativação do umidificador, o que indica que o sistema passou a exigir menos correções abruptas para manter o conforto dentro de uma faixa adequada. Em termos práticos, isso sugere que o microclima se tornou mais estável, com menor ocorrência de variações súbitas, contribuindo para uma percepção de conforto mais consistente pelos ocupantes.

Os resultados consolidados na Tabela 13 confirmam o efeito positivo do umidificador sobre o desempenho do sistema.

Tabela 13 – Comparativo das métricas estatísticas antes e depois da ativação do umidificador

Métrica	Antes	Depois
Desvio padrão	0,14	0,05
Amplitude	0,60	0,18
Energia	91,06	76,98

Fonte: O Autor

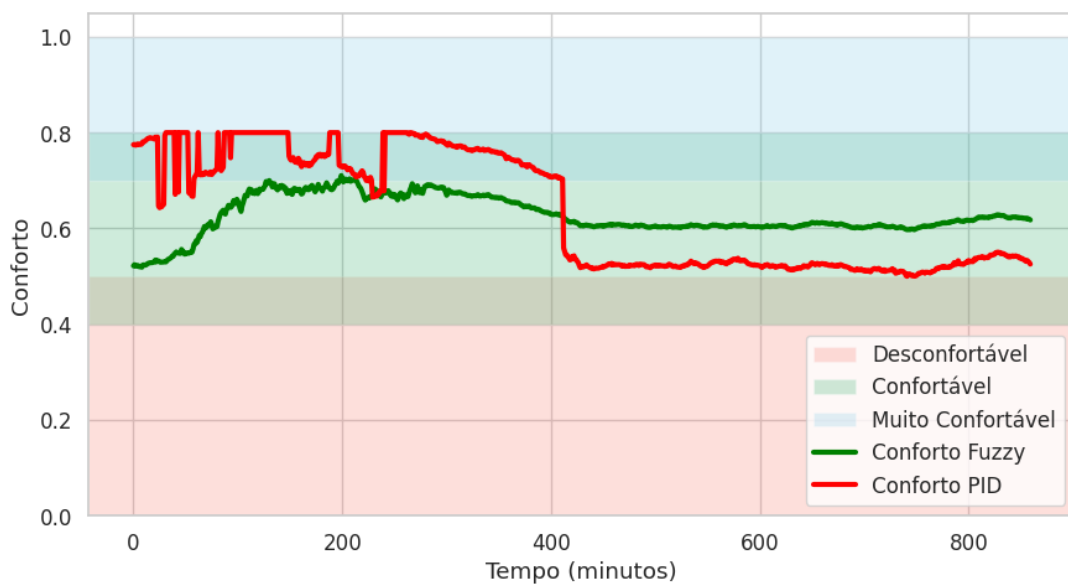
A análise desses indicadores evidencia que a redução simultânea do desvio padrão, da amplitude e da energia do sinal refletiu uma operação mais controlada do sistema. Em

conjunto, essas métricas mostram que os níveis de conforto passaram a apresentar menor variabilidade e menor intensidade acumulada das oscilações ao longo do tempo, indicando uma melhoria significativa no desempenho do ambiente monitorado. Dessa forma, os dados fornecem uma compreensão quantitativa clara sobre a melhoria do microclima interno e reforçam que a integração do umidificador foi decisiva para otimizar o desempenho do sistema, garantindo um ambiente mais equilibrado e confortável para os ocupantes.

5.4 Análise Quantitativa entre os Controladores *Fuzzy* e PID

A Figura 59 apresenta a comparação entre os sistemas de controle utilizando lógica fuzzy e controle PID, ambos aplicados no mesmo ambiente e sob condições semelhantes, com o objetivo de avaliar a evolução da variável conforto.

Figura 59 – Variação da variável conforto ao longo do teste, conforme a saída dos sistemas fuzzy e PID.



Fonte: O Autor (2025)

Observa-se que a curva referente ao sistema controlado pela lógica fuzzy, já apresentada na Figura 57, evidencia um crescimento gradual da variável conforto, estabilizando-se em torno de 0,6 com pequenas oscilações residuais. Este comportamento indica uma resposta suavizada, permitindo que o sistema mantenha níveis de conforto consistentes ao longo do tempo.

Em contraste, a resposta do sistema sob controle PID mostra maior sensibilidade às variações iniciais, apresentando flutuações mais acentuadas nos primeiros instantes. Após esse período transitório, o PID tende a se aproximar da resposta fuzzy, mas ainda exibe oscilações consideráveis, chegando próximo à faixa de desconforto, com a variável controlada estabilizando próxima de 0,54. Esse comportamento evidencia maior variabilidade e menor previsibilidade, especialmente em ambientes sujeitos a ruídos ou mudanças rápidas nas condições ambientais.

Além disso, a análise quantitativa revela que apenas 47,91% das amostras controladas pelo PID permaneceram acima de 0,6, enquanto o sistema baseado em lógica fuzzy alcançou 90,58% das amostras acima desse mesmo limiar. Considerando que valores acima de 0,6 representam níveis de conforto satisfatórios, estes resultados reforçam a superioridade da abordagem fuzzy, que combina menor variabilidade com maior manutenção da qualidade do ambiente interno.

A Tabela 14 apresenta uma comparação detalhada dos principais indicadores entre os dois sistemas.

Tabela 14 – Comparação dos indicadores quantitativos entre os sistemas Fuzzy e PID

Indicador	PID	Fuzzy
Desvio padrão	0,12	0,04
Amplitude	0,30	0,19
Energia	360,21	339,25
Amostras acima de 0,6 (%)	47,91	90,58

Fonte: O Autor (2025)

Considerando a energia total acumulada, o fuzzy apresentou 339,25 frente a 360,21 do PID, refletindo uma redução significativa no esforço global necessário para manter o conforto. Essa combinação de menor variabilidade, amplitude restrita e menor consumo energético evidencia que o controle fuzzy oferece um desempenho mais eficiente e previsível, sendo especialmente indicado para ambientes em que a suavidade da resposta e a precisão do controle são prioritárias.

Observa-se que o desvio padrão do fuzzy (0,04) é consideravelmente inferior ao do PID (0,12), indicando flutuações menos intensas. De maneira semelhante, a amplitude, que representa a diferença entre os valores extremos, é menor no fuzzy (0,19) em relação ao PID (0,30), evidenciando que o controle fuzzy consegue limitar melhor os extremos da variável conforto.

6 CONSIDERAÇÕES FINAIS

O presente estudo teve como objetivo desenvolver um sistema inteligente para monitoramento e melhoria da qualidade do ar em ambientes internos, utilizando a lógica *fuzzy* como abordagem central. A pesquisa se concentrou na análise de variáveis ambientais críticas, incluindo temperatura, umidade relativa, monóxido de carbono (CO) e dióxido de carbono (CO₂), aplicando uma lógica difusa capaz de lidar com a incerteza e a subjetividade inerentes à interpretação dessas grandezas. Essa abordagem permitiu a criação de um sistema adaptativo, que reflete de maneira mais próxima à percepção humana as condições do ambiente interno, oferecendo soluções de baixo custo e potencialmente replicáveis em diferentes contextos.

Durante a execução do projeto, foram realizadas coletas de dados experimentais em cenários controlados e variáveis, permitindo avaliar a resposta do sistema em condições reais. Os resultados obtidos mostraram que o sistema baseado em lógica *fuzzy* apresentou desempenho consistente e eficiente na manutenção de níveis de conforto ambiental, demonstrando capacidade de adaptação frente a flutuações nas condições ambientais. Esta constatação evidencia que abordagens baseadas em lógica difusa podem ser aplicadas de maneira prática para melhorar a qualidade do ar, consolidando-se como alternativa viável em relação a métodos tradicionais de controle.

A integração de um umidificador ao sistema automatizado constituiu um avanço significativo, permitindo o controle direto da umidade do ambiente e promovendo impactos positivos na percepção de conforto dos ocupantes. A inclusão deste atuador reforça a capacidade adaptativa do sistema, tornando-o capaz de responder de forma automática e eficiente às variações detectadas pelos sensores. Tais resultados sugerem que o desenvolvimento de sistemas *fuzzy* voltados ao controle ambiental não apenas atende às demandas de monitoramento, mas também contribui para o bem-estar dos usuários, ao manter condições internas mais adequadas e saudáveis.

Para validação da abordagem, foi realizada uma comparação paralela com um controlador tradicional do tipo PID, amplamente utilizado em automação industrial. Essa análise permitiu estabelecer uma referência clássica de controle, evidenciando diferenças de comportamento, variabilidade e eficiência entre as abordagens. Embora os resultados detalhados sejam apresentados em seções específicas, o planejamento experimental garante que o sistema *fuzzy* possa ser avaliado de forma objetiva, fornecendo dados confiáveis para futuras publicações e disseminação científica.

Como parte do processo de consolidação da pesquisa, pretende-se submeter artigos relacionados a este projeto em periódicos indexados, contribuindo para o avanço do conhecimento na área de automação e qualidade do ar. Além disso, é previsto o compartilhamento de códigos e scripts utilizados sob licenças de software livre compatíveis com práticas de ciência aberta, permitindo que outros pesquisadores repliquem, aprimorem e utilizem o sistema em diferentes contextos. Essa estratégia fortalece a colaboração científica e amplia o impacto do projeto,

alinhando-se a diretrizes de boas práticas de pesquisa.

Entre as perspectivas futuras, destaca-se a incorporação de novas variáveis ambientais, como partículas inaláveis ($PM_{2.5}$) e compostos orgânicos voláteis, bem como a experimentação de métodos híbridos de inferência, incluindo redes neurais artificiais e sistemas neuro-*fuzzy*. Esses aprimoramentos têm o potencial de aumentar a inteligência do sistema, permitindo decisões mais precisas e adaptativas, além de abrir oportunidades para integração com protocolos de Internet das Coisas (*IoT*) e redes de monitoramento ambiental distribuídas.

Por fim, a continuidade deste trabalho poderá contribuir para a inovação tecnológica em monitoramento da qualidade do ar e para criar referências metodológicas sólidas para projetos acadêmicos e comunitários, especialmente em regiões remotas da Amazônia com acesso limitado a sensores ambientais. A implementação de controladores inteligentes, aliada à validação experimental, oferece uma base para estudos comparativos, desenvolvimento de políticas locais e expansão de soluções adaptáveis a áreas com infraestrutura restrita, consolidando o projeto como uma contribuição relevante para engenharia, saúde ambiental e qualidade de vida.

REFERÊNCIAS

- Adafruit Industries. **DHT library for Arduino**. 2023. <<https://github.com/adafruit/DHT-sensor-library>>. 52
- ALMEIDA, T. A.; PEREIRA, G. M. Uso de sensores de baixo custo e lógica fuzzy no monitoramento da qualidade do ar na amazônia. **Tecnologia e Inovação**, v. 12, n. 3, p. 45–59, 2021. 16
- ANSI; ASHRAE. Thermal environmental conditions for human occupancy. **American Society of Heating, Refrigerating and Air-Conditioning Engineers, Atlanta, GA**, 2017. 37
- AOSONG ELECTRONICS. **DHT11 Temperature and Humidity Sensor Datasheet**. 2015. <<https://www.hamiltoncompany.com/process-analytics/sensors/dissolved-oxygen>>. 52
- ARBEX, M. A. et al. A poluição do ar e o sistema respiratório. **Jornal Brasileiro de Pneumologia**, v. 38, n. 5, p. 643–655, 2012. Disponível em: <<https://www.scielo.br/j/jbpneu/a/SD3cLkXqQwmDFpgzsyj7gBm/>>. 13
- ASHRAE. **ASHRAE Handbook - Fundamentals**. Atlanta, GA: ASHRAE (American Society of Heating, Refrigerating and Air-Conditioning Engineers), 2017. 56
- BANZI, M. **Getting Started with Arduino**. [S.l.]: Maker Media, 2010. 51
- BANZI, M.; SHILOH, M. **Arduino: A Technical Reference**. 1st. ed. Sebastopol, CA: O’Reilly Media, 2014. 66
- BERNSTEIN, J. A. et al. Indoor air pollution and asthma: a review of the evidence. **Environmental health perspectives**, National Institute of Environmental Health Sciences, v. 116, n. 1, p. 141–147, 2008. 32
- BONT, J. de et al. Ambient air pollution and cardiovascular diseases: An umbrella review of systematic reviews and meta-analyses. **Journal of Internal Medicine**, Wiley, v. 292, n. 3, p. 274–287, 2022. 16
- BRAGA et al. Indoor air pollution from biomass burning in brazil: a review. **Journal of the Brazilian Chemical Society**, v. 18, p. 1435–1441, 2007. 34
- BRAINVENDRA, V. e. a. Environment indoor air quality assessment using fuzzy inference system. **International Journal of Engineering Research & Technology (IJERT)**, v. 8, n. 5, 2020. Disponível em: <<https://www.ijert.org/research/environment-indoor-air-quality-assessment-using-fuzzy-inference-system-IJERTV8IS05012.pdf>>. 58
- BRASIL, M. d. M. A. **Poluição do ar nas grandes cidades brasileiras**. 2020. Disponível em: <<https://www.mma.gov.br/poluicao-do-ar>>. 12
- BRIMBLECOMBE, P. **The Big Smoke: A History of Air Pollution in London Since Medieval Times**. London: Routledge, 1987. 11
- BRITO, R. P.; COSTA, S. N. Desafios no monitoramento da qualidade do ar na amazônia: uma análise crítica. **Revista de Saúde Pública**, v. 57, n. 4, p. 99–110, 2023. 16

- BUSHNAG, A. An improved air quality and climate control monitoring system using fuzzy logic for enclosed areas. **Journal of Ambient Intelligence and Humanized Computing**, Springer, v. 14, n. 5, p. 6339–6347, 2022. 40, 43
- A. Callender e R. Stevenson. **Automatic Controllers**. 1939. GB523938A. British Patent filed in 1936 and published in 1939. 38
- CARBAJAL, J. A.; LEYVA, A.; MALACARA, D. Effect of indoor air pollutants on respiratory diseases: a review. **Environmental Science and Pollution Research**, v. 22, n. 3, p. 2134–2143, 2015. 61
- CC, A. **Arduino Project**. 2023. <<https://www.arduino.cc/>>. 51
- CHEN, W.; ZHANG, J.-g.; XIE, K.-m. Fuzzy comprehensive evaluation of indoor air quality. **Building and Environment**, Elsevier, v. 44, n. 6, p. 1244–1251, 2009. 33
- CIBSE. **CIBSE Guide A: Environmental Design**. London, UK: CIBSE(Chartered Institution of Building Services Engineers), 2015. 56
- COLELLA, F.; ROSSI, L.; BIANCHI, A. A fuzzy inference system for the assessment of indoor air quality in an operating room to prevent surgical site infection. **International Journal of Environmental Research and Public Health**, MDPI, v. 19, n. 6, p. 3533, 2022. 42, 44
- DAVIS, D. K. Urban air pollution and its impacts. **Environmental History**, v. 7, n. 4, p. 613–634, 2002. 11
- DIONOVA, W. et al. Environment indoor air quality assessment using fuzzy inference system. **Journal of Applied Engineering Science**, Faculty of Engineering, University of Kragujevac, v. 18, n. 4, p. 586–593, 2020. 41, 43
- DOCKERY, D. W. et al. An association between air pollution and mortality in six u.s. cities. **New England Journal of Medicine**, v. 329, n. 24, p. 1753–1759, 2019. 55
- DUBOIS, D.; PRADE, H. **Fuzzy sets and systems: theory and applications**. [S.l.]: Academic press, 1980. 21, 29
- ENVIRONMENTAL PROTECTION AGENCY. **Carbon Dioxide (CO₂) Pollution in Outdoor Air**. 2020. 57
- ENVIRONMENTAL PROTECTION AGENCY. **Carbon Monoxide (CO) Pollution in Outdoor Air**. 2020. <www.epa.gov/co-pollution>. 56
- EZZATI, M.; KAMMEN, D. M. Indoor air pollution from biomass fuel: a major environmental and public health challenge in the developing world. **Environmental Health Perspectives**, v. 113, n. 12, p. 1871–1875, 2005. 61
- FANGER, P. Air pollution in the indoor environment. **Atmospheric Environment (1967)**, Elsevier, v. 22, n. 10, p. 2189–2201, 1988. 32, 35, 36, 37
- FERREIRA, B. L.; COSTA, M. T. Tecnologias emergentes para o monitoramento da qualidade do ar na amazônia: desafios e oportunidades. **Revista de Inovações Tecnológicas**, v. 10, n. 4, p. 33–45, 2023. 16
- FISCHER, J. et al. Perception of indoor air quality and comfort in office spaces. **HVAC&R Research**, Taylor & Francis, v. 13, n. 2, p. 171–188, 2007. 35

- FISK, W. J. Health and productivity gains from better indoor environments and their relationship with building energy efficiency. **Energy Efficiency**, v. 10, n. 1, p. 23–44, 2017. 58
- FISK, W. J. et al. Estimating the health-related costs of 10 common indoor environmental exposures in the united states. **Indoor Air**, v. 27, n. 2, p. 356–367, 2017. 59, 60
- GOLDBERG, M. S.; BURNETT, R. T.; BAILAR, J. C. The association between daily mortality and ambient air particle pollution in montreal, quebec: 2. cause-specific mortality. **Environmental Research**, v. 86, n. 1, p. 26–36, 2001. 13
- GONÇALVES, A. P. Aplicação de lógica fuzzy em guerra eletrônica. **Instituto Tecnológico da Aeronáutica**, 2007. 23
- GROOT, J. et al. Residential exposure to mold, dampness, and indoor air pollution and risk of respiratory tract infections: a study among children ages 11 and 12 in the danish national birth cohort. **European Journal of Epidemiology**, v. 39, p. 299–311, 2024. 15
- HUANG, C.; CHEN, W. Application of fuzzy logic to assess indoor air quality. **Sustainability**, v. 11, n. 17, p. 4779, 2019. 62
- INMON, B. **Building the Data Warehouse**. 4th. ed. Hoboken, NJ: Wiley, 2005. 68
- Instituto Ar. **Qual a qualidade do ar que respiramos?** 2024. Acessado em: 24 nov. 2024. Disponível em: <<https://institutoar.org.br/tpost/i0djak18c1-qual-a-qualidade-do-ar-que-respiramos>>. 33
- INSTITUTO DE PESQUISA AMBIENTAL DA AMAZÔNIA. Poluição do ar e seus efeitos na saúde na amazônia. **Revista Ambiental Brasileira**, v. 33, n. 1, p. 77–85, 2024. 16
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Monitoramento de Queimadas no Sudeste do Pará**. 2024. Acesso em 20 de dezembro de 2024. Disponível em: <<https://www.inpe.br>>. 16
- IPAM, I. de Pesquisa Ambiental da A. **Emissão de CO₂ por queimadas na Amazônia cresce 60%**. 2024. Disponível em: <<https://ipam.org.br/emissao-de-co2-por-queimadas-na-amazonia-cresce-60/>>. 15
- Isen, A.; Rossin-Slater, M.; Walker, R. Does pollution matter? measuring the effects of air quality on children’s health. **American Economic Review**, v. 107, n. 6, p. 1344–1375, 2017. 11
- JANG, J. S. R.; SUN, C. T.; MIZUTANI, E. **Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence**. [S.l.]: Prentice Hall, 1997. 27, 28
- JORNAL BRASILEIRO DE PNEUMOLOGIA. Impacto da poluição atmosférica no sistema respiratório. **Revista Brasileira de Pneumologia**, v. 44, n. 3, p. 150–160, 2018. Disponível em: <<https://www.scielo.br/j/jbpneu/a/sD3cLkXqQwmDFpgzsyj7gBm>>. 13
- JUNIOR, C. H. L. S. Lógica fuzzy e processo analítico hierárquico (ahp) aplicados ao zoneamento de Áreas suscetíveis a deslizamentos: Uma revisão. **Revista Monografias Ambientais**, v. 14, n. 3, p. 42–58, sep 2015. 21
- KIM, J.; LEE, S. Development of a low-cost gas sensor system based on mq-9 for household safety. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 18, n. 11, p. 3795, 2018. 54, 55

- KLEPEIS, N. E. et al. The national human activity pattern survey (nhaps): a resource for assessing exposure to environmental pollutants. **Journal of Exposure Analysis and Environmental Epidemiology**, Springer, v. 11, n. 3, p. 231–252, 2001. 31
- KLIR, G. J.; YUAN, B. **Fuzzy Sets and Fuzzy Logic: Theory and Applications**. [S.l.]: Prentice Hall PTR, 1995. 23, 25, 26, 30
- KOWALSKI, W. J. Indoor air quality: The role of humidity. **ASHRAE Journal**, v. 54, n. 11, p. 38–45, 2012. 59, 60
- KUMAR, P.; SKOULOUDIS, A. N.; BELL, M. L. e. a. The rise of low-cost sensing for managing air pollution in cities. **Environment International**, v. 85, p. 45–54, 2015. 16
- LAN, L. et al. Effects of thermal discomfort in the office on perceived air quality, sbs symptoms, and productivity. **Indoor air**, Wiley Online Library, v. 21, n. 5, p. 376–382, 2011. 35
- LAURENT, J. G. Cedeño et al. Associations between acute exposures to pm_{2.5} and carbon dioxide indoors and cognitive function in office workers: a multicountry longitudinal prospective observational study. **Environmental Research Letters**, v. 16, n. 9, p. 094061, 2021. 15
- LEE, C. C. Fuzzy logic in control systems: Fuzzy logic controller. **IEEE Transactions on Systems, Man, and Cybernetics**, IEEE, v. 20, n. 2, p. 404–418, 1990. 25, 30
- LIU, Y. Smart greenhouse monitoring and controlling based on nodemcu. **International Journal of Agricultural and Biological Engineering**, Springer, v. 14, n. 3, p. 34–43, 2021. 40, 43
- LY, H.-B. et al. Development of an ai model to measure traffic air pollution from multisensor and weather data. **Sensors**, MDPI, v. 19, n. 22, p. 4941, 2019. 42, 44
- MAMDANI, E. H.; ASSILIAN, S. An experiment in linguistic synthesis with a fuzzy logic controller. **International Journal of Man-Machine Studies**, v. 7, n. 1, p. 1–13, 1975. 27, 28
- MARTINEZ, V. H. V. **Sistema Híbrido Fuzzy–Redes Neurais para Controle de Processos**. Dissertação (Dissertação de Mestrado) — Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio), Rio de Janeiro, 2010. Disponível em: <https://www.maxwell.vrac.puc-rio.br/32823/32823_3.PDF>. 24, 25
- MARTINS, J. F.; ALMEIDA, C. R. Monitoramento e os impactos da poluição do ar na saúde pública da amazônia. **Journal of Environmental Health**, v. 44, n. 2, p. 53–65, 2022. 16
- MCKINNEY, W. **Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython**. Sebastopol, CA: O’Reilly Media, 2010. 68
- MELENDEZ, A.; SALAS, R.; MUNOZ, F. J. A fuzzy logic approach to evaluate indoor air quality and comfort level. **Building and Environment**, v. 153, p. 47–56, 2019. 62
- MENDELL, M. J.; HEATH, G. A. Do indoor pollutants and thermal conditions in schools influence student performance? **International Journal of Indoor Air Quality and Health**, v. 16, n. 5, p. 368–373, 2006. 36, 58, 59, 60
- MINORSKY, N. Directional stability of automatically steered bodies. **Journal of the American Society for Naval Engineers**, v. 34, n. 2, p. 280–309, 1922. 38

- MUDARRI, D. Most people spend most of their time indoors: implications for exposure models. **Proceedings of the 9th International Conference on Indoor Air Quality and Climate**, v. 1, p. 608–613, 2004. 31
- MUDHOLKAR, R.; PATIL, C. Design and implementation of genetic fuzzy controller for split air-conditioner control based on fanger's pmv index. **International Journal of Air-Conditioning and Refrigeration**, World Scientific Publishing Company, v. 27, n. 4, p. 1–12, 2019. 40, 42
- OKAFOR, C. J.; ADEWALE, T. O.; MUSA, H. A. Exposure–response relationship of residential dampness and mold and risk of severe lower respiratory tract infections in under-five children: a case–control study in nigeria. **Environmental Epidemiology**, v. 7, n. 5, p. e2400637, 2023. 15
- OLIVEIRA, L. F.; SOUZA, C. A. Uso de biomassa e seus efeitos sobre a qualidade do ar na amazônia. **Revista de Ciências Ambientais**, v. 38, n. 1, p. 20–35, 2019. 15
- ORFÃO, G. Intoxicação por monóxido de carbono. **Faculdade de Medicina da Universidade de Coimbra**, 2011. Disponível em: <<https://estudogeral.uc.pt/bitstream/10316/81004/1/%C3%93rf%C3%A3o%2C%20Gon%C3%A7alo%20-%20Intoxica%C3%A7%C3%A3o%20por%20Mon%C3%B3xido%20Carbono%20-%20FMUC%20-%202011.pdf>>. 14
- PAHO, P. A. H. O. Nine out of ten people worldwide breathe polluted air. **PAHO Health Reports**, v. 6, n. 1, p. 20–30, 2018. Disponível em: <<https://www.paho.org>>. 13
- PAHO, P. A. H. O. New data from who reveals billions still breathe unhealthy air. **PAHO Environmental Reports**, v. 8, n. 2, p. 5–15, 2022. Disponível em: <<https://www.paho.org>>. 13
- PEDRYCZ, W.; GOMIDE, F. **Fuzzy systems engineering: toward human-centric computing**. [S.l.]: John Wiley & Sons, 2007. 21
- PENNEY, D. G. **Carbon Monoxide Toxicity**. [S.l.]: CRC Press, 2000. 13, 14
- PIERCE, K.; YANTASEE, W. Calibration of a low-cost mq-9 gas sensor for methane detection in agricultural environments. **Sensors and Instrumentation**, v. 3, n. 2, p. 111–120, 2012. 54
- PIERRE, J. et al. Iot and fuzzy logic applied to smart public hall for covid-19 monitoring system. **Journal of Ambient Intelligence and Humanized Computing**, v. 14, n. 5, p. 4567–4582, 2023. 41, 43
- POLIVKA, B. J. The great london smog of 1952. **American Journal of Nursing**, v. 118, n. 4, p. 57–61, 2018. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/29596258/>>. 11
- POPE C. ARDEN, I. et al. Lung cancer, cardiopulmonary mortality, and long-term exposure to fine particulate air pollution. **Jama**, American Medical Association, v. 287, n. 9, p. 1132–1141, 2002. 31, 32, 34
- Portal Amazônia. **Aplicativo 'Selva' monitora queimadas e qualidade do ar na Amazônia**. 2023. Acesso em 15 de dezembro de 2024. Disponível em: <<https://portalamazonia.com>>. 16
- PROCKOP, L. D.; CHICHKOVA, R. I. Carbon monoxide: a hazard to the brain. **Journal of neurology**, Springer, v. 250, n. 4, p. 383–390, 2003. 34
- PRODANOV, E. V.; FREITAS, E. C. **Metodologia do trabalho científico: métodos e técnicas de pesquisa e projetos de pesquisa**. [S.l.]: Editora Atheneu, 2013. 46

- Python Software Foundation. **Python Software Foundation**. 2023. <<https://www.python.org/>>. 50
- RAUB, J. A. et al. Carbon monoxide poisoning—a public health perspective. **Toxicology**, v. 145, n. 1, p. 1–14, 2000. 14
- ROSS, T. J. **Fuzzy logic with engineering applications**. [S.l.]: John Wiley & Sons, 2010. 21, 24, 25, 29
- ROSSUM, G. v. Python tutorial. **CWI Quarterly**, v. 4, n. 4, p. 259–276, 1991. 50
- SAINI, J.; DUTTA, M.; MARQUES, G. Adfist: Adaptive dynamic fuzzy inference system tree driven by optimized knowledge base for indoor air quality assessment. **Sensors**, v. 22, n. 3, p. 1008, 2022. Disponível em: <<https://www.mdpi.com/1424-8220/22/3/1008>>. 41, 43
- SAMET, J. M.; SPENGLER, J. D.; MITCHELL, C. S. Epidemiology of indoor air pollution. **Environmental health perspectives**, National Institute of Environmental Health Sciences, v. 108, n. suppl 4, p. 945, 2000. 31, 32
- SATISH, U. et al. A review of studies on the co2 levels and prevalence of sick building syndrome in five selected countries. **Indoor air**, Wiley Online Library, v. 22, n. 3, p. 227–245, 2012. 35
- Schwartz, J. Air pollution and daily mortality: a review and meta-analysis. **Environmental Research**, v. 64, n. 1, p. 36–52, 1994. 11
- SEPPÄNEN, O.; FISK, W.; MENDELL, M. Indoor air quality and health in offices. **Indoor air**, Wiley Online Library, v. 16, n. 2, p. 86–101, 2006. 31, 32, 35
- SEPPÄNEN, O.; SATERI, J.; PALONEN, J. Indoor air quality and sources of air pollutants. **Atmospheric Environment**, Elsevier, v. 31, n. 6, p. 761–768, 1997. 34
- SEPPÄNEN, O.; SÄTERI, J.; PALONEN, J. Indoor air quality and sources of air pollutants. **Atmospheric Environment**, Elsevier, v. 31, n. 6, p. 761–768, 1997. 36
- SILVA, J. P.; OLIVEIRA, A. M. Impactos da qualidade do ar nas populações da amazônia: um estudo preliminar. **Revista Brasileira de Saúde Ambiental**, v. 45, n. 2, p. 45–60, 2021. 15
- SMITH, K. R.; WOODWARD, A.; CAMPBELL-LENDRUM, D. Public health benefits of strategies to reduce greenhouse-gas emissions: health implications of short-lived greenhouse pollutants. **The Lancet**, v. 374, n. 9707, p. 2091–2103, 2009. 14
- SOUZA, B. de et al. Controlador automático remoto para ar condicionado via arduino, aplicando a lógica fuzzy. **Revista Interdisciplinar Pensamento Científico**, v. 2, n. 2, 2016. 17
- SOUZA, M. R.; LIMA, V. S. Queimadas e poluição atmosférica na amazônia: uma revisão dos impactos sobre a saúde. **Revista de Ecologia e Meio Ambiente**, v. 50, n. 3, p. 102–116, 2022. 15
- SPENGLER, J. D.; SAMET, J. M. Indoor air pollution: A public health perspective. **Annual review of public health**, Annual Reviews 4139 El Camino Way, PO Box 10139, Palo Alto, CA 94303-0139, USA, v. 15, n. 1, p. 203–232, 1994. 31
- Elmer A. Sperry. **Gyroscopic Apparatus for Controlling the Steering of Ships**. 1911. US989958A. Patent filed in 1910 and granted in 1911. 38

- SUNDELL, J. Indoor air and human health. **Atmospheric Environment**, Elsevier, v. 45, n. 21, p. 3606–3607, 2011. 32, 37, 38
- TANABE, S.-i.; NISHIHARA, N.; HANEDA, M. Effects of air temperature on office workers' well-being, productivity and work performance: Two field experiments. **Building and Environment**, Elsevier, v. 44, n. 12, p. 2418–2424, 2009. 37
- US Environmental Protection Agency. National ambient air quality standards for ozone. **Federal Register**, v. 77, n. 28, p. 9073–9177, 2012. 31
- WAHID, F. et al. An efficient artificial intelligence hybrid approach for energy management in intelligent buildings. **KSII Transactions on Internet and Information Systems**, Korea Society of Internet Information, v. 13, n. 12, p. 5904–5927, 2019. 42, 44
- WARGOCKI, P. et al. The effects of outdoor air supply rate in an office on perceived air quality, sick building syndrome (sbs) symptoms and productivity. **Indoor air**, Wiley Online Library, v. 10, n. 4, p. 222–236, 2000. 35
- WATTS, N. et al. The 2018 report of the lancet countdown on health and climate change: shaping the health of nations for centuries to come. **The Lancet**, v. 392, n. 10163, p. 2479–2514, 2018. 14, 15
- WESCHLER, C. J. Ozone in indoor environments: concentration and chemistry. **Indoor air**, Wiley Online Library, v. 17, n. 4, p. 269–288, 2007. 36
- WHO, W. H. O. **Air Quality Guidelines: Global Update 2006**. 2006. Disponível em: <<https://www.who.int/publications/i/item/9789241546820>>. 61
- WHO, W. H. O. **Indoor Air Quality and Health**. 2009. Disponível em: <<https://www.who.int/airpollution/indoor/en/>>. 58
- WIDHIADA, W. et al. Temperature stability and humidity on infant incubator based on fuzzy logic control. **Energies**, MDPI, v. 14, n. 20, p. 6505, 2019. 41, 43
- WOLKOFF, P. Volatile organic compounds—sources, measurements, emissions, and the impact on indoor air quality. **Indoor air**, Wiley Online Library, v. 8, n. s3, p. 123–134, 1998. 38
- WOLKOFF, P. et al. Indoor air quality—a public health issue in developing countries. **Atmospheric Environment**, Elsevier, v. 40, n. 2, p. 259–274, 2006. 31, 32
- World Health Organization. **WHO guidelines for indoor air quality: selected pollutants**. [S.l.]: World Health Organization, 2010. 32, 34
- WORLD HEALTH ORGANIZATION. **Indoor Air Quality Guidelines: Household Fuel Combustion**. 2020. Retrieved from [<https://www.who.int/publications/i/item/9789241548885>]. 55
- WORLD HEALTH ORGANIZATION. **Qualidade do ar e saúde**. 2020. Disponível em: <<https://www.who.int/airpollution/en/>>. 11, 12
- WORLD HEALTH ORGANIZATION. Air pollution and health: Current global challenges. **WHO Reports**, v. 12, n. 4, p. 1–10, 2022. Disponível em: <<https://www.who.int/>>. 13
- YEN, J.; LANGARI, R. Fuzzy logic: intelligence, control, and information. **Prentice-Hall, Upper Saddle River**, v. 1, 1999. 24

- ZADEH, L. A. Fuzzy sets. **Information and control**, Academic press, v. 8, n. 3, p. 338–353, 1965. 19, 21, 22, 26, 27, 28, 29
- ZADEH, L. A. Outline of a new approach to the analysis of complex systems and decision processes. **IEEE Transactions on systems, Man, and Cybernetics**, IEEE, n. 1, p. 28–44, 1973. 23, 25
- ZADEH, L. A. The concept of a linguistic variable and its application to approximate reasoning—i. **Information sciences**, Elsevier, v. 8, n. 3, p. 199–249, 1975. 22, 23
- ZADEH, L. A. Fuzzy logic, computing with words, and their impact on the development of human-centric systems. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 24, n. 2, p. 103–111, 1994. 17, 27, 62
- ZHANG, H.; YOSHINO, H.; HASEGAWA, Y. Thermal comfort and building energy consumption—a review. **Building and Environment**, Elsevier, v. 42, n. 10, p. 3481–3489, 2007. 32, 35, 36
- ZHAO, X.; WANG, F.; CHEN, L. Real-time air quality monitoring and forecasting based on iot technology. **Environmental Monitoring and Assessment**, v. 192, n. 9, p. 1–10, 2020. 66
- ZIEGLER, J. G.; NICHOLS, N. B. Optimum settings for automatic controllers. **Transactions of the ASME**, v. 64, n. 11, p. 759–768, 1942. 38
- ZIMMERMANN, H.-J. **Fuzzy set theory—and its applications**. [S.l.]: Springer Science & Business Media, 2011. 20