



DISPOSITIVO IOT PARA ATUAR CONTRA O DESPERDÍCIO DE ALIMENTOS

André Carlos Teixeira Vasconcelos

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação, do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, CEFET/RJ, como parte dos requisitos necessários à obtenção do título de mestre.

Orientador: João Roberto de Toledo Quadros

Rio de Janeiro
Fevereiro 2024

DISPOSITIVO IOT PARA ATUAR CONTRA O DESPERDÍCIO DE ALIMENTOS

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação, do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, CEFET/RJ, como parte dos requisitos necessários à obtenção do título em Mestre em Ciência da Computação.

André Carlos Teixeira Vasconcelos

Banca Examinadora:

Presidente, Prof. D.Sc. João Roberto de Toledo Quadros, CEFET/RJ
(orientador)

Prof. D.Sc. Eduardo Soares Ogasawara, CEFET/RJ

Prof. D.Sc. Joel André Ferreira dos Santos, CEFET/RJ

Prof. D.Sc. Jader Lugon Junior, IFF/RJ

Rio de Janeiro
Fevereiro 2024

Ficha catalográfica elaborada pela Biblioteca Central do CEFET/RJ

V331 Vasconcelos, André Carlos Teixeira
Dispositivo IOT para atuar contra o desperdício de alimentos /
André Carlos Teixeira Vasconcelos. — 2024.
140f. : il. color. , enc.

Dissertação (Mestrado) Centro Federal de Educação
Tecnológica Celso Suckow da Fonseca, 2024.

Bibliografia : f. 126-140

Orientador: João Roberto de Toledo Quadros

1. Robótica. 2. Internet das coisas. 3. Alimentos - Desperdício.
4. Inteligência Artificial. I. Quadros, João Roberto de Toledo.
(Orient.). II. Título.

CDD 629.892

DEDICATÓRIA

Dedico este trabalho: Ao Grande Arquiteto do Universo. À memória de meu querido pai, a minha mãe e ao meu irmão. Ao amor de minha vida. Ao meu filho do coração. Aos meus amigos. E a todos que sempre nos ajudam a seguir em frente.

AGRADECIMENTOS

Ao grande Arquiteto de Universo, no qual me concebeu esta oportunidade única de estudar em uma instituição de prestígio nome, que sempre me guiou, iluminou e protegeu por todo o caminho nesta longa jornada.

A meu orientador Prof. João Roberto de Toledo Quadros por acreditar em mim, pelo estímulo e atenção na explanação de ideias, pelas orientações e nas palavras de motivação que conduziu minha orientação ao longo de todo o processo.

Aos meus amigos por todo o incentivo, a confiança, o apoio e pela ajuda com o fornecimento de material para a realização deste trabalho.

A todos os meus familiares pelo incentivo, apoio e colaboração.

“A coisa mais indispensável a um homem é reconhecer o uso que deve fazer do seu próprio conhecimento”.

Platão, filósofo grego.

RESUMO

Dispositivo IoT para atuar contra o desperdício de alimento

Um terço dos alimentos produzidos anualmente para o consumo humano são perdidos ou desperdiçados globalmente. Os alimentos são em grande parte desperdiçados na fase de consumo, sendo que eles possuem a carga nutricional intacta, mas são de aparência desagradável e, por isso, são descartados. Isso acontece ainda no processo de respiração do alimento, o que significa que ocorre o descarte quando ainda são adequados para consumo humano. Os alimentos na fase de senescência iniciam o processo de decomposição da matéria orgânica por ação de organismos heterótrofos como bactérias e fungos. Como resultado desse processo, ocorre a liberação de água, amônia, gás carbônico e metano para o meio ambiente. Como os gases liberados estão associados à fase de maturação do alimento, existe a ideia de identificar os aclives e declives dos gases emitidos, durante sua decomposição, justamente para que se possa avaliar se o alimento ainda está disponível para consumo, ou precisa ser descartado de todo. Esta pesquisa consiste no desenvolvimento de uma plataforma (de hardware e software), composta de uma caixa com dispositivo IoT, e sensores, além de um software com algoritmo de *Machine Learning*, denominado de CONT3NT3, que vem a ser um container inteligente com um aplicativo para dispositivo móvel, para indicar a um usuário comum, uma cozinheira caseira por exemplo, se o alimento na fase de senescência é próprio ou impróprio para o consumo.

Palavras-chave: Robótica; Nariz eletrônico; Internet das coisas; Combate no desperdício de alimentos; Inteligência Artificial.

ABSTRACT

IoT Device to act against waste food

One third of the food produced annually for human consumption is lost or wasted globally. Food is largely wasted during the consumption phase, as its nutritional content is intact, but it has an unpleasant appearance and is therefore discarded. This happens during the food's respiration process, which means that it is discarded when it is still suitable for human consumption. Foods in the senescence phase begin the process of decomposition of organic matter through the action of heterotrophic organisms such as bacteria and fungi. As a result of this process, water, ammonia, carbon dioxide and methane are released into the environment. As the gases released are associated with the maturation phase of the food, there is the idea of identifying the slopes and slopes of the gases emitted during its decomposition, precisely so that it can be assessed whether the food is still available for consumption or needs to be discarded. all. This research consists of the development of a platform (hardware and software), composed of a box with an IoT device, and sensors, in addition to software with a Machine Learning algorithm, called CONT3NT3, which is a smart container with an application for a mobile device, to indicate to a common user, a home cook for example, whether food in the senescence phase is suitable or unsuitable for consumption.

Keywords: Robotics; Electronic nose; Internet of things; Fighting food waste; Artificial Intelligence.

LISTA DE ILUSTRAÇÕES

FIGURA 1: RESULTADOS ENCONTRADOS E SUAS INTERSEÇÕES.	20
FIGURA 2: SISTEMA OLFATIVO BIOLÓGICO HUMANO: A) EPITÉLIO OLFATIVO; B) BULBO OLFATIVO.	21
FIGURA 3: ANALOGIA ENTRE SISTEMA BIOLÓGICO E NARIZ ELETRÔNICO	23
FIGURA 4: BLOCOS BÁSICOS DE UM SENSOR.	25
FIGURA 5: MECANISMO DE TRANSDUÇÃO EM SENSORES ELETROACÚSTICOS: A) PROCESSO DE ADSORÇÃO E DESSORÇÃO DE MOLÉCULAS NA SUPERFÍCIE DO SENSOR QCM; B) VARIAÇÃO DA MASSA AO LONGO DO PROCESSO DE ADSORÇÃO E DESSORÇÃO; C) A FREQUÊNCIA EM FUNÇÃO DA MASSA NA SUPERFÍCIE.....	28
FIGURA 6: MECANISMO DE TRANSDUÇÃO EM SENSORES ELETROQUÍMICOS: A) ESTRUTURA BÁSICA DE UM SENSOR ELETROQUÍMICO; B) MUDANÇA DO FLUXO DE CORRENTE.....	29
FIGURA 7: MECANISMO DE TRANSDUÇÃO EM SENSORES QUIMIORRESISTIVOS.	31
FIGURA 8: PROJETO ESQUEMÁTICO DO SENSOR TIPO MOS.	32
FIGURA 9: FUNCIONAMENTO DO SENSOR MOS. A) AMBIENTE LIVRE DO ANALITO; B) INÍCIO DA QUEBRA DE LIGAÇÕES QUÍMICAS NA PRESENÇA DO ANALITO; C) MÁXIMO DE DETECÇÃO PELO QUIMIORRESISTOR.....	33
FIGURA 10: KERNELING DO SVM.	39
FIGURA 11: EXEMPLO DA ESTRUTURA DE UMA ANN	40
FIGURA 12: FUNÇÕES DE ATIVAÇÃO PARA NEURÔNIOS EM ANN.	40
FIGURA 13: EXEMPLOS DE AJUSTES AO MODELO DE DADOS.	41
FIGURA 14: FASES DE DESENVOLVIMENTO DO FRUTO.....	54
FIGURA 15: CONCEPÇÃO DO PROJETO CONT3NT3.	58
FIGURA 16: DIAGRAMA DE CASOS DE USO DA PLATAFORMA CONT3NT3.	61
FIGURA 17: ARQUITETURA DO PROJETO PARA USO DO APLICATIVO.....	62
FIGURA 18: TRECHO DE CÓDIGO APRESENTANDO A CONFIGURAÇÃO DAS ROTAS NO API GATEWAY. ...	64
FIGURA 19: MC CATÁLOGO. A) CRUD ; B) API POST; C) BANCO H2 PARA SUPORTAR O CRUD.	65
FIGURA 20: INTERFACE WEB DO APACHE SPARK.	66
FIGURA 21: MICROSERVIÇO TREINAR. A) TRECHO DE CÓDIGO DO VERBO POST EM PYTHON; B) ARMAZENAMENTO DOS MODELOS APÓS TREINADOS; C) TESTE DE TREINAMENTO ATRAVÉS DA API.	67
FIGURA 22: MICROSERVIÇO ESTIMADOR COM RETORNOS DE INFORMAÇÃO: A) ALIMENTO “CONSUMÍVEL”; B) ALIMENTO “NÃO-CONSUMÍVEL; C) ALIMENTO “CONSUMO IMEDIATO”	68
FIGURA 23: AVALIAÇÃO DO MODELO COMBINADO. A) MÉTRICAS; B) CURVA DE APRENDIZADO.	70
FIGURA 24: DIAGRAMA DE SEQUÊNCIA DAS FUNCIONALIDADES NA APLICAÇÃO MOBILE.....	72
FIGURA 25: TELAS DA APLICAÇÃO MOBILE. A) NÃO CONECTADO; B) CONECTANDO; C) CONECTADO; D) INÍCIO DO PROCESSO DE COLETA; E) INDICAÇÃO DO CONSUMO; F) INDICAÇÃO DE CONSUMO IMEDIATO; G) INDICAÇÃO PARA NÃO CONSUMIR; H) ANÁLISE DOS DADOS COLETADOS.....	73
FIGURA 26: DESENHO DO CIRCUITO ELETRÔNICO REPRESENTATIVO DO HARDWARE DIGITAL DO SISTEMA E-NOSE DA CONT3NT3.....	75
FIGURA 27: TESTE DOS INVÓLUCROS DE PAPELÃO, MADEIRA E MDP.	78
FIGURA 28: VARIAÇÕES DOS PARÂMETROS DE TEMPERATURA INTERNA E UMIDADE DOS INVÓLUCROS FEITOS COM MDP (A, D), FERRO (B, E) E VIDRO (C, F).....	79
FIGURA 29: MÉDIAS NA ESCALA LOG. A) TEMPERATURA; B) UMIDADE.	80
FIGURA 30: MAPEAMENTO TEMPORAL DAS AMOSTRAS, COM INFORMAÇÕES SOBRE MESES, O NÚMERO DE AMOSTRAS APROVEITADAS E DESCARTADAS.....	85
FIGURA 31: EXEMPLO DE DADOS DE AMOSTRAS, NO QUAL AS LINHAS HORIZONTAIS EM BRANCO REPRESENTAM DADOS AUSENTES: A) AMOSTRA COM DADOS ÍNTEGROS; B) AMOSTRA COM DADOS PARA SEREM RECUPERADOS; C) AMOSTRA DESCARTADA.....	87
FIGURA 32: PROCEDIMENTOS APLICADOS ÀS INSTÂNCIAS PREPARADAS. A) DADOS ORIGINAIS; B) SUAVIZAÇÃO DOS DADOS; C) AGRUPAMENTO DE 15 EM 15 MINUTOS; D) AGRUPAMENTO DE HORA EM HORA.	89
FIGURA 33: MODELO DE DADOS DA AMOSTRA-01. A) DADOS ORIGINAIS; B) DADOS AUSENTES ARTIFICIALMENTE; C) DADOS APÓS O AGRUPAMENTO EM QUARTO DE HORA.....	91

FIGURA 34: DADOS AUSENTES ARTIFICIALMENTE E VERSÕES IMPUTADAS.	92
FIGURA 35: GRÁFICO DE DISPERSÃO DE DADOS ORIGINAIS VS. DADOS IMPUTADOS, NOS QUAIS A COLUNA AM1-CO2 APRESENTA A OBTENÇÃO DE DADOS PARA O GÁS CARBÔNICO, A AM1-CH4 PARA O METANO E A AM1-NH3 PARA A AMÔNIA.	97
FIGURA 36: APLICAÇÃO DAS MÉTRICAS DE AVALIAÇÃO NAS VERSÕES DE DADOS INSERIDOS PELAS DIFERENTES TÉCNICAS DE IMPUTAÇÃO.	98
FIGURA 37: DADOS OBTIDOS COM A DEGRADAÇÃO FÚNGICA EM FRUTO CLIMATÉRICO USANDO O MODELO DA AMOSTRA-01. A) NAS MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ ; B) NA MEDIÇÃO DA UMIDADE; C) NA MEDIÇÃO DA TEMPERATURA.	100
FIGURA 38: DADOS OBTIDOS COM A DEGRADAÇÃO FÚNGICA EM FRUTO NÃO CLIMATÉRICO DA AMOSTRA-16. A) NAS MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ ; B) NA MEDIÇÃO DA UMIDADE; C) NA MEDIÇÃO DA TEMPERATURA.	101
FIGURA 39: DADOS OBTIDOS COM A PUTREFAÇÃO EM FRUTO CLIMATÉRICO DA AMOSTRA-07. A) NAS MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ ; B) NA MEDIÇÃO DA UMIDADE; C) NA MEDIÇÃO DA TEMPERATURA.	104
FIGURA 40: DADOS OBTIDOS COM A PUTREFAÇÃO EM FRUTO NÃO CLIMATÉRICO DA AMOSTRA-23. A) NAS MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ ; B) NA MEDIÇÃO DA UMIDADE; C) NA MEDIÇÃO DA TEMPERATURA.	105
FIGURA 41: DADOS OBTIDOS COM A DECOMPOSIÇÃO MULTIFATORIAL EM FRUTO CLIMATÉRICO DA AMOSTRA-11. A) NAS MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ ; B) NA MEDIÇÃO DA UMIDADE; C) NA MEDIÇÃO DA TEMPERATURA.	107
FIGURA 42: DADOS OBTIDOS COM A DECOMPOSIÇÃO POR DESIDRATAÇÃO EM FRUTO NÃO CLIMATÉRICO DA AMOSTRA-29. A) NAS MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ ; B) NA MEDIÇÃO DA UMIDADE; C) NA MEDIÇÃO DA TEMPERATURA.	109
FIGURA 43: TOMATE (LYCOPERSICUM ESCULENTUM MILL) EM ÓTIMO ESTADO, PRÓPRIO PARA O CONSUMO.	111
FIGURA 44: TESTE 01 - MEDIÇÕES DA VALIDAÇÃO DO TESTE PARA O TOMATE. A) MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ ; B) MEDIÇÃO DA TEMPERATURA; C) MEDIÇÃO DA UMIDADE; D) RESULTADO.	112
FIGURA 45: MAÇA GALA (MALUS COMMUNIS) NO ESTÁGIO INICIAL DE DECOMPOSIÇÃO.	113
FIGURA 46: TESTE 02 - MEDIÇÕES DA VALIDAÇÃO DO TESTE PARA A MAÇA. A) MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ ; B) MEDIÇÃO DA TEMPERATURA; C) MEDIÇÃO DA UMIDADE; D) RESULTADO.	114
FIGURA 47: ALIMENTOS NO ESTÁGIO DE DECOMPOSIÇÃO. A) MAÇA GALA (MALUS COMMUNIS); B) PÊSSEGO PREMIER (PRUNUS PERSICA).	115
FIGURA 48: REMOÇÃO DAS PARTES ATINGIDAS PELA DECOMPOSIÇÃO. A) MAÇA; B) PÊSSEGO.	116
FIGURA 49: MEDIÇÕES E RESULTADOS ANTES E APÓS A REMOÇÃO DA REGIÃO AFETADA PELA DECOMPOSIÇÃO DO TECIDO DA MAÇA. A) MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ ANTES DA REMOÇÃO; B) RESULTADO DA VERIFICAÇÃO ANTES DA REMOÇÃO; C) MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ APÓS A REMOÇÃO; D) RESULTADO APÓS A REMOÇÃO DO TECIDO.	117
FIGURA 50: MEDIÇÕES E RESULTADOS ANTES E APÓS A REMOÇÃO DA REGIÃO AFETADA PELA DECOMPOSIÇÃO DO TECIDO DO PÊSSEGO. A) MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ ANTES DA REMOÇÃO; B) RESULTADO DA VERIFICAÇÃO ANTES DA REMOÇÃO; C) MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ APÓS A REMOÇÃO; D) RESULTADO APÓS A REMOÇÃO DO TECIDO.	118
FIGURA 51: MAÇÃ GALA (MALUS COMMUNIS) EM AVANÇADO ESTÁGIO DE DECOMPOSIÇÃO.	119
FIGURA 52: RESULTADO DA VALIDAÇÃO DO TESTE PARA A MAÇÃ QUE NÃO É CONSUMÍVEL. A) NAS MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ ; B) NA MEDIÇÃO DA TEMPERATURA; C) NA MEDIÇÃO DA UMIDADE; D) INDICAÇÃO DE FRUTO NÃO CONSUMÍVEL.	120
FIGURA 53: AMOSTRA APÓS A REMOÇÃO DA ÁREA COMPROMETIDA PELO PROCESSO DE DECOMPOSIÇÃO. A) MEDIÇÕES DOS GASES CO ₂ , CH ₄ E NH ₃ ; B) RESULTADOS DAS VERIFICAÇÕES.	121

LISTA DE TABELAS

TABELA 1: TIPOS DE SENSORES E SUAS PROPRIEDADES.	26
TABELA 2: VANTAGENS E DESVANTAGENS DOS ALGORITMOS UTILIZADOS POR SISTEMAS DE NARIZ ELETRÔNICO.	37
TABELA 3: MÉTRICAS COMUMENTE UTILIZADAS PARA MEDIR O DESEMPENHO DE MODELOS.	43
TABELA 4: REQUISITOS FUNCIONAIS.	59
TABELA 5: REQUISITOS NÃO FUNCIONAIS.....	60
TABELA 6: PROPRIEDADES TÉRMICAS DOS MATERIAIS E RESISTÊNCIA A UMIDADE.....	77
TABELA 7: DISTRIBUIÇÃO DE AMOSTRAS.....	83
TABELA 8: CLASSIFICAÇÃO DAS AMOSTRAS.....	83
TABELA 9: PROBLEMAS NA OBTENÇÃO DOS DADOS E SUAS CAUSAS.	86

LISTA DE EQUAÇÕES

EQUAÇÃO 1: EQUAÇÃO DE SAUERBREY.	27
EQUAÇÃO 2: MSE (MEAN ABSOLUTO ERROR).	96
EQUAÇÃO 3: MAE (MEAN SQUARED ERROR).	96
EQUAÇÃO 4: R ²	96

LISTA DE ABREVIações E SIGLAS

AM	Aprendizado de Máquina
API	Interface de Programação de Aplicativos (<i>Application Programming Interface</i>)
APP	Aplicativo de dispositivo eletrônico
FAO	<i>Food and Agriculture Organization</i>
IA	Inteligência Artificial
IDC	Internet das Coisas
IOT	<i>Internet of Things</i>
MAE	<i>Mean Absoluto Error</i>
MC	Microserviço
MI	Múltiplas Imputações (<i>Multiple Imputation</i>)
MSE	<i>Mean Squared Error</i>
MOS	<i>Metal Oxide Semiconductor</i>
NG	Nanogramas
ODS	Objetivos de Desenvolvimento Sustentável
OMS	Organização Mundial de Saúde
ONU	Organização das Nações Unidas
QCM	<i>Quartz Crystal Microbalance</i>
SAN	Segurança Alimentar e Nutricional
UUID	<i>Universally Unique Identifier</i>

SUMÁRIO

INTRODUÇÃO	16
1 REVISÃO BIBLIOGRÁFICA	19
1.1. Sistemas olfativos biológicos	20
1.2 Sistemas olfativos artificiais.....	22
1.3. Sobre tipos de sensores de nariz eletrônico.....	24
1.3.1 Sensores eletroacústicos.....	26
1.3.2. Sensores eletroquímicos	28
1.3.3. Sensores quimiorresistivos	30
1.3.4. Sensores de efeito de campo	34
1.4. Algoritmos de aprendizado de máquina	35
1.4.1. Reconhecimento de padrões e classificação	36
1.4.2. Problemas de métricas e avaliação dos algoritmos AM	41
1.5. Sobre Sistemas de <i>E-nose</i>	44
1.6. Sobre problemas, soluções e iniciativas ligadas a sustentabilidade e controle de desperdício de alimentos	47
1.7. Sobre o uso de sistemas <i>E-nose</i> contra o desperdício de alimentos	52
1.8. Sobre as fases de existência e consumo de frutas, legumes e hortaliças	53
2 CONT3NT3	56
2.1. Objetivo	56
2.2. Concepção da Plataforma	57
2.2.1. Análise dos requisitos	58
2.2.2. Diagrama de Casos de Uso	60
2.3. Desenvolvimento do Software	61
2.3.1. Arquitetura	61
2.3.2. Framework para o módulo de Aprendizado de Máquina.....	69
2.3.3. Construção da interface de usuário	71
2.4. Desenvolvimento do Hardware.....	74
2.4.1. Projeto do Circuito eletrônico (Sistema <i>E-nose</i>)	74
2.4.2. Sobre o Container.....	76
3 BASE DE TREINAMENTO	82
3.1. Tipos de amostras e sua preparação para os testes	82
3.2 Procedimentos da coleta de dados e seus problemas	85
3.2. Tratamento dos dados coletados	88

3.2.1. Sobre as técnicas de imputação para dados ausentes ou com problemas	90
3.2.2 Análise das técnicas de imputação e das versões geradas	94
3.3 Mapeamento dos perfis da fase de decomposição das amostras.....	98
3.3.1 Decomposição fúngica	99
3.3.2 Decomposição natural por putrefação	102
3.3.3. Decomposição multifatorial	106
3.3.4. Decomposição por desidratação	108
4. RESULTADOS.....	110
4.1. Testes com alimento que pode ser consumido a longo prazo	110
4.2. Testes com alimento que deve ser consumido imediatamente (sem intervenção humana).....	112
4.3. Testes com alimento tratado com intervenção humana.....	114
4.4. Testes com alimento para o descarte imediato.....	118
4.4. Discussão sobre resultados	120
5 CONSIDERAÇÕES FINAIS	123
REFERÊNCIAS BIBLIOGRÁFICAS.....	126

INTRODUÇÃO

Nos últimos anos, o diálogo sobre Segurança Alimentar e Nutricional (SAN) vem constantemente sendo discutido no âmbito mundial. Segundo o representante regional da FAO (*Food and Agriculture Organization of the United Nations*) para a América Latina e o Caribe, Raúl Benítez (2021), o desperdício dos alimentos produzidos é um dos grandes desafios pendentes para alcançar a plenitude da segurança alimentar.

Em média um terço dos alimentos produzidos anualmente no mundo para o consumo humano são perdidos ou desperdiçados ao longo da cadeia de sua existência, considerando desde a fase de produção, através de atividades de agricultura ou pecuária, até ao consumo final pelos indivíduos comuns ou suas famílias (GUSTAVSSON et al., 2011).

Nos países com mais baixa renda per capita, verifica-se que o desperdício ocorre nos estágios iniciais e intermediários da cadeia. Já nos países com renda per capita alta ou média a maior parte dos alimentos são desperdiçados na fase final desta cadeia, ou seja, na fase final de consumo. Isto significa que tais alimentos, nesses países, são descartados em estágios ainda adequados para o consumo humano (GUSTAVSSON et al., 2011).

Além disso, os cuidados com a segurança alimentar também são um ponto de proeminência a serem percebidos, segundo a Organização Mundial de Saúde (OMS)¹, que alerta sobre o perigo de se consumir frutas e legume, que possam estar impróprios para ingeridos.

Os fatores, que podem contribuir para essa inadequação ao consumo, incluem o fato deles estarem irremediavelmente apodrecidos (ainda que não seja visível tal característica) ou deteriorados (2018). As doenças transmitidas por alimentos inseguros, afetam 1 em cada 10 pessoas no mundo e, de acordo com a OMS (2022), são mais de 200 doenças associadas, variando de diarreia a

¹ Em inglês: *World Health Organization* - WHO.

câncer.

Uma motivação para o desenvolvimento do sistema C0NT3NT3 é pelo fato dele apoiar a redução do desperdício de alimentos entre as pessoas que mais consomem no planeta, o usuário comum de cozinhas simples. A ideia é utilizar esse recurso na melhor conscientização sobre o tema e também na necessidade de agir de forma responsável diante de um problema global, pois o desperdício de alimentos tem implicações negativas que afetam tanto o meio ambiente quanto as pessoas.

Com base nesse contexto, essa pesquisa se propõe a apresentar o desenvolvimento de uma ferramenta que possa identificar quais gases estão sendo liberados por determinados tipos de alimentos, e, por consequência, analisar se tais alimentos estão aptos ou não para o consumo.

A ideia é que, com esse exame dos gases liberados durante uma fase de sua existência (após colheita e disponibilização para consumo), evite-se que alimentos com aparência não agradável sejam descartados de forma indevida, ajudando o consumidor a ver que eles ainda estão úteis e sem risco.

Esse trabalho levou ao desenvolvimento de uma plataforma proposta para indicar a necessidade ou não de descarte, não sendo ela uma ferramenta de descarte em si, pois a tarefa de descartar apropriadamente o alimento vai ser um ônus total do usuário.

Entretanto, essa plataforma, além de indicar se o alimento deve ou não ser descartado, se propõe a fornecer informações para realizar o descarte de forma sustentável, evitando que essa matéria orgânica seja descartada equivocadamente, reduzindo-se, assim, os danos ao meio ambiente.

A plataforma que foi desenvolvida é formada por uma interface eletrônica, que funciona acoplada a um software, esse construído com base em um algoritmo utilizando *Machine Learning*. A interface eletrônica é um dispositivo de automação, baseado em IoT, denominado de C0NT3NT3, ou container inteligente.

O objetivo da plataforma, já descrito acima, é o de analisar e indicar se um determinado tipo de alimento está próprio ou impróprio para consumos, de modo a evitar descartes indevidos. A ideia é que essa plataforma possa ser

utilizada como um dispositivo caseiro, ou de cozinhas pequenas, auxiliando as pessoas que cozinham a aproveitar melhor os alimentos disponíveis.

Para esse estudo, e visando um melhor aproveitamento da plataforma desenvolvida, visou-se aplicar tal ferramenta para analisar alimentos do tipo frutas ou hortaliças, tendo em vista que, em estudos preliminares, observou-se que alimentos baseados em proteína animal (carnes e laticínios) contém mais parâmetros a serem verificados do que frutas e hortaliças, tornando-os mais complexos de se examinar (GUSTAVSSON et al., 2011).

A plataforma, na sua interface eletrônica, se constitui em um circuito contendo um microcontrolador, que é o principal gerenciador eletrônico, e três tipos de sensores de gás, de modo a ser um sistema similar à ferramenta *E-nose*, que é um sistema para detecção de fragrâncias. Há também a parte de comunicação, utilizando o protocolo *bluetooth* para possibilitar o acesso da plataforma a um dispositivo móvel simples e vice-versa.

Já no software, foram realizadas várias medidas, com variados parâmetros, inclusive com diferentes tipos de material de caixa, para formar uma base de conhecimento a ser utilizada no classificador e analisador das frutas e hortaliças utilizadas para o desenvolvimento da plataforma.

Há dois módulos do software básico, o que vai obter os dados dos sensores e formatá-los e o que analisa, com uso da base de conhecimento, se o mesmo está em condições de uso. Parte desse software se baseia em uma aplicação mobile (APP), que vai estar instalada no dispositivo móvel do usuário principal.

Para ser possível verificar todo o material utilizado no desenvolvimento da plataforma, assim como o próprio desenvolvimento em si e os métodos utilizados nos testes, esta dissertação se apresenta com introdução, capítulo 1 abordando os trabalhos relacionados, o capítulo 2 abarcando a concepção da ferramenta, o capítulo 3 abrange a coleta de dados, suas tratativas e o modelo construído, no capítulo 4 apresenta os resultados obtidos com a experimentação da plataforma e finalmente as conclusões e considerações finais.

1 REVISÃO BIBLIOGRÁFICA

No levantamento de uma base bibliográfica preliminar para esse trabalho, foram procurados artigos na plataforma Google Scholar através da pesquisa com uso de termos associados, que foram: *electronic, device, food, waste, reduce, prevent* e *quality*; o que possibilitou encontrar 259 ocorrências até 2022.

Posteriormente, foi realizado a busca em artigos nos motores de buscas do ScienceDirect com os mesmos termos e critérios temporais, no qual foram localizadas 5736 ocorrências em uma primeira linha de busca. Utilizando-se de um refinamento para encontrar itens mais específicos, acrescentando outros termos: "*food waste*" and "*electronic device*" e "*reduce or prevent or food quality*"; foram relacionadas, ao final, 169 artigos até 2022.

Para melhorar mais ainda a base bibliográfica utilizada neste trabalho, outra busca foi realizada no ambiente do ResearchGate com o intuito de localizar outros artigos, ainda não publicados ou muito recentes, que não foram relacionados nas outras buscas.

Na primeira tentativa nesse novo ambiente, foram utilizadas as mesmas expressões utilizadas na ScienceDirect, no qual foi obtido apenas um resultado. Na segunda tentativa, ao invés do uso da expressão "*electronic device*" utilizou-se uma nova estrutura composta de: ("*food waste*") AND (*reduce OR prevent OR quality*) AND ("*electronic nose*" OR *E-nose* OR *eNose*). Nessa nova estrutura foram encontrados 11 novos artigos.

Por último, outra busca foi realizada na base da SciELO, utilizando as expressões "*nariz eletrônico*" OR *E-nose* OR "*electronic nose*", sendo eu, nesse caso, a busca retornou o total de 43 novos artigos relacionados.

Após a fase de busca, foi realizado um trabalho de classificação e escolha de artigos que foram obtidos, com o fim de compor a base bibliográfica deste trabalho. De acordo com o representado na Figura 1, separou-se cerca de 86% dos artigos oriundos do Google Scholar, sendo que 34% apareceram apenas nas buscas nessa plataforma. Uma parcela dos artigos selecionados,

correspondente à 14%, foram classificados e escolhidos senso aqueles com o maior número de citações. Os artigos selecionados serviram para poder extrair os conceitos técnicos e matemáticos usados nesse trabalho.

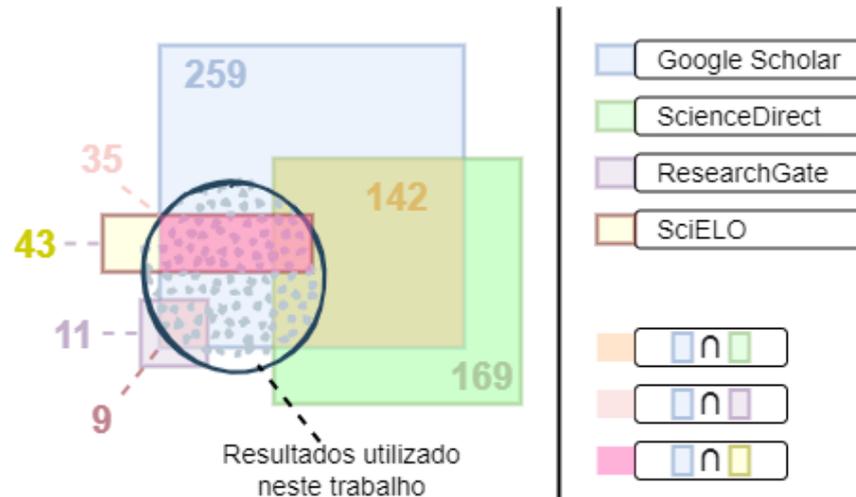


Figura 1: Resultados encontrados e suas interseções.

Fonte: Própria autoria.

1.1. Sistemas olfativos biológicos

O olfato para muitas espécies é o sentido mais aguçado e complexo, pois dele depende totalmente para sobreviver. Os estímulos sensoriais olfativos concedem informações importantes da natureza, limites territoriais e sobre a localização de predadores, presas e parceiros (HICKMAN et al., 2016). As pistas olfativas do ambiente ajudam no rastreamento e na navegação quando pistas visuais são limitadas ou mesmo ausentes (MARIN; SCHAEFER; ACKELS, 2021).

No sentido oposto, os seres humanos não possuem uma percepção sensorial olfativa desenvolvida, comparada com a de outros mamíferos. Os seres humanos possuem a capacidade de distinguir em torno de 10.000 odores (CARLSON, 2002) e a percepção olfativa nos cães é pelo menos um milhão de

vezes mais sensível (HICKMAN et al., 2016). Segundo Hickman et al. (2016), os cães exploram novos ambientes com seu nariz da mesma forma que os humanos fazem com os olhos.

O sistema olfativo nos humanos (Figura 2) se inicia através das narinas onde os odores são captados. A cavidade nasal, localizada no interior do nariz, é revestida por uma mucosa respiratória, epitélio respiratório e por pelos, denominados de vibrissas nasais (NASCIMENTO-JÚNIOR, 2020). O muco produzido e as vibrissas nasais funcionam como uma barreira para filtrar as partículas sólidas que entram junto com o ar inspirado (VALLE, 2015).

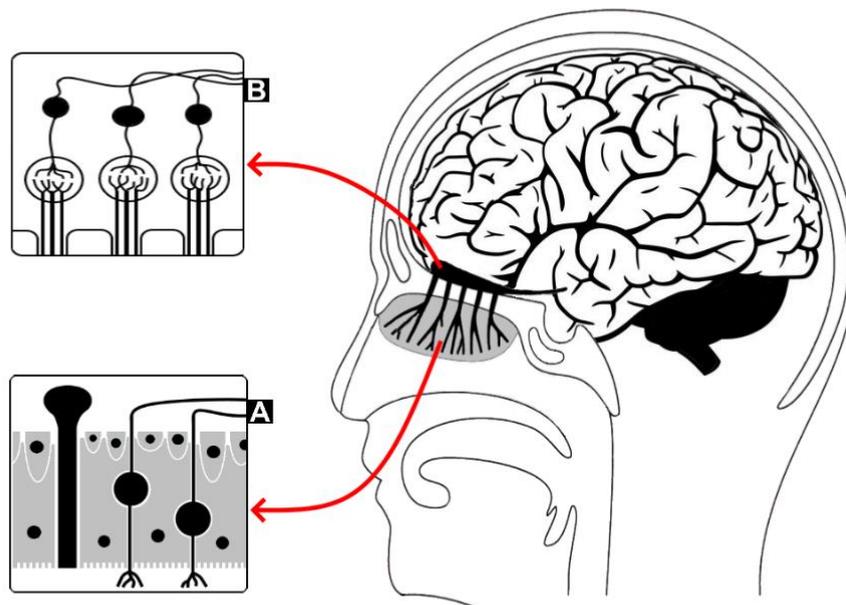


Figura 2: Sistema olfativo biológico humano: A) Epitélio olfativo; B) Bulbo olfativo.

Fonte: Adaptado de Hickman et al. (2016).

A parte interna do nariz além de promover a filtragem do ar, também possui as funções para o aquecimento e umidificação do ar inalado, auxiliando na modificação das vibrações da fala, na medida que passam pelas câmaras de ressonância, ampliando ou modificando o som (VALLE, 2015). Os padrões de fluxo de ar são afetados pelos fatores anatômicos, que auxiliam a direcionar o ar

na direção do epitélio olfatório (PINTO, 2011).

No terço superior da cavidade nasal está localizado o epitélio olfativo (Figura 2-A), no qual aparecem as terminações olfatórias posicionadas no fundo da cavidade nasal coberto por uma fina camada de muco. Este muco olfativo é essencial para o sentido sensorial olfativo, secretado pelos ácidos de Bowman, sendo uma substância serosa com a capacidade de diluir substâncias químicas odoríferas (PINTO, 2011).

Na região do epitélio olfatório estão localizados uma variedade de células (PINTO, 2011), ou neurônios olfatórios, ligados aos pelos olfativos (HICKMAN et al., 2016), (NASCIMENTO-JÚNIOR, 2020). As moléculas de odores que entram no nariz através das narinas se ligam a proteínas receptoras presentes nos pelos olfativos.

Ainda de acordo com Nascimento-Júnior (2020), também existem feixes amielínicos² do nervo olfatório, que conduzem os estímulos odoríferos das terminações da mucosa até o bulbo olfatório (conforme Figura 2-B) e descem em direção a região inferior do cérebro.

Quando os estímulos sensoriais olfativos alcançam o córtex olfativo, os odores são analisados, após esse processo de interpretação, as informações obtidas são enviadas para outras áreas do sistema nervoso central influenciando funções de apetite, salivação e contração gástrica (PINTO, 2011).

1.2 Sistemas olfativos artificiais

A limitação do olfato humano estimulou pesquisadores a propor sistemas olfativos artificiais, entre eles o trabalho de Zwaardemaker e Hogewind (1920) que é o artigo científico mais antigo com uma proposta de um sistema de nariz artificial. Segundo John et al. (2021), os autores deste trabalho de 1920 apresentaram apenas conceitos, já que a implementação de um protótipo se

² São os axônios que não possuem um revestimento de múltiplas camadas de proteínas e lipídios para formar uma bainha de mielina. Possuem uma velocidade de condução do impulso nervoso muito menor em comparação com os axônios mielínicos (VALLE, 2015).

tornou inviável por escassez de infraestrutura eletrônica e computacional.

Na década de 60 do século passado, Wilkens e Hartman (1963), apresentaram um protótipo de um sistema artificial, já com uso da tecnologia disponível à época. No seu artigo, há a definição prática do que seria o primeiro nariz eletrônico desenvolvido (SÁNCHEZ; SANTOS; LOZANO, 2019). Depois, Persaud e Dodd (1982) construíram uma definição mais robusta do que seria e como funcionaria um nariz eletrônico, ou um *E-nose*.

Já com os avanços tecnológicos atuais (Estakhroyeh et al, 2018) foram possíveis novos desenvolvimentos e aprimoramentos do sistema *E-nose*, no qual os receptores biológicos puderam ser implementados por melhores sensores artificiais, com a interpretação cerebral substituída por métodos de análise baseados em algoritmos inteligentes (Dung et al, 2018).

A Figura 3 apresenta uma comparação análoga entre os sistemas olfativo biológico e o de nariz eletrônico artificial, na qual se percebe que, nos sistemas artificiais, o papel do nariz, ou do receptor olfativo biológico, é substituído por um conjunto de sensores específicos para tal fim (TAN; XU, 2020).

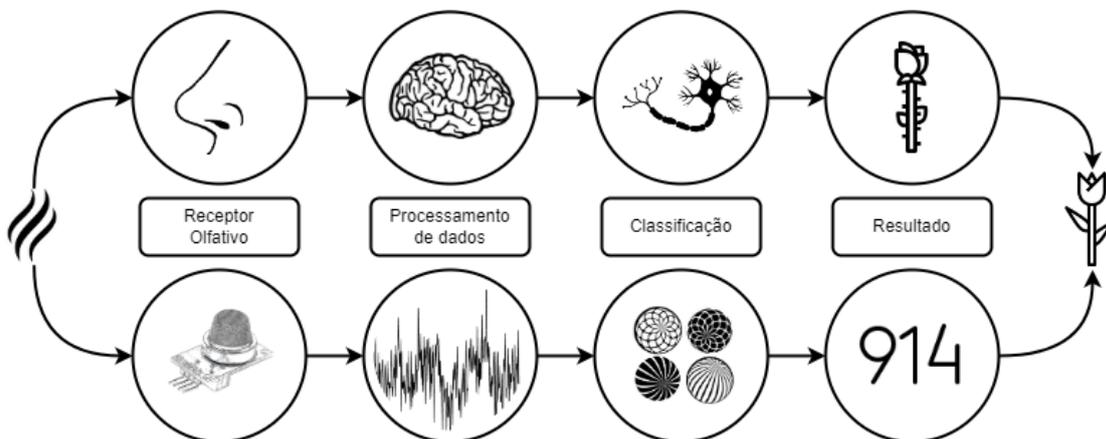


Figura 3: Analogia entre sistema biológico e nariz eletrônico

Fonte: Adaptado de Jońca et al. (2022).

Nessa transformação do biológico para o eletrônico, os sinais elétricos gerados pelo sensor ou por uma matriz de sensores são convertidos de analógico para digital, tal qual ocorre no epitélio olfatório (TAN; XU, 2020), sendo

que, nos sistemas artificiais, os “odores” são processados através de algoritmos sofisticados que os transformam em dados interpretáveis e os armazenam e classificam (KARAKAYA; ULUCAN; TURKAN, 2020).

Segundo Jońca et al (2022), a fase de classificação deve ser caracterizada pela análise através de um algoritmo para identificação de padrões para dados multivariados, que serão obtidos da matriz de sensores. Os algoritmos empregados nesta fase são do tipo de aprendizado de máquina (AM) (*Machine Learning*), com uso de métodos estatísticos, permitindo detectar novos padrões e associá-los a novos odores

1.3. Sobre tipos de sensores de nariz eletrônico

Conforme já dito, o “nariz” no sistema *E-nose* é um conjunto específico de sensores e softwares que transformam sinais analógicos em digitais e vice-versa (AOUADI et al., 2020). Cada sensor é responsável por identificar um tipo de odor, formando a composição final da matriz de dados obtida (KARAKAYA; ULUCAN; TURKAN, 2020).

Entre os tipos de sensores a serem utilizados, há os sensores químicos, que são compostos por elementos agrupados em 3 (três) blocos básicos (conforme visto na Figura 4). Esses blocos são: O de reconhecimento capaz de interagir seletivamente com o(s) analito(s); o de transdução, onde a informação é transformada, química em informação física, geralmente elétrica e o de transmissão, que consiste em um sistema eletrônico de amplificação e processamento de sinais, de modo a propagar os resultados (QUIÑONES-MONTENEGRO; HERRERA-PEDRAZA; ORTEGA-CHÁVEZ, 2013).

De acordo com Sánchez, Santos e Lozano (2019), a utilização de um determinado tipo de sensor varia de acordo com a aplicação ou necessidade, pois cada sensor vai tratar de sinais diferentes de formas diferentes. Os sensores de gás, por exemplo, são transdutores que transformam as interações químicas entre duas camadas em um sinal elétrico (JOńCA et al., 2022).

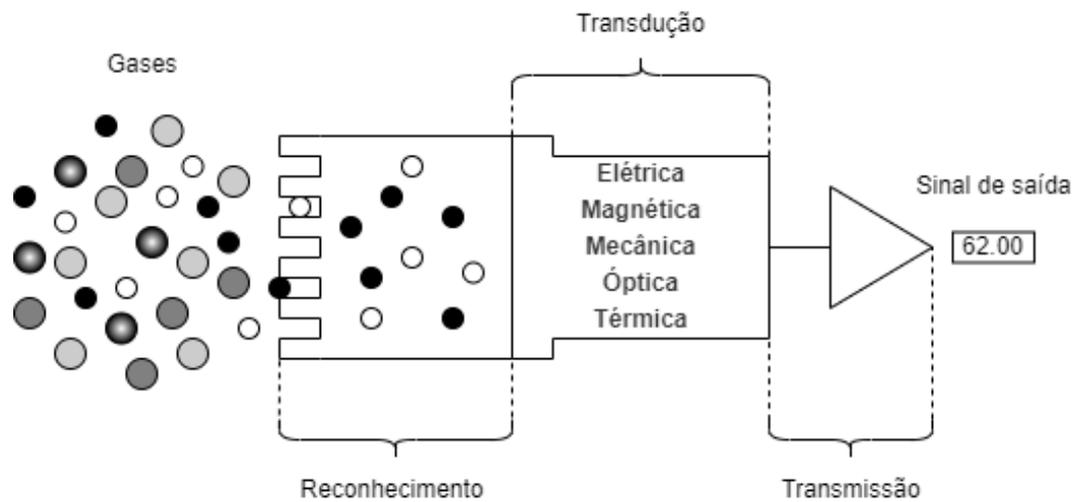


Figura 4: Blocos básicos de um sensor.

Fonte: Adaptado de Quiñones-Montenegro, Herrera-Pedraza e Ortega-Chávez (2013)

Cada tipo de sensor possui um grupo de características para cada aplicação de rastreamento de sinais. De modo a verificar as vantagens e desvantagens dos tipos de sensores mais comumente, essas características gerais são apresentadas na Tabela 1.

Analisando cada parte de prós e contras de cada sensor, pode-se, então, construir a matriz de sensores adequada para a aplicação proposta, nos quais os diferentes tipos de sensores utilizados podem balancear as características gerais de detecções, maximizando as vantagens e evitando as desvantagens (SÁNCHEZ; SANTOS; LOZANO, 2019).

Um tipo de classificação dos sensores é feito a partir do material ou mecanismo aplicado para seu propósito de detecção, ou transdução. Neste tipo de classificação, os sensores são separados em quatro categorias: eletroacústicos, eletroquímicos, quimiorresistivos e transistor de efeito de campo (JOHN et al., 2021), (JOÑCA et al., 2022).

Tabela 1: Tipos de sensores e suas propriedades.

Fonte: Adaptado de Dey (2018) e Karakaya, Ulucan e Turkan (2020).

Tipo de Sensor	Faixa de detecção	Vantagens	Desvantagens
Óxido metálico semiconductor (MOS)	5-500 ppm	<ul style="list-style-type: none"> - Baixo custo - Fácil de usar - Operação em alta temperatura - Tempo de resposta rápida - Sensível a diversos gases - Tamanho pequeno 	<ul style="list-style-type: none"> - Alta especificidade - Envenenamento por enxofre - Baixa precisão operando a temperatura abaixo de 150 °C (requer <i>Burn-in time</i>) - Recuperação lenta - Sensível à umidade - Alto consumo de energia
Polímero condutor (CP)	0,1-100 ppm	<ul style="list-style-type: none"> - Baixo custo - Resiste ao envenenamento do sensor - Sensível a diversos gases - Tempo de resposta rápida 	<ul style="list-style-type: none"> - Desvio na resposta - Sensível à temperatura - Sensível à umidade - Vida útil limitada do sensor
Microbalanço de cristal de quartzo (QCM)	1,5 Hz / ppm 1 ng de mudança de massa	<ul style="list-style-type: none"> - Boa sensibilidade - Limites de detecção baixos - Tempo de resposta rápida 	<ul style="list-style-type: none"> - Difícil de implementar - Relação sinal-ruído ruim - Sensível à temperatura - Sensível à umidade
Onda acústica de superfície (SAW)	50-1000 MHz	<ul style="list-style-type: none"> - Baixo custo - Boa sensibilidade - Resposta a quase todos os gases - Tamanho pequeno - Tempo de resposta rápida 	<ul style="list-style-type: none"> - Desvio na resposta - Difícil de implementar - Relação sinal-ruído ruim - Sensível à temperatura
Eletroquímico (EC)	0-1000 ppm (ajustável)	<ul style="list-style-type: none"> - Potência eficiente e robusta - Sensível a diversos gases - Temperatura de operação de alta faixa 	<ul style="list-style-type: none"> - Sensibilidade limitada - Tamanho grande
Térmicos ou calorimétricos (CB)	Grande escala	<ul style="list-style-type: none"> - Alta especificidade para gases combustíveis - Tempo de resposta rápida 	<ul style="list-style-type: none"> - Operar em alta temperatura - Somente para compostos com oxigênio
Óptico	Mudança com parâmetros de luz (baixo ppb)	<ul style="list-style-type: none"> - Baixo custo - Imune a interferência eletromagnética - Peso leve do dispositivo - Sensibilidade rápida e muito alta 	<ul style="list-style-type: none"> - Afetado por interferência de luz - Baixa portabilidade - Difícil de implementar

1.3.1 Sensores eletroacústicos

Os sensores eletroacústicos utilizam a propriedade piezoelétrica do cristal de quartzo. Nesse tipo de sensor, o sinal é obtido através da variação de frequência gerada pela oscilação do cristal de quartzo em resposta a mudança

de massa na superfície do sensor (JOÑCA et al., 2022). A medida da frequência de ressonância se altera com a percepção de massa, induzida pela adsorção de gás na superfície do eletrodo modificado.

Dentre os diversos sensores eletroacústicos, o sensor microbalanço de cristal de quartzo (QCM³) é o mais utilizado em sistemas do tipo *E-nose*. Esse tipo de sensor trabalha com a equação de Sauerbrey (Equação 1) (1959), que fornece que a adsorção e dessorção de moléculas de gás na massa do sistema transdutor causa alterações na frequência de ressonância (JOHN et al., 2021).

$$\Delta f = -C_f * \Delta m \quad (1)$$

Nessa equação:

Δf é a variação de frequência observada, em Hz;

Δm é a variação de massa por unidade de área, em ng/cm²; e

C_f é o fator de sensibilidade do cristal utilizado (ou seja, 56,6 Hz µg-1 cm² para um cristal de quartzo de corte AT de 5 MHz à temperatura ambiente).

O mecanismo de transdução é dividido em duas fases básicas: adsorção e dessorção, como apresentado na Figura 5-A. Na adsorção, conforme moléculas se acumulam na superfície do sensor, mudanças tênues de massa, na ordem de nanogramas (ng), ocorrem até alcançar o limite de moléculas acumuladas na área total do cristal (ng/cm²). Na dessorção, as moléculas se desprendem da placa, ocorrendo a redução da massa obtida (conforme visto na Figura 5-B).

³ Acrônimo em inglês de *Quartz Crystal Microbalance*.

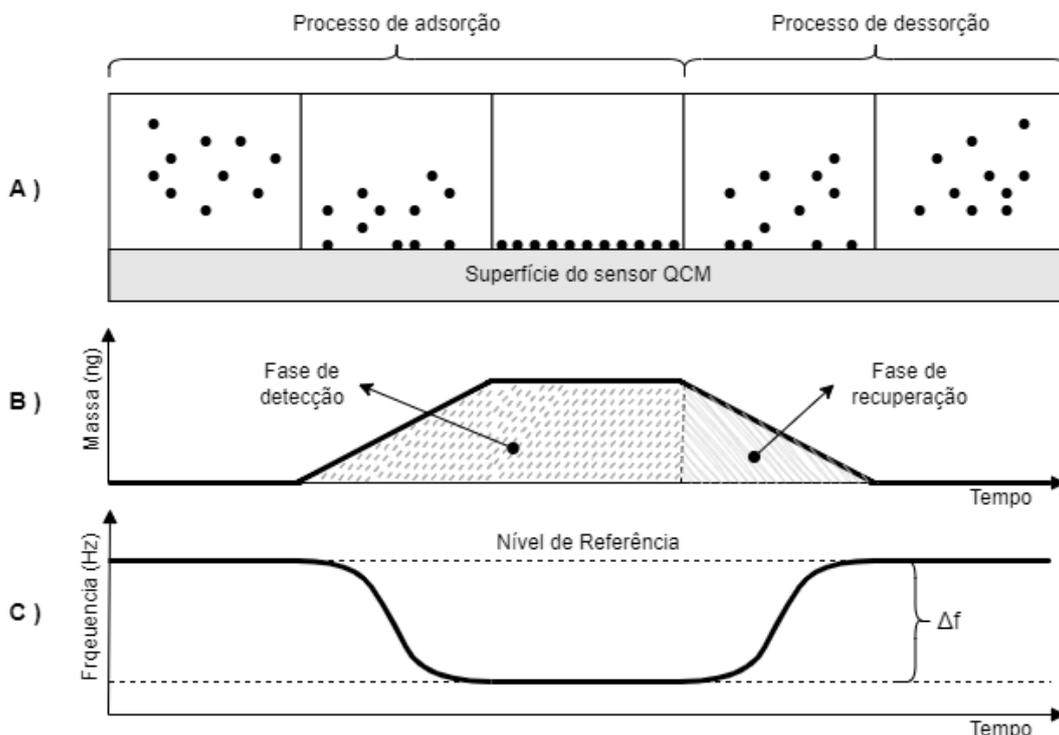


Figura 5: Mecanismo de transdução em sensores eletroacústicos: A) Processo de adsorção e dessorção de moléculas na superfície do sensor QCM; B) Variação da massa ao longo do processo de adsorção e dessorção; C) A frequência em função da massa na superfície.

Fonte: Própria autoria.

Uma voltagem é aplicada no sensor QCM, fazendo com que o cristal de quartzo oscile a uma frequência contínua, formando um nível de referência (Figura 5-C). A frequência de oscilação gradativamente diminui de acordo com o aumento do número de moléculas depositadas na superfície do sensor. E quando as moléculas acumuladas se desprendem da placa do sensor retorna ao nível de referência.

1.3.2. Sensores eletroquímicos

Os sensores eletroquímicos trabalham com as medições das mudanças de corrente geradas por redução ou a oxidação de moléculas na superfície do eletrodo catalítico (KARAKAYA; ULUCAN; TURKAN, 2020),

(JOñCA et al., 2022). A Figura 6-A apresenta o mecanismo de transdução deste tipo de sensor, que se baseia em uma configuração com 3 tipos de eletrodos, no qual as medidas das mudanças no fluxo de corrente são proporcionais à concentração de gás medida (Figura 6-B).

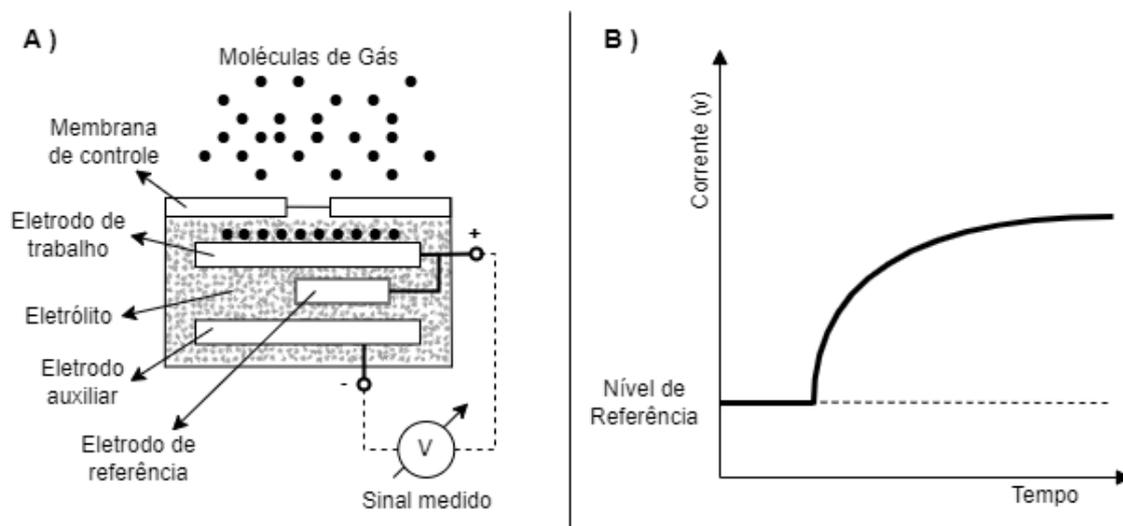


Figura 6: Mecanismo de transdução em sensores eletroquímicos: A) Estrutura básica de um sensor eletroquímico; B) Mudança do fluxo de corrente.

Fonte: Adaptada de Szulczyński e Gębicki (2017) e John et al. (2021).

De acordo com John et al. (2021), os sensores eletroquímicos são classificados em quatro subcategorias:

- **Amperométricos:** Nos quais os três eletrodos são de trabalho básico (sensível ao analito), auxiliar (reação eletroquímica, ocorre a passagem de corrente) e de referência (Indicador de potencial conhecido e constante), conectados por meio de um eletrólito. Quando o analito é inserido no eletrólito através da membrana de controle, as mudanças de corrente são medidas.
- **Potenciométricos de equilíbrio:** Este tipo de sensor opera mediante os eletrodos de referência e de trabalho, em ambos os lados de um eletrólito sólido, medindo com isso a diferença de potencial entre eles.
- **Potenciométricos mistos:** Se baseiam em reações catalíticas

concorrentes entre o eletrodo de detecção e o analito, e entre o analito e oxigênio (O_2). A detecção do sensor é realizada no momento em que a medida que as taxas de ambas as reações se tornam iguais.

- Impedométricos: Possui similaridade com às demais técnicas anteriores, no entanto, a resposta gerada por este sensor é com base na tensão, no qual a medida é analisada utilizando um circuito elétrico, denominado de circuito de Randles.

O uso dos sensores eletroquímicos é recomendado para aplicações de segurança, monitoramento industrial (KARAKAYA; ULUCAN; TURKAN, 2020) e em bafômetros (SZULCZYŃSKI; GĘBICKI, 2017). Possuem boa eficiência de energia, ótima robustez, temperatura de operação entre $15^\circ C$ e $100^\circ C$ e capacidade de detectar diversos tipos de gases (KARAKAYA; ULUCAN; TURKAN, 2020).

No entanto, de acordo com o visto no trabalho de Szulczyński e Gębicki (2017), existe um limite de moléculas por partículas por milhão (ppm) que podem ser detectadas por esse tipo sensor, reduzindo o alcance de uso do mesmo.

Entre os gases que sofrem dessa limitação estão, por exemplo, o dióxido de enxofre (SO_2), o dióxido de nitrogênio (NO_2), a amônia (NH_3), o sulfeto de hidrogênio (H_2S), o formaldeído ($HCHO$) e o glutaraldeído ($C_5H_8O_2$).

1.3.3. Sensores quimiorresistivos

Os sensores quimiorresistivos comumente são construídos com um sistema de dois eletrodos, no qual a resistência da camada de detecção entre os eletrodos é monitorada em função do tempo quando exposta ao gás (JOHN et al., 2021). Ainda segundo John et al. (2021), o maior uso deste tipo de sensor, entre todas as demais diferentes metodologias, está relacionada com as

vantagens de ser de mais fácil de fabricação, determinando um baixo custo, mas com uma robusta capacidade de medição eletrônica (JOÑCA et al., 2022).

Os sensores quimiorresistivos operam segundo a Lei de Ohm (JOHN et al., 2021), no qual os gases interagem com o mecanismo de detecção, acarretando propriedades elétricas de condutividade, gerando assim um sinal de tensão (TAN; XU, 2020), (JOHN et al., 2021). A Figura 7 apresenta como a medição da condutividade é obtida, medindo-se a tensão de saída do sensor, com base no pico de tensão elétrica, tempo de resposta e tempo de recuperação.

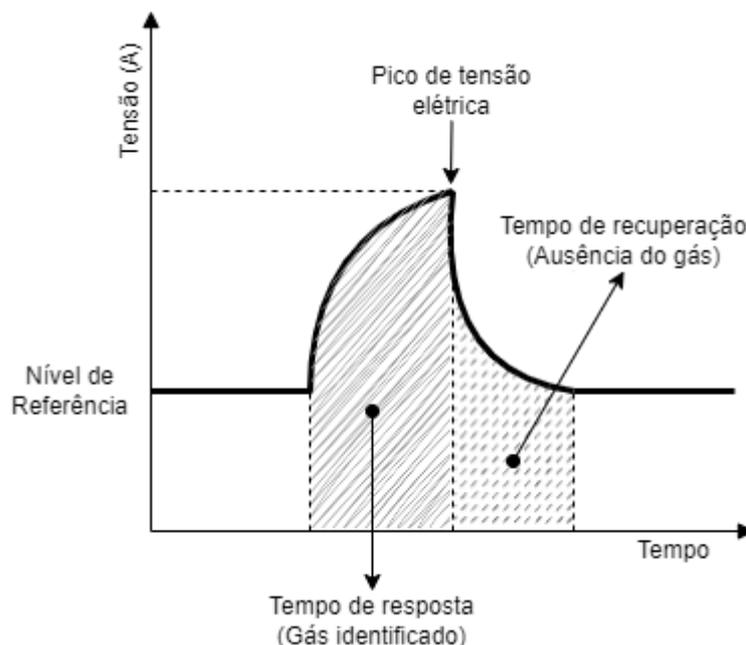


Figura 7: Mecanismo de transdução em sensores quimiorresistivos.

Fonte: Adaptada de Tan e Xu (2020) e John et al. (2021).

A camada de detecção dos sensores quimiorresistivos são baseadas em diferentes materiais, divididos em três grupos: polímeros condutores e seus derivados; materiais à base de carbono e os óxidos metálicos semicondutores (MOS⁴), sendo os MOS, os materiais mais utilizados para construir narizes eletrônicos do tipo *E-nose* (TAN; XU, 2020), (JOHN et al., 2021).

Nos sensores MOS, as partículas do analito se difundem em direção

⁴ Acrônimo em inglês de *Metal Oxide Semiconductor*. A propósito, há autores que o nomeiam como *Semiconducting Metal Oxides* (SMO).

à superfície receptora, que é o óxido metálico ou o quimiorresistor. Na Figura 8, é apresentado o esquema básico deste tipo de sensor, no qual, através da bobina de aquecimento, o quimiorresistor permanece a uma temperatura de modo que ocorra a quimissorção. Esse processo resulta em mudança de resistência do quimiorresistor para conseqüente formação de sinal (SZULCZYŃSKI; GĘBICKI, 2017).

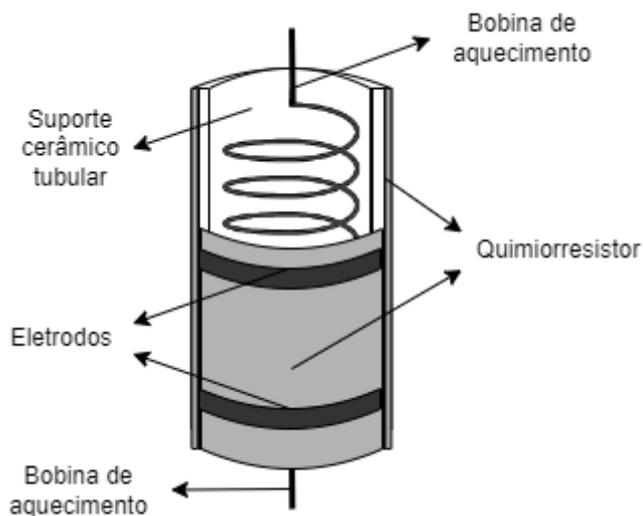


Figura 8: Projeto esquemático do sensor tipo MOS.

Fonte: Adaptada de John et al. (2021).

A eficiência do sensor MOS na detecção de gases é dependente do que o quimiorresistor (JOHN et al., 2021) pode identificar. Existem 2 (dois) tipos de quimiorresistores, de tipo N e tipo P, que respectivamente, reagem na presença de compostos redutores e oxidantes (SZULCZYŃSKI; GĘBICKI, 2017), (TAN; XU, 2020).

O mecanismo de detecção do sensor MOS tipo N se baseia na quimissorção entre as moléculas de oxigênio contidas no ar e a superfície do quimiorresistor. As moléculas de oxigênio adsorvidas se ligam através de reações químicas aos elétrons livres na parede do quimiorresistor (Figura 9-A). As moléculas do analito são de caráter redutor e também reagem com o oxigênio (Figura 9-B), fazendo com que ocorra a liberação dos elétrons (SZULCZYŃSKI; GĘBICKI, 2017).

Com a mudança de resistência é possível realizar as medições para detecção do gás. O nível de referência deste sensor é aquele no qual não há elétrons livres (conforme observado na Figura 9-A. Quando o analito reage com o oxigênio, se inicia a liberação de elétrons, até o limite máximo, perfazendo a detecção do gás pelo quimiorresistor (vide Figura 9-B e Figura 9-C).

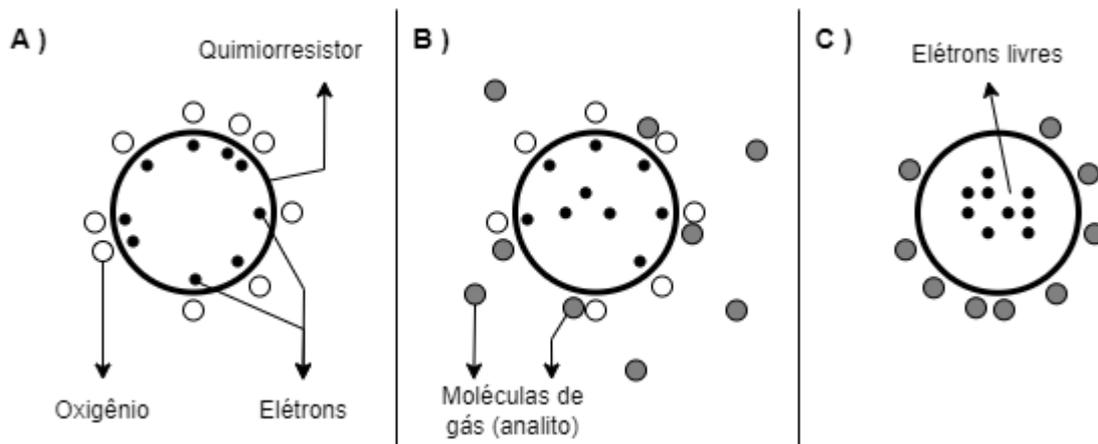


Figura 9: Funcionamento do sensor MOS. A) Ambiente livre do analito; B) Início da quebra de ligações químicas na presença do analito; C) Máximo de detecção pelo quimiorresistor.

Fonte: Própria autoria.

Nos sensores MOS tipo P, que alteram sua resistência na presença de analitos oxidantes, o princípio é inverso. Moléculas dos compostos gasosos removem elétrons do quimiorresistor, produzindo buracos ao longo de sua superfície (SZULCZYŃSKI; GĘBICKI, 2017), (KARAKAYA; ULUCAN; TURKAN, 2020).

A sensibilidade do sensor MOS, em ambos os tipos, é melhor do que outros tipos, devido a reatividade da superfície do quimiorresistor (DEY, 2018). A principal desvantagem do sensor MOS está relacionada com a sua temperatura de operação, que varia entre 150 e 500 °C. Outras desvantagens incluem: elevado consumo de energia (acima de 100 mW), precisam de um tempo mais longo de pré-aquecimento para operar com a máxima precisão e tem custo maior para sua manutenção (TAN; XU, 2020), (JOŃCA et al., 2022).

1.3.4. Sensores de efeito de campo

Os sensores de gás baseados em transistores de efeito de campo (FET⁵) usam o material de detecção como porta ou canal de transmissão de elétrons. Nesses casos, quando o sensor é exposto ao analito a ser examinado, vai ocorrer uma alteração na tensão limite ou na corrente de drenagem (HONG et al., 2021). Existem diversos sensores de gás do tipo FET, que se diferenciam mais por aspectos estruturais ou propriedades elétricas (HONG et al., 2021), sendo o metal óxido semiconductor (MOSFET⁶) o mais difundido entre eles (CRUZ; JÚNIOR, 2007).

No trabalho Lundström et al. (1975) foi proposto o primeiro sensor FET com porta de metal catalítico, ou o MOSFET. Ao longo dos anos o MOSFET se tornou o dispositivo padrão a ser utilizado na fabricação de circuitos integrados, por sua facilidade na redução de tamanho e, na época, baixa emissão termiônica (CRUZ; JÚNIOR, 2007).

O mecanismo de funcionamento dos MOSFET se apoia na variação do potencial eletrostático, no qual, através do dispositivo transdutor, ocorre transformação de uma alteração física ou química do material examinado em um conjunto de sinais elétricos (ARSHAK et al., 2004). A principal propriedade associada a esse efeito é a impedância elétrica de entrada, que se mantém em valores entre 10^{12} e $10^{14} \Omega$, no que resulta numa corrente de porta praticamente nula (CRUZ; JÚNIOR, 2007).

No seu funcionamento básico, uma tensão é aplicada na porta, que é composta por um isolante de óxido e uma camada de metal, e vai controlar o fluxo de elétrons, através da formação de um canal (ARSHAK et al., 2004). Quando a porta é carregada negativamente, uma região de depleção é criada interrompendo o fluxo de elétrons no canal. Em contrapartida, quando a porta é carregada positivamente, os elétrons são atraídos para o canal, permitindo a passagem de corrente.

⁵ Acrônimo em inglês de *Field Effect Transistor*.

⁶ Acrônimo em inglês de *Metal Oxide Semiconductor Field Effect Transistor*.

O sensor MOSFET se utiliza do princípio de variação na condutividade do canal de semicondutor para detectar a presença de gases. Qualquer alteração na resistência (pela emissão de gases) é detectada como pelo valor da tensão de saída, que vai indicar a concentração do gás detectado (ARSHAK et al., 2004). As propriedades de sensibilidade e seletividade deste tipo de sensor podem ser amplificadas quando é implementado, na fabricação do mesmo, uma camada que vai ser sensível para cada tipo de gás diferente.

1.4. Algoritmos de aprendizado de máquina

O termo Aprendizado de Máquina (AM), ou *Machine Learning (ML)*, refere-se aos algoritmos que possibilitam um sistema computacional ser capaz de identificar padrões a partir de amostras de dados e realizar previsões com base em novos dados captados (MITCHELL, 1997).

O AM é utilizado para processar e compreender grandes quantidades de dados e fornecer resultados de classificação e reconhecimento (KARAKAYA; ULUCAN; TURKAN, 2020), segundo regras específicas. Na área de sistemas *E-nose*, os algoritmos de AM estão sendo aplicados para o processamento de dados e classificação dos mesmos.

No trabalho de Alpaydin (2010), é destacado que o AM busca construir modelos e sistemas capazes de melhorar seu desempenho em tarefas específicas com base na experiência acumulada, permitindo que eles realizem previsões ou tomem decisões sem intervenção humana direta. Os algoritmos de AM são agrupados em quatro grupos de aprendizado: a) supervisionado; b) não supervisionado; c) semi-supervisionado; d) por reforço.

O aprendizado supervisionado consiste em aprender uma função (ou modelo) de mapeamento robusto no qual é treinado a partir de um conjunto de dados rotulados de entrada e saída (ALPAYDIN, 2010). O objetivo é que o modelo generalize a relação entre os dados, de modo que o mapeamento permitirá que o sistema realize previsões de dados não rotulados (KARAKAYA;

ULUCAN; TURKAN, 2020).

Já no aprendizado não supervisionado utiliza-se um conjunto de dados contendo apenas entradas. O objetivo é encontrar estruturas, padrões e informações úteis nos dados de entrada e identificação de padrões específicos observando correlações e relacionamentos (ALPAYDIN, 2010). As técnicas de agrupamento, associação e redução de dimensionalidade usam o aprendizado não supervisionado (KARAKAYA; ULUCAN; TURKAN, 2020).

O aprendizado semi-supervisionado adapta recursos do aprendizado supervisionado e não supervisionado, ou seja, dados rotulados e não rotulados no conjunto de dados. A sua finalidade é aproveitar as informações dos dados rotulados para melhorar a qualidade da aprendizagem sobre os dados não rotulados (ALPAYDIN, 2010). É uma abordagem utilizada em problemas com uma grande quantidade de dados não rotulados reduzindo com a complexidade computacional e o tempo (KARAKAYA; ULUCAN; TURKAN, 2020).

No aprendizado por reforço o sistema aprende através de tentativa e erro, explorando o ambiente e recebendo recompensas ou punições em resposta às suas ações (RIEDMILLER et al., 2009). Esse modelo é utilizado em uma variedade de aplicações, robótica, jogos, processamento de linguagem natural, otimização de recursos, controle de processos e muitos outros (LI, 2018).

1.4.1. Reconhecimento de padrões e classificação

Segundo Bishop (1995) o processo de identificação de padrões utilizando um algoritmo de IA é definido como reconhecimento de padrões. A técnica de reconhecimento de padrões abrange a análise de um conjunto de dados com o objetivo de identificar padrões, tendências ou atributos distintos. A partir dos padrões identificados, a classificação é possível, permitindo a categorização ou identificação de um conjunto de dados (KARAKAYA; ULUCAN; TURKAN, 2020).

A área de pesquisa de sistemas *E-nose* utiliza diversas abordagens

de reconhecimento de padrões com uso de algoritmos de AM (KARAKAYA; ULUCAN; TURKAN, 2020). Na Tabela 2, são listados os principais algoritmos usados em aplicações de nariz eletrônico, que são: o *Principal Component Analysis* (PCA); o *Linear Discriminant Analysis* (LDA); o *Support Vector Machine* (SVM) e o *Artificial Neural Network* (ANN).

Tabela 2: Vantagens e desvantagens dos algoritmos utilizados por sistemas de nariz eletrônico.

Fontes: (KARAKAYA, ULUCAN, TURKAN 2020), (TAN; XU, 2020), (MUNEKATA et al., 2023)

Algoritmo	Vantagem	Desvantagem
PCA	<ul style="list-style-type: none"> - Redução da dimensionalidade - Eliminação das correlações - Mede estimativas de probabilidade de dados de alta dimensão - Compressão de dados 	<ul style="list-style-type: none"> - Perda de interpretabilidade - Sensibilidade a outliers - Pressuposto de linearidade - Dependência da escala dos dados - Alto tempo computacional ao lidar com grande quantidade de dados
LDA	<ul style="list-style-type: none"> - Redução da dimensionalidade - Melhora a separação das classes - Eficiência computacional - Limite de decisão linear - Interpretabilidade 	<ul style="list-style-type: none"> - Dependência das classes rotuladas - Sensibilidade a outliers - Operações com matrizes complexas - Restrição linear - Para treinamento exige alto tempo computacional - Suposição de normalidade
SVM	<ul style="list-style-type: none"> - Eficaz em espaços de alta dimensão - Memória relativamente eficiente - Bom desempenho em conjuntos de dados pequenos - Alta capacidade de generalização - Rápido na classificação binária e múltiplas classe - Funciona muito bem com dados não lineares 	<ul style="list-style-type: none"> - Sensível aos parâmetros de ajuste - Alto tempo computacional ao lidar com grande quantidade de dados - Difícil interpretação dos resultados - Dados com ruído podem causar sobreposição de classes
ANN	<ul style="list-style-type: none"> - Generalização - Aprendizado adaptativo (consegue operar com conhecimento incompleto) - Tolerância a falhas - Depois de treinadas, as predições são rápidas - Eficaz com a grande quantidade de dados - Processamento paralelo 	<ul style="list-style-type: none"> - Difícil descobrir a estrutura ideal de rede neural - Requer grande quantidade de dados - Complexidade computacional com o seu crescimento - Interpretabilidade limitada - Pode ocorrer <i>Overfitting</i>

Entre eles existem diversas vantagens e desvantagens, sendo que a escolha do mais adequado para uma determinada aplicação é baseada no tipo de categorização exigida, ou qual o limite de classificação viável para os objetivos do sistema.

Os métodos de reconhecimento de padrões para sistemas *E-nose* envolvem a utilização de algoritmos de AM, mineração de dados, análise estatística e processamento de sinais (BISHOP, 2006). Os dados obtidos a partir da matriz de sensores do sistema de nariz eletrônico são analisados por esse tipo de algoritmo, de modo a identificar as regularidades ou similaridades contidas nos dados.

De acordo com Wijaya et al. (2022), um sistema de nariz eletrônico eficiente é aquele que tem uma mais ampla gama de classificações, através do uso de algoritmos de reconhecimento de padrões.

Exemplos de algoritmos de reconhecimento baseados em AM são os PCAs, que são algoritmos de AM não-supervisionados utilizados para a redução da dimensionalidade do conjunto de dados (TAN; XU, 2020), (MUNEKATA et al., 2023). Na área de sistemas *E-nose*, eles são aplicados por trabalharem com espaços de alta dimensão, associado um maior número de sensores de gás e também dos múltiplos sinais obtidos (TAN; XU, 2020).

Outros tipos de algoritmos AM são os LDAs, que são aplicados para encontrar combinações lineares das variáveis, de modo a maximizar a categorização de classes e minimizar as variações dentro de cada uma dessas classes (MCLACHLAN, 2005). Segundo Shlens (2014), a abordagem do LDA é particularmente relevante e eficiente em problemas com poucas amostras de treinamento e são pouco utilizadas em sistemas *E-nose* mais complexos.

Os algoritmos SVM, são do tipo supervisionado usados para resolver problemas complexos de classificação com dados de diversos domínios (KARAKAYA; ULUCAN; TURKAN, 2020). Ele visa obter um plano específico e separador para cada dado, definido por uma função de *kernel*. Esta função permite mapear os dados em um espaço denominado hiperplano no qual irão ser separada as classes obtidas.

O processo para definir a melhor função de *kernel* é denominado mapeamento de *kernel* ou *Kerneling* (Figura 10), O *Kerneling* é uma técnica que permite lidar com problemas de classificação não lineares. No caso de conjuntos de dados que não são separáveis, o uso de uma função de kernel apropriada é necessário para adicionar uma dimensão adicional a este novo espaço de dados

(JOñCA et al., 2022).

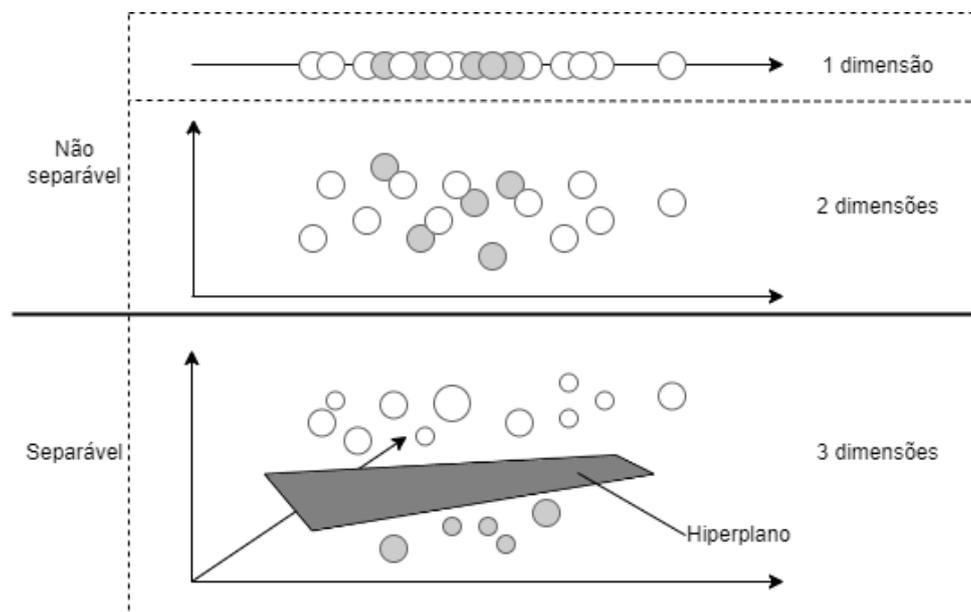


Figura 10: *Kerneling* do SVM.

Fonte: (JOñCA et al., 2022).

Os algoritmos ANN, são algoritmos AM classificadores inspirados no funcionamento do cérebro humano (SINHA et al., 2022). Esse tipo de algoritmo se apresenta com um modelo composto por vários nós ou neurônios artificiais, interconectados em camadas, uma rede multicamada.

Como demonstrado na Figura 11, a estrutura de uma rede do ANN é composta por camadas, no qual, a primeira camada é a camada de entrada, seguida por uma ou mais camadas intermediárias (ocultas) e por último a camada de saída. (SINHA et al., 2022).

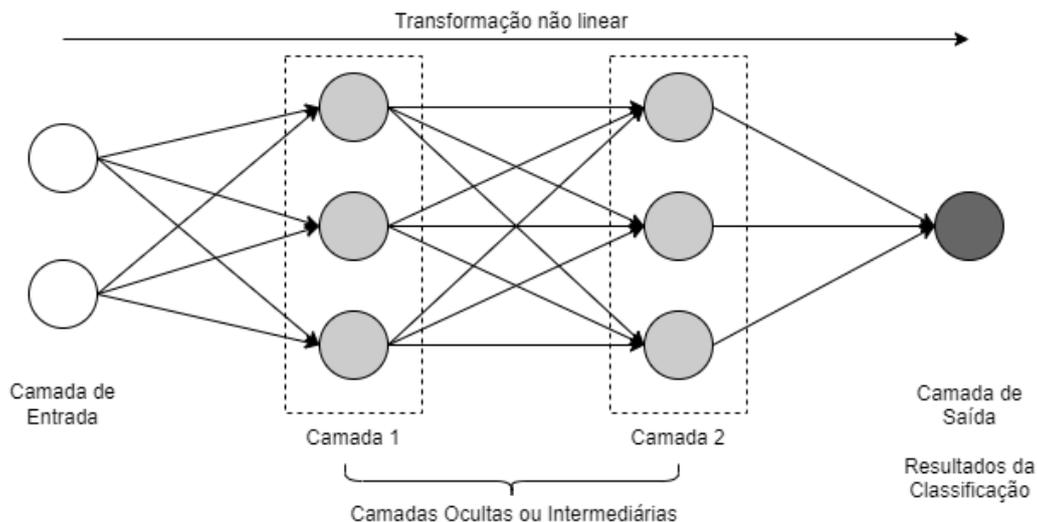


Figura 11: Exemplo da estrutura de uma ANN

Fonte: Adaptado de Karakaya, Ulucan e Turkan (2020).

Na Figura 12, são listadas as principais funções de ativação utilizadas nos algoritmos do tipo ANN, sendo estas as funções de Identidade, etapa binária, sigmoide, TanH, ReLU e *Softmax* (SINHA et al., 2022).

Função de Ativação	Representação Matemática	Representação Gráfica	Função de Ativação	Representação Matemática	Representação Gráfica
Identidade	$f(x) = x$		TanH	$f(x) = \frac{2}{1 + e^{-2x}} - 1$	
Etapa binária	$f(x) \begin{cases} 0, x < 0 \\ 1, x \geq 0 \end{cases}$		ReLU	$f(x) \begin{cases} 0, x < 0 \\ 1, x \geq 0 \end{cases}$	
Sigmoide	$f(x) = \frac{1}{1 + e^{-x}}$		Softmax	$\theta(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$ para $i = 1, \dots, K$	

Figura 12: Funções de ativação para neurônios em ANN.

Fonte: Adaptado de Karakaya, Ulucan e Turkan (2020).

1.4.2. Problemas de métricas e avaliação dos algoritmos AM

Nos algoritmos AM, dois desafios comuns que podem ocorrer ao treinar um modelo são o *underfitting* e o *overfitting* (Figura 13). Os conceitos destes desafios são úteis ao lidar com qualquer tipo de algoritmo AM e servem para aprimorar mais a detecção de sinais em sistemas *E-nose* (MUNEKATA et al., 2023).

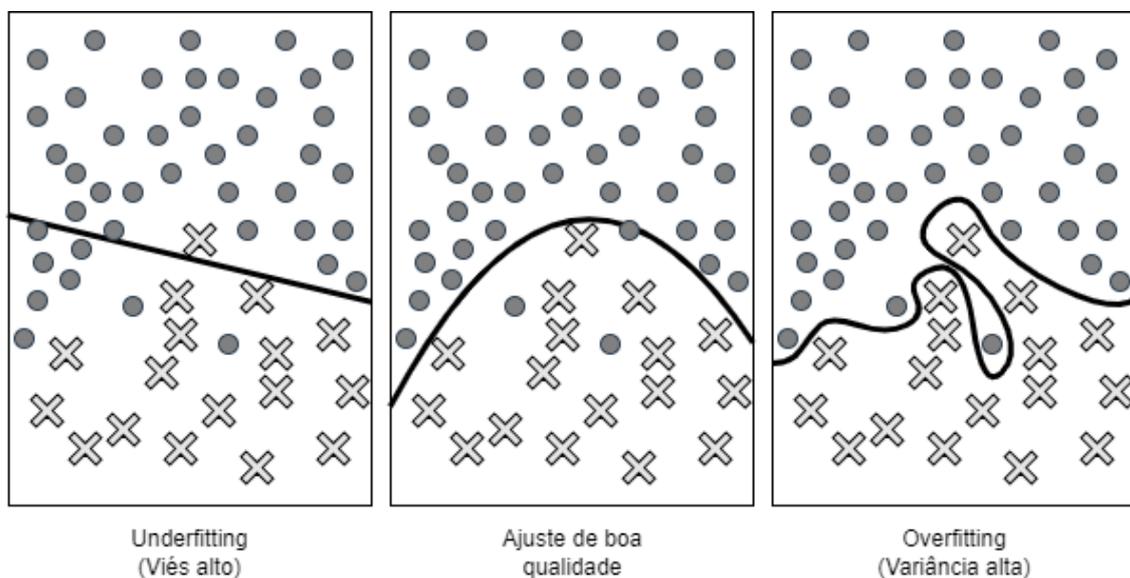


Figura 13: Exemplos de ajustes ao modelo de dados.

Fonte: Adaptado de Bishop (2006) e Hastie et al. (2009).

O problema de *underfitting* acontece quando o modelo não é capaz de extrair padrões e suas relações complexas, tendendo a menores ajustes sobre os dados de treinamento (BISHOP, 2006). De acordo com Hastie et al. (2009), o *underfitting* ocorre quando o modelo apresenta variância baixa e um viés alto nas previsões e não possui capacidade de generalizar os dados de forma eficiente. Neste caso, acaba sendo um modelo que "decora" os dados de treinamento, ao invés de aprender os padrões.

Por outro lado, o problema de *overfitting* ocorre quando o modelo se ajusta excessivamente aos dados de treinamento (BISHOP, 2006). O modelo se

torna muito complexo e específico para os dados de treinamento, perdendo a capacidade de generalização para novos dados. Modelos com *overfitting* são caracterizados por uma variância alta e um viés baixo (HASTIE et al., 2009).

O grande desafio é identificar um equilíbrio entre o viés e a variância, para que o modelo seja capaz de generalizar os dados novos, ou não vistos, de forma correta. Uma abordagem comum para mitigar o *overfitting* é a regularização, que é uma técnica de penalização do modelo (HASTIE et al., 2009). Contudo, se a técnica de regularização for utilizada de forma rigorosa e intensa, pode ocorrer um *underfitting* do modelo.

Segundo Bishop (2006), é recomendado o uso frequente de métodos de avaliação, tal como, a validação cruzada (*cross-validation*) para evitar estes problemas sobre os modelos. Uma desses métodos, o *K-Fold Cross-Validation*, é bem simples e amplamente utilizada para estimar o erro de predição (HASTIE et al., 2009). O funcionamento básico da técnica *K-Fold Cross-Validation* é dividir o problema em três partes: divisão dos dados, treinamento e teste e avaliação do desempenho.

A divisão dos dados ocorre no conjunto de dados, dividindo-o em K blocos (*folds*), todos de mesmo tamanho. Em seguida, por K vezes o modelo é treinado, em cada iteração um dos K blocos será utilizado como o conjunto de testes e os demais $K - 1$ blocos será utilizado como conjunto de treinamento. A partir da matriz de confusão de cada iteração é possível calcular as métricas de desempenho para avaliar a qualidade do modelo (HASTIE et al., 2009).

A matriz de confusão, é uma tabela que apresenta a contagem efetiva do modelo de classificação com as previsões corretas e incorretas realizadas pelo modelo em cada classe de destino. Os resultados são totalizados em duas dimensões: classes verdadeiras e classes preditas. A tabela é composta por quatro valores: verdadeiros positivos (TP), falsos positivos (FP), verdadeiros negativos (TN) e falsos negativos (FN) (MONARD; BARANAUSKAS, 2003).

A análise da matriz de confusão na validação cruzada fornece uma visão detalhada do desempenho do modelo. Para auxiliar na identificação de problemas, como desequilíbrio de classe, erros sistemáticos, confusão entre classes semelhantes, entre outros. De acordo com o trabalho de Karakaya,

Ulucan e Turkan (2020), as métricas de avaliação mais aplicadas em sistemas de nariz eletrônico são *accuracy*, *precision*, *recall*, *specificity* e *F1-score*, conforme a Tabela 3.

Tabela 3: Métricas comumente utilizadas para medir o desempenho de modelos.

Fonte: Adaptado de Karakaya, Ulucan e Turkan (2020) e Munekata et al. (2023).

Métrica	Descrição
Acurácia (Accuracy)	Corresponde a proporção de exemplos classificados corretamente em relação ao total de exemplos. $Acurácia = \frac{\text{Número de predições corretas}}{\text{Número total de predições}}$ Ou $Acurácia = \frac{(\text{Verdadeiros positivos} + \text{Verdadeiros negativos})}{\text{Número total de predições}}$
Precisão (Precision)	Corresponde a proporção de exemplos positivos corretamente classificados em relação ao total de exemplos classificados como positivos. $Precisão = \frac{\text{Verdadeiros positivos}}{(\text{Verdadeiros positivos} + \text{Falsos Positivos})}$
Sensibilidade (Recall ou Sensibility)	É a proporção de exemplos positivos corretamente classificados em relação ao total de exemplos verdadeiramente positivos. $Sensibilidade = \frac{\text{Verdadeiros positivos}}{(\text{Verdadeiros positivos} + \text{Falsos negativos})}$
Especificidade (Specificity)	Mede a capacidade do modelo em identificar corretamente os exemplos negativos em relação ao total de exemplos verdadeiramente negativos. $Especificidade = \frac{\text{Verdadeiros negativos}}{(\text{Falsos positivos} + \text{Verdadeiros negativos})}$
F1-score	É a média harmônica entre precisão e a sensibilidade. Ao combinar as duas métricas, obtém-se uma visão geral do desempenho do modelo. $FScore = \frac{2 \times (\text{Precisão} \times \text{Sensibilidade})}{(\text{Precisão} + \text{Sensibilidade})}$

As métricas de avaliação são também utilizadas para prevenir problemas situações de *underfitting* e *overfitting*. Um modelo com *underfitting* possui um desempenho baixo nas métricas de avaliação, como baixa precisão, recall ou acurácia. Com *overfitting* o modelo apresenta um desempenho alto nas métricas de avaliação com os dados de treinamento, mas um desempenho baixo

com os dados de teste (HASTIE et al., 2009).

1.5. Sobre Sistemas de *E-nose*

As limitações biológicas do nariz humano na identificação de diferentes odores, de novas fragrâncias e na detecção de gases tóxicos fez surgir as áreas de desenvolvimento de sistemas eletrônicos de detecção de sinais gasosos, ou os sistemas *E-nose* (TAN et al., 2022).

Nos últimos dez anos, ocorreu um maior número de projetos de desenvolvimento de aplicações baseadas em *E-nose* (WILSON, 2013), (JOHN et al., 2021), (JOÑCA et al., 2022). Algumas dessas aplicações trabalham no emprego de sistemas olfativos artificiais em seus processos para melhoria de eficiência de serviços e também para contribuições em sistemas sustentáveis (DUNG et al., 2018). Entre as diversas aplicações possíveis identificadas para sistemas *E-nose* tem-se:

- Agricultura (WILSON, 2013), (JIA et al., 2019), (SEESAARD et al., 2022).
- Autenticação biométrica (JHA, 2017), (YANG; LEE, 2018), (VESOVIĆ; ZLATANOVIĆ; TEODOROVIĆ, 2019), (KANAKAM; CHAKRAVARTHY, 2021), (JIRAYUPAT et al., 2022).
- Ciência forense (WILSON, 2014), (FERREIRO-GONZÁLEZ et al., 2016), (LEITE et al., 2021).
- Detecção de anomalias:
 - Adulteração (HONG; WANG, 2014), (HEIDARBEIGI et al., 2015), (XIA; CAI; SHAO, 2015), (ROY; YADAV, 2021), (ZAREZADEH et al., 2021).
 - Contaminação:
 - Patogênica (BONAH et al., 2020), (EZHILAN et al., 2020), (BONAH et al., 2021).
 - Fúngica (SANAEIFAR et al., 2017), (SHEN et al.,

- 2018), (LIU et al., 2018).
- Microbiana (SBERVEGLIERI et al., 2014).
 - Deterioração (ESTAKHROYEH; ESMAT; MAHDIYEH, 2018), (XING et al., 2018), (GAMBOA et al., 2019), (VAJDI et al., 2019), (ANDRE et al., 2022).
 - Gases perigosos⁷ (WILSON, 2012), (WONGCHOOSUK et al., 2014), (RUBIO et al., 2015), (JOÑCA et al., 2022), (TAN et al., 2022).
 - Distinção de material:
 - Compostos orgânicos voláteis (RUBIO et al., 2017).
 - Ervas (ESTAKHROYEH; ESMAT; MAHDIYEH, 2018).
 - Produtos derivados do petróleo (ALIAÑO-GONZÁLEZ et al., 2018), (ESTAKHROYEH; ESMAT; MAHDIYEH, 2018).
 - Indústria:
 - Aeroespacial (REIDT et al., 2017), (TAN et al., 2022).
 - Cervejeira (NIMSUK, 2019), (VIEJO; FUENTES, 2020).
 - Cosméticos (EAMSA-ARD et al., 2018).
 - Farmacêutica (WASILEWSKI et al., 2019).
 - Forças armadas (BRUDZEWSKI; OSOWSKI; PAWLOWSKI, 2012), (LÓPEZ et al., 2017), (NAGAPPAN; SUBRAMANIAM; WANG, 2017).
 - Medicina:
 - Anosmia / hiposmia⁸ (PINGER et al., 2021), (HANY et al., 2022).
 - Diagnóstico médico (BRUINS et al., 2013), (WILSON, 2015), (SAIDI et al., 2018), (FARRAIA et al., 2019), (WOJNOWSKI et al., 2019), (LIU et al., 2021), (KUCHMENKO et al., 2022).

⁷ São classificados como compostos orgânicos voláteis (do original em inglês *Volatile Organic Compound* – VOCs) (TAN et al., 2022).

⁸ Se referem, respectivamente, a perda completa ou parcial do olfato (PINGER et al., 2021).

- Monitoramento:
 - Ambiental (WILSON, 2012), (CAPELLI; SIRONI; ROSSO, 2014), (JOHN et al., 2021).
 - Industrial (DESHMUKH et al., 2015).
- Nível de frescor em produtos perecíveis:
 - Camarão (JIANG et al., 2016), (SRINIVASAN et al., 2020).
 - Carnes frescas (HUANG et al., 2014), (LI et al., 2014), (GÓRSKA-HORCZYCZAK et al., 2016), (WIJAYA et al., 2017), (LIU et al., 2022).
 - Frango (LU et al., 2017), (WOJNOWSKI et al., 2017), (EDITA et al., 2018).
 - Frutos do mar (GRASSI et al., 2022).
 - Peixes (HAN et al., 2014), (GÜNEY; ATASOY, 2015), (RADI et al., 2021).
- Qualidade:
 - Armazenamento / prazo de validade (XIONG et al., 2014), (XING et al., 2018), (COZZOLINO et al., 2021), (JOHN et al., 2021), (MODESTI et al., 2021).
 - Características organolépticas (RIZZOLO et al., 2013), (QUARTO et al., 2017), (HASAN; SARNO; SABILA, 2020), (FUJIOKA, 2021).
 - Comparação de produtos (GÓRSKA-HORCZYCZAK et al., 2017), (CAO; WU; WENG, 2020), (FUJIOKA, 2021).
 - Controle de qualidade (FALASCONI et al., 2012), (AL-DAYYENI et al., 2021).
 - Formulações alimentícias (TALAWAR et al., 2021), (LI et al., 2022).
 - Perfis sensoriais (SONG et al., 2014), (JO et al., 2016), (BASSEY et al., 2022).
 - Saturação (SIHOMBING; RITONGA, 2021).
 - Uniformidade do cultivo / lote (JIA et al., 2019), (ALI et

- al., 2020), (SHARMILAN et al., 2022).
- Vigilância alimentar (YANG et al., 2021).
- Silvicultura (WILSON, 2013).

Entre as soluções de problemas para esses sistemas, incluem-se os trabalhos de Romain e Nicolas (2010) e Zhang et al. (2013), nos quais são propostas pesquisas para reduzir o desgaste e envelhecimento natural dos sensores, que provocam desvios nas leituras ao longo do tempo, interferindo no percentual de precisão (JOHN et al., 2021).

Em relação a garantia de confiabilidade do sistema, os trabalhos de Zhang et al. (2017), Yi e Li (2019) propuseram métodos para reduzir a detecção incorreta ou a má-interpretação de algoritmos. Outros trabalhos, como os de Cao et al. (2021), Tian et al. (2021), Zhu et al. (2021), Guo et al. (2022) e Yan et al. (2022), também tem novos desenvolvimentos, tanto de hardware, quanto de software, sobre técnicas mais ágeis de compensação de desvios de medida que possam ocorrer.

1.6. Sobre problemas, soluções e iniciativas ligadas a sustentabilidade e controle de desperdício de alimentos

Considerando que o desperdício de alimentos é um problema que afeta aspectos econômicos, ambientais e sociais na sociedade e que se tornou uma preocupação global devido ao seu impacto negativo na capacidade de pessoas produzirem ou comprarem alimentos em quantidades suficientes para suas necessidades diárias (situação definida pela FAO com a sigla SAN) (FAO, 2012), esse aspecto da sustentabilidade é um dos nortes filosóficos deste trabalho.

Com o objetivo de abarcar melhor esse problema e propor soluções eficazes, a ONU (2023) através de uma série de metas, promoveu os objetivos de desenvolvimento sustentável (ODS) como parte da agenda 2030. Os ODS

compõem-se de 17 objetivos interconectados, que abrangem áreas ligadas ao desenvolvimento econômico, social e ambiental, sendo que cada objetivo é acompanhado por metas específicas a serem alcançadas.

Estima-se que um terço de toda produção de alimentos para consumo humano seja perdido ou desperdiçado (GUSTAVSSON et al., 2011). Um dos principais objetivos da ONU (2023) está relacionado a ODS nº 12, que informa: “assegurar padrões de produção e de consumo sustentáveis”.

A perda ou desperdício ocorrem em diferentes pontos da cadeia alimentar, desde a produção agrícola até o consumo final (HALL et al., 2009). O item 12.3 do ODS nº 12 apresenta como meta, *in verbis*:

“Reduzir pela metade o desperdício de alimentos per capita mundial, nos níveis de varejo e do consumidor, e reduzir as perdas de alimentos ao longo das cadeias de produção e abastecimento, incluindo as perdas pós-colheita”.

As perdas de alimentos são maiores em países com menor índice de desenvolvimento, pois esses possuem infraestrutura de armazenamento, transporte e processamento de alimentos menos desenvolvidos (GUSTAVSSON et al., 2011). Isso causa graves impactos sociais nestes países, o que aponta para os objetivos da ODS nº 1 (“erradicação da pobreza”) e da ODS nº 8 “trabalho decente e crescimento econômico”, ambas associadas à ODS nº 12.

O trabalho de Parfitt, Barthel e Macnaughton (2010) relata que o comportamento dos consumidores é a principal causa do desperdício de alimentos. Os consumidores que possuem hábito de comprar em excesso, não planejam as refeições deixando os alimentos estragarem e os que preferem por consumir apenas produtos visualmente perfeitos contribuem para o desperdício de alimentos (QUESTED et al., 2013).

O desperdício de alimentos também contribui para as emissões de gases de efeito estufa e o uso inadequado dos recursos naturais. Devido a esse volume de desperdício, visando também atender à crescente demanda por alimentos, a “solução” do problema passa pelo aumento das áreas de plantio, implicando em destruição de ecossistemas naturais e conseqüente aumento de CO₂ e outros gases prejudiciais a atmosfera. (QUESTED et al., 2013)

A produção de alimentos requer utilização de energia, água e terras agrícolas, e quando esses alimentos são desperdiçados, esses recursos são perdidos (GUSTAVSSON et al., 2011), (FAO, 2013), (MASSON-DELMOTTE et al., 2021). A pesquisa de Hall et al. (2009), relata que, por ano, um quarto do uso total de água doce é destinada a produção dos alimentos desperdiçados.

Os alimentos descartados que se putrefazem nos aterros são responsáveis por uma elevada produção de metano (SILVA; CHILANTI; THEODORO, 2018). Dos gases relacionados com o efeito estufa, o metano (CH_4) é o mais prejudicial ao meio ambiente, por ser 25 vezes mais agressivo que o CO_2 (HALL et al., 2009), (FAO, 2013). Além de produzir gases nocivos, os alimentos descartados em aterros sanitários, também provocam a contaminação dos lençóis freático e do solo.

A contribuição do desperdício de alimentos para a mudança climática é tão significativa quanto ao consumo de combustível fóssil e seu impacto nas mudanças climáticas (HALL et al., 2009). O ODS nº 13 reconhece a necessidade urgente de reduzir as emissões de gases de efeito estufa, aumentar a resiliência e capacidade de adaptação aos efeitos do clima (MASSON-DELMOTTE et al., 2021).

O combate ao desperdício de alimentos exige uma abordagem que envolva todos os setores da sociedade, seja por indivíduos que se despertem as necessidades de se evitar essas situações, ou das nações se conscientizarem para tratar deste problema. Em três trabalhos, foram apontadas diferentes propostas de soluções para a mitigação do problema:

- **Melhoria da eficiência na produção agrícola:** Promover a utilização de técnicas agrícolas sustentáveis, como práticas de irrigação eficientes, a utilização de fertilizantes e pesticidas ecológicos. (GUSTAVSSON, 2011)
- **Inovar na colheita e armazenamento:** Embarcar modernas tecnologias para a redução de danos físicos aos alimentos na colheita. Investir em modernas tecnologias de embalagem e processamento para garantir o adequado prolongamento da vida útil dos alimentos atenuando as perdas por deterioração.

(GUSTVASSON, 2011)

- **Melhoria na logística e distribuição:** Evolução dos sistemas de transporte e distribuição para redução do tempo evitando as perdas de alimentos. (GUSTVASSON, 2011)
- **Investimentos em infraestrutura e tecnologia:** Inserir o uso de sistemas para rastreamento e monitoramento ao longo da cadeia de suprimentos (GUSTVASSON, 2011)
- **Sensibilização e educação do consumidor:** Estabelecer campanhas de conscientização sobre os diversos impactos do desperdício alimentar. Promover a utilização de técnicas de armazenamento adequado e o aproveitamento integral dos alimentos. Encorajar práticas de planejamento de refeições e aproveitamento de sobras (BUZBY, FARAH-WELLS, HYMAN, 2014).
- **Padronização de embalagens e porções:** Estabelecer padrões de embalagem para atender as necessidades de consumo. Evitando com isso o desperdício de alimentos no preparo de porções superdimensionadas em razão do uso de embalagens excessivamente grandes (BUZBY, FARAH-WELLS, HYMAN, 2014).
- **Tecnologias de processamento e conservação:** Incentivar o uso de tecnologias avançadas para o processamento de alimentos, como a desidratação, congelamento e conservação por alta pressão, para prolongar a vida útil dos alimentos e reduzir perdas por deterioração (BUZBY, FARAH-WELLS, HYMAN, 2014).
- **Políticas e regulamentações:** Implementação de políticas governamentais e regulamentações que incentivem a redução do desperdício de alimentos, como a padronização de práticas de rotulagem, estabelecimento de metas de redução de desperdício e incentivos fiscais para empresas que adotam práticas sustentáveis (BUZBY, FARAH-WELLS, HYMAN,

2014).

- **Monitoramento e análise de dados:** Desenvolver sistemas de monitoramento e coleta de dados para acompanhar e avaliar o desperdício de alimentos em toda a cadeia alimentar. Para identificar problemas e implementar medidas corretivas eficazes (STENMARCK, 2016).
- **Doações e redistribuição de alimentos:** Organizar parcerias entre produtores, varejistas e organizações sociais para captar doações de alimentos excedentes ou próximos do prazo de validade para organizações de combate à fome, instituições de caridade e bancos de alimentos. Viabilizar incentivos fiscais para encorajar as empresas a doarem alimentos não vendidos em vez de descartá-los. Propor políticas e regulamentações que facilitem a doação de alimentos excedentes. (STENMARCK, 2016)
- **Aproveitamento integral dos alimentos:** Promover ações para o engajamento do consumo de partes não convencionais: casca, folhas, talos, sementes e flores dos alimentos por meio de receitas e técnicas culinárias adequadas. (STENMARCK, 2016)
- **Utilização de alimentos imperfeitos:** Desenvolver produtos e mercados para alimentos "fora dos padrões" estéticos (STENMARCK, 2016)

Diferentes movimentos e iniciativas sociais surgiram para combater o desperdício de alimentos, um destes movimentos, *Dumpster Diving*, se refere à prática de obter itens jogados fora, neste caso alimentos para consumo jogado em lixeiras (EIKENBERRY; SMITH, 2005). Neste movimento, visa-se uma forma de aproveitar os alimentos que seriam descartados, reduzindo assim o desperdício.

Um outro movimento, *Freeganism*, possui como ideal, procurar por alimentos e outros produtos ainda utilizáveis em lixeiras. Segundo Moré (2011),

o foco nesta filosofia de vida se concentra no resgate de itens como frutas, legumes e outros recursos descartados, evitando consumir novos produtos. Os *freegans* são motivados por preocupações ambientais, éticas e econômicas.

O *Ugly food* é outro movimento contra o desperdício alimentar e à conscientização sobre a SAN (CALVO-PORRAL; MEDÍN; LOSADA-LÓPEZ, 2017). O termo *Ugly food* é usado para descrever alimentos que não atendem aos padrões de beleza ou aparência dos consumidores. Fazendo com que muitos desses alimentos sejam descartados pelos produtores, varejistas e mercados antes mesmo de chegar às prateleiras.

De acordo com os autores Calvo-Porral, Medín e Losada-López (2017), diversos varejistas vêm comercializando os produtos “feios” não utilizando a referência *Ugly* para descrevê-los.

Existem outros movimento e grupos associados a solução de problemas contra o desperdício de alimentos, tais como, o *Foodsharing* (SCHANES; STAGL, 2019); o *Food Not Bombs* (VO-THANH et al., 2021); o *Too Good To Go* (CARMEN et al., 2022) entre outros. Esta gama de movimentos sociais indica a importância de desenvolvimento de ferramentas, acessíveis às pessoas comuns, que possam ajudar no problema de desperdício de alimentos.

1.7. Sobre o uso de sistemas *E-nose* contra o desperdício de alimentos

Um recurso útil para tratar de problema de desperdício de alimentos é poder identificar se um alimento ainda está apto ou não para o consumo, evitando seu descarte antecipado. Entre os recursos disponibilizados estão os dos dispositivos com sistemas *E-nose* ou de nariz eletrônicos, que, por captação de “cheiro” ou dos gases emitidos, podem ser treinados para verificação da utilidade de um alimento. (GUO et al., 2020).

No trabalho de GUO et al (2020), é apresentado um modelo de nariz eletrônico composto por um código de barras colorimétrico para avaliar o frescor da proteína animal de um alimento. Os códigos de barras compreendem de 20

tipos diferentes de nanocompósitos⁹ que reagem com os gases produzidos ao longo do processo de decomposição. A marca combinatória do código de barras é avaliada por redes neurais convolucionais profundas que preveem o frescor ou não da carne. (GUO et al., 2020).

De acordo com o trabalho de Malochleb (2021), a capacidade de utilização do nariz artificial no trabalho de Guo et al (2020), pode ser aplicada também aos materiais de embalagem do alimento. Quando testado em amostras de frango, peixe e carne bovina embaladas comercialmente, a rede neural previu o quanto as embalagens poderiam influenciar no frescor das carnes, usando o mecanismo de barras colorimétricas.

No trabalho de Nair et al. (2021) é apresentado um outro desenvolvimento de um sistema *E-nose* para tratar da revisão do prazo de validade de frutas embaladas. Ele consiste na análise dos valores oriundos dos sinais do sensor de gás para frutas, que são submetidos ao exame na fase de maturação. Sobre esses dados obtidos são aplicados diversos algoritmos de AM que indicam a previsão da fruta estar ou não dentro da data de validade da embalagem.

No trabalho de Bajwa et al. (2021), foi construído um sistema *E-nose* para detectar emissões de metano, gás carbônico e amônia de diferentes itens alimentares, auxiliada por um mecanismo de balança para garantir a precisão e eficiência do sistema. Os dados são analisados pelo algoritmo de árvore de decisão apresentando como resultado uma previsão do descarte do item.

1.8. Sobre as fases de existência e consumo de frutas, legumes e hortaliças

O exame da disponibilidade alimentícia de frutas, legumes e hortaliças depende do seu comportamento em suas fases de existência na cadeia alimentar, que vão desde a colheita até o descarte irreversível, passando pela fase de crescimento, maturação, amadurecimento e senescência (conforme

⁹ São materiais em que pelo menos um de seus componentes apresentam dimensões nanométricas.

ilustrado na Figura 14) (BAUER; WALLY; PETER, 2014).

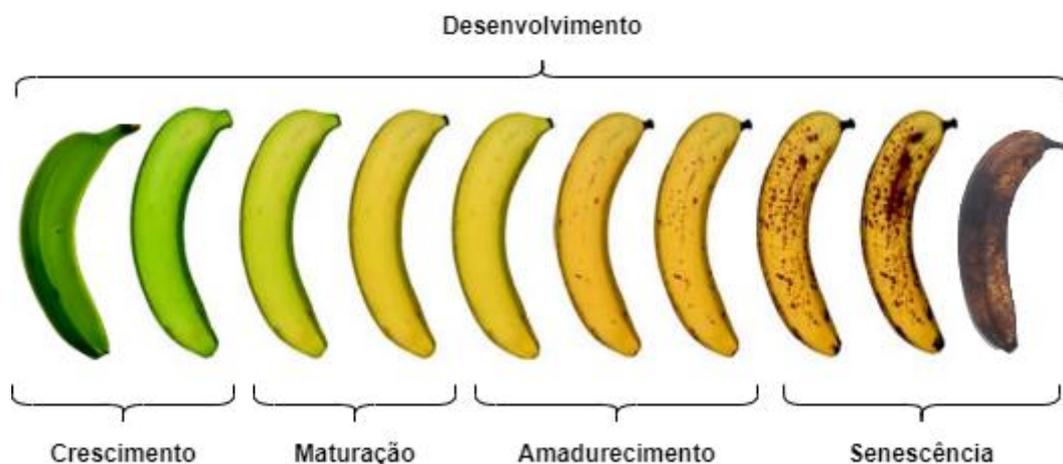


Figura 14: Fases de desenvolvimento do fruto.

Fonte: Adaptado de (ESCALANTE-MINAKATA *et al.*, 2013).

Observa-se que, após a colheita, frutas, legumes e hortaliças continuam a respirar e a transpirar (BAUER; WALLY; PETER, 2014). Na respiração aeróbia ocorre a liberação da energia presente na matéria orgânica combinada com o oxigênio (O_2) livre, resultando na formação de gás carbônico e água (LUENGO *et al.*, 2007). A respiração ocorre por meio de pequenas aberturas chamadas estômatos, presentes em suas superfícies, como cascas e folhas (TAIZ *et al.*, 2017).

As frutas nesse processo são classificadas como climatéricas ou não climatéricas, também de acordo com suas características respiratórias (BAUER; WALLY; PETER, 2014). Frutos climatéricos são colhidos verdes, para ampliar o tempo de conservação, uma vez que continuam em processo de amadurecimento apresentam taxas respiratórias mais elevadas.

Os frutos não climatéricos não apresentam aumentos na taxa respiratória e na produção de etileno (C_2H_4) e só podem ser colhidos quando reúnem características adequadas ao consumo (LUENGO *et al.*, 2007), (BRON; JACOMINO, 2007), (TAIZ *et al.*, 2017).

Durante a etapa de maturação ocorre o desenvolvimento do fruto e das hortaliças, marcada por intensas alterações estruturais, fisiológicas e

bioquímicas. Entre a maturação e a senescência das frutas climatéricas, na subfase de amadurecimento, ocorre grande liberação do etileno que age como hormônio catalizador. Na fase de senescência, é iniciado o processo de degradação dos frutos, legumes e hortaliças (BAUER; WALLY; PETER, 2014).

Na fase de degradação, ocorre o surgimento de pigmentos marrons, invasão de microrganismos, desidratação e enfraquecimento do invólucro natural. Assim, o fruto perde as características sensoriais do odor, coloração e doçura, o que faz com que se inicie o exame sobre seu descarte.

Ainda nas situações iniciais da fase de degradação, o valor nutricional desses tipos de alimento pode estar conservado, mas como sua aparência não produz agrado ao consumidor, as pessoas tendem a descartar um alimento que ainda poderia ser aproveitado (BARROZO et al., 2019).

O processo de decomposição final da matéria orgânica acontece pela ação de organismos heterótrofos, como bactérias e fungos. Como a matéria orgânica é constituída principalmente de carbono, hidrogênio, oxigênio e nitrogênio, os organismos decompositores liberam minerais e outras substâncias inorgânicas. Assim, como resultado do processo ocorre a liberação de água, amônia (NH_3), gás carbônico e metano (CH_4) para o meio ambiente e o alimento fica, então, imprestável para consumo (TAIZ et al., 2017).

2 CONT3NT3

Neste capítulo será possível acompanhar as fases de concepção do sistema e as motivações a ele associado. Tendo em vista a importância de desenvolvimento de sistemas do tipo *E-nose* acessíveis as pessoas comuns, cujo custo, tanto de produção do sistema, quanto uma provável comercialização, não inviabilize adquirir uma unidade, faz-se importante a proposta deste sistema *E-nose* (CONT3NT3) apresentado nesse trabalho.

Esse sistema visa preencher lacunas, trabalhando no envolvimento de pessoas comuns (os usuários do sistema) no campo da sustentabilidade. Eles estariam adquirindo um sistema complexo, mas com fácil manipulação, servindo aos propósitos e objetivos (as ODS), tanto da ONU, quanto dos diversos dos movimentos sociais que trabalham nesse campo.

2.1. Objetivo

A contínua onda de evolução tecnológica favorece com que as novas tecnologias sejam constantemente disponibilizadas ao público em geral, permitindo o rápido barateamento das tecnologias que deixam de ser de ponta. Com o uso de tecnologias de mais baixo custo e que consumem menos energia, é plausível a construção de uma ferramenta precisa que contribua na luta contra o desperdício de alimentos.

No *backstage* do projeto CONT3NT3, a crença é que a menor das ações pode fazer a diferença. Embora o problema do desperdício de alimentos seja complexo, cada indivíduo pode contribuir para a redução através de suas escolhas e comportamentos. Além disso, cada ação positiva para a redução é capaz de inspirar outras pessoas ao seu redor.

Por isso, o sistema CONT3NT3 visa ser uma ferramenta acessível, de fácil manipulação, de baixo custo de fabricação, com baixo consumo de energia e capaz de trabalhar na identificação de situações de consumo de alimentos,

podendo indicar se os mesmos estão ainda em condições de consumo ou não. Isso tudo aliado ao desenvolvimento de um software, utilizando algoritmos de AM, capaz de indicar e prever a capacidade de consumo dos mesmos, através de uma base de conhecimento configurável e que possa elevar a precisão das suas indicações

A filosofia associada a motivação e objetivo da CONT3NT3 se baseia na “Teoria da Autodeterminação” de Edward Deci e Richard Ryan (2013), na qual se parte do pressuposto que todos os indivíduos têm uma tendência para o crescimento, o desenvolvimento e a autorrealização,

Ela destaca também a importância das ações individuais positivas em um contexto social mais amplo, dando suporte a autonomia e às necessidades psicológicas de cada um desses indivíduos envolvidos, através de compartilhamento de ideias e ações (DECI; RYAN, 2013).

2.2. Concepção da Plataforma

Conforme apresentado na Figura 15, a plataforma CONT3NT3 consiste em dois artefatos interligados, o container, com os componentes eletrônicos, e o aplicativo para dispositivos móveis. O circuito com os componentes eletrônicos forma um dispositivo robótico, no modelo IoT, que é responsável pelas medições dos gases emitidos pelos alimentos que são colocados no interior do container.

O conjunto de microcontroladores e detectores de gases constituem-se no sistema *E-nose* construído para a CONT3NT3. Acoplado a esse sistema há um transmissor para que os dados possam ser enviados a um dispositivo móvel, que possua o aplicativo para a CONT3NT3, para isso se utiliza da comunicação via protocolo *Bluetooth*.

A utilização de microsserviços está pautado na premissa de que o aplicativo deve ser utilizado por qualquer indivíduo. As operações que exigem maior processamento e recursos do *smartphone* são microsserviços na nuvem.

Desta forma, indivíduos que possuam *smartphone* mais fraco poderão utilizar sem maiores problemas.

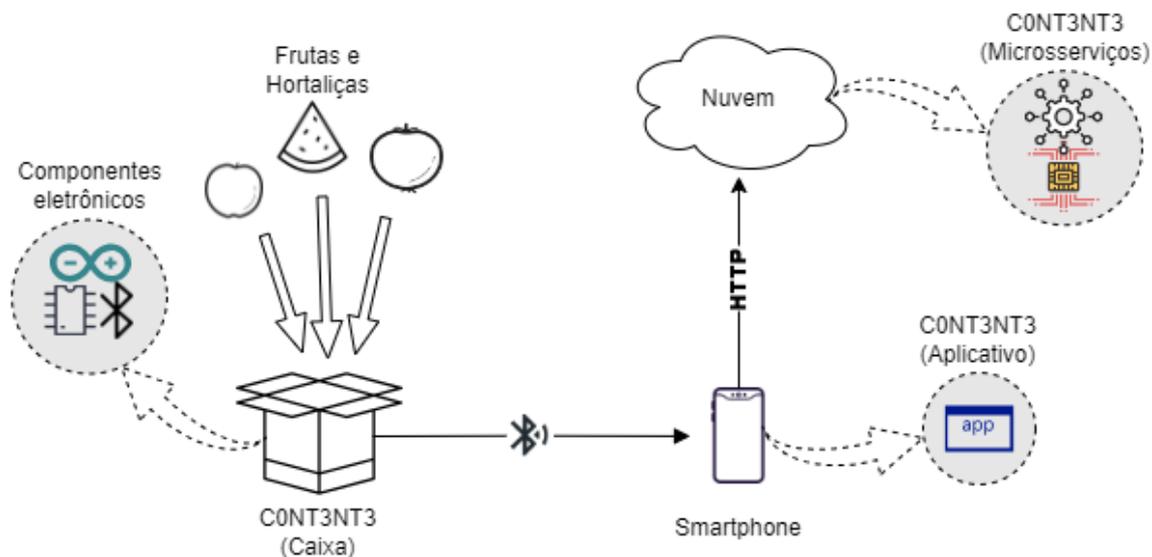


Figura 15: Concepção do projeto C0NT3NT3.

Fonte: Própria autoria.

O aplicativo para dispositivo móvel utilizará os dados para realizar os processamentos e apresentará os resultados em tela. Esse aplicativo poderá ser baixado de uma loja de aplicativos, ou via acesso a um link de instalação (através de acesso via QR CODE, por exemplo). A seguir serão apresentadas cada fase do projeto, desde a análise de requisitos, até a implementação física do mesmo.

2.2.1. Análise dos requisitos

Nesta fase visa-se levantar as necessidades do sistema, descrevendo suas funcionalidades e restrições. A definição dessas características, dependências e comportamentos previstos ao sistema procuraram mapear as tarefas e descobrir suas operacionalidades, bem como, minimizar erros de desenvolvimento em si.

Os requisitos garantem que os objetivos e regras de negócio sejam

aplicadas na ferramenta desde a sua concepção. Para os desenvolvimentos do hardware e software desta plataforma, os requisitos funcionais estão listados na Tabela 4.

Tabela 4: Requisitos funcionais.

Referência	Requisito funcional	Descrição
RF01	Realizar conexão.	O sistema deve permitir que o usuário através do aplicativo, instalado no dispositivo móvel, realize conexão através de <i>bluetooth</i> com o dispositivo eletrônico.
RF02	Informar status de conexão.	O sistema deve informar o status de conexão do dispositivo móvel com o dispositivo eletrônico.
RF03	Verificar <i>burn-in time</i> .	O dispositivo eletrônico deve somente iniciar a captura de dados quando estiver ligado por no mínimo 3 minutos.
RF04	Medir amostra	Uma vez a amostra colocada no container, o sistema vai verificar as medidas obtidas pelos sensores, comparar com a base de conhecimento que foi previamente configurada e emitir um resultado
RF05	Obter dados.	O sistema deve somente permitir acesso aos dados medidos pelo sistema <i>E-nose</i> quando houver disponibilidade sistêmica.
RF06	Apresentar Resultados	O sistema vai mostrar na tela do dispositivo móvel o resultado de análise sobre o alimento ali depositados

Os requisitos não funcionais descrevem as funcionalidades que não estão diretamente relacionadas com o desenvolvimento do projeto de software ou do dispositivo eletrônico. Não é um tipo de requisito vinculado à uma regra de negócio, mas que indica como o sistema se comportará diante de uma situação específica (BEZERRA, 2015). Os requisitos não funcionais para este trabalho estão listados na Tabela 5.

Tabela 5: Requisitos não funcionais.

Código	Categoria	Descrição
RNF01	Disponibilidade	O dispositivo eletrônico deve estar disponível após ser iniciado.
RNF02	Eficiência	O aplicativo deve permitir conexões simultâneas.
RNF03	Eficiência	O aplicativo deve permitir exclusivamente que 1 (uma) única medição seja executada por vez.
RNF04	Eficiência	O aplicativo deve se desconectar automaticamente do dispositivo eletrônico após 5 (cinco) minutos de inatividade.
RNF05	Eficiência	O aplicativo deve se desconectar automaticamente do dispositivo eletrônico após a execução de uma medição quando houver conexões simultâneas.
RNF06	Ético	O aplicativo não deve compartilhar quaisquer dados de cunho privativo.
RNF07	Ético	O aplicativo somente deve solicitar permissão para acesso e controle para uso do <i>bluetooth</i> no dispositivo móvel.
RNF08	Legais	O aplicativo não irá capturar, redirecionar ou expor quaisquer informações do dispositivo móvel conectado.
RNF09	Portabilidade	O aplicativo deve ser executado em qualquer plataforma.
RNF10	Produto	O dispositivo eletrônico deve estar com a tampa fechada para que seja realizada uma coleta mais eficiente sem interferência do meio externo.
RNF11	Produto	O aplicativo deve fornecer dicas para descarte de forma sustentável quando o resultado de uma medição indicar que o alimento está impróprio para o consumo humano.
RNF12	Usabilidade	O aplicativo deve permitir a seleção dos idiomas português e inglês.

2.2.2. Diagrama de Casos de Uso

A partir do exame dos requisitos, tornou-se possível traçar o Diagrama de Caso de Uso representativo da plataforma CONT3NT3. Esse tipo de diagrama apresenta a sequência de ações executadas entre o sistema e um ou mais agentes externos (BEZERRA, 2015). Os casos de uso do projeto CONT3NT3 são apresentados na Figura 16.

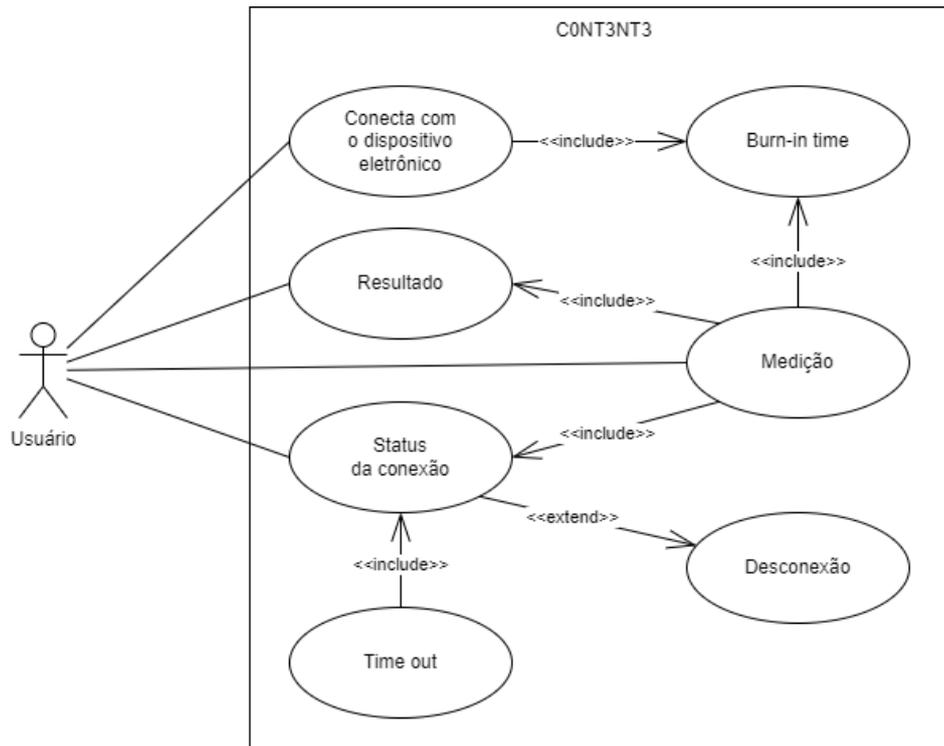


Figura 16: Diagrama de Casos de Uso da plataforma CONT3NT3.

Fonte: Própria autoria.

Para esse Diagrama de Casos de Uso, relaciona-se o requisito RF1 com o Caso de Uso “Conectar Ao Dispositivo Eletrônico”; o requisito RF2 com os Casos de Uso “Status da Conexão”, “TimeOut” e “Desconexão”; o requisito RF3 com o caso de Uso “Burn-InTime”; o requisito RF4 com o Caso de Uso “Medição” e os requisitos RF5 e o RF6 com o Caso de Uso “Resultado”.

2.3. Desenvolvimento do Software

2.3.1. Arquitetura

O projeto visa conectar um dispositivo eletrônico com uma aplicação específica, através de *bluetooth*, para que possa executado a análise da situação

(no caso, se um alimento está ou não apto ao consumo) no próprio dispositivo móvel do usuário.

Entretanto, a utilização de um estimador¹⁰ representando um modelo preditivo na aplicação mobile, retrata um desafio, devido ao grande volume de dados do conjunto de treinamento e validação. Com isso, para instalar a aplicação, previa-se muito um uso excessivo de recurso de armazenamento do dispositivo.

Sendo o CONT3NT3 um facilitador para vida de usuário comum, ao invés de uma ferramenta que cause problemas no dispositivo móvel do mesmo, principalmente em modelos mais antigos de *smartphones*; adotou-se como solução própria para o software da CONT3NT3, uma arquitetura baseada em microsserviços (MCs) (apresentada na Figura 17), que vai permitir disponibilizar serviços independentes e autônomos. Essa arquitetura permite uma instalação com baixa taxa de uso do espaço de armazenamento de um dispositivo móvel.

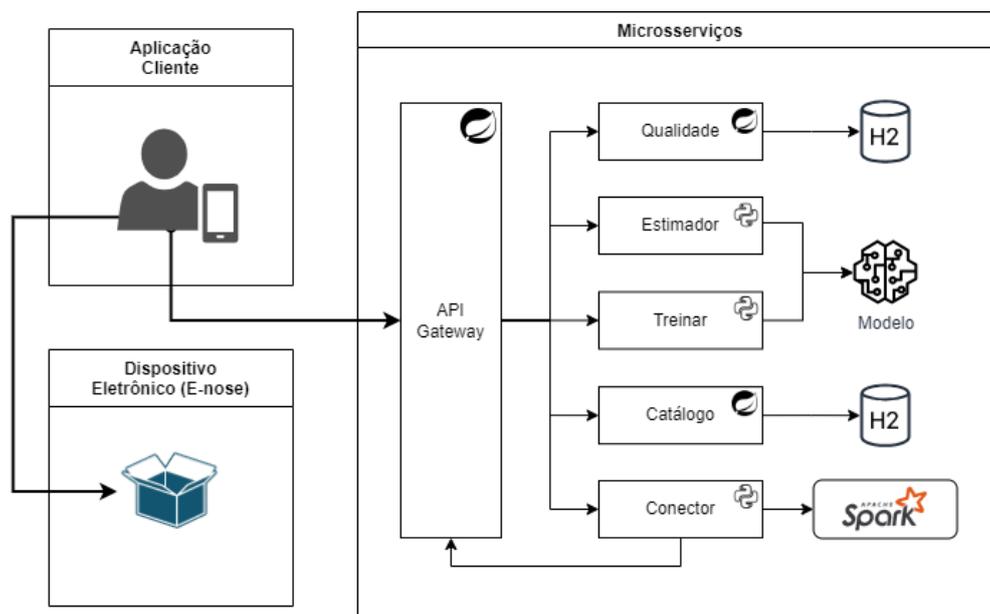


Figura 17: Arquitetura do projeto para uso do aplicativo.

Fonte: Própria autoria.

¹⁰ Um estimador é uma ferramenta estatística que ajuda a estimar ou prever valores desconhecidos com base em informações já conhecidas. Em outras palavras, de acordo com Guimarães (2018), é qualquer estatística cujos valores são usados para estimar θ (ou uma função de θ).

Nesta arquitetura, cada MC disponível é responsável por uma funcionalidade da aplicação, de modo que geram funcionalidades executadas de forma independente das demais (VALENTE, 2020). Essa independência das funcionalidades permite manter e atualizar cada uma delas sem afetar o funcionamento de outras. Existem três outras vantagens, que são: a escalabilidade, o uso da tecnologia adequada e a resiliência (VALENTE, 2020).

A escalabilidade flexibiliza os MCs para que sejam escalonados de forma independente, permitindo disponibilizar recursos (como CPU e memória) para os MCs de maior criticidade. Esta característica também permite a escalabilidade horizontal, que consiste em disponibilizar instâncias da aplicação em diversas máquinas (VALENTE, 2020).

Em termos de tecnologia utilizada, cada MC pode ser implementado utilizando uma tecnologia mais apropriada para a sua tarefa, de modo que se pode utilizar a linguagem de programação, o framework ou o banco de dados mais adequado.

Isso permite um paralelismo no desenvolvimento, no qual equipes separadas de forma autônoma possam trabalhar em diferentes partes do aplicativo, de forma independente em termos de qual tecnologia utilizada. Isso facilita o desenvolvimento ágil, acelera o processo de desenvolvimento e permite a entrega de novos recursos mais rapidamente.

Já em relação a resiliência, ela está associada com tolerância a falhas. Como os MCs são independentes, um erro em um MC não compromete o funcionamento de toda a aplicação. Na arquitetura monolítica quaisquer falhas são plenas, fazendo com que todas as funcionalidades sejam impactadas (VALENTE, 2020).

A comunicação com os MCs ocorre por meio de Interfaces de Programação de Aplicativos (APIs). As APIs são um conjunto de regras que exercem um papel essencial nas interconexões sistêmicas de forma eficiente e consistente, fazendo com que uma aplicação possa utilizar recursos de outra aplicação, interagir com serviços, controlar hardware entre outras tarefas (VALENTE, 2020).

Um tipo de API para a aplicações de classificação são as APIs

Gateway, que servem para simplificar a comunicação da aplicação principal com os MCs distribuídos, evitando o envio de solicitações para cada serviço individualmente, de modo que a aplicação principal se comunique apenas com o *gateway*. Além dessa facilidade, uma *API Gateway* fornece uma camada extra de segurança no gerenciamento de autenticações e tokens de acesso, protegendo os serviços subjacentes de ataques diretos.

Neste projeto, a *API Gateway* foi construída com o uso do *Java Spring Boot* com *Maven*. O *Java Spring Boot* é uma extensão do *Spring Framework*, sendo um *framework* específico para a criação de aplicações Java baseadas em MC. O *Maven* é uma ferramenta usada para gerenciar a construção e as dependências em projetos Java, para simplificar todo o processo de implementação e documentação de artefatos.

As rotas do *gateway* foram construídas com *Spring Cloud Gateway*, um projeto dentro do ecossistema *Spring Cloud*. Na Figura 18, é apresentado um trecho de código Java deste projeto, que é a implementação das rotas do *gateway*. Com esse *gateway*, há apenas um único canal de acesso.

```
@Bean
RouteLocator customRouteLocator(RouteLocatorBuilder builder) {
    return builder.routes()
        .route("catalogo", r -> r
            .path("/catalogo")
            .uri(servers[0] + ":8081/"))
        .route("conector", r -> r
            .path("/conector")
            .uri(servers[1] + ":8082/"))
        .route("estimador", r -> r
            .path("/estimador")
            .uri(servers[2] + ":8083/"))
        .route("qualidade", r -> r
            .path("/qualidade")
            .uri(servers[3] + ":8084/"))
        .route("treinar", r -> r
            .path("/treinar")
            .uri(servers[4] + ":8085/"))
        .build();
}
```

Figura 18: Trecho de código apresentando a configuração das rotas no *API Gateway*.

Fonte: Própria autoria.

Os MCs Catálogo usam a porta 8081 e os MCs Qualidade a porta. 8084. Ambos foram implementados em Java com auxílio do *Spring Framework*. Por outro lado, os MCs Conector, que usam a porta 8082, o Estimador, configurado para a porta: 8083 e Treinamento, que faz uso da porta 8085, foram desenvolvidos em Python com apoio do *microframework* Flask, dentro da filosofia que os MCs podem ser programados com tecnologias diferentes.

O MC Catálogo possui a responsabilidade de gerenciar as sugestões ou dicas disponibilizadas no aplicativo mobile, que são aqueles que informa o que fazer com o alimento, caso seja descartado. O acesso ao CRUD¹¹ do Catálogo é possível através de APIs específicas, vistas na Figura 19-A.

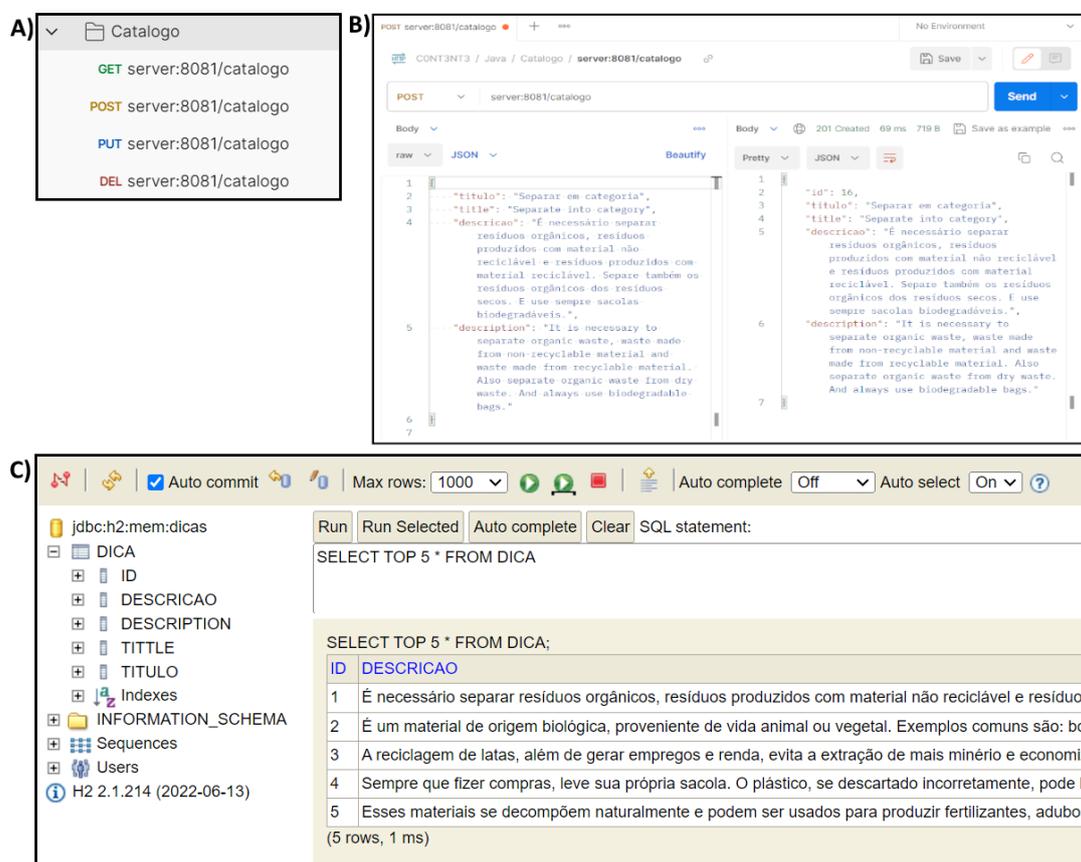


Figura 19: MC Catálogo. A) CRUD ; B) API POST; C) Banco H2 para suportar o CRUD.

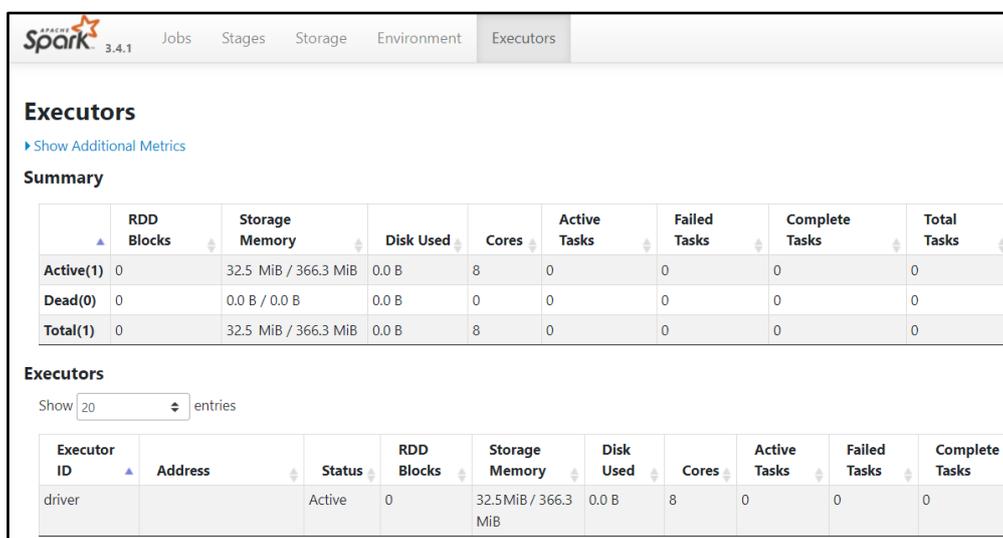
Fonte: Própria autoria.

¹¹ É o acrônimo de quatro operações básicas de um banco de dados: [C]: *create*, [R]: *read*, [U]: *update* e [D]: *delete*.

Nesta Figura, observa-se que a inclusão de novos registros deve ser utilizada a função indicada como POST, a implementação do POST é observada na Figura 19-B. A função indicada como GET vai servir para a leitura de registros, já as funções de PUT ou PATCH servem para acessar atualizações e a DEL para excluir registros no banco de dados de sugestões ou dica.

O banco de dados de dicas ou sugestões, nomeado na Figura 19-C como H2, vai ser preenchido de acordo com o tipo de alimentos ao qual a CONT3NT3 irá averiguar, que, no caso dos testes, foram certas frutas ou hortaliças.

O MC Conector é responsável por iniciar o processamento dos dados, através da interface Apache Spark, que é um framework usado em computação distribuída para grandes conjuntos de dados (conforme visto na Figura 20). Essa ferramenta fornece recursos para o processamento distribuído através de diversos executores, com armazenamento gerenciado pelo Apache HBase (um BD NoSQL distribuído).



The screenshot shows the Apache Spark web interface with the 'Executors' tab selected. It includes a navigation bar with 'Jobs', 'Stages', 'Storage', 'Environment', and 'Executors'. Below the navigation bar, there is a 'Summary' section with a table showing overall metrics for Active, Dead, and Total executors. Below that, there is a section for individual executors, showing a table with columns for Executor ID, Address, Status, RDD Blocks, Storage Memory, Disk Used, Cores, Active Tasks, Failed Tasks, and Complete Tasks. The 'driver' executor is listed as 'Active' with 0 RDD Blocks, 32.5 MiB / 366.3 MiB Storage Memory, 0.0 B Disk Used, 8 Cores, 0 Active Tasks, 0 Failed Tasks, and 0 Complete Tasks.

	RDD Blocks	Storage Memory	Disk Used	Cores	Active Tasks	Failed Tasks	Complete Tasks	Total Tasks
Active(1)	0	32.5 MiB / 366.3 MiB	0.0 B	8	0	0	0	0
Dead(0)	0	0.0 B / 0.0 B	0.0 B	0	0	0	0	0
Total(1)	0	32.5 MiB / 366.3 MiB	0.0 B	8	0	0	0	0

Executor ID	Address	Status	RDD Blocks	Storage Memory	Disk Used	Cores	Active Tasks	Failed Tasks	Complete Tasks
driver		Active	0	32.5 MiB / 366.3 MiB	0.0 B	8	0	0	0

Figura 20: Interface web do Apache Spark.

Fonte: Própria autoria.

Após o MC Conector retornar com os dados processados, ele os vai enviar para o MC Treinamento, que é a responsável pelos modelos de treinamento e AM utilizado (vide Figura 21-A). O MC Conector pode trabalhar

com cerca de 10.000 tuplas aleatórias e distintas do BD Hbase, que vai conter os dados obtidos pelos sensores. O BD HBase tem capacidade de trabalhar com até de 1 milhão de registros dos sensores.

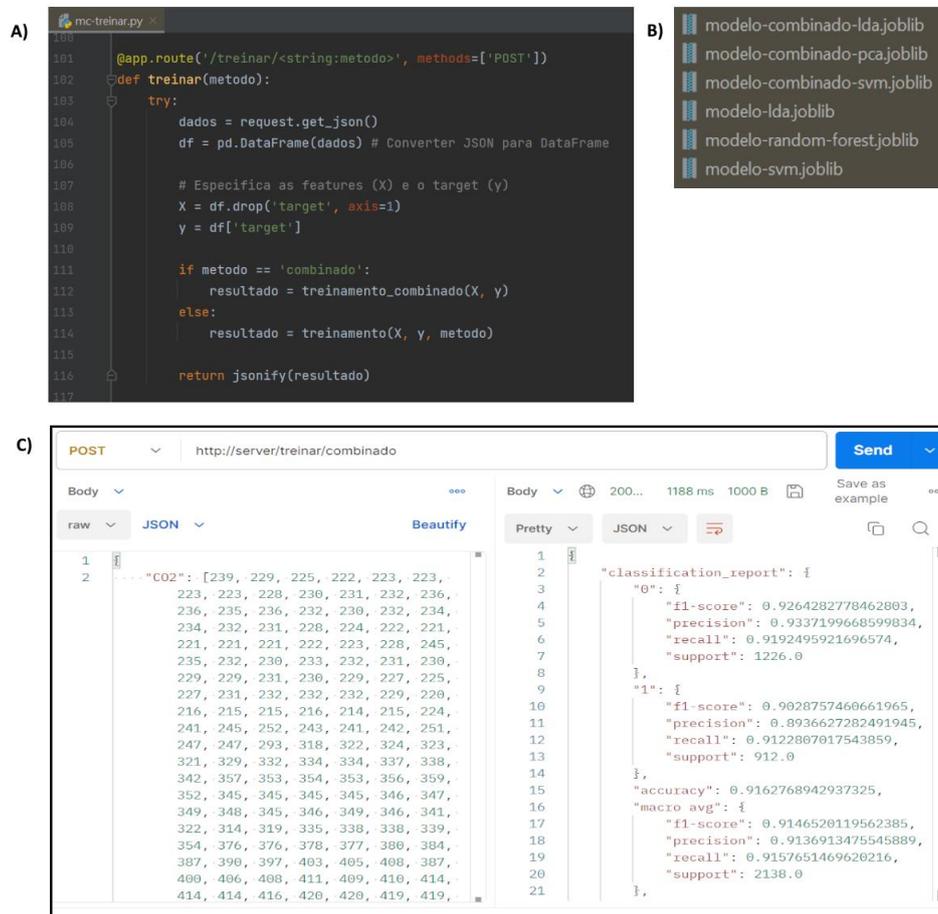


Figura 21: Microserviço treinar. A) Trecho de código do verbo POST em Python; B) Armazenamento dos modelos após treinados; C) Teste de treinamento através da API.

Fonte: Própria autoria.

O MC Treinamento é o serviço que retorna as métricas de avaliação e treinamento, com seus erros anotados (vide Figura 21-C). A estratégia implementada foi a de salvar cada modelo gerado após passar pelo Treinamento (conforme visto na Figura 21-B) para que o MC Estimador pudesse acessá-los de forma imediata. A execução do Treinamento, para geração dos modelos de treinamento, foi configurada com o parâmetro tempo otimizado, e, nos testes, levou cerca de um segundo para processar 10.000 registros no formato JSON

(conforme observado na Figura 21-C).

O MC estimador, assim como o MC catálogo, são os serviços mais utilizados pela aplicação mobile. A atribuição do MC estimador é a de receber os dados, aplicar sobre o modelo previamente salvo e retornar com a predição. O retorno deste serviço será “0” (Figura 22-A) para alimentos que podem ser consumidos, “1” para alimentos que devem ser consumidos imediatamente (Figura 22-C) e “2” (Figura 22-B) para alimentos que devem ser descartados.

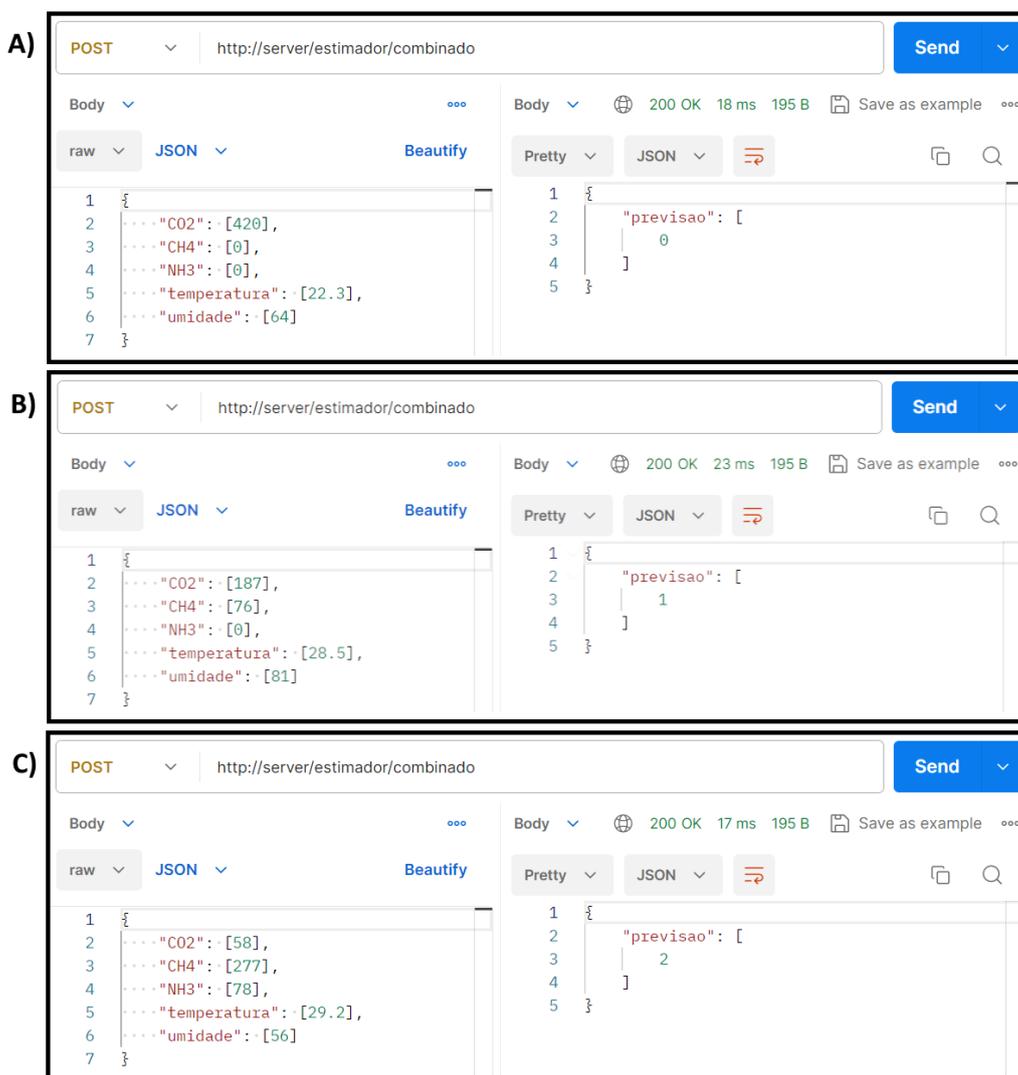


Figura 22: Microserviço estimador com retornos de informação: A) Alimento “consumível”; B) Alimento “não-consumível; C) Alimento ”Consumo imediato”

Fonte: Própria autoria.

O MC Qualidade realiza os tratamentos e validações nos dados obtidos, através da matriz de sensores, visando tratar de inconsistências e problemas com os mesmos. Uma parte da sua programação visa utilizar uma instância do banco H2 para tratar de persistência e configuração dos modelos de fragmentos (Vide Capítulo 3 para ver a solução proposta).

Todos os cinco MCs implementados são desacoplados, cada um executa uma função específica, interagindo entre si por meio de APIs. Durante os testes observou-se alta performance, devido a facilidade de isolar partes do sistema e dedicar mais recursos. Os MCs catálogo e estimador possuem processamento síncrono e dedicado, pois precisam ser concluídas de imediato.

2.3.2. Framework para o módulo de Aprendizado de Máquina

Analisar grandes volumes de dados e identificar padrões complexos é uma tarefa difícil para os seres humanos. É importante ressaltar que, para alcançar resultados relevantes e eficazes, é crucial possuir um entendimento profundo do domínio específico da aplicação. Sendo assim, o modelo de AM é um artefato de grande importância ao projeto.

A principal função do modelo de AM é aprender com os dados e usar o conhecimento adquirido para realizar previsões ou tomadas de decisões. Após análise de diversas técnicas, verificou-se que o modelo deveria possuir alta precisão, ótima generalização e eficiência computacional. Então, o modelo construído foi baseado na combinação das técnicas PCA (*Principal Component Analysis*), LDA (*Linear Discriminant Analysis*) e SVM (*Support Vector Machine*).

Com a técnica PCA é possível reduzir a dimensionalidade dos dados, preservando a maior parte da variabilidade. No LDA, maximizar a separação entre classes nos dados, obtendo desta forma a máxima distância entre as médias das classes e a mínima dispersão intraclasse. O SVM é um algoritmo de classificação para encontrar o hiperplano que melhor separa as classes, maximizando a margem entre elas.

O modelo combinado aplicado sobre os dados do projeto demonstrou alta performance no treinamento e teste. A Figura 23-A apresenta as métricas utilizadas para avaliação do desempenho do modelo, como acurácia, precisão, recall e F1-score e as métricas de erro, como MAE (*Mean Squared Error*), MSE (*Mean Absolute Error*) e R2. Estas métricas ajudam avaliar diferentes aspectos do desempenho do modelo.

A)

Mean Squared Error (MSE): 0.03648269410664172
 Mean Absolute Error (MAE): 0.03648269410664172
 R2 Score: 0.8498110074111032

Relatório de Classificação:

	precision	recall	f1-score	support
0	0.99	0.95	0.97	1249
1	0.93	0.99	0.96	889
accuracy			0.96	2138
macro avg	0.96	0.97	0.96	2138
weighted avg	0.97	0.96	0.96	2138

Matriz de Confusão:

```
[[1183  66]
 [  12 877]]
```

B)

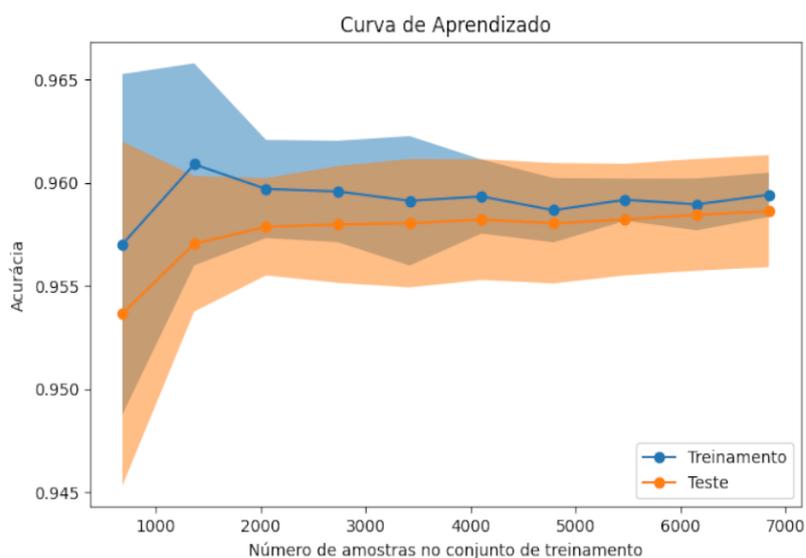


Figura 23: Avaliação do modelo combinado. A) Métricas; B) Curva de aprendizado.

Fonte: Própria autoria.

A curva de aprendizado é uma representação gráfica da evolução do desempenho de um modelo à medida que mais dados são acrescentados ao treinamento. A Figura 23-B ilustra que o modelo apresenta boa performance tanto para os dados de treinamento quanto de teste. Indicando inclusive que não será útil adquirir novos dados para treinar o modelo, pois a capacidade de generalização do modelo foi alcançada.

Devido ao elevado índice de acurácia nos conjuntos de treinamento e teste, indica que o modelo:

- Facilidade em identificar padrões nos dados de treinamento.
- Desempenho excelente ao generalizar para dados não vistos, representados pelo conjunto de teste. Indicando que não sofre de *overfitting*.
- Propensão para capturar as relações de maneira geral e as características importantes dos dados.

O acompanhamento da curva de aprendizado é uma prática comum durante o desenvolvimento do modelo de AM. Através desta análise é possível otimizar a escolha de hiperparâmetros, arquiteturas de modelo e quantidade de dados de treinamento. A análise realizada corrobora que o modelo combinado é apropriado para a tarefa em questão.

2.3.3. Construção da interface de usuário

O projeto da aplicação mobile utiliza a arquitetura de microsserviços. A aplicação mobile é responsável por ser a interface gráfica de interação com o usuário. As possíveis ações da aplicação são simples, permite ao usuário se conectar ou desconectar com o dispositivo eletrônico e a de realizar uma ou mais verificações dos alimentos quando conectado (Figura 24).

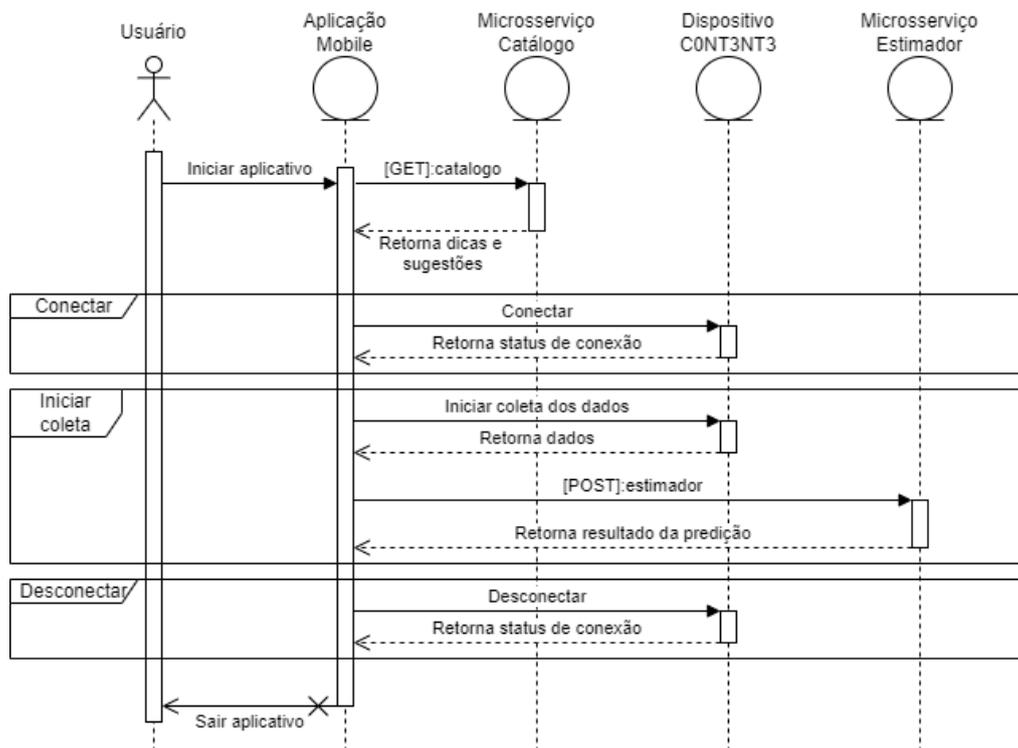


Figura 24: Diagrama de sequência das funcionalidades na aplicação mobile.

Fonte: Própria autoria.

A aplicação mobile foi construída em Java Spring Boot com Maven. Inicialmente, a aplicação foi desenvolvida para a plataforma Android utilizando a API Android Bluetooth. O escopo do projeto não contempla a plataforma iOS, pois o código será significativamente diferente e deverá ser construído apoiado na *framework* Core Bluetooth da Apple.

No contexto de *Bluetooth*, foi atribuído um UUID¹² ao componente do dispositivo eletrônico C0NT3NT3 para ser identificado facilmente. O UUID é útil para identificar exclusivamente informações em sistemas distribuídos. Assim, o UUID, representa o serviço de comunicação serial padrão para a comunicação Bluetooth serial (SPP - *Serial Port Profile*).

A aplicação foi desenvolvida para ser simples e intuitiva ao usuário. Os botões estão sincronizados, ao conectar com o dispositivo (Figura 25-B) o botão INICIAR (Figura 25-C) é habilitado. Ao iniciar, a aplicação realiza a coleta

¹² Acrônimo de *Universally Unique Identifier*. O UUID é um identificador único universalmente, que é uma sequência de 128 bits (16 bytes). Uma sequência de 32 caracteres alfanuméricos e 4 hifens.

de 10 conjuntos de dados e os envia para o serviço estimador ao longo deste processamento (Figura 25-D).

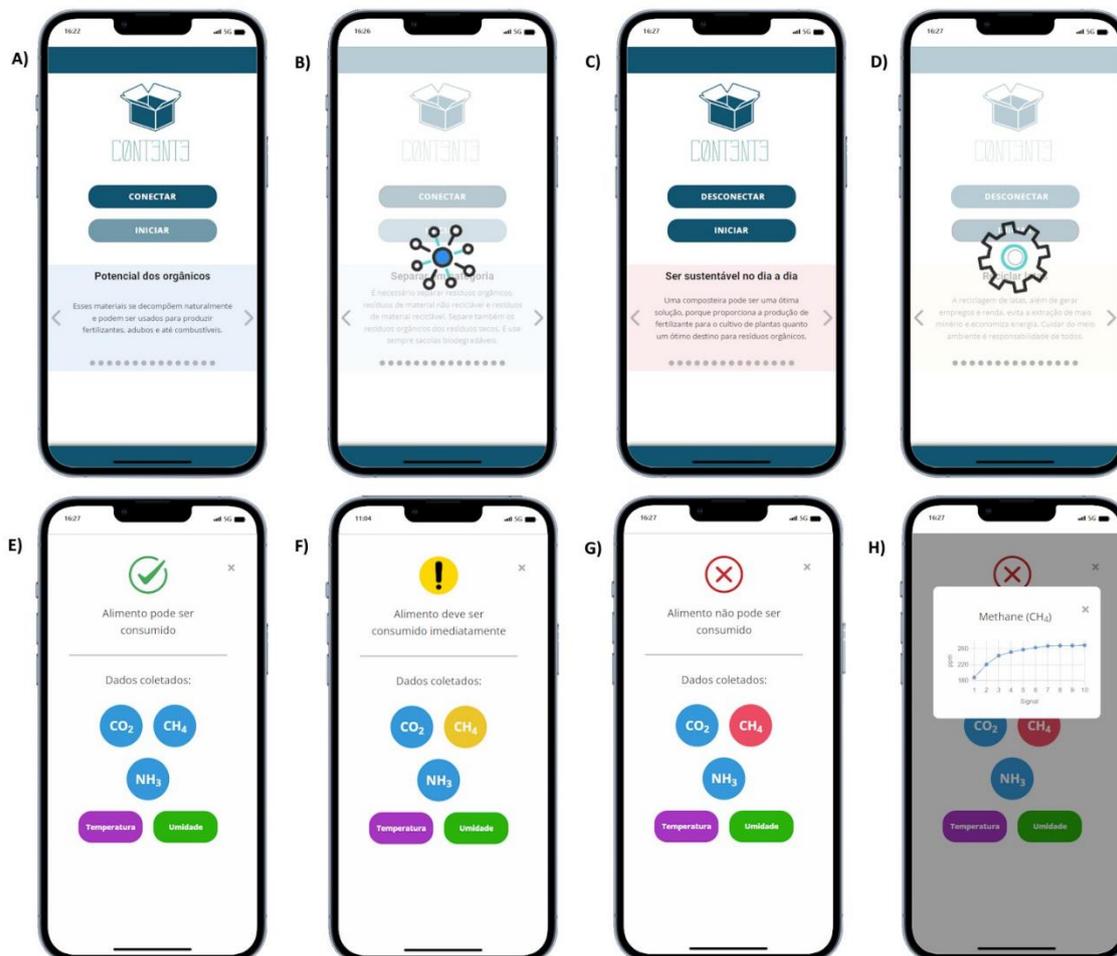


Figura 25: Telas da aplicação mobile. A) Não conectado; B) Conectando; C) Conectado; D) Início do processo de coleta; E) Indicação do consumo; F) Indicação de consumo imediato; G) Indicação para não consumir; H) Análise dos dados coletados.

Fonte: Própria autoria.

O resultado após a análise indica se o alimento pode ser consumido (Figura 25-E), consumido imediatamente (Figura 25-F) e se o alimento não deve ser consumido (Figura 25-G). Na tela de resultado é possível visualizar os dados capturados ao longo das 10 medições (Figura 25-H). E ao desconectar retorna ao estado inicial (Figura 25-A).

2.4. Desenvolvimento do Hardware

2.4.1. Projeto do Circuito eletrônico (Sistema *E-nose*)

Na Figura 26, o circuito eletrônico, com seus componentes, é apresentado, no qual, o sensor MQ135 é o que vai ser usado para identificar o dióxido de carbono, o MQ137 é o que vai identificar a amônia, o MQ4 vai identificar o metano, o DHT11 é para captar dados sobre temperatura e umidade e o HC06 é o dispositivo de comunicação Bluetooth utilizado, sendo que os resistores R1, R2, R3 e R4 variam entre 2K ohms e 10K ohms. O microcontrolador utilizado é um ATMEGA328P, que fisicamente no circuito foi implementado através da placa de interface Arduino R3.

Os sensores MQ utilizam como porta para conexão e envio dos dados captados, a porta que tratam sinais analógicos do microcontrolador, que é a porta C. Estes sensores também utilizam porta de interface geral, identificadas no ATMEGA38P como porta B.

O sensor de umidade também está conectado na porta B. O módulo HC06 precisa estar conectado nos pinos de recepção e transmissão do microcontrolador, que, no caso, são os pinos PD3 e PD2 (porta D). A fonte utilizada deve funcionar entre 5V e 5.5V no máximo.

O ATMEGA328P é um microcontrolador da família AVR, que possui uma arquitetura interna baseada no modelo Havard, na qual há uma memória Flash de 32KB, para conter os programas propriamente ditos; uma memória RAM (de cerca de 2KB), para conter as variáveis e os valores dos registradores principais, e uma memória EEPROM de 1KB, para conter as constantes que são carregadas no momento de ligar o dispositivo (BANZI; SHILOH, 2015).

O ATMEGA328P possui 23 pinos de entrada e saída, divididos em 4 portas (A, B, C e D), sendo que 6 destes pinos trabalham com entradas analógicas e os restantes com as entradas e saídas digitais. Dois destes pinos digitais são reservados para comunicação serial de qualquer espécie, mas também possui outros pinos que tratam de comunicação serial do tipo I2C e ISP (BANZI; SHILOH, 2015).

A escolha na utilização da placa de interface Arduino R3, que possui o microcontrolador ATMEGA328P, se deve ao fato dela ser uma plataforma de

prototipagem eletrônica de hardware livre, de baixo custo, de fácil e rápida implementação. Com ela é possível utilizar uma grande quantidade de sensores e componentes e também existe a possibilidade de utilizar Shields para expandir suas funcionalidades.

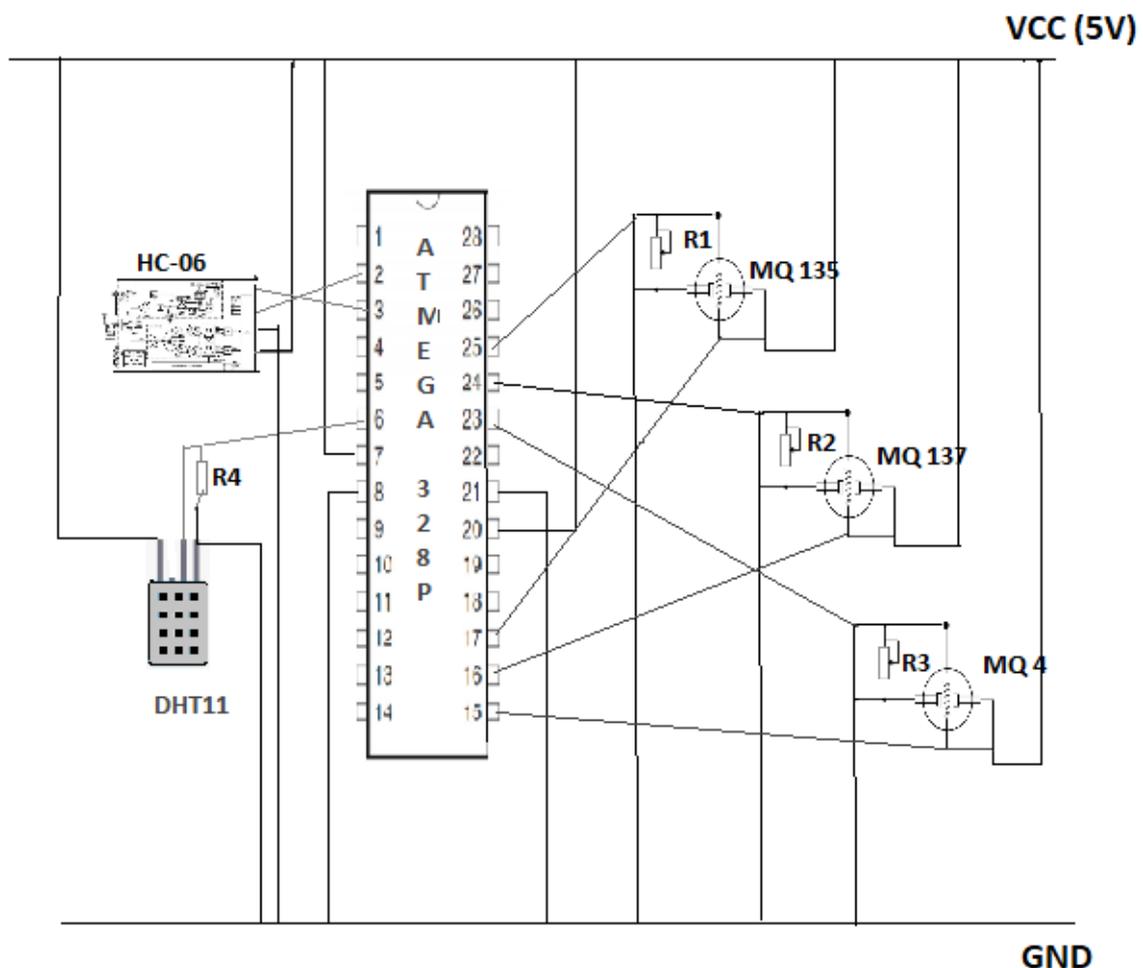


Figura 26: Desenho do circuito eletrônico representativo do hardware digital do sistema *E-nose* da CONT3NT3.

Fonte: Própria autoria.

Os sensores de gás são do tipo MOS e foram escolhidos devido ao fato de serem os mais utilizados em sistemas de narizes eletrônicos (TAN; XU, 2020), (JOHN et al., 2021), além de possuírem uma faixa de detecção entre 5-500 ppm, alta sensibilidade aos gases, baixo tempo de resposta, pequeno

tamanho, fácil implementação e serem de baixo custo (DEY, 2018), (KARAKAYA; ULUCAN; TURKAN, 2020), (LAUDON; LAUDON, 2011).

A detecção em cada um dos sensores da matriz está baseada nas mudanças de condutividade na presença do gás. Cada sensor seletivamente será responsável por adsorver um gás. Através da interação do material do sensor e os analitos ocorrem mudanças nas propriedades físicas e químicas resultando na alteração da condutividade (JOHN et al., 2021).

Também em relação aos sensores de gás, é recomendado que, para uma maior precisão nas medições, seja necessário ter tempo de pré-aquecimento (*Preheat time*) ou tempo de queima (*Burn-in time*). No Datasheet dos sensores, informa-se que, para obter a máxima precisão nos sensores, no MQ-4 o tempo ótimo de *Burn-in time* ocorre após 48 horas, já nos sensores MQ-135 e MQ-137 ocorrem após 24 horas, contudo, a melhora da precisão já ocorre após três minutos de aquecimento.

Para os testes, e também como recomendação do uso comum, foi usado um tempo de aguardo de três minutos, após a ligação do dispositivo, para que fosse executado as medições da matriz de sensores. Esse tempo de espera permite o pré-aquecimento das resistências R1, R2 e R3 para que a medição já começasse com uma melhor precisão.

A comunicação, conforme já dito, é executada com o emprego do módulo HC06. Este módulo trabalha com frequência de 2,4 GHz e possui um alcance de transmissão/recepção de dez metros. Em versões mais atuais deste módulo, estão disponíveis recursos para autenticação e encriptação dessas conexões, fornecendo maior garantia de segurança.

2.4.2. Sobre o Container

O invólucro, container ou meramente caixa é o item mais simples e cuja características também influenciam a captura de dados, sendo importante para a pesquisa. Devido a necessidade da entrada de oxigênio para o processo

de decomposição do alimento, foi buscado uma caixa não-hermética para os experimentos. No entanto, percebeu-se que a caixa precisava ser constituída de um material resistente a umidade e a temperatura.

Nos primeiros testes, a caixa utilizada era feita de papelão, cuja escolha foi pautada pelo fato de ser um material reciclável. Todavia, em pouco tempo de utilização, deformidades surgiram na caixa indicando um problema. Desta forma, foi necessário buscar por outros materiais que pudessem atender o parâmetro de resistência, pois a caixa final também vai ficar sujeitas às condições ambientais externas.

Testes foram executados com diferentes materiais, conforme ilustra a Figura 27, sendo que as caixas permaneceram em observação durante 10 dias, visando verificar o comportamento do material a transferência de calor e a robustez contra umidade entre o ambiente interno e o externo da caixa.

Após os primeiros testes, determinou-se um primeiro teste específico com 3 tipos de caixas, feitas com papelão, madeira e MDP (*Medium Density Particleboard*), visando encontrar o tipo de material adequado para o invólucro da caixa. Na Tabela 6, seguem os valores referentes as propriedades térmicas dos materiais utilizados.

Tabela 6: Propriedades térmicas dos materiais e resistência a umidade.

Fonte: Ashrae (2001).

Material	Condutividade térmica (W/mK)	Calor específico ($kJ/(kg * K)$)	Resistência à Umidade
Papelão	0,07	1,40	Baixa resistência. Suscetível a deformação e danos estruturais.
Madeira	0,11 a 0,26	1,70	Baixa a moderada resistência. Depende do tipo de madeira.
MDP	0,10 a 0,17	2,30	Resistência moderada a alta. Depende do aglutinante utilizado.
Vidro	1,00	0,84	Não sofre os efeitos da umidade. Não é um material poroso.
Ferro (Aço)	55	0,50	Suscetível à oxidação e corrosão quando exposto à umidade.

Na Figura 27, pode ser observado que não ocorreu grandes variações

para A (papelão), B (madeira) e C (MDP), correlatos a ação da temperatura. No caso do MDP, este apresentou uma propriedade de maior calor específico em comparação com o papelão e a madeira (conforme visto na Tabela 6).

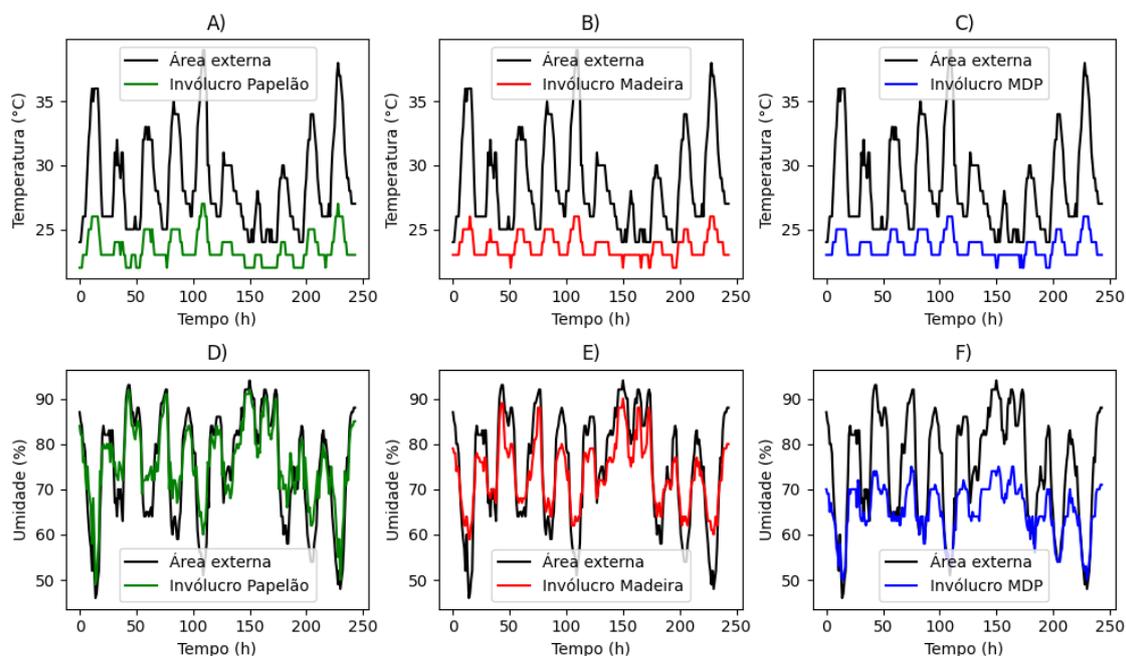


Figura 27: Teste dos invólucros de papelão, madeira e MDP.

Fonte: Própria autoria.

Com relação a característica de reação ante a umidade, a umidade externa penetrou mais nas caixas de papelão (Figura 27-D) e madeira (Figura 27-E) do que na de MDP (Figura 27-F). Isso se deve ao fato de que o MDP é fabricado com partículas de madeira e resina, que proporcionam resistência e estabilidade ao material, já o papelão e a madeira são materiais que possuem estrutura celular porosa, com muitos espaços vazios.

Em outro ciclo de testes, foi realizado outro rastreamento com outros três tipos de caixas. O objetivo foi de se obter confirmação dos resultados da caixa de MDP. Para esse ciclo, foram adicionadas uma caixa de vidro e uma de ferro com 2 mm de espessura. As caixas foram monitoradas durante 5 dias.

Conforme ilustra a Figura 28, com a apuração foi possível verificar a influência das propriedades térmicas dos materiais nos resultados de detecção, conforme apresentado na Tabela 6. Verificou-se que a temperatura média no

interior da caixa manteve-se em torno de 23 °C, influenciado pela energia térmica gerada pelos 3 sensores, conforme indicado na Figura 28-A.

Na caixa de ferro, a variação da temperatura no ambiente interno da caixa de ferro cresceu em cerca de 5 °C, aumentando a temperatura média para 28 °C (Figura 28-B), enquanto na caixa de vidro a variação de temperatura interna foi de ± 2 °C em relação à temperatura da caixa MDP, gerando uma temperatura interna entre 21 °C e 25 °C (Figura 28-C).

Conforme visto, em relação aos parâmetros de umidade e temperatura interna, as caixas de ferro e vidro não apresentaram bons resultados. O melhor material identificado foi o MDP, que apresentou os melhores índices frente, tanto a umidade, quanto frente a temperatura interna.

As caixas de ferro e vidro apresentaram problemas nas trocas de ar. Ao observar as caixas de ferro e vidro com uma lupa de 30x foi possível visualizar frestas nas junções e nos cantos favorecendo essas trocas de ar, que acabaram influenciando negativamente nos resultados da umidade e temperatura interna.

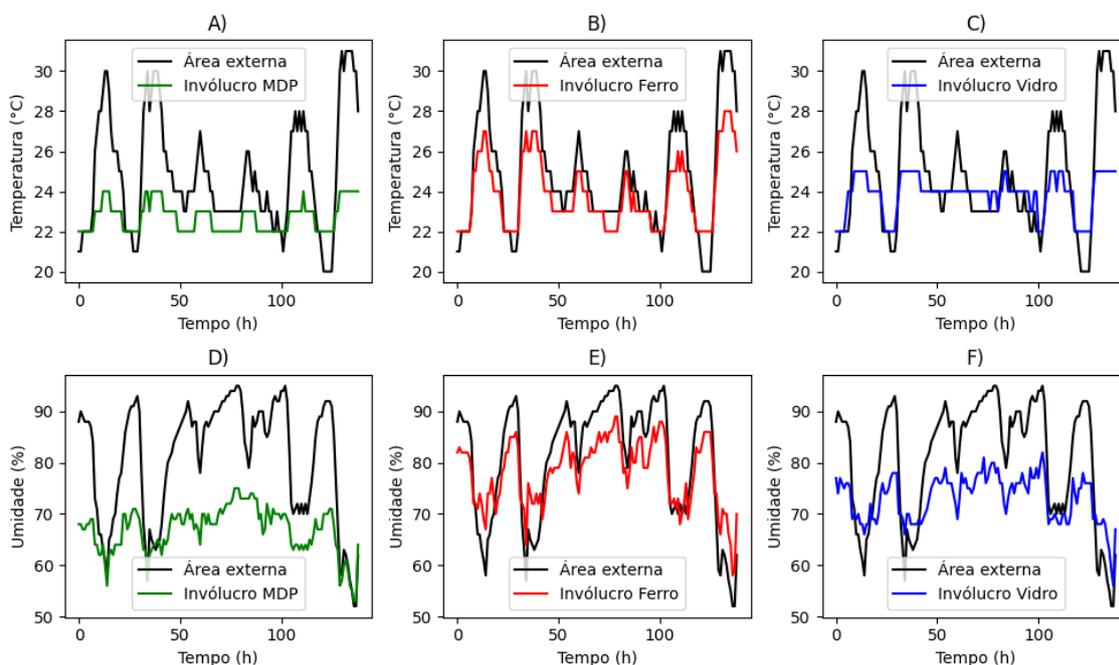


Figura 28: Variações dos parâmetros de temperatura interna e umidade dos invólucros feitos com MDP (A, D), ferro (B, E) e vidro (C, F).

Fonte: Própria autoria.

Para verificar a influência de frestas nos parâmetros examinados, foi realizado um teste consistiu na imersão com as caixas de cada material em um tonel com água. Ao imergir totalmente a caixa de ferro, verificou-se que a pressão interna foi alterada, visualizada pela liberação bolhas de ar dos pontos com vazamentos. Em sequência, a caixa de vidro ao ser imersa não suportou a pressão e se desfez, comprovando que a vedação apresentava fragilidades em relação a pressão externa maior.

Observou-se que, por problemas de fabricação destes tipos de invólucros, a solda na caixa de ferro apresentou-se estar oca em determinados pontos. Na caixa de vidro a temperatura interna mais elevada, em pouco tempo ressecou o silicone, deixando-o poroso e quebradiço, o que facilitou sua desintegração quando na imersão no tonel de água.

Além deste teste de imersão, a média dos resultados (Figura 29) obtidos dos testes de umidade e temperatura (Figura 27 e Figura 28), foram suficientes para indicar ser a caixa de MDP como o melhor invólucro também neste grupo. A média da temperatura interna dos invólucros de ferro e vidro foram vistas como mais elevadas quando comparadas com a do invólucro de MDP.

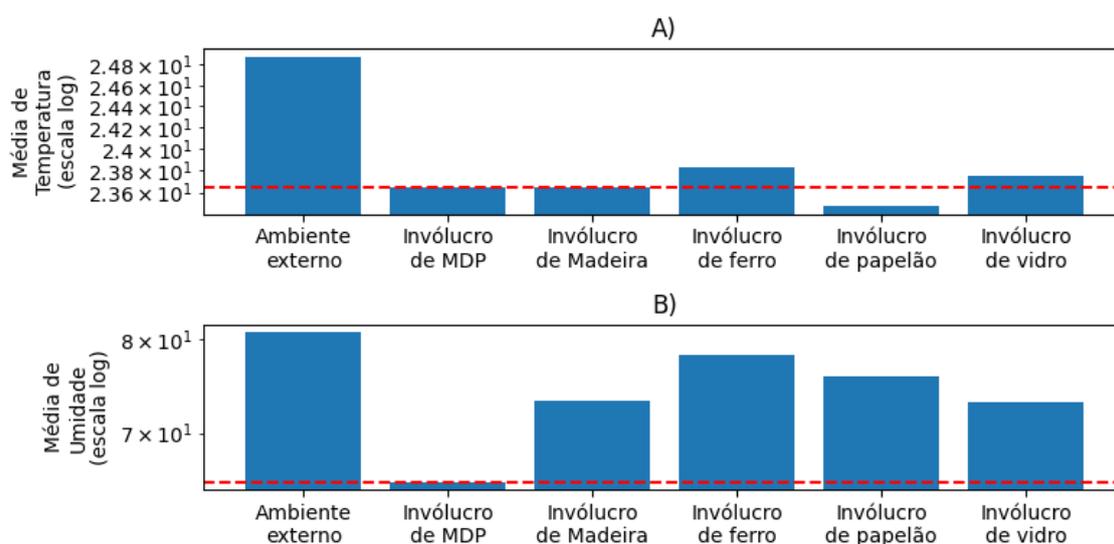


Figura 29: Médias na escala log. A) Temperatura; B) Umidade.

Fonte: Própria autoria.

Desse modo, verificando outros tipos de material para a fabricação da caixa, a escolha do invólucro de MDP para ser aplicado no projeto baseou-se nas melhores medidas dos dois parâmetros, comprovando ser o MDP o material adequado para ser utilizado nesse trabalho. Além disso, verificou-se que a caixa de MDP representou uma melhor na relação custo-benefício que todos os outros materiais pesquisados.

3 BASE DE TREINAMENTO

Neste capítulo são descritos os processos realizados nesta pesquisa para a coleta dos dados e as tratativas necessárias para o refinamento dos dados utilizados para montagem da base de conhecimento a ser usada nos testes do protótipo da CONT3NT3 (caixa MDP com o circuito do item 2.5.1.).

Esta análise mostra todas as tecnologias, métodos e problemas da construção da base de treinamento utilizada para a classificação das amostras usada nos testes. Para a coleta dos dados para a base de treinamento, foi acrescentado, na parte eletrônica, um módulo SD Card para armazenamento destes dados.

3.1. Tipos de amostras e sua preparação para os testes

Para o mapeamento dos dados usados para a construção da base de conhecimento aplicados na pesquisa, foram separados sete tipos de alimentos, entre frutas e hortaliças, conforme visto na Tabela 7. Esta tabela também mostra a quantidade de amostras usadas em cada tipo de alimento, que totalizou 54 amostras.

Os alimentos foram selecionados de acordo com a sazonalidade, de forma que não houvesse equidade nas amostras, evitando-se um “efeito memória”. Além disto, tal procedimento evitou a contaminação de obtenção destes dados pelo efeito de sazonalidade e disponibilidade da amostra em si.

Para formar a base de conhecimento, essas amostras permaneceram no dispositivo pôr 20 dias, no qual foram registradas as leituras dos sensores de gás, medidos por minutos, gerando assim, uma coleção de aproximadamente 28 mil registros para cada amostra. As medições de temperatura e umidade foram coletadas em intervalos de 15 minutos, gerando em torno de 1.920 registros em cada amostra.

Entretanto, como as amostras não apresentaram um padrão de senescência, fez-se necessário uma outra busca, visando coletar mais dados essenciais para entender, mapear e classificar os diversos processos de decomposição aos quais essas amostras passaram.

Tabela 7: Distribuição de amostras.

Alimento	Nome Científico¹³	Tipo	Número de Amostras
Banana prata	<i>Musa acuminata Colla x Musa balbisiana Colla</i> (grupo AAB)	Climatérico	5
Limão	<i>Citrus aurantifolia Swing</i>	Não climatérico	9
Pêssego premier	<i>Prunus persica</i>	Climatérico	2
Maça gala	<i>Malus Communis</i>	Climatérico	12
Morango	<i>Fragaria vesca L.</i>	Não climatérico	6
Tomate	<i>Lycopersicum esculentum Mill.</i>	Climatérico	13
Uva verde	<i>Vitis vinífera L.</i>	Não climatérico	7

Na Tabela 8, apresenta-se a classificação das amostras ao longo do processo de decomposição, com suas características anotadas, verificando se houve mudança de cor, textura, proliferação de fungos ou líquidos.

Tabela 8: Classificação das amostras.

Tipo	Descrição das Características	Número de Amostras
Mudança de cor	Apresenta escurecimento ou desbotamento da parte externa da amostra.	14
Mudança de textura	Apresenta textura enrugada, murcha e menos firme ou seca e quebradiça.	6
Proliferação de fungos	Apresenta machas brancas ou pretas na parte externa da amostra.	25
Produção de líquidos	Rompimento da parede estrutural da amostra com excessiva produção de líquidos.	9

¹³ Fonte dos nomes científicos: Núcleo de Estudos e pesquisas em Alimentação (NEPA, 2011).

As amostras selecionadas foram preparadas de modo que cumprissem com a exigência de possuir peso entre 130 e 140 gramas. Isso para evitar o caso de alimentos menores, no qual observou-se a incapacidade de o medir os dados com acuracidade.

Para melhor exame do comportamento das amostras, elas foram distribuídas em dois supergrupos. Uma parcela das amostras foi destinada para se registrar todos os detalhes ao longo de todo o processo (vide Tabela 8). Mesmo assim, com a aleatoriedade no tipo de processos de decomposição, foi necessário aumentar a parcela de dados, para que fosse registrado o maior número de variantes no processo.

A outra parcela, em menor em número, foi separada com o propósito de medir os gases produzidos antes e depois que uma parte do alimento fosse afetada e precisasse ser removida. Esse tipo de amostras foi separado de modo a verificar, a influência da umidade, calor e oxigênio no processo da decomposição.

Conforme já visto, esses parâmetros (umidade, calor e oxigênio) tem influência tanto sobre os componentes da plataforma, quantos nos alimentos examinados. Notou-se, nos testes, que a umidade proporcionou à proliferação de fungos e bactérias, o calor acelerou a decomposição gerando mais micro-organismos e o oxigênio auxiliou a respiração celular desses micro-organismos.

Adicionalmente, com objetivo de obter mais precisão, as medições da temperatura e umidade obtidas do interior da caixa foram comparadas com a base de dados do Sistema Alerta Rio da Prefeitura do Rio de Janeiro (2021-2023), dia a dia. Esta base contém os registros de temperatura e umidade da região na qual os testes foram executados.

3.2 Procedimentos da coleta de dados e seus problemas

Como o tempo de coleta de dados de uma amostra foi de 20 dias, para obter os dados de todas as amostras escolhidas, foram precisos cerca de 30 meses de tempo de coleta total e suas tratativas. Durante este período houve obtenções intercaladas ao longo do processo, para cada grupo de amostra. O tempo médio por grupo de amostras foi de dois meses.

Após o período de seis meses, no qual obteve-se dados de nove amostras, observou-se quatro tipos de processos de decomposição. Como o processo de coleta dos dados estava relativamente lento, e precisava-se de dados de comparação, dois outros protótipos semelhantes foram construídos e incluídos ao processo de coleta.

A partir deste ponto, por mais 18 meses, auxiliado pelos três protótipos, alcançou-se o exame de 81 amostras. Entretanto, um terço das amostras foram descartadas por apresentarem inconsistências na fase de captação de dados. A Figura 30 apresenta toda as etapas da coleta de dados, relacionando-a a cada grupo de amostras.

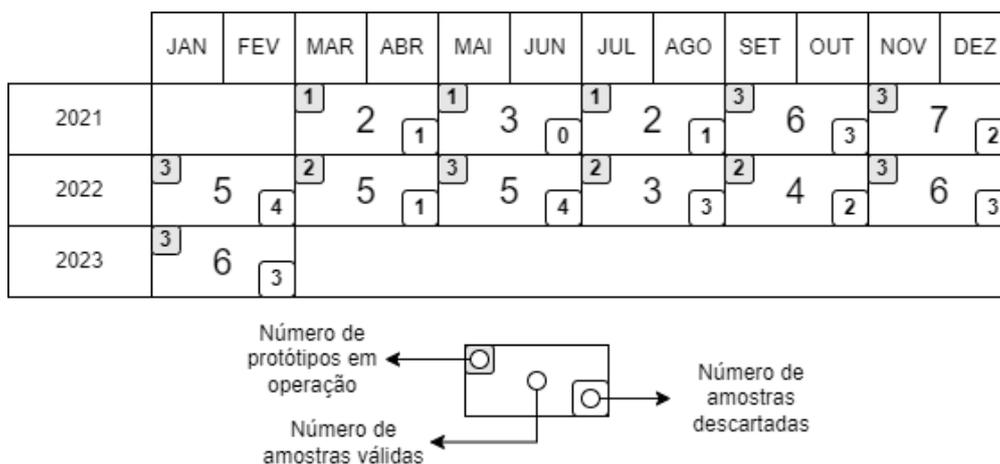


Figura 30: Mapeamento temporal das amostras, com informações sobre meses, o número de amostras aproveitadas e descartadas.

Fonte: Própria autoria.

Como resultado dos protótipos permanecerem ininterruptamente ligados, os seus componentes apresentaram desgastes naturais pela manutenção deste tempo contínuo de operacionalidade. Além de sofrerem com as falhas devido à sobrecargas de corrente, curto-circuito e surtos de energia ou ainda pelo excesso de aquecimento, o tempo contínuo causou desgastes nos circuitos MOS dos sensores.

Devido a esse desgaste e falhas no decorrer do processo de coleta de dados, todos os componentes tiveram que ser substituídos ao menos uma vez. Componentes, como o sensor MQ-137, tiveram que ser importados de sites internacionais, por sua ausência no mercado nacional, o que elevou o custo do projeto.

A Tabela 9 apresenta uma listagem dos problemas das coletas, relacionando-os com os problemas dos componentes da plataforma e causas extras que foram identificadas. Destaca-se que, a reposição de componentes defeituosos por novos foi suficiente para sanar os problemas identificados.

Tabela 9: Problemas na obtenção dos dados e suas causas.

Problema	Descrição	Causa
Dados ausentes	Valores faltantes ou incompletos em uma ou mais variáveis.	Falha nos sensores por defeito ou desgaste
Dados duplicados	Grandes faixas de conteúdo com conteúdo duplicado.	Falha no microcontrolador por problemas elétricos
Dados inconsistentes	Ausência de quebras de linha e espaço entre os conteúdos coletados, não permitindo identificar os padrões característicos dos dados.	Falha no módulo SD Card por problemas elétricos
Dados errôneos ou inválidos	Erro na coleta e inserção dos dados, produzindo caracteres e símbolos ao invés de um conteúdo numérico.	Falha no módulo SD e no microcontrolador
Perda total dos dados	Arquivo corrompido, danificado ou com sua estrutura comprometida de alguma forma, tornando-o inacessível.	SD Card danificado por problemas elétricos

Devido aos problemas ocorridos com o sistema eletrônico de captação de dados (o módulo SD Card), e para formar uma base de conhecimento com o máximo de dados possíveis, incluiu-se etapas de recuperação de dados para

tratamento de dados inconsistentes, inválidos ou perdidos.

No caso dos dados ausentes, por meio da imputação estatística, a reposição dos valores faltantes foi estimada com base em dados de outras amostras. Também foi observado a ocorrência de ruídos na obtenção de algumas coletas de dados, que prejudicaram a identificação da influência da umidade e temperatura nas amostras e caixa, o que gerou não-conformidade dos dados. Para esses casos, optou-se pelo descarte.

Para os dados duplicados ou inválidos, foi realizado um processo de *Listwise deletion* para remoção destas duplicações ou defeitos (conforme Figura 31-B). Todavia, essa abordagem para a remoção não foi aplicada para todos dados com problemas, pois esta retirada iria reduzir em muito do total de dados coletados.

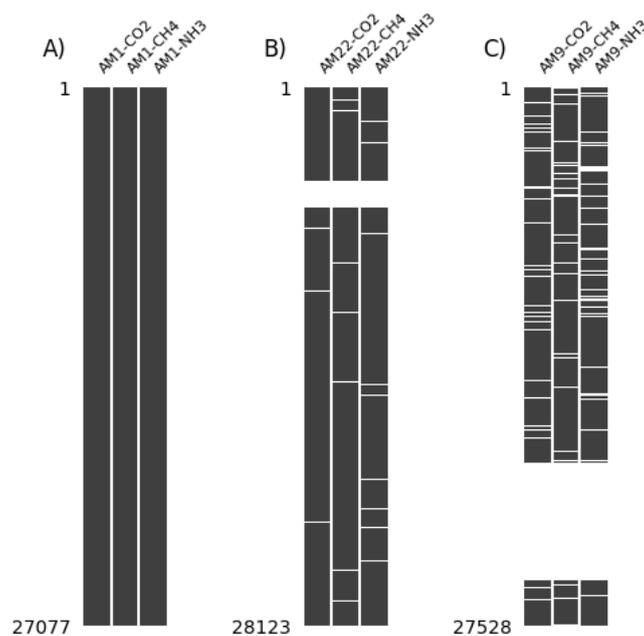


Figura 31: Exemplo de dados de amostras, no qual as linhas horizontais em branco representam dados ausentes: A) Amostra com dados íntegros; B) Amostra com dados para serem recuperados; C) Amostra descartada.

Fonte: Própria autoria.

Quando um sensor apresentava problemas, o dado não era registrado (ficando como dado ausente), sendo que o reparo ou substituição deste foi

imediatamente, para não se formar um grande bloco de dados ausentes (como visto na Figura 31-C). Nos casos das amostras que redundaram em aproveitamento de suas coletas abaixo de 60% optou-se também pelo descarte.

3.2. Tratamento dos dados coletados

Para tratar a recuperação de dados das amostras que tiveram decomposição e apresentaram dados inválidos, utilizou-se os dados das amostras integras ou que não apresentaram erros na sua leitura para comparações.

Para a recuperação de dados que apresentaram inconsistências, foi aplicada a técnica Múltiplas Imputações (MI - *Multiple Imputation*) proposta por D. B. Rubin (1987). Nesta técnica, a primeira fase consiste em assumir que os dados faltantes são do tipo perdas ao acaso (MAR - *Missing at Random*) (RUBIN, 1987), que, no caso da pesquisa, foram representados por dados relacionados com temperatura e de umidade.

Todavia, conforme já visto, os dados dos três sensores de gases foram obtidos de minuto a minuto (conforme Figura 32-A), enquanto as variáveis auxiliares de temperatura e umidade em ciclos de 15 minutos. Com a finalidade de potencializar e, conseqüentemente, reduzir o tempo de processamento da técnica MI, os dados das amostras foram suavizados e agrupados com base em uma série temporal.

O processo de suavização foi realizado com o propósito de reduzir o ruído ou variabilidade desta série temporal, tornando-a mais simples de analisar e interpretar (conforme Figura 32-B). A média móvel foi utilizada como uma parte do método para suavização de dados. Considerando a série temporal aplicada, o cálculo da média dos pontos adjacentes foi realizado, a fim de identificar padrões subjacentes e tendências ao longo do tempo das coletas.

O agrupamento de dados, foi realizado para duas instâncias, sendo a primeira, o agrupamento da série temporal para períodos de 15 em 15 minutos,

conforme visto na Figura 32-C, e a segunda para períodos de hora em hora, sendo observada na Figura 32-D.

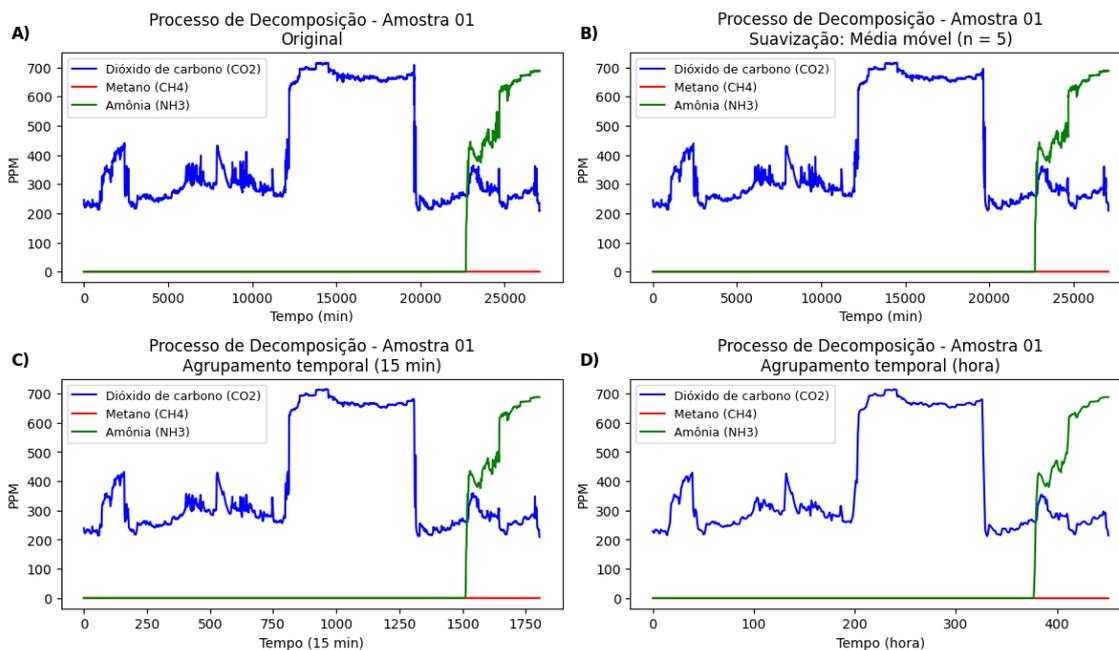


Figura 32: Procedimentos aplicados às instâncias preparadas. A) Dados originais; B) Suavização dos dados; C) Agrupamento de 15 em 15 minutos; D) Agrupamento de hora em hora.

Fonte: Própria autoria.

Houve perdas de informações na instância de agrupamento por hora, em comparação com a outra instância referente ao agrupamento de 15 em 15 minutos. Quanto mais elevado o agrupamento da série temporal, maior foi a dificuldade para o tratamento de valores ausentes, prejudicando o cálculo de valores faltantes, o que prejudicou também a visualização de padrões e tendências (RUBIN, 1987).

A fim de mitigar esse problema, foi estabelecido uma padronização das bases, de modo a ter-se um agrupamento de dados de $\frac{1}{4}$ de hora, igualando, desta forma, da frequência de medições de temperatura e umidade (que foi de 15 em 15 minutos).

Foi possível, então, verificar o comportamento das diferentes abordagens de imputação de dados na base de conhecimento e verificar a

eficiência de identificação do conjunto de dados para uma amostra específica, levando-se em conta a forma aleatória que o processo de obtenção e tratamento dos dados levou.

3.2.1. Sobre as técnicas de imputação para dados ausentes ou com problemas

Antes da definição do Estimador de imputação dos dados ausentes nas amostras com inconsistências, foi necessário realizar análise dos melhores métodos de imputação. A Amostra-01, que não possui não possui valores ausentes e mantém todos os seus obtidos dados íntegros, foi selecionada como amostra modelo para aplicação do Estimador.

Para aplicar o Estimador e usar essa amostra modelo, proporcionou-se que 20% dos valores fossem removidos artificialmente, gerando uma nova versão do modelo de dados da Amostra-01 com esses dados ausentes de forma intencional.

Com esse modelo da Amostra-01, foi possível verificar o desempenho entre um conjunto de dados completo com o desempenho dos outros conjuntos de dados imputados. Nos primeiros processos com a Amostra 01 foi identificado que as pequenas falhas de dados foram sanadas com a aplicação de um processo de agrupamento de dados simples (conforme visto na Figura 33).

O agrupamento de dados resolveu o problema das pequenas faixas de dados com problemas, contudo, para as faixas mais largas de dados ausentes, o agrupamento não resolveu.

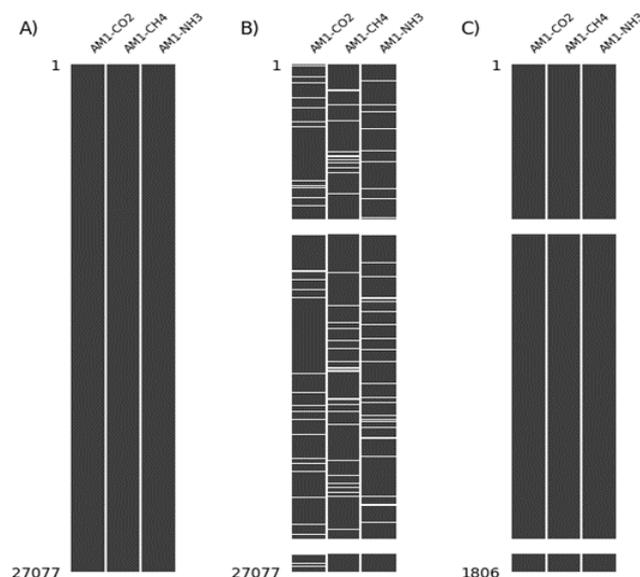


Figura 33: Modelo de dados da Amostra-01. A) Dados originais; B) Dados ausentes artificialmente; C) Dados após o agrupamento em quarto de hora.

Fonte: Própria autoria.

Para resolver os problemas dessas faixas mais largas, foi necessário aplicar outras técnicas de imputação. A cada aplicação de uma nova técnica, foi produzido uma nova versão de dados imputados, conforme ilustra a Figura 34.

A técnica de imputação por alisamento exponencial (Figura 34-B) foi útil para prever valores futuros em séries temporais. O papel da constante de alisamento α foi de regular o grau de suavização das flutuações nos dados e fornecer estimativas razoáveis para os valores ausentes do conjunto de dados. (DELURGIO, 1998).

A imputação por KNN condicional (Figura 34-C) usou uma variação do algoritmo KNN tradicional para estimar os valores ausentes em um conjunto de dados. A técnica consistiu na seleção dos K vizinhos, que nesta pesquisa, foram os 25 vizinhos mais próximos dos os pontos de dados que possuíam valores não ausentes, e aplicação de uma predição baseada nestes vizinhos. Esta abordagem demonstrou-se ser útil por preservar as relações entre as variáveis ao imputar dados ausentes.

Na imputação utilizando Hot-Deck (LOCF - *Last Observation Carried Forward*) (Figura 34-D) a técnica demonstrou ser também útil, quando se trabalhou com dados de uma série temporal. Consistiu na imputação dos valores

ausentes pelo valor da última observação válida anterior. Nesta técnica, a seleção dos valores não ocorreu de forma aleatória, mas baseada em uma ordenação padrão (DE CASTRO; FERRARI, 2016).

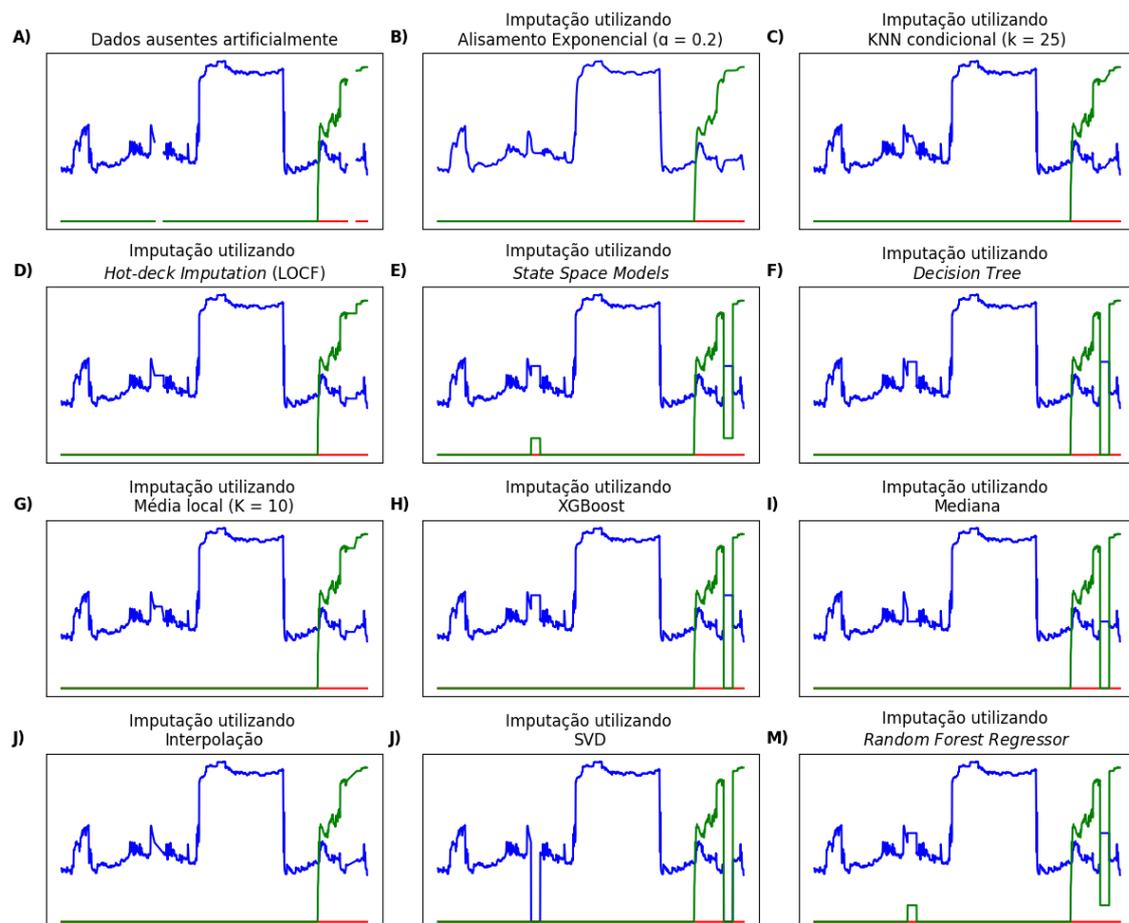


Figura 34: Dados ausentes artificialmente e versões imputadas.

Fonte: Própria autoria.

Com a imputação por *State Space Models* (Figura 34-E), o processo de estimação dos valores ausentes nos dados observados foi auxiliado pelo as informações do modelo da Amostra-01. A filtragem de Kalman (1960) foi aplicada para predição de um estado, utilizando média ponderada. O valor imputado foi uma estimativa, que descreveu a evolução do estado latente não observável ao longo do tempo.

A imputação por *Decision Tree* (Figura 34-F) foi a técnica que se utilizou de árvores de decisão. Nela, os dados foram divididos em ramificações

ou nós, com base em critérios específicos. A árvore de decisão não se utilizou de imputação por base na média global, mas se utilizou da média como se fosse um dos critérios de divisão.

Na imputação por média local (Figura 34-G) utilizou-se os 10 valores disponíveis nas proximidades de um espaço de valor ausente para criar modos de previsão. Foi levado em consideração a estrutura dos dados, de modo a se manter a coerência das informações. Ao invés de calcular a média global de todos os valores existentes gerando uma única constante, foi aplicado a média apenas dos valores próximos ao ponto de dado ausente.

Outra técnica usada foi o *XGBoost* (Figura 34-H), que também é um algoritmo de AM baseado em árvores. Embora o *XGBoost* não seja uma técnica de imputação de dados, ele pôde ser aplicado nesta pesquisa. O algoritmo por se basear em árvores apresentou um mecanismo de imputação de dados semelhante a abordagem por *Decision Tree* (Figura 34-F).

Na imputação utilizando a mediana (Figura 34-I), os valores ausentes foram imputados com a mediana dos valores observados no conjunto de dados. Ao ser aplicada demonstrou ser menos sensível a problemas de *outliers*, nos quais ocorre um efeito negativo na área de valores extremos, ou em regiões do conjunto de dados que contêm grande quantidade de zeros.

A imputação por interpolação (Figura 34-J) foi utilizada para estimar valores ausentes em um conjunto de dados por meio da interpolação de pontos conhecidos. Nesta técnica, o preenchimento dos espaços vazios considerou os valores conhecidos ao redor dos pontos ausentes. Tanto a interpolação linear quanto a polinomial apresentaram desempenho análogo, apresentando previsões de modo que conjunto de dados pôde seguir um padrão contínuo e suave. Ligando os espaços ausentes.

Na imputação por SVD (*Singular Value Decomposition*) (Figura 34-L) os dados ausentes foram preenchidos através de uma matriz de dados usando a decomposição SVD. Com a redução da dimensionalidade, a grande quantidade de zeros em determinadas variáveis influenciou negativamente na imputação dos dados para todo o conjunto. Além disso, ocorreu o truncamento de valores corretos por um valor próximo de zero, elevando exponencialmente o

número de *outliers* do conjunto.

A imputação por *Random Forest Regressor* (Figura 34-M) foi utilizada para prever os valores ausentes com base em outras variáveis independentes no conjunto de dados que estão completas. O conjunto de dados foi dividido em duas partes, uma parte com valores completos e outra com valores ausentes, sendo que a parte completa é utilizada como treinamento. Os dados imputados por esta abordagem foram semelhantes a imputação *State Space Models* (Figura 34-E).

Todas essas técnicas foram aplicadas aos conjuntos de dados que apresentaram problemas, gerando diferentes versões com soluções de preenchimento para os casos de ausência de dados, baseada nas estatísticas da amostra íntegra Amostra-O1.

No item a seguir, essas versões criadas foram analisadas e avaliadas para verificar aquela que melhor reduziria o problema de viés causado pelo processo de inserção de dados. As métricas de avaliação foram criadas com a finalidade de auxiliar na identificação de qual das técnicas aplicadas seriam as mais eficientes para esta pesquisa.

3.2.2 Análise das técnicas de imputação e das versões geradas

A metodologia de avaliação as técnicas de imputação foram realizadas com duas etapas. A primeira baseada na análise de dispersão da imputação e a segunda baseada na aplicação de análises estatísticas, para fornecer mais detalhes sobre o desempenho destas técnicas de imputação.

A análise de dispersão da imputação permitiu visualizar a relação entre os valores imputados e os valores reais. Serviu para fornecer *insights* iniciais sobre a qualidade da imputação, todavia não substituiu análises estatísticas mais detalhadas.

O gráfico de dispersão permitiu avaliar quão próximos os valores imputados estavam dos valores reais. Caso os pontos no gráfico estivessem

próximos de uma linha diagonal, indicariam uma boa imputação, enquanto pontos dispersos, indicariam uma imputação imprecisa.

Além de permitir uma visualização rápida e visual da qualidade da imputação de dados, o gráfico de dispersão permitiu identificar padrões, detectar *outliers* nos valores imputados e comparar as diferentes técnicas de imputação vistas no item anterior.

Na segunda fase, foram utilizadas as métricas MSE, MAE e R2 para as análises estatísticas. Essa combinação de métricas permitiu obter uma visão do desempenho de cada técnica, além de também permitir uma ampla comparação deste desempenho com as técnicas de imputação de dados utilizadas entre si.

A métrica MSE foi utilizada para calcular a média de diferença entre o valor imputado com o real (aplicando a Equação 2). Quanto menor o valor calculado do MSE, mais foi técnica de imputação realizou imputações dentro do modelo Amostra-01, ou seja, com mais precisão, significando estar mais próximos dos valores reais (BRUCE; BRUCE, 2019). Logo, as técnicas com valores maiores representaram valores distantes dos valores reais.

No uso da métrica MAE foi determinado a média das diferenças absolutas entre o valor real com o imputado. Quanto menor for o valor do MAE, melhor foi considerado o desempenho da técnica, pois indicou que as imputações estão muito próximas dos valores reais. O cálculo do MAE (utilizando a Equação 3) não é afetado pelos *outliers*, ou seja, é menos sensível a valores extremos, tal como na métrica MSE.

Outra métrica utilizada foi a do coeficiente de determinação, também chamado de estatística de R-quadrado ou R2 (BRUCE; BRUCE, 2019) que representa o grau de variância dos dados. Nesta métrica, os resultados devem variar entre 0 a 1 (conforme a Equação 4).

Para essa consideração de valores da R2, valores mais próximos de 1 representaram que os dados imputados foram próximos dos valores reais; enquanto, valores próximos de 0, indicaram que a versão ou modelo não possuía nenhuma variabilidade ou flutuações nos valores observados, estando mais distantes dos valores ideais ou reais.

$$\mathbf{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (\text{Equação 2})$$

$$\mathbf{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (\text{Equação 3})$$

$$\mathbf{R2} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (\text{Equação 4})$$

No qual, para (Eq. 2), (Eq, 3) e (Eq, 4), n é o número de dados faltantes; y representa os valores reais; \hat{y} significa os valores imputados pela abordagem; e \bar{y} é a média dos valores reais.

Conforme dito, a Amostra-01 foi usada como a base de comparação, por representar dados íntegros. Comprando os dados obtidos por cada métrica, gerou-se o gráfico de dispersão de dados originais e dados imputados, visto na Figura 35. Ocorreu que sete modelos de imputações (versões diferentes) que apresentaram maiores dispersões, enquanto, em quatro versões, os *outliers* se concentram próximo da linha de igualdade.

Na coluna AM1-CH4, da técnica de imputação por *XGBoost*, ocorreu imputação de diversos valores próximo de zero, o que não seria adequado; na imputação por SVD a substituição e o truncamento de valores na coluna AM1-CO2 forçaram o deslocamento da linha de igualdade, o que poderiam prejudicar a montagem da base de conhecimento.

Outro ponto a ser destacado ocorreu com a imputação por alisamento exponencial, no qual diversos valores foram atribuídos com base no parâmetro de alisamento α para suavizar as flutuações nos dados.

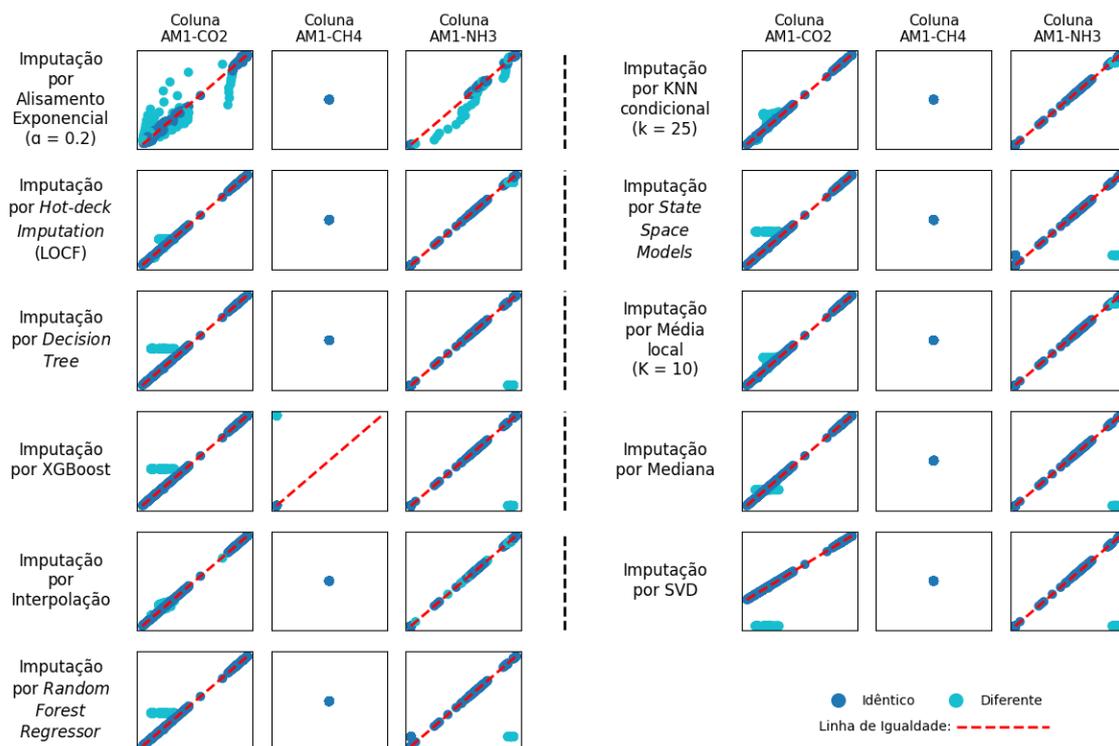


Figura 35: Gráfico de dispersão de dados originais vs. dados imputados, nos quais a coluna AM1-CO2 apresenta a obtenção de dados para o gás carbônico, a AM1-CH4 para o metano e a AM1-NH3 para a amônia.

Fonte: Própria autoria.

Ao observar o gráfico de dispersão verificou-se precisar de mais dados para concluir quais seriam as melhores técnicas de imputação de dados a serem utilizadas para montagem da base de conhecimento final. Assim as métricas MSE, MAE e R^2 (Figura 36) foram aplicadas sobre também as versões imputadas para também avaliar essas técnicas de imputação, incrementando a precisão sobre quais delas tem resultados mais próximos do ideal.

Com base nas aplicações destas três métricas, foi possível classificar quais técnicas seriam a mais e menos apropriadas para o tipo de dados a ser recuperado. As técnicas menos apropriadas, por apresentar resultados muito destoantes, foram a *XGBoost* e a *SVD*.

A interpolação foi a melhor técnica, por ter seus valores mais próximos da situação ideal, seguida por *hot-deck imputation*, com média local k igual a 10 e a técnica *KNN condicional*, com média local k igual a 25.

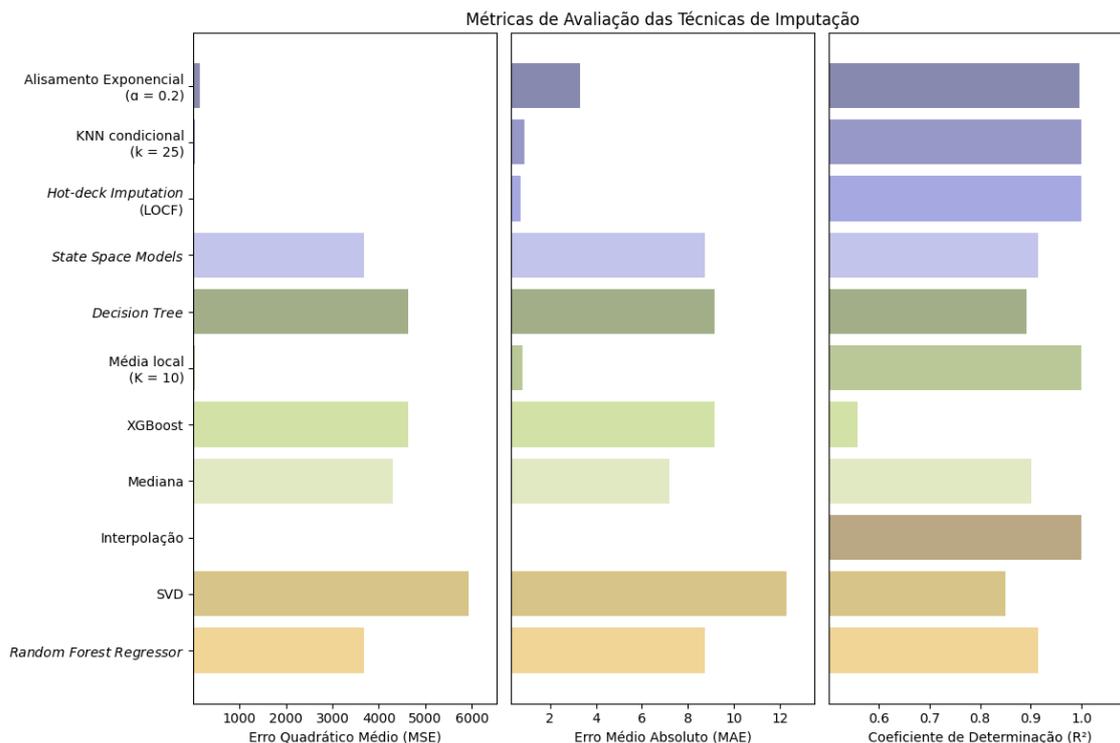


Figura 36: Aplicação das métricas de avaliação nas versões de dados inseridos pelas diferentes técnicas de imputação.

Fonte: Própria autoria.

3.3 Mapeamento dos perfis da fase de decomposição das amostras

Neste tópico serão apresentadas as diversas formas de identificação de situações relativas a decomposição dos alimentos. Os alimentos podem sofrer decomposição por ação de fungos, putrefação natural (por microrganismos), por ação combinada da temperatura, umidade e nível de oxigenação e por desidratação.

Neste caso, foi importante identificar e mapear o comportamento de cada uma destas situações de decomposição, de modo que a classificação de alimentos (se ainda disponíveis ou em situação de descarte), pudesse ser cruzada com estas informações e aumentar a precisão do resultado.

Cada situação de decomposição vai apontar para uma classificação final relativa ao alimento poder ainda ser consumido ou não, pois cada uma delas tem ênfase na emissão dos gases examinados e vão compor a base de dados de conhecimento utilizada para essa verificação final.

3.3.1 Decomposição fúngica

A degradação por fungos é um processo que auxilia a reciclagem da matéria orgânica junto ao meio ambiente, pois os fungos fazem a quebra da matéria orgânica em componentes mais simples, devolvendo os nutrientes de volta ao ambiente (TAIZ et al., 2017).

Essa degradação fúngica se inicia com a colonização da matéria orgânica pelos esporos, que são transportados pelo ar ou pela água, de modo que, quando os esporos encontram um ambiente adequado, germinam e formam uma rede que se estende sobre a matéria orgânica.

Conforme a Figura 37 apresenta, em frutos climatérios, identificou-se a decomposição fúngica na fase de senescência, com a emissão de amônia e a elevação da umidade no interior da caixa.

De acordo com Taiz et al. (2017, p. 659), em frutos climatéricos a elevação da respiração indica o início do amadurecimento e o início da fase de senescência do alimento, que também gera uma queda na taxa respiratória do mesmo.

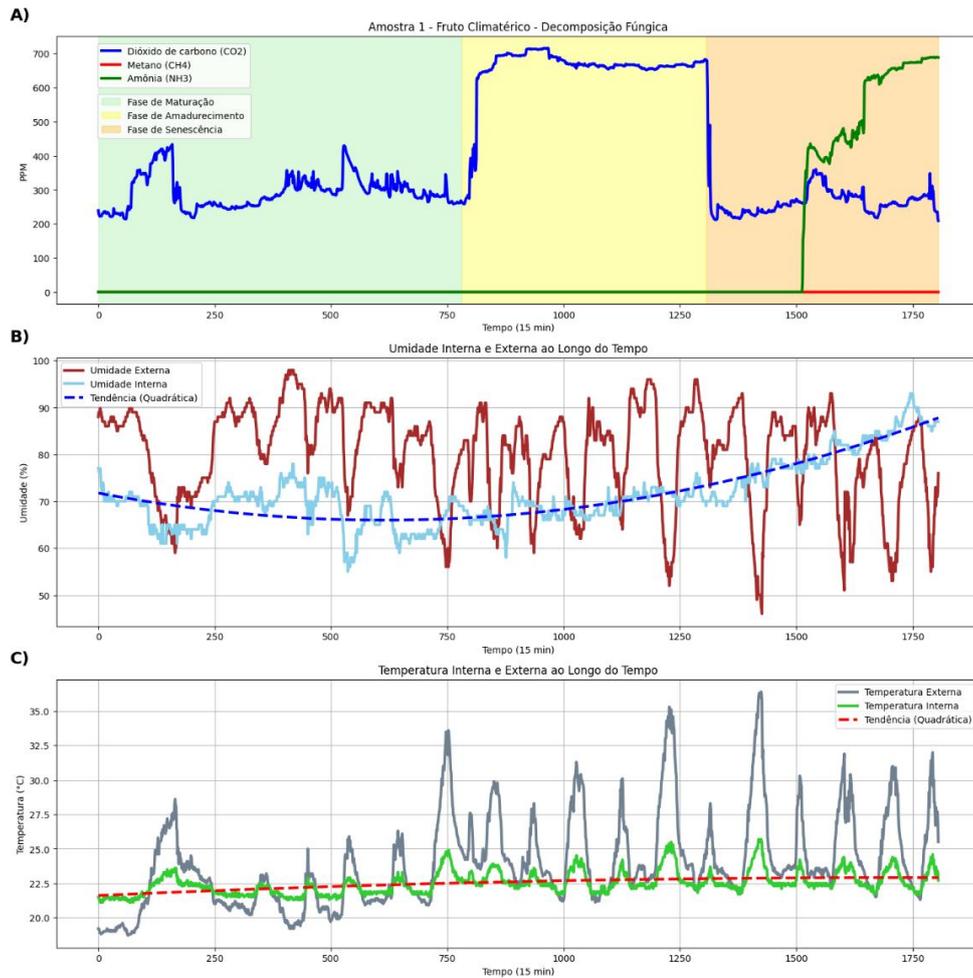


Figura 37: Dados obtidos com a degradação fúngica em fruto climatérico usando o modelo da Amostra-01. A) Nas medições dos gases CO_2 , CH_4 e NH_3 ; B) na medição da umidade; C) na medição da temperatura.

Fonte: Própria autoria.

A Figura 38 apresenta os mesmos dados para um fruto não climatérico, no qual percebe-se que há características distintas em comparação com o visto na Figura 37.

Como esses frutos que permanecem na planta até atingir o estado ótimo de amadurecimento, quando colhidos, de acordo com a espécie do fruto, possuem poucos dias para serem consumidos. Estes frutos tendem a manter uma taxa de respiração relativamente constante e em declínio após a colheita.

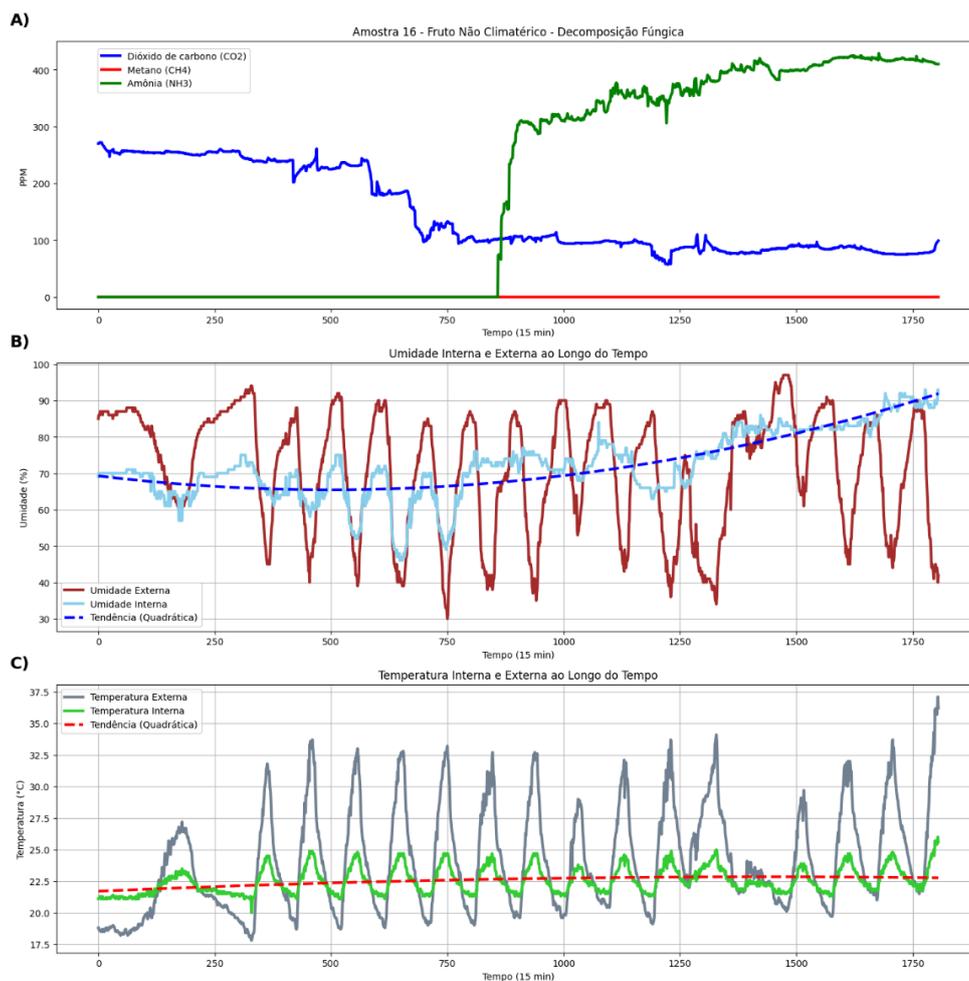


Figura 38: Dados obtidos com a degradação fúngica em fruto não climatérico da Amostra-16. A) Nas medições dos gases CO_2 , CH_4 e NH_3 ; B) Na medição da umidade; C) Na medição da temperatura.

Fonte: Própria autoria.

Ao comparar as Figura 37-B e Figura 38-B, verifica-se a elevação da umidade interna tornando o ambiente ideal para a proliferação fúngica. Com a disponibilidade de nutrientes, ocorre o crescimento do fungo, que decompõem a matéria orgânica e, com o metabolismo da colônia de fungos, são liberados subprodutos no ambiente (TAIZ et al., 2017)..

Um desses subprodutos é a amônia, um composto químico com odor desagradável e que pode indicar deterioração ou contaminação dos alimentos. Nas Figura 37-A e Figura 38-A, foi possível observar a detecção de amônia em ambos os casos.

A caixa foi outro fator observado na proliferação fúngica, sendo que ela pôde influenciar esse tipo de decomposição da seguinte forma:

- Por ausência de Luz: Como os fungos não necessitam de luz direta para crescer e muitos prosperam mais rapidamente em ambientes escuros, não havendo fonte de iluminação no interior da caixa, isso favoreceu a essa decomposição;
- Por ausência de circulação de ar: Uma circulação de ar eficiente auxilia na redução da umidade e ajuda a dispersar os esporos dos fungos. Como a caixa não possui circulação de ar, isso também favoreceu esse tipo de decomposição; e
- Pela relação da temperatura: A temperatura no interior da caixa variou entre 21 e 25 °C, que é um intervalo de temperatura ideal para crescimento de fungos.

Cerca de 64% das amostras apresentaram aspectos de decomposição do tipo fúngico, mostrando características semelhantes as apresentadas nas Figura 37 e Figura 38. A principal característica que se observou nas amostras, relativa a esse tipo de decomposição, foi a subida abrupta de amônia após o aumento da umidade.

3.3.2 Decomposição natural por putrefação

Após 20 dias na caixa, percebeu-se que, as amostras de alimentos que apresentaram a característica de mudança de cor e produção de líquidos (conforme visto na Tabela 8) tiveram o mesmo tipo de processo de decomposição. Ambas as características fazem parte do processo geral de putrefação, mas são estágios diferentes dentro deste processo.

Devido ao desconhecimento do verdadeiro estágio de senescência nestas amostras, as características físicas do processo ocorridas durante os 20 dias, não se comportaram dentro da mesma linha do tempo das demais amostras. Assim, algumas dessas amostras foram retiradas no estágio “1” de

putrefação, outras no estágio “2” ou “3”.

A mudança de cor na superfície do fruto é a fase inicial da decomposição por putrefação, ou estágio “1”, enquanto o rompimento da parede estrutural da amostra foi observado na fase posterior (estágio “2”), sendo à liberação de líquidos a fase final do processo de putrefação (estágio “3”).

O escurecimento ou desbotamento da parte externa da amostra foi relacionado com a oxidação de compostos fenólicos causada por enzimas presentes no próprio fruto (TAIZ et al., 2017) ou por atuação de microrganismos (REECE et al., 2015).

A decomposição interna, que leva ao colapso da estrutura e à liberação de líquidos, ocorreu quando microrganismos se proliferaram no interior do fruto. A quebra dos componentes orgânicos, açúcares, amidos e pectina, levou à produção de gases e líquidos, acarretando o aumento da pressão interna fazendo com que a estrutura do alimento fosse rompida.

Foi observado também que a temperatura internada caixa se elevou gradativamente, à medida que a presença de microrganismos aumentou e a atividade metabólica se intensificou, conforme pode ser observado nos gráficos da Figura 39.

A Amostra-07 foi um exemplo da que sofre por todo esse processo, no qual também foi possível identificar duas elevações de temperatura interna ao longo do processo de putrefação (vide dados da Figura 39-C). A primeira subida da temperatura correspondeu a quebra inicial dos compostos orgânicos com produção de gases. Além do mais, os gases, que não foram liberados para fora da caixa, se acumularam e resultaram no aumento da pressão interna da caixa.

A segunda elevação na temperatura da Amostra-07 causou o rompimento da estrutura e a liberação de líquidos. Com o colapso da estrutura do alimento, a parte interna do mesmo entrou com o oxigênio contido na caixa o que gerou um aumento na velocidade da decomposição e o crescimento mais rápido da população de microrganismos.

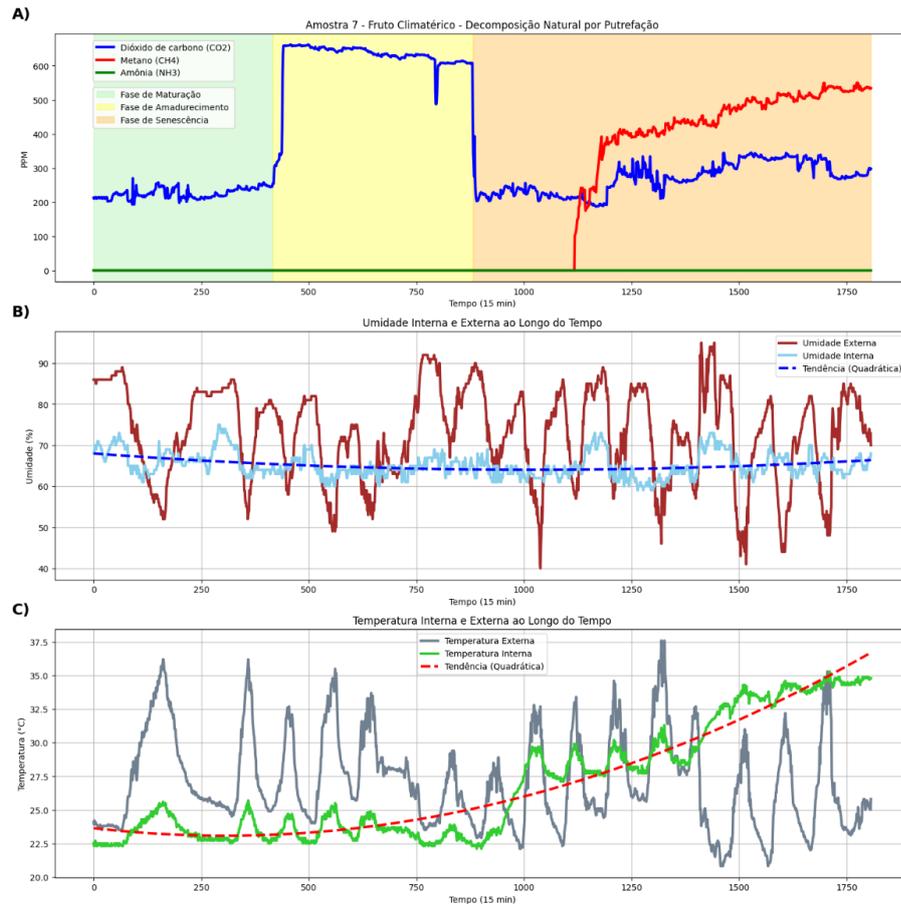


Figura 39: Dados obtidos com a putrefação em fruto climatérico da Amostra-07. A) Nas medições dos gases CO_2 , CH_4 e NH_3 ; B) Na medição da umidade; C) Na medição da temperatura.

Fonte: Própria autoria.

Com a Amostra-23, que é um fruto não climatérico, a tendência da decomposição por putrefação apresentou uma estabilidade no parâmetro de umidade, com este índice se estabelecendo acima dos 60%, e também mostrou uma ausência de amônia. Com a temperatura, ocorreu gradativa se elevação, com a liberação de metano, conforme visto nos gráficos da Figura 40,

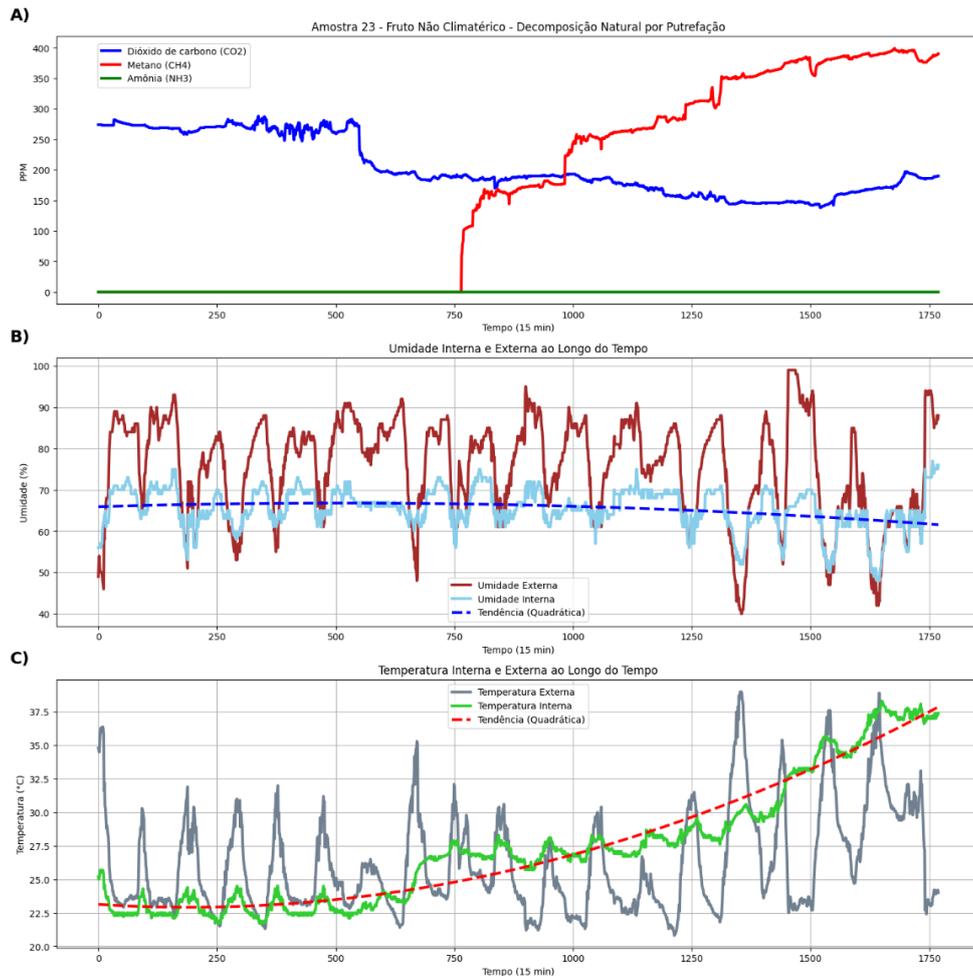


Figura 40: Dados obtidos com a putrefação em fruto não climatérico da Amostra-23. A) Nas medições dos gases CO_2 , CH_4 e NH_3 ; B) Na medição da umidade; C) Na medição da temperatura.

Fonte: Própria autoria.

Em outras amostras que apresentaram apenas mudança de cor como aspecto resultante do processo, ou seja, o primeiro estágio deste processo de decomposição, Os dados indicaram apenas uma única elevação da temperatura em comparação com as da Amostra-7 (Figura 39) e Amostra-23 (Figura 40). As outras características são muito semelhantes, bem como, a liberação de metano.

Observou-se que em condições de maior temperatura e umidade externa, a decomposição ocorreu de forma mais rápida, pois a temperatura externa alta influenciou no aumento da temperatura interna da caixa. Já em períodos de menor temperatura e de pouca umidade externas, a evolução do

processo foi mais lenta.

Em condições normais de temperatura e umidade, o processo de putrefação é bem menos comum de ocorrer, pois esse processo ocorre melhor em um ambiente com bactérias anaeróbias, que prosperam em lugares de baixo oxigênio.

Com os dados obtidos nesse processo, foi possível trazer uma melhor predição de quando esse processo de putrefação pode ocorrer, que seria nos casos em que: as amostras estejam já contaminadas por bactérias anaeróbicas; ou elas já estavam danificadas; ou possuíam alguma lesão no epicarpo que viabilizou a invasão de microrganismos ou quando a caixa for mais sensível a umidade e sem ventilação adequada, tornando a amostra propensa à putrefação.

3.3.3. Decomposição multifatorial

Sete amostras apresentaram em seus dados características diferentes, que identificaram um outro tipo de decomposição. O processo associado a esse tipo especial de decomposição do alimento foi denominado, para este trabalho, como processo ou decomposição multifatorial.

Geralmente, esses tipos de decomposição ocorrem por circunstâncias e em ambientes diferentes. A decomposição é influenciada por diversos fatores, temperatura, umidade, o nível de oxigenação e a composição orgânica presente. Conforme a Figura 41, a identificação de metano e amônia na Amostra-11, são indícios de alguma sobreposição entre a decomposição fúngica e a putrefação.

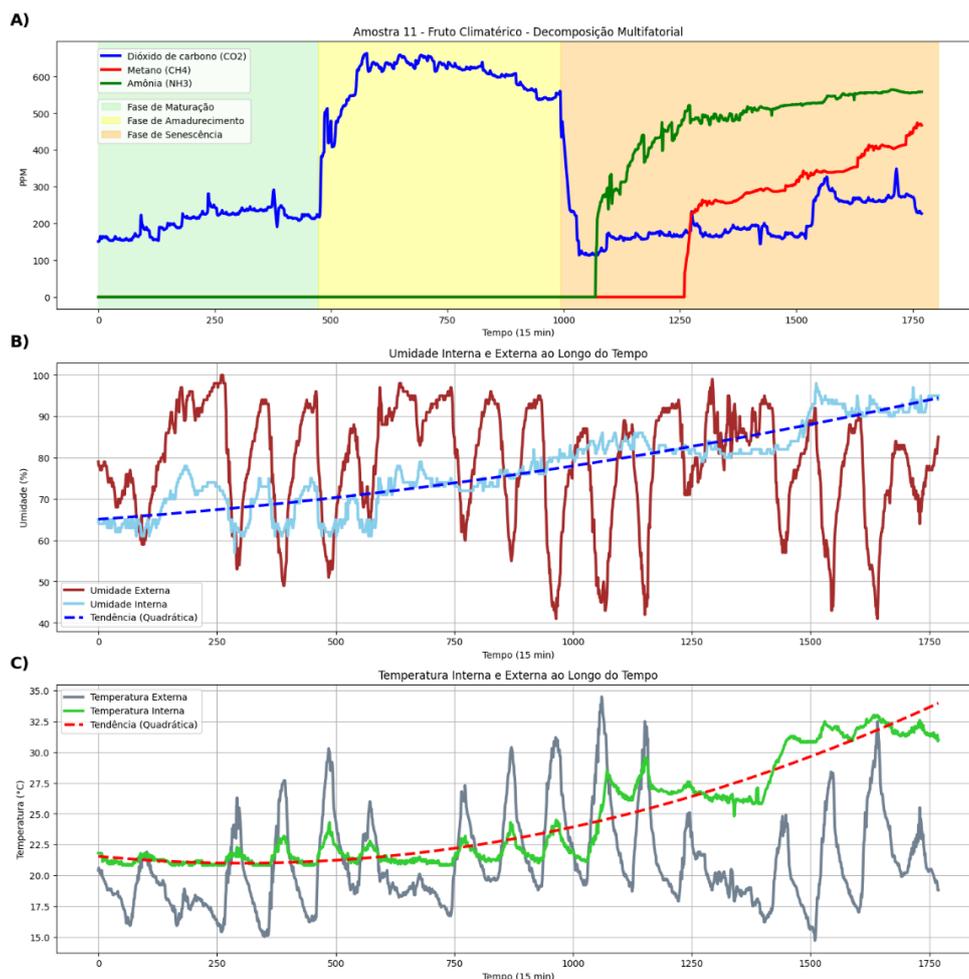


Figura 41: Dados obtidos com a decomposição multifatorial em fruto climatérico da Amostra-11.

A) Nas medições dos gases CO_2 , CH_4 e NH_3 ; B) Na medição da umidade; C) Na medição da temperatura.

Fonte: Própria autoria.

A aparência final da Amostra-11 apresentou semelhança com uma as amostras do grupo de decomposição fúngica, mas na comparação e análise dos fenômenos desses outros processos, percebeu-se que a ocorrência da liberação de metano indicou que outros fatores estavam atuando sobre essa amostra.

A amostra que sofreu do processo multifatorial apresentou a tendência da umidade e da temperatura se manterem ascendentes ao longo dos seus processos de decomposição, conforme podem ser vistos nas Figura 41-B e Figura 41-C, que foi um fator diferencial sobre os outros tipos de decomposição.

3.3.4. Decomposição por desidratação

A decomposição por desidratação é um processo químico que envolve a retirada de água da amostra (REECE et al., 2015). A desidratação ocorre devido as condições específicas de temperatura e umidade, e não está, de forma direta, relacionada com exposição e intensidade da luz solar (TAIZ et al., 2017).

Em locais com sol forte e clima seco, no entanto, pode haver mais influência sobre a taxa de desidratação. Colocar o alimento nesses ambientes, geralmente, é relevante quando o objetivo é a secagem de alimentos, preservando suas características alimentícias, como é o caso da secagem de grãos de café.

O processo de desidratação, com o uso da caixa, ocorreu de forma aleatória e inesperada. Com base nas aparências das outras decomposições e nas características físicas observadas nas amostras, verificou-se que ocorreu um processo de quebras das ligações químicas, resultando na desidratação de seis das amostras examinadas.

Observou-se que o processo de desidratação encontrou condições específicas para acontecer. Entretanto, observando as amostras e os dados obtidos, não foi possível identificar a ação de algum catalizador para promover a reação química.

Com o auxílio dos dados coletados, foi possível verificar que ocorreu total supressão de gás carbônico durante o processo (conforme visto na Figura 42-A). A liberação de gás carbônico aconteceu através do processo da respiração do fruto ou também da atividade metabólica dos microrganismos nele existentes. Também, não houve vestígios da detecção de metano e de amônia nas amostras que sofreram desidratação.

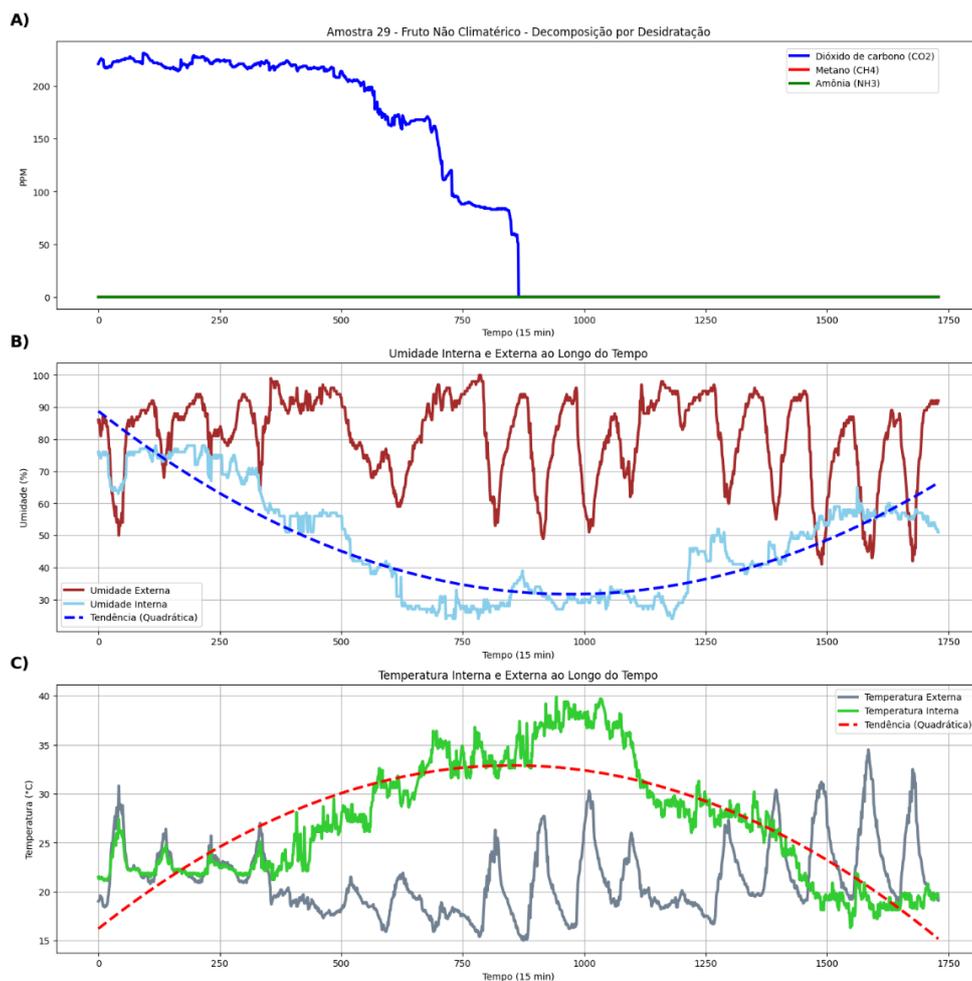


Figura 42: Dados obtidos com a decomposição por desidratação em fruto não climatérico da Amostra-29. A) Nas medições dos gases CO_2 , CH_4 e NH_3 ; B) Na medição da umidade; C) na medição da temperatura.

Fonte: Própria autoria.

A curva de tendência da umidade (Figura 42-B) e temperatura (Figura 42-C) apresentaram uma correlação inversa. Como a água é um produto da desidratação, a condição de ambiente mais seco da caixa evitou que ocorresse a reabsorção a água no fruto, enquanto, a elevação da temperatura indicou que a amostra sofreu uma reação química.

4. RESULTADOS

Neste capítulo são descritos os resultados obtidos com o auxílio do modelo treinado (estimador) para a identificação de alimentos que podem ou não ser consumidos; uma vez que o sistema foi treinado para identificar o tipo de decomposição que o alimento sofreria e que também foi programado para associar esse tipo de decomposição a característica do alimento ser ou não apto para consumo.

A tarefa de verificação levou em conta os indicativos emitidos pelo fruto, captado pelos sensores e classificados pela base de treinamento, possibilitando previsões mais acuradas. Foi possível realizar os testes sobre a viabilidade da CONT3NT3 na execução da tarefa de verificar o reaproveitamento ou não de um alimento, trabalhando com os dados do estágio inicial do seu processo de decomposição.

4.1. Testes com alimento que pode ser consumido a longo prazo

Para este teste foi utilizado um tomate de pequeno tamanho, adquirido dentro de um dia, com boas características visuais e olfativas. A amostra foi posta na caixa (Figura 43-A), que foi ligada para que fosse aquecido os resistores dos sensores.

Com um dispositivo móvel contendo o aplicativo principal, foi estabelecido o pareamento com a caixa. Uma vez estabelecido a comunicação, foi dado o comando que iniciou todo o processo de análise do alimento. Após 5 minutos, foi apresentado o resultado, indicando que o alimento poderia ser consumido sem riscos (Figura 43-B).

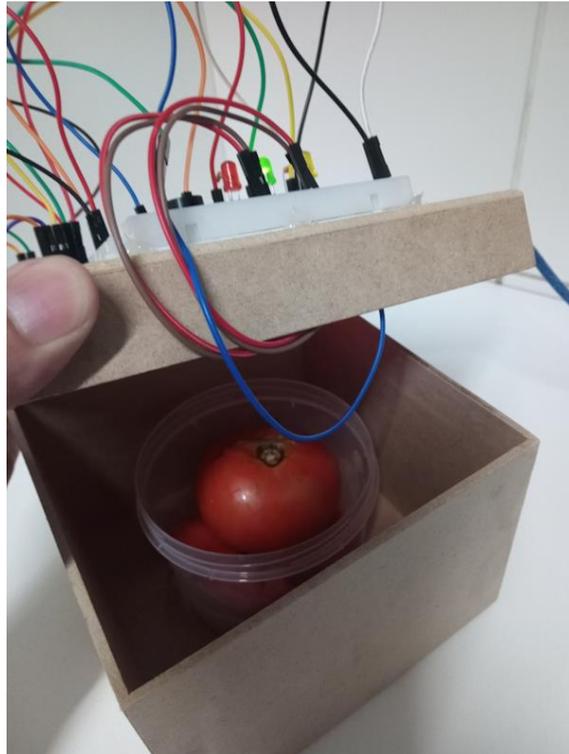


Figura 43: Tomate (*Lycopersicum esculentum Mill*) em ótimo estado, próprio para o consumo.

Fonte: Própria autoria.

O aplicativo realizou 10 rápidas leituras ao longo do processo de análise, verificando se havia a qualidade nos dados, para então submeter esses dados ao MC que compara com a base e retorna à predição sobre as condições do alimento.

A fim de confirmar essa primeira análise, que informou ser o alimento próprio para o consumo, outras 30 coletas, totalizando 300 leituras, foram realizadas durante o período de 60 minutos através do aplicativo. A informação final de todo processo consolidado pode ser observada na Figura 44.

Conforme pode ser visto nos dados obtidos, não foram identificadas oscilações nos dados dos gases (Figura 44-A), da temperatura (Figura 44-B) ou na umidade (Figura 44-C), também não houve registros dos gases metano e amônia ao longo das 30 medições

A amostra tinha uma coloração vermelha bem nítida e um elevado índice de dióxido de carbono, fator esse que indicou estar a amostra no ápice da fase de amadurecimento, também demonstrando que, através do processo de

análise, a CONT3NT3 identificou apreciação do tomate.

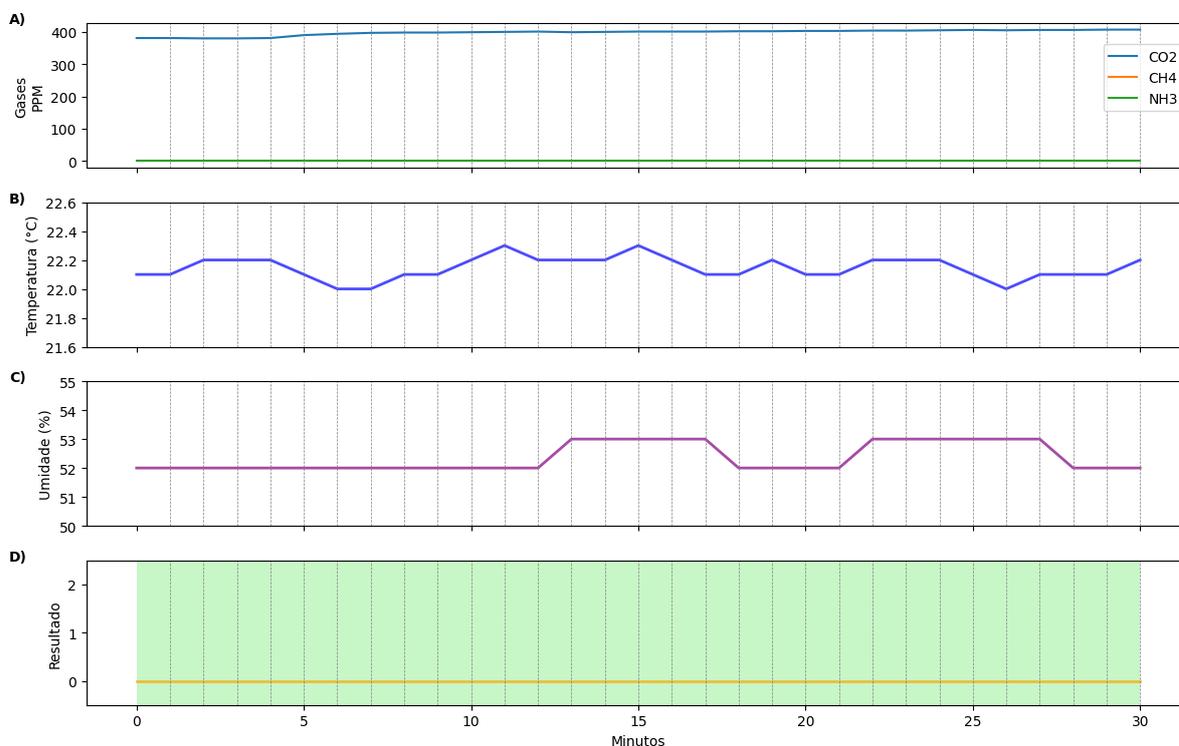


Figura 44: Teste 01 - Medições da validação do teste para o tomate. A) Medições dos gases CO_2 , CH_4 e NH_3 ; B) Medição da temperatura; C) Medição da umidade; D) Resultado.

Fonte: Própria autoria.

A Figura 44-D apresenta a análise final com a indicação verde, pois, uma vez não resultando, na comparação, nenhuma restrição em relação a gases nocivos, umidade ou temperatura, o aplicativo retorna com indicação positiva, ou seja, o valor 0. A construção da visualização gráfica do resultado para o usuário aparece na core verde.

4.2. Testes com alimento que deve ser consumido imediatamente (sem intervenção humana)

Para esse caso, foi inserida na caixa uma maçã de epicarpo bem

rugoso (Figura 45). Também, exala um aroma intenso, indicando que o fruto é suculento e doce. Ao ser colocada na caixa, apresentou um quadro de emissão similar ao visto na Figura 46.



Figura 45: Maça gala (*Malus Communis*) no estágio inicial de decomposição.

Fonte: Própria autoria.

Nesta mesma figura (Figura 46), pode-se observar que, ao longo do tempo, há o aparecimento de metano em baixa concentração. O odor fétido deste gás em baixas concentração é imperceptível aos seres humanos, todavia o sistema *E-nose* conseguiu identificá-lo. Isso é um indicativo de que o fruto iniciou a fase de decomposição e se aproxima do limite de se tornar não consumível.

Neste caso, o sistema *E-nose* indica um resultado marcado como “1”, o que significa que o alimento ainda é consumível, mas tem que ser consumido em no máximo 2 dias, antes que ele ingresse na fase de se tornar totalmente inconsumível.

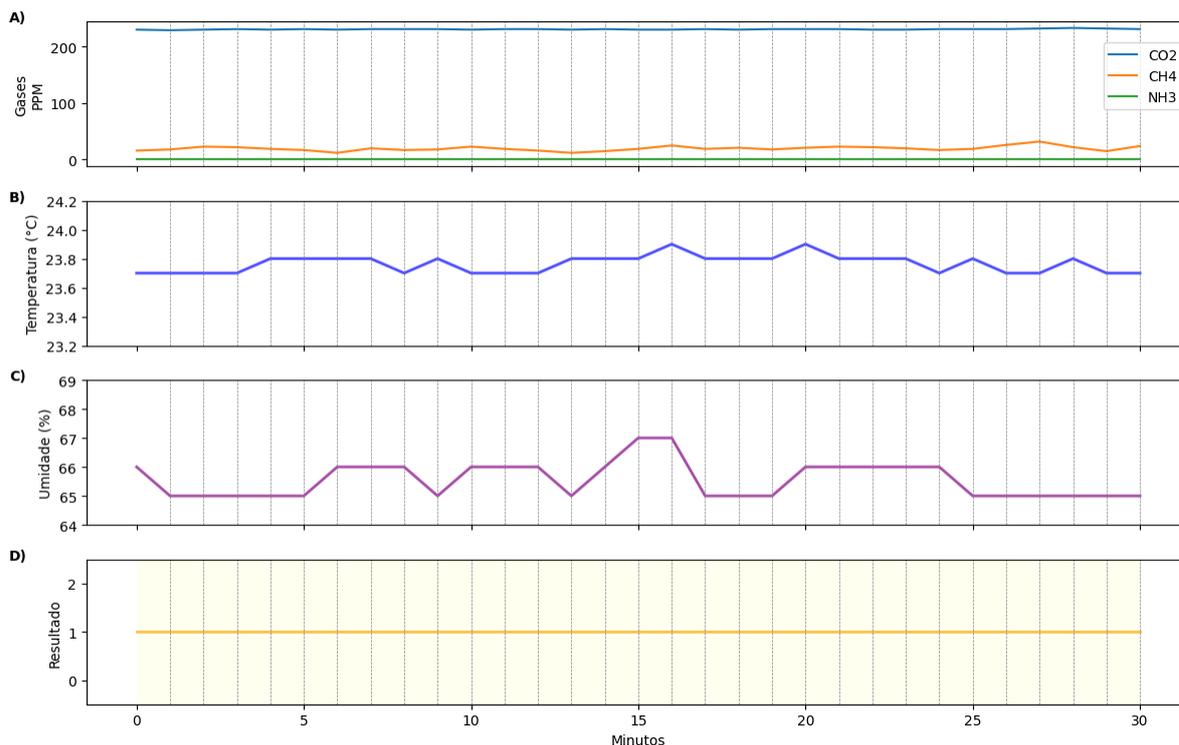


Figura 46: Teste 02 - Medições da validação do teste para a maçã. A) Medições dos gases CO_2 , CH_4 e NH_3 ; B) Medição da temperatura; C) Medição da umidade; D) Resultado.

Fonte: Própria autoria.

Para esse caso, é indicado uma cor de atenção (amarela), conforme visto na Figura 46-D. Isso informa que esse alimento está no limite para ser consumido sem problemas. Essa indicação auxilia para que se evite o descarte antecipado.

Essa situação também pode contribuir para que o alimento possa ser submetido ao processo visto no item posterior (de remoção da camada degradada), levando a novas fases de medidas.

4.3. Testes com alimento tratado com intervenção humana

Dois alimentos foram selecionados para essa modalidade de teste, uma maçã (Figura 47-A) e um pêssigo (Figura 47-B). Ambos apresentando

sinais mais acentuados do processo de decomposição. Enquanto a maçã mostrou sinais do processo de decomposição por putrefação, o pêssigo apresentou a degradação fúngica.

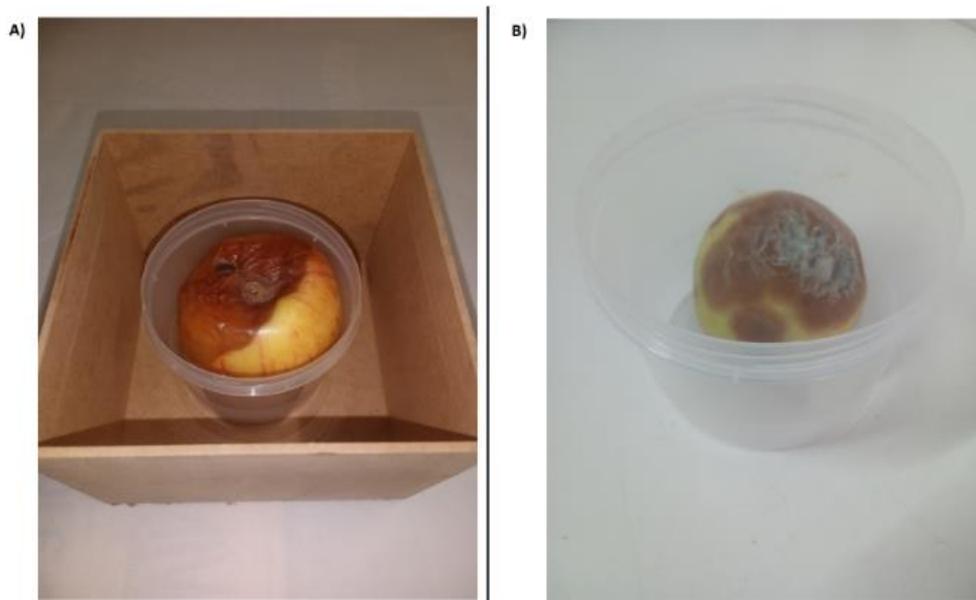


Figura 47: Alimentos no estágio de decomposição. A) Maçã gala (*Malus Communis*); B) Pêssego premier (*Prunus persica*).

Fonte: Própria autoria.

A abordagem deste tipo de teste se concentrou no registro das medições de controle em duas etapas. Para a primeira etapa, foram registradas as medições do alimento no estado inicial, sem a intervenção humana. E na segunda etapa, os registros foram obtidos após a remoção de parcela do alimento que apresentaram sinais da decomposição (Figura 48). Essas novas medições mostraram a situação dos alimentos após uma intervenção manual, que removeu as partes desinteressantes.

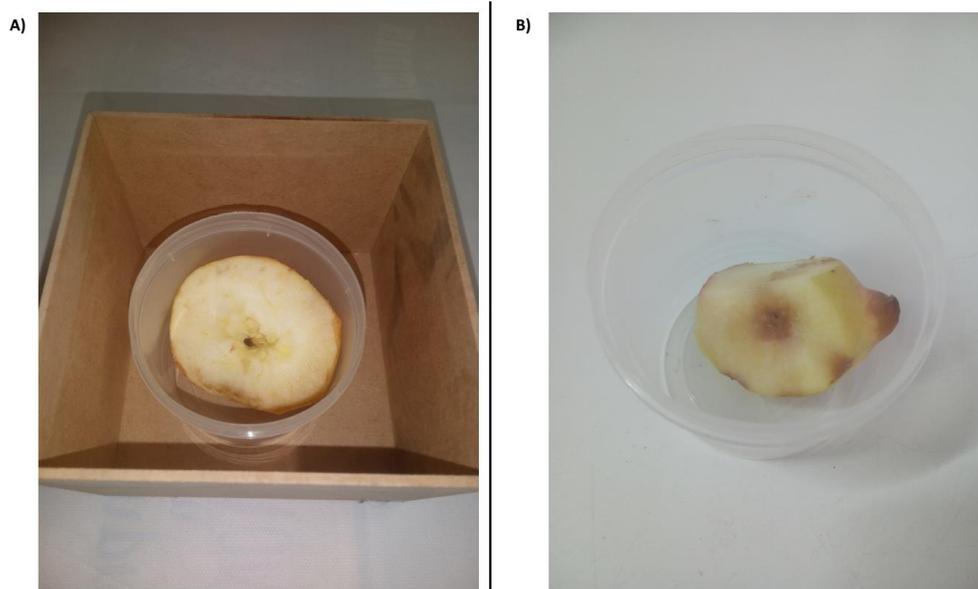


Figura 48: Remoção das partes atingidas pela decomposição. A) Maça; B) Pêssego.

Fonte: Própria autoria.

Para as novas medições, não foi necessário incluir os dados de temperatura e umidade na consolidação dos resultados. A flutuação destas características não variou, ao contrário do que ocorreu com os gases dióxido de carbono, metano e amônia que apresentaram variações em relação aos dados anteriormente obtidos dentro de um curto espaço de tempo.

Antes de expurgar o tecido danificado da maçã, foram coletadas 30 medições, conforme a Figura 49-A, no qual o aplicativo indicou em todas as medições estar o alimento em condições de não ser consumido (resultado visto na Figura 49-B).

Com a remoção do tecido degradado, novas 30 medições foram realizadas e a indicação do aplicativo apresentou modificação (Figura 49-D), indicando que a maçã estava apta para consumo.

Também, não foram identificadas medições de metano, devido a remoção da área afetada. Com a diminuição do peso do alimento, ocorreu a diminuição na emissão de dióxido de carbono (Figura 49-A e Figura 49-C).

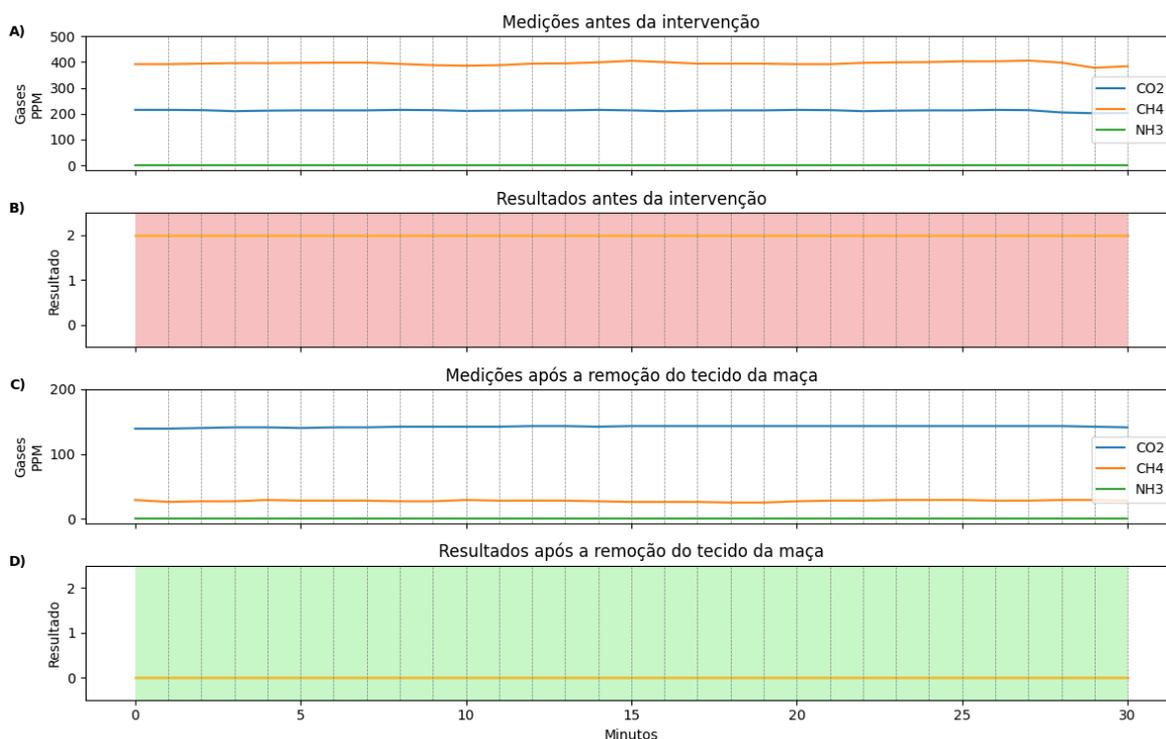


Figura 49: Medições e resultados antes e após a remoção da região afetada pela decomposição do tecido da maçã. A) Medições dos gases CO_2 , CH_4 e NH_3 antes da remoção; B) Resultado da verificação antes da remoção; C) Medições dos gases CO_2 , CH_4 e NH_3 após a remoção; D) Resultado após a remoção do tecido.

Fonte: Própria autoria.

O mesmo processo foi repetido com a amostra do pêssigo, obtendo-se medições do alimento com a parte degradada e depois com a extração manual desta parte. O aplicativo, após a remoção, também indicou a possibilidade de consumo da parte restante do alimento (Figura 50). Neste caso, durante os 30 minutos, não houve registros de gases produzidos.

Em ambos os casos, após a remoção da parte degradada, o alimento foi considerado apto para consumo a longo prazo, indicado pela cor verde no resultado, diferente da situação anterior, na qual, sem intervenção humana, o alimento indicou a necessidade de consumo rápido. Isso auxilia na tomada de decisão de consumo ou descarte por parte do usuário da CONT3NT3.

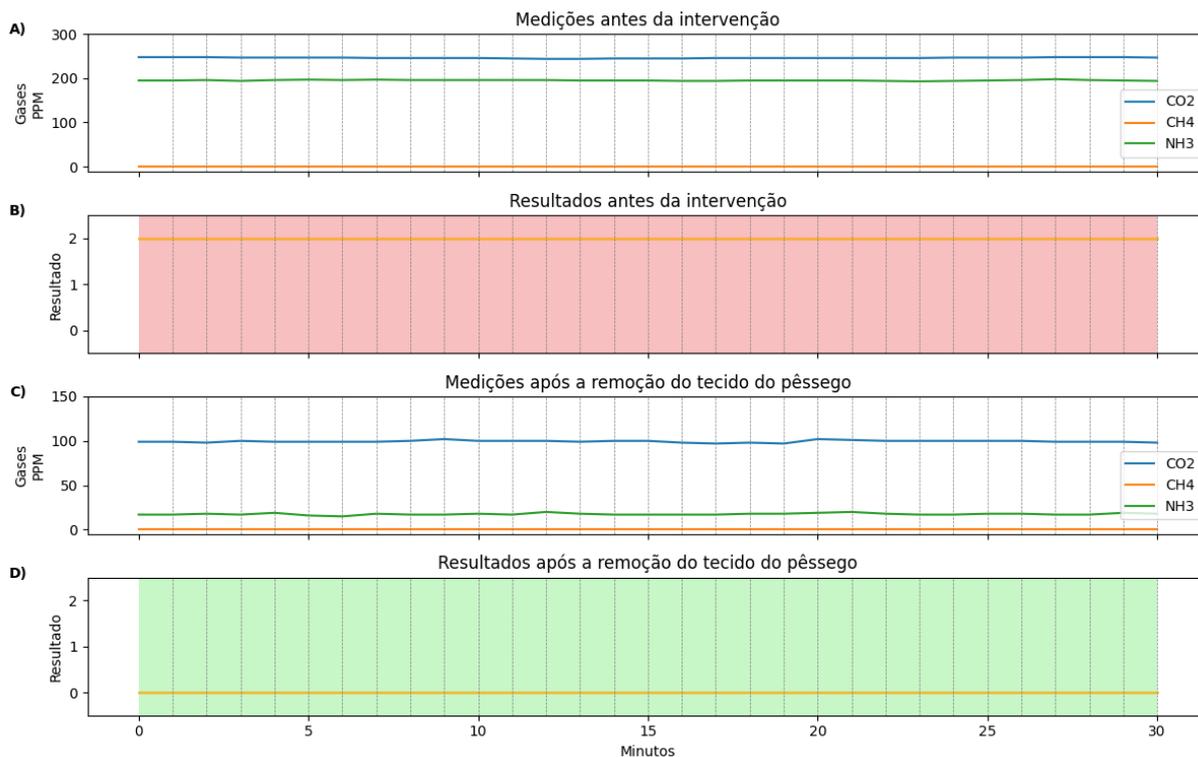


Figura 50: Medições e resultados antes e após a remoção da região afetada pela decomposição do tecido do pêssego. A) Medições dos gases CO_2 , CH_4 e NH_3 antes da remoção; B) Resultado da verificação antes da remoção; C) Medições dos gases CO_2 , CH_4 e NH_3 após a remoção; D) Resultado após a remoção do tecido.

Fonte: Própria autoria.

4.4. Testes com alimento para o descarte imediato

Neste teste, foi utilizada uma maçã tomada por fungos ao longo de sua superfície (Figura 51). Com base nas características visuais, devido aos indicativos do estágio avançado de decomposição, concluiu-se, de forma empírica, que o alimento não deveria ser consumido.

Para contribuir com a conclusão empírica, que foi baseada apenas na observação visual, o alimento foi submetido ao mesmo processo que os casos anteriores, no qual, após a análise, o aplicativo recomendou que este alimento não fosse consumido, indicando isso com o resultado parecendo com a cor de

fundo vermelha (que informa que o retorno das análises foi 2).



Figura 51: Maçã gala (*Malus Communis*) em avançado estágio de decomposição.

Fonte: Própria autoria.

Após o primeiro resultado fornecido pelo aplicativo, por 30 minutos, novas coletas foram realizadas. Estas novas medições tiveram como objetivo verificar se o aplicativo manteria a decisão sobre o alimento. Conforme a Figura 52-D apresenta, a análise do aplicativo manteve o resultado com base nos gases capturados pelo sistema *E-nose*, comparação nas bases de conhecimento extraídas e nas demais características.

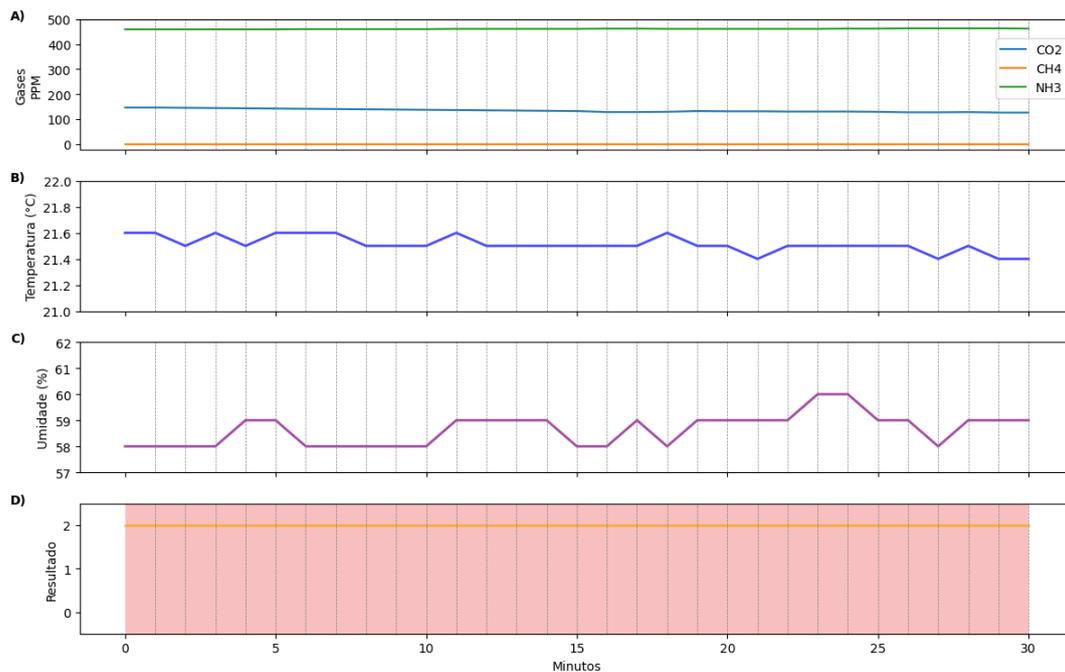


Figura 52: Resultado da validação do teste para a maçã que não é consumível. A) Nas medições dos gases CO_2 , CH_4 e NH_3 ; B) Na medição da temperatura; C) Na medição da umidade; D) Indicação de fruto não consumível.

Fonte: Própria autoria.

4.4. Discussão sobre resultados

Nos testes realizados, duas amostras apresentaram as características de serem consumidas de imediato (sinalização amarela), independente das condições visuais, que indicariam degradação e descarte imediato (Figura 53).

Isso mostra que as chances de reaproveitamento do alimento são menores de acordo com o avanço do processo de decomposição. Três quartos das amostras foram classificadas como inaproveitável de forma plena, conforme ilustra a Figura 53. A grande parcela destas amostras apresentou a característica de contaminação fúngica.

Contudo, na experiência sobre essas amostras, provou-se que a CONT3NT3 consegue “enxergar” além das decisões empíricas, baseadas em

olho e cheiro captados por órgãos humanos. Com critérios de IA, a CONT3NT3 consegue “salvar” do descarte prematuro alimentos que ainda podem ser reaproveitados, mesmo que em curto espaço de tempo.

Além disso, no experimento com intervenção humana, a CONT3NT3 também demonstrou ser capaz de identificar até que limite os dados da decomposição podem colocar um alimento na condição de descarte irreversível.

Sendo um instrumento de tomada de decisão, os testes demonstraram que a CONT3NT3 tem condições de atender as necessidades dos pequenos cozinheiros e “salvar” alimentos antes de uma ação de descarte muito apressada, contribuindo para a redução no desperdício de alimentos.

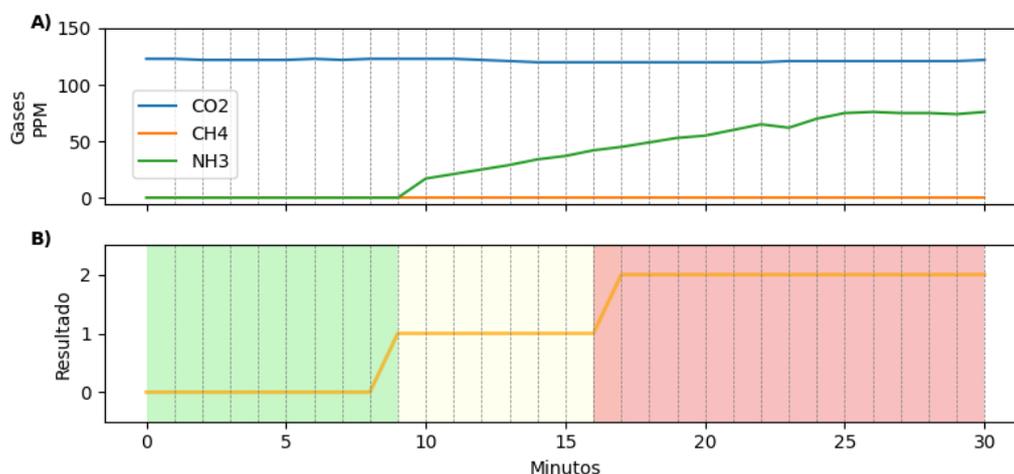


Figura 53: Amostra após a remoção da área comprometida pelo processo de decomposição. A) Medições dos gases CO_2 , CH_4 e NH_3 ; B) Resultados das verificações.

Fonte: Própria autoria.

Inicialmente, nas primeiras medições, em quatro amostras não foram detectadas a presença de amônia. Conforme a amostra permanecia no interior da caixa, o aplicativo indicou o consumo imediato e depois, com a continuidade da amostra ao longo do tempo, iniciou a apresentação das situações de descarte irreversível (Figura 53 **Erro! Fonte de referência não encontrada.**-B).

É importante ressaltar que esse processo de reaproveitamento do fruto, foi possível em apenas um quarto do total de amostras destinadas para este tipo de teste, incluindo as que apresentaram, condição amarela. Quanto

mais rápida e precoce a identificação do processo de decomposição, maior será a possibilidade de reaproveitamento com segurança alimentar.

Também, identificou-se que se o alimento apresentar deterioração no epicarpo (região externa, superfície) e a propagação seguir para o centro, mais fácil e rápida será a propagação para as regiões restante do fruto. Quanto mais avançado o processo de decomposição, maior o risco de contaminação por bactérias, fungos e outros microrganismos. Alimentos que estão visivelmente deteriorados, apresentam algum odor desagradável, textura alterada ou com a presença de mofo, tendem a não ser consumidos, sendo, em sua maioria, descartados.

O consumo de alimentos deteriorados pode levar a intoxicações alimentares e outros problemas de saúde; mas a conciliação deste exame de descartar ou não um alimento, com um grau de segurança alimentar satisfatório, foi uma tarefa bem menos complicada com o uso da CONT3NT3, que dirimiu as dúvidas visuais e possibilitou impedir descartes prematuros, ou consumo equivocado de alimentos já contaminados.

5 CONSIDERAÇÕES FINAIS

A experiência de utilizar a CONT3NT3 foi iniciada com o planejamento do projeto em 2019. A primeira versão operacional do dispositivo C0NT3NT3 foi exposta no evento internacional Green Rio de 2021, que foi um evento em parceria com o SELEA 21, e visava apresentar soluções para sustentabilidade, com apoio da UNESCO.

Neste evento, o projeto C0NT3NT3 e outros projetos, obtiveram notoriedade da comunidade acadêmica, junto a outras soluções para os temas de alimentação saudável e sustentável, luta contra o desperdício de alimentos e o impacto no meio-ambiente.

A partir daí a CONT3NT3 foi desenvolvida para ser uma plataforma no apoio a sustentabilidade, visando reduzir o desperdício de alimentos, indicando se um alimento está ou não apto de ser consumido. A base de sua tecnologia é que o menor sinal de decomposição é captado através da matriz de sensores do sistema de nariz eletrônico C0NT3NT3 e processado através da plataforma.

A coleta e tratamento dos dados utilizou-se de uma ampla pesquisa e aplicação dos métodos ligados a AM para a construção de um modelo eficiente de base de treinamento para identificar os padrões de decomposição e classificar a condição do alimento.

O modelo de AM construído com a combinação das técnicas PCA, LDA e SVM alcançou desempenho satisfatório durante o treinamento, obtendo um grau de precisão na classificação e predição da situação de alimentos de cerca de 96%

O aplicativo foi criado com foco em ser de fácil utilização e intuitivo, de forma que, os usuários executem as funcionalidades de forma simples. Todas as informações contidas no aplicativo têm como objetivo de ensinar o usuário sobre ações para ajudar o meio ambiente de maneira geral.

A plataforma de microsserviços foi construída para ser independente, tolerante a falhas, escalável e utilizando a tecnologia apropriada para a sua tarefa. Durante o uso, a velocidade na execução dos serviços, promoveu ao

usuário um processamento rápido e eficaz.

Durante os testes foram demonstradas a capacidade de identificação do estado do alimento através da plataforma CONT3NT3. Mediante uma rápida verificação o aplicativo foi possível informar o estado do alimento, indicando se deve ou não ser consumido. Esta aplicação pode ser utilizada em diversos setores, desde início da cadeia de produção, distribuição e entrega de um produto.

O projeto pode ser adaptado com a finalidade de ser utilizado para o reaproveitamento de alimentos na indústria alimentícia. Mas para alcançar este objetivo, se faz necessário estudos mais detalhados sobre a contaminação do alimento em estágios mais avançados no processo de decomposição.

Entretanto, a OMS alerta sobre os principais cuidados em consumir frutas e legumes parcialmente podres ou descartados. Todavia, existindo uma ferramenta que seja precisa em captar o odor de quaisquer toxinas produzidas por fungos e bactérias torna essa possibilidade muito tangível.

As recomendações para trabalhos futuros no que tange o combate ao desperdício de alimentos:

- Implementação de um dispositivo que contenha nariz e língua eletrônica. Os sabores podem fornecer informações mais ricas para entendimento do processo de decomposição;
- Expandir a capacidade do *E-nose* com sensores capazes de identificar toxinas produzidas por fungo e bactérias;
- Inserir sensores de etileno e pressão para buscar melhor compreensão sobre a influência ao longo do processo de amadurecimento em frutos climatéricos.
- Inserir uma balança de precisão para medir o ganho e a perda do peso do alimento ao longo das fases de desenvolvimento, amadurecimento e senescência.

Acrescenta-se que a CONT3NT3 foi um projeto que gerou um registro de depósito de patente, conforme as regras do INPI em 2022, gerando o processo associado e em estágio de exame de patente iniciado em outubro de

2023, respeitando-se os seis meses de tempo de espera para projetos acadêmicos (INPI, 2022). Espera-se que o exame possa, ao final, registrar a patente da CONT3NT3 como um invento que possa ser comercializado e fabricado serialmente.

REFERÊNCIAS BIBLIOGRÁFICAS

ABONIZIO, J. Consumo alimentar e anticonsumismo: veganos e freeganos. **Ciências Sociais Unisinos**, 49, n. 2, 2013. 191-196.

AL-DAYYENI, W. S. et al. A review on electronic nose: coherent taxonomy, classification, motivations, challenges, recommendations and datasets. **IEEE Access**, 9, 2021. 88535-88551.

ALI, M. M. et al. Principles and recent advances in electronic nose for quality inspection of agricultural and food products. **Trends in Food Science & Technology**, 99, 2020. 1-10.

ALIAÑO-GONZÁLEZ, M. J. et al. An electronic nose based method for the discrimination of weathered petroleum-derived products. **Sensors**, 18, n. 7, 2018. 2180.

ALPAYDIN, E. **Introduction to machine learning**. 3ª. ed. Cambridge: MIT press, 2010. ISBN 978-0-262-02818-9.

ANDRE, R. S. et al. Electronic nose based on hybrid free-standing nanofibrous mats for meat spoilage monitoring. **Sensors and Actuators B: Chemical**, 353, 2022. 131114.

AOUADI, B. et al. Historical evolution and food control achievements of near infrared spectroscopy, electronic nose, and electronic tongue—Critical overview. **Sensors**, 20, n. 19, 2020. 5479.

ARSHAK, K. et al. A review of gas sensors employed in electronic nose applications. **Sensor review**, 24, n. 2, 2004. 181-198.

ASHRAE, H. **Fundamentals: 2001 Ashrae Handbook**. Revised Edition. ed. Atlanta: Amer Society of Heating, 2001. ISBN 978-1883413873.

BAJWA, I. S. et al. Smart eNose Food Waste Management System. **Hindawi Journal of Sensors**, p. 13, jul. 2021.

BANZI, M.; SHILOH, M. **Getting started with Arduino: the open source electronics prototyping platform**. 3ª. ed. [S.l.]: Maker Media, Inc., 2015. 262 p. ISBN 9781449363338.

BARROZO, V. P. et al. Desperdício de Alimentos: O peso das perdas para os Recursos Naturais. **Revista Agroecossistemas**, v. 11, n. 1, p. 75-96, 2019.

BASSEY, A. P. et al. Evaluation of physicochemical, microbiological, and sensory profiles of vacuum-packed cooked low-salt pork belly under refrigeration and

room-temperature storage. **LWT**, 167, 2022. 113847.

BAUER, V. R. P.; WALLY, A. P.; PETER, M. Z. **Tecnologia de frutas e hortaliças**. Pelotas: Rede e-Tec Brasil, 2014.

BENÍTEZ, R. O. Perdas e desperdícios de alimentos na América Latina e no Caribe. **Food and Agriculture Organization of the United Nations**, 2021. Disponível em: <<https://www.fao.org/americas/noticias/ver/pt/c/239394/>>. Acesso em: 23 set. 2021.

BEZERRA, . **Princípios de Análise e Projeto de Sistemas com UML**. 3. ed. Rio de Janeiro: Elsevier, 2015. 416 p. ISBN 978-85-352-2626-3.

BISHOP, C. M. **Neural networks for pattern recognition**. Oxford: Oxford university press, 1995.

BISHOP, C. M. **Pattern recognition and machine learning**. 1. ed. New York: Springer, 2006. 738 p. ISBN 978-1-4939-3843-8.

BONAH, E. et al. Application of electronic nose as a non-invasive technique for odor fingerprinting and detection of bacterial foodborne pathogens: A review. **Journal of food science and technology**, 57, 2020. 1977-1990.

BONAH, E. et al. Detection of Salmonella Typhimurium contamination levels in fresh pork samples using electronic nose smellprints in tandem with support vector machine regression and metaheuristic optimization algorithms. **Journal of Food Science and Technology**, 58, 2021. 3861-3870.

BRON, I. U.; JACOMINO, A. P. Classificação de frutos por "climatério" é um conceito em extinção? **Visão Agrícola**, Piracicaba, p. 8-10, Janeiro 2007.

BRUCE, A.; BRUCE, P. **Estatística Prática para Cientistas de Dados - 50 Conceitos Essenciais**. 1ª. ed. Rio de Janeiro: Alta Books, 2019. 392 p. ISBN 978-85-508-1300-4.

BRUDZEWSKI, K.; OSOWSKI, S.; PAWLOWSKI, W. Metal oxide sensor arrays for detection of explosives at sub-parts-per million concentration levels by the differential electronic nose. **Sensors and Actuators B: Chemical**, 161, n. 1, 2012. 528-533.

BRUINS, M. et al. Diagnosis of active tuberculosis by e-nose analysis of exhaled air. **Tuberculosis**, 93, n. 2, 2013. 232-238.

BUZBY, J. C.; FARAH-WELLS, H.; HYMAN, J. The estimated amount, value, and calories of postharvest food losses at the retail and consumer levels in the United States. **USDA-ERS Economic Information Bulletin**, n. 121, 2014.

CALVO-PORRAL, C.; MEDÍN, A. F.; LOSADA-LÓPEZ, C. Can marketing help in

tackling food waste?: Proposals in developed countries. **Journal of food products marketing**, 23, n. 1, 2017. 42-60.

CAO, J. et al. Drift Compensation on Massive Online Electronic-Nose Responses. **Chemosensors**, 9, n. 4, 2021. 78.

CAO, Y.; WU, Z.; WENG, P. Comparison of bayberry fermented wine aroma from different cultivars by GC-MS combined with electronic nose analysis. **Food Science & Nutrition**, 8, n. 2, 2020. 830-840.

CAPELLI, L.; SIRONI, S.; ROSSO, R. D. Electronic noses for environmental monitoring applications. **Sensors**, 14, n. 11, 2014. 19979-20007.

CARLSON, N. R. **Fisiologia do comportamento**. 7^a. ed. Barueri: Manole, 2002. 749 p. ISBN 85-204-1161-4.

CARMEN, E. et al. The social dynamics in establishing complex community climate change initiatives: the case of a community fridge in Scotland. **Sustainability Science**, 17, n. 1, 2022. 259-273.

COZZOLINO, R. et al. Electronic-nose as non-destructive tool to discriminate "ferrovia" sweet cherries cold stored in air or packed in high CO₂ modified atmospheres. **Frontiers in Nutrition**, 8, 2021. 720092.

CRUZ, E. C. A.; JÚNIOR, S. C. **Eletrônica Aplicada**. 2^a. ed. São Paulo: Érica, 2007. 296 p. ISBN 978-85-365-1163-4.

DE CASTRO, L. N.; FERRARI, D. G. **Introdução à mineração de dados: conceitos básicos, algoritmos e aplicações**. São Paulo: Saraiva, 2016. ISBN 978-85-472-0099-2.

DECI, E. L.; RYAN, R. M. **Intrinsic Motivation and Self-Determination in Human Behavior**. New York: Springer Science & Business Media, 2013. 372 p. ISBN 9781489922717.

DELURGIO, S. A. **Forecasting principles and applications**. Singapore: McGraw-Hill, 1998. 802 p.

DESHMUKH, S. et al. Application of electronic nose for industrial odors and gaseous emissions measurement and monitoring - an overview. **Talanta**, 144, 2015. 329-340.

DEY, A. Semiconductor metal oxide gas sensors: A review. **Materials science and Engineering: B**, 229, 2018. 206-217.

DUNG, T. et al. Applications and advances in bioelectronic noses for odour sensing. **Sensors**, v. 18, p. 103, 2018.

EAMSA-ARD, T. et al. Development of Electronic Nose for evaluation of Fragrance and human body Odor in the cosmetic industry. **2018 IEEE 7th global Conference on consumer Electronics (GCCE)**. Nara, Japan: IEEE. 2018. p. 363-364.

EDITA, R. et al. Rapid evaluation of fresh chicken meat quality by electronic nose. **Czech Journal of Food Sciences**, 36, 2018. 420-426.

EIKENBERRY, N.; SMITH,. Attitudes, beliefs, and prevalence of dumpster diving as a means to obtain food by Midwestern, low-income, urban dwellers. **Agriculture and Human Values**, p. 187-202, 2005.

ESCALANTE-MINAKATA, P. et al. Optimización de la extracción enzimática de jugo de banano a partir de los cultivares enano gigante, FHIA-17 y FHIA-23. **Universidad y ciencia**, 29, 2013. 1-9.

ESTAKHROYEH, H. R.; ESMAT, R.; MAHDIYEH, M. Design and construction of electronic nose for multi-purpose applications by sensor array arrangement using IBGSA. **Journal of Intelligent & Robotic Systems**, v. 92, p. 205-221, 2018.

EZHILAN, M. et al. A multiple approach combined with portable electronic nose for assessment of post-harvest sapota contamination by foodborne pathogens. **Food and Bioprocess Technology**, 13, 2020. 1193-1205.

FALASCONI, M. et al. Electronic nose for microbiological quality control of food products. **International Journal of Electrochemistry**, 2012, 2012. 12.

FAO. **Criar Cidades Mais Verdes**. Food and Agriculture Organization of the United Nations. Roma, p. 20. 2012.

FAO. **Food wastage footprint Impacts on natural resources**. Food and Agriculture Organization of the United Nations. [S.l.], p. 63. 2013. (978-92-5-107752-8).

FAO. O desperdício alimentar tem consequências ao nível do clima, da água, da terra e da biodiversidade. **Food and Agriculture Organization of the United Nations.**, 11 set. 2013. Disponível em: <<https://www.fao.org/news/story/pt/item/204029/icode/>>. Acesso em: 13 out. 2021.

FARRAIA, M. V. et al. The electronic nose technology in clinical diagnosis: A systematic review. **Porto biomedical journal**, 4, n. 4, 2019.

FERREIRO-GONZÁLEZ, M. et al. Determination of ignitable liquids in fire debris: Direct analysis by electronic nose. **Sensors**, 16, n. 5, 2016. 695.

FISHER, R. A. The use of multiple measurements in taxonomic problems. **Annals of eugenics**, 7, n. 2, 1936. 179-188.

FUJIOKA, K. Comparison of cheese aroma intensity measured using an electronic nose (e-nose) non-destructively with the aroma intensity scores of a sensory evaluation: A pilot study. **Sensors**, 21, n. 24, 2021. 8368.

GAMBOA, J. C. R. et al. Electronic nose dataset for detection of wine spoilage thresholds. **Data in brief**, 25, 2019. 104202.

GÓRSKA-HORCZYCZAK, E. et al. Applications of electronic noses in meat analysis. **Food Science and Technology**, 36, 2016. 389-395.

GÓRSKA-HORCZYCZAK, E. et al. Differentiation of chill-stored and frozen pork necks using electronic nose with ultra-fast gas chromatography. **Journal of Food Process Engineering**, 40, n. 5, 2017. e12540.

GRASSI, S. et al. Seafood freshness: E-nose data for classification purposes. **Food Control**, 138, 2022. 108994.

GUIMARÃES, P. R. B. **Métodos quantitativos estatísticos**. 2^a. ed. Curitiba: IESDE BRASIL S/A, 2018. 174 p. ISBN 978-85-387-6447-2.

GÜNEY, S.; ATASOY, A. Study of fish species discrimination via electronic nose. **Computers and Electronics in Agriculture**, 119, 2015. 83-91.

GUO, L. et al. Portable food-freshness prediction platform based on colorimetric barcode combinatorics and deep convolutional neural networks. **Advanced Materials**, v. 32, n. 45, p. 8, 2020. ISSN 2004805.

GUO, T. et al. Domain adaptive subspace transfer model for sensor drift compensation in biologically inspired electronic nose. **Expert Systems with Applications**, 208, 2022. 118237.

GUSTAVSSON, J. et al. **Global food losses and food waste**. Food and Agriculture Organization of the United Nations. Rome. 2011. (978-92-5-107205-9).

HALL, K. D. et al. The progressive increase of food waste in America and its environmental impact. **PloS one**, 4, n. 11, 2009. e7940.

HAN, F. et al. Nondestructive detection of fish freshness during its preservation by combining electronic nose and electronic tongue techniques in conjunction with chemometric analysis. **Analytical Methods**, 6, n. 2, 2014. 529-536.

HANY, A. et al. An Intelligent Electronic Nose for the assistance of Anosmic-Patients. **2022 2nd International Mobile, Intelligent, and Ubiquitous Computing Conference (MIUCC)**. Cairo, Egypt: IEEE. 2022. p. 197-202.

HASAN, M. A.; SARNO, R.; SABILA, S. I. Optimizing Machine Learning

Parameters for Classifying the Sweetness of Pineapple Aroma Using Electronic Nose. **Jornal Internacional de Engenharia e Sistemas Inteligentes**, v. 13, n. 5, p. 122-132, 2020.

HASTIE, T. et al. **The elements of statistical learning: data mining, inference, and prediction**. New York: Springer, v. 2, 2009. ISBN 978-0-387-84857-0.

HEIDARBEIGI, K. et al. Detection of adulteration in saffron samples using electronic nose. **International Journal of Food Properties**, 18, n. 7, 2015. 1391-1401.

HICKMAN, C. P. et al. **Princípios Integrados de Zoologia**. 16^a. ed. Rio de Janeiro: Guanabara Koogan, 2016. 1928 p. ISBN 978-85-277-2960-4.

HONG, S. et al. FET-type gas sensors: A review. **Sensors and Actuators B: Chemical**, 330, 2021. 129240.

HONG, X.; WANG, J. Detection of adulteration in cherry tomato juices based on electronic nose and tongue: Comparison of different data fusion approaches. **Journal of Food Engineering**, 126, 2014. 89-97.

HUANG, L. et al. Nondestructive measurement of total volatile basic nitrogen (TVB-N) in pork meat by integrating near infrared spectroscopy, computer vision and electronic nose techniques. **Food chemistry**, 145, 2014. 228-236.

JHA, S. K. Characterization of human body odor and identification of aldehydes using chemical sensor. **Reviews in Analytical Chemistry**, 36, n. 2, 2017.

JIA, W. et al. Advances in electronic nose development for application to agricultural products. **Food Analytical Methods**, 12, 2019. 2226-2240.

JIANG, J. et al. Rapid freshness analysis of mantis shrimps (*Oratosquilla oratoria*) by using electronic nose. **Journal of Food Measurement and Characterization**, 10, 2016. 48-55.

JIRAYUPAT, C. et al. Breath odor-based individual authentication by an artificial olfactory sensor system and machine learning. **Chemical Communications**, 58, n. 44, 2022. 6377-6380.

JO, Y. et al. Comparative analysis of sensory profiles of commercial cider vinegars from Korea, China, Japan, and US by SPME/GC-MS, E-nose, and E-tongue. **Korean Journal of Food Science and Technology**, 48, n. 5, 2016. 430-436.

JOHN, A. T. et al. An Outlook of Recent Advances in Chemiresistive Sensor-Based Electronic Nose Systems for Food Quality and Environmental Monitoring. **Sensors**, v. 21, n. 7, p. 2271, 2021.

JOÑCA, J. et al. Electronic noses and their applications for sensory and analytical measurements in the waste management plants—A review. **Sensors**, 22, n. 4, 2022. 1510.

KALMAN, R. E. A new approach to linear filtering and prediction problems. **Transactions of the ASME - Journal of Engineering**, 1960. 35-45.

KANAKAM, P.; CHAKRAVARTHY, A. Human Identification with their VOC distribution through CMS - SEN Model. **Soft Computing**, 25, 2021. 13015-13025.

KARAKAYA, D.; ULUCAN, O.; TURKAN, M. Electronic Nose and Its Applications: A Survey. **International journal of Automation and Computing**, 17, 2020. 179-209.

KUCHMENKO, T. et al. Portable electronic nose system for fast gynecological-conditions diagnosis in consulting room: A case study. **Sensors and Actuators B: Chemical**, 358, 2022. 131538.

LAUDON, K.; LAUDON, J. **Sistemas de Informações Gerenciais**. Tradução de Luciana do Amaral Teixeira. 9ª. ed. São Paulo: Pearson, 2011.

LEITE, L. S. et al. Design and implementation of an electronic nose system for real-time detection of marijuana. **Instrumentation Science & Technology**, 49, n. 5, 2021. 471-486.

LI, H. et al. Non-destructive evaluation of pork freshness using a portable electronic nose (E-nose) based on a colorimetric sensor array. **Analytical Methods**, 6, n. 16, 2014. 6271-6277.

LI, L. et al. Effects of soy protein isolate on the physicochemical properties of Fresh extruded rice-shaped kernels, 2022. 1-11.

LI, Y. Deep reinforcement learning: An overview. **arXiv preprint arXiv:1701.07274**, 2018.

LIU, B. et al. Lung cancer detection via breath by electronic nose enhanced with a sparse group feature selection approach. **Sensors and Actuators B: Chemical**, 339, 2021. 129896.

LIU, C. et al. Fusion of electronic nose and hyperspectral imaging for mutton freshness detection using input-modified convolution neural network. **Food Chemistry**, 385, 2022. 132651.

LIU, Q. et al. Discrimination and growth tracking of fungi contamination in peaches using electronic nose. **Food chemistry**, 262, 2018. 226-234.

LÓPEZ, P. et al. Electronic nose prototype for explosive detection. **2017**

CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON). Pucon, Chile: IEEE. 2017. p. 1-4.

LU, W. et al. Establishment of a freshness-evaluating standard for chilled yellow chicken meat. **Food Analytical Methods**, 10, 2017. 2629-2635.

LUENGO, R. D. F. A. et al. **Pós-colheita de Hortaliças**. Brasília, DF: Embrapa Informação Tecnológica, 2007. 100 p. ISBN 978-85-7383-383-6.

LUNDSTRÖM, I. et al. A hydrogen - sensitive MOS field - effect transistor. **Applied Physics Letters**, 26, n. 2, 1975. 55-57.

LUNDSTRÖM, I. et al. From hydrogen sensors to olfactory images—twenty years with catalytic field-effect devices. **Sensors and Actuators B: Chemical**, 13, n. 1-3, 1993. 16-23.

MALOCHLEB, M. Artificial nose detects meat freshness. **Food Technology**, v. 75, n. 1, p. 10, 2021. ISSN 0015-6639.

MARIN, A. C.; SCHAEFER, A. T.; ACKELS, T. Spatial information from the odour environment in mammalian olfaction. **Cell and Tissue Research**, 383, 2021. 473-483.

MARQUES, Â. E. B. et al. **Dispositivos Semicondutores Diodos e transistores**. 4^a. ed. São Paulo: Érica, 2001.

MASSON-DELMOTTE, V. et al. Climate change 2021: the physical science basis. **Contribution of working group I to the sixth assessment report of the intergovernmental panel on climate change**, 2, 2021.

MCLACHLAN, G. J. **Discriminant analysis and statistical pattern recognition**. New Jersey: John Wiley & Sons, 2005.

MITCHELL, T. M. **Machine learning**. [S.l.]: McGraw-hill New York, v. 1, 1997. 432 p. ISBN 9780071154673.

MODESTI, M. et al. E-nose and olfactory assessment: Teamwork or a challenge to the last data? The case of virgin olive oil stability and shelf life. **Applied Sciences**, 11, n. 18, 2021. 8453.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos Sobre Aprendizado de Máquina. In: REZENDE, S. O. **Sistemas inteligentes: fundamentos e aplicações**. Barueri: Manole Ltda, 2003. Cap. 4, p. 39-56.

MORÉ, V. C. Dumpster Dinners: An Ethnographic Study of Freeganism. **The Journal for Undergraduate Ethnography**, n. 1, p. 43-55, 2011.

MUNEKATA, P. E. et al. Applications of Electronic Nose, Electronic Eye and Electronic Tongue in Quality, Safety and Shelf Life of Meat and Meat Products: A Review. **Sensors**, 23, n. 2, 2023. 672.

NAGAPPAN, P. G.; SUBRAMANIAM, S.; WANG, D.-Y. Olfaction as a soldier - a review of the physiology and its present and future use in the military. **Military Medical Research**, 4, n. 1, 2017. 1-12.

NAIR, K. et al. Expiry Prediction and Reducing Food Wastage using IoT and ML. **International journal of electrical and computer engineering systems**, v. 12, n. 3, p. 155-162, 2021.

NASCIMENTO-JÚNIOR, B. J. D. **Anatomia humana sistemática básica**. 1ª ed. Petrolina: UNIVASF, 2020. 228 p. ISBN 978-65-991384-4-7.

NEPA. **Tabela brasileira de composição de alimentos - TACO**. Núcleo de Estudos e pesquisas em Alimentação. Campinas, p. 161. 2011.

NIMSUK, N. Improvement of accuracy in beer classification using transient features for electronic nose technology. **Journal of Food Measurement and Characterization**, 13, n. 1, 2019. 656-662.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS. Objetivos de Desenvolvimento Sustentável. **Nações Unidas Brasil**, 2023. Disponível em: <<https://brasil.un.org/pt-br/sdgs>>. Acesso em: 14 fev. 2023.

PARFITT, J.; BARTHEL, M.; MACNAUGHTON, S. Food waste within food supply chains: quantification and potential for change to 2050. **Philosophical transactions of the royal society B: biological sciences**, 365, n. 1554, 2010. 3065-3081.

PERSAUD, K.; DODD, G. Analysis of discrimination mechanisms in the mammalian olfactory system using a model nose. **Nature**, 299, 1982. 352–355.

PINGER, M. et al. Perceived utility of electronic noses in patients with loss of smell. **European Archives of Oto-Rhino-Laryngology**, 278, 2021. 2155-2156.

PINTO, J. M. Olfaction. **Proceedings of the American Thoracic Society**, 8, n. 1, 2011. 46-52.

QUARTO, A. et al. Electronic nose for evaluating water use in beer production. **2017 ISOCS/IEEE International Symposium on Olfaction and Electronic Nose (ISOEN)**. Montreal, QC, Canadá: IEEE. 2017. p. 1-3.

QUESTED, T. E. et al. Spaghetti soup: The complex world of food waste behaviours. **Resources, Conservation and Recycling**, 79, 2013. 43-51.

QUIÑONES-MONTENEGRO, L. Y.; HERRERA-PEDRAZA, E.; ORTEGA-

CHÁVEZ, L. Fabricación de un detector de N₂O a base de un polímero conductor. **TECNOCENCIA Chihuahua**, 7, n. 1, 2013. 25-31.

RADI, R. et al. Freshness assessment of tilapia fish in traditional market based on an electronic nose. **Bulletin of Electrical Engineering and Informatics**, 10, n. 5, 2021. 2466-2476.

REECE, J. B. et al. **Biologia de Campbell**. 10^a. ed. Porto Alegre: Artmed, 2015. 1442 p. ISBN 978-85-8271-230-6.

REIDT, U. et al. Detection of microorganisms onboard the international space station using an electronic nose. **Gravitational and Space Research**, 5, n. 2, 2017. 89-111.

RIEDMILLER, M. et al. Reinforcement learning for robot soccer. **Autonomous Robots**, 27, 2009. 55-73.

RIZZOLO, A. et al. Electronic nose to detect volatile compound profile and quality changes in 'Spring Belle' peach (*Prunus persica* L.) during cold storage in relation to fruit optical properties measured by time-resolved reflectance spectroscopy. **Journal of agricultural and food chemistry**, 61, n. 8, 2013. 1671-1685.

ROMAIN, A.-C.; NICOLAS, J. Long term stability of metal oxide-based gas sensors for e-nose environmental applications: An overview. **Sensors and Actuators B: Chemical**, 146, n. 2, 2010. 502-506.

ROY, M.; YADAV, B. K. Electronic nose for detection of food adulteration: A review. **Journal of Food Science and Technology**, 2021. 1-13.

RUBIN, D. B. **Multiple Imputation for Nonresponse in Surveys**. Hoboken: John Wiley & Sons, 1987. ISBN 9780470316696.

RUBIO, J. J. et al. A fuzzy inference system for the identification. **IEEE Latin America Transactions**, v. 13, n. 9, p. 2823-2829, 2015.

RUBIO, J. J. et al. Classification via an Embedded Approach. **Designs**, v. 1, p. 7, 2017.

SAIDI, T. et al. Exhaled breath analysis using electronic nose and gas chromatography - mass spectrometry for non-invasive diagnosis of chronic kidney disease, diabetes mellitus and healthy subjects. **Sensors and actuators B: chemical**, 257, 2018. 178-188.

SANAEIFAR, A. et al. Early detection of contamination and defect in foodstuffs by electronic nose: A review. **TrAC Trends in Analytical Chemistry**, 97, 2017. 257-271.

SÁNCHEZ, C.; SANTOS, J. P.; LOZANO, J. Use of Electronic Noses for

Diagnosis of Digestive and Respiratory Diseases through the Breath. **Biosensors**, 9, 2019. 35.

SAUERBREY, G. Verwendung von Schwingquarzen zur Wägung dünner Schichten und zur Mikrowägung. **Zeitschrift für Physik**, 155, 1959. 206-222.

SBERVEGLIERI, G. et al. MOX-NW electronic nose for detection of food microbial contamination. **SENSORS, 2014 IEEE**. Valencia, Spain: IEEE. 2014. p. 1376-1379.

SCHANES, K.; STAGL, S. Food waste fighters: What motivates people to engage in food sharing? **Journal of cleaner production**, 211, 2019. 1491-1501.

SEESAARD, T. et al. Advances in gas sensors and electronic nose technologies for agricultural cycle applications. **Computers and Electronics in Agriculture**, 193, 2022. 106673.

SHARMILAN, T. et al. Application of electronic nose to predict the optimum fermentation time for low-country Sri Lankan tea. **Journal of Food Quality**, 2022, 2022.

SHEN, F. et al. Detection of Aspergillus spp. contamination levels in peanuts by near infrared spectroscopy and electronic nose. **Food Control**, 93, 2018. 1-8.

SHLENS, J. A tutorial on principal component analysis. **arXiv preprint arXiv:1404.1100**, 2014.

SIHOMBING, Y. A.; RITONGA, M. A. Detection of the cooking oil aroma by using a gas sensor in an electronic nose system. **Journal of Physics: Conference Series**, v. 1811, p. 6, 2021.

SILVA, J. C. D.; CHILANTI, G.; THEODORO, H. Segurança Alimentar e Nutricional (SAN) na perspectiva do desperdício de alimentos no Brasil. In:

ZARO, M. **Desperdício de alimentos: velhos hábitos, novos desafios**. Caxias do Sul: Educs, 2018. p. 251-268. ISBN 978-85-7061-917-4.

SINHA, K. et al. Analyzing chronic disease biomarkers using electrochemical sensors and artificial neural networks. **TrAC Trends in Analytical Chemistry**, 2022. 116861.

SISTEMA ALERTA RIO / GEO-RIO. **Dados Meteorológicos**. Sistema Alerta Rio da Prefeitura do Rio de Janeiro. Rio de Janeiro. 2021-2023.

SONG, S. et al. Effect of enzymatic hydrolysis with subsequent mild thermal oxidation of tallow on precursor formation and sensory profiles of beef flavours assessed by partial least squares regression. **Meat science**, 96, n. 3, 2014. 1191-1200.

SRINIVASAN, P. et al. Development of electronic nose (Shrimp-Nose) for the determination of perishable quality and shelf-life of cultured Pacific white shrimp (*Litopenaeus Vannamei*). **Sensors and Actuators B: Chemical**, 317, 2020. 128192.

STENMARCK, Å. et al. **Estimates of European food waste levels**. Stockholm: IVL Swedish Environmental Research Institute, 2016. 80 p. ISBN 978-91-88319-01-2.

] SZULCZYŃSKI, B.; GĘBICKI, J. Currently commercially available chemical sensors employed for detection of volatile organic compounds in outdoor and indoor air. **Environments**, 4, n. 1, 2017. 21.

TAIZ, L. et al. **Fisiologia e desenvolvimento vegetal**. 6ª. ed. Porto Alegre: Artmed, 2017. 888 p. ISBN 978-85-8271-367-9.

TALAWAR, S. T. et al. Effect of wheat bran oil concentrates on quality and nutrition of WBO dark compound chocolates. **LWT**, 142, 2021. 111005.

TAN, J.; XU, J. Applications of electronic nose (e-nose) and electronic tongue (e-tongue) in food quality-related properties determination: A review. **Artificial Intelligence in Agriculture**, 4, 2020. 104-115.

TAN, L. et al. Development Trend of Electronic Nose Technology in Closed Cabins Gas Detection: A Review. **Applied Sciences**, 12, n. 18, 2022. 9326.

TIAN, Y. et al. Local manifold embedding cross-domain subspace learning for drift compensation of electronic nose data. **IEEE Transactions on Instrumentation and Measurement**, 70, 2021. 1-12.

VAJDI, M. et al. Using electronic nose to recognize fish spoilage with an optimum classifier. **Journal of Food Measurement and Characterization**, 13, 2019. 1205-1217.

VALENTE, M. T. **Engenharia de software moderna: princípios e práticas para desenvolvimento de software com produtividade**. Belo Horizonte: Universidade Federal de Minas Gerais, 2020. 395 p. ISBN 978-65-00-01950-6.

VALLE, P. H. C. D. **Ciências morfofuncionais dos sistemas nervoso e cardiorrespiratório**. 1ª. ed. Londrina: Editora e Distribuidora Educacional S.A, 2015. 216 p. ISBN 978-85-8482-221-8.

VESOVIĆ, J.; ZLATANOVIĆ, A.; TEODOROVIĆ, S. How do I smell? The potential of body odor in human personal identification. **Thematic conference proceedings of international significance. Vol. 2 / International scientific conference "Archibald Reiss Days"**. Belgrado: University of Criminal Investigation and Police Studies. 2019. p. 415-426.

VIEJO, C. G.; FUENTES, S. Low-cost methods to assess beer quality using artificial intelligence involving robotics, an electronic nose, and machine learning. **Fermentation**, 6, n. 4, 2020. 104.

VO-THANH, T. et al. How a mobile app can become a catalyst for sustainable social business: The case of Too Good To Go. **Technological Forecasting and Social Change**, 171, 2021. 120962.

WASILEWSKI, T. et al. Critical review of electronic nose and tongue instruments prospects in pharmaceutical analysis. **Analytica chimica acta**, 1077, 2019. 14-29.

WIJAYA, D. R. et al. Development of mobile electronic nose for beef quality monitoring. **Procedia Computer Science**, 124, 2017. 728-735.

WIJAYA, D. R. et al. Ensemble machine learning approach for electronic nose signal processing. **Sensing and Bio-Sensing Research**, 36, 2022. 100495.

WILKENS, W. F.; HARTMAN, J. D. An electronic analog for the olfactory processes. **Journal of Food Science**, 29, n. 3, 1963. 372-378.

WILSON, A. D. Review of electronic-nose technologies and algorithms to detect hazardous chemicals in the environment. **Procedia Technology**, 1, 2012. 453-463.

WILSON, A. D. Diverse applications of electronic-nose technologies in agriculture and forestry. **Sensors**, 13, n. 2, 2013. 2295-2348.

WILSON, A. D. Electronic-nose applications in forensic science and for analysis of volatile biomarkers in the human breath. **Journal of Forensic Science & Criminology**, 1, n. S103, 2014. 1-21.

WILSON, A. D. Advances in electronic-nose technologies for the detection of volatile biomarker metabolites in the human breath. **Metabolites**, 5, n. 1, 2015. 140-163.

WOJNOWSKI, W. et al. Poultry meat freshness evaluation using electronic nose technology and ultra-fast gas chromatography. **Monatshefte Für Chemie-Chemical Monthly**, 148, 2017. 1631-1637.

WOJNOWSKI, W. et al. Electronic noses in medical diagnostics. **Current medicinal chemistry**, 26, n. 1, 2019. 197-215.

WONGCHOOSUK, C. et al. Electronic nose for toxic gas detection based on photostimulated core - shell nanowires. **RSC Advances**, 4, n. 66, 2014. 35084-35088.

WORLD HEALTH ORGANIZATION. Natural toxins in food. **World Health Organization**, 2018. Disponivel em: <<https://www.who.int/news-room/fact-sheets/detail/natural-toxins-in-food>>. Acesso em: 16 maio 2022.

WORLD HEALTH ORGANIZATION. Food safety. **World Health Organization**, 2022. Disponivel em: <<https://www.who.int/news-room/fact-sheets/detail/food-safety>>. Acesso em: 2022 jun. 22.

XIA, Z.; CAI, W.; SHAO, X. Rapid discrimination of slimming capsules based on illegal additives by electronic nose and flash gas chromatography. **Journal of Separation Science**, 38, n. 4, 2015. 621-625.

XING, M. et al. Development of novel electronic nose applied for strawberry freshness detection during storage. **International Journal of Food Engineering**, 14, n. 7-8, 2018. 20180111.

XIONG, Y. et al. Quality control of *Lonicera japonica* stored for different months by electronic nose. **Journal of Pharmaceutical and Biomedical Analysis**, 91, 2014. 68-72.

YAN, J. et al. Subspace alignment based on an extreme learning machine for electronic nose drift compensation. **Knowledge-Based Systems**, 235, 2022. 107664.

YANG, B.; LEE, W. Human Body Odor Based Authentication Using Machine Learning. **2018 IEEE Symposium Series on Computational Intelligence (SSCI)**. Bangalore, India: IEEE. 2018. p. 1707-1714.

YANG, Y. et al. Application of E-nose combined with ANN modelling for qualitative and quantitative analysis of benzoic acid in cola-type beverages. **Journal of Food Measurement and Characterization**, 15, 2021. 5131-5138.

YI, Z.; LI, C. Anti-drift in electronic nose via dimensionality reduction: A discriminative subspace projection approach. **IEEE Access**, 7, 2019. 170087-170095.

ZAREZADEH, M. R. et al. Olive oil classification and fraud detection using E-nose and ultrasonic system. **Food Analytical Methods**, 14, 2021. 2199-2210.

ZHANG, L. et al. Chaotic time series prediction of E-nose sensor drift in embedded phase space. **Sensors and Actuators B: Chemical**, 182, 2013. 71-79.

ZHANG, L. et al. Anti-drift in E-nose: A subspace projection approach with drift reduction. **Sensors and Actuators B: Chemical**, 253, 2017. 407-417.

ZHU, X. et al. One-Class Drift Compensation for an Electronic Nose. **Chemosensors**, 9, n. 8, 2021. 208.

ZWAARDEMAKER, H.; HOGEWIND, F. On spray-electricity and waterfall-

electricity. **KNAW**, Amsterdam, v. 22, p. 429-437, 1920.