

Universidade Federal do Maranhão  
Centro de Ciências Exatas e Tecnologia  
Programa de Pós-Graduação em Engenharia Elétrica

---

*NÓ SENSOR INTELIGENTE PARA  
DETECÇÃO E CLASSIFICAÇÃO DE  
DERIVADOS DE PETRÓLEO EM AMBIENTE  
AQUÁTICO*

---

Yan Ferreira da Silva

São Luís  
2024

Universidade Federal do Maranhão  
Centro de Ciências Exatas e Tecnologia  
Programa de Pós-Graduação em Engenharia Elétrica

---

*NÓ SENSOR INTELIGENTE PARA  
DETECÇÃO E CLASSIFICAÇÃO DE  
DERIVADOS DE PETRÓLEO EM AMBIENTE  
AQUÁTICO*

---

**Yan Ferreira da Silva**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da UFMA para a obtenção do grau de Doutor em Engenharia Elétrica na área de Automação e Controle.

**São Luís  
2024**

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).  
Diretoria Integrada de Bibliotecas/UFMA

Ferreira da Silva, Yan.

Nó Sensor Inteligente Para Detecção e Classificação de Derivados de Petróleo Em Ambiente Aquático / Yan Ferreira da Silva. - 2024.

145 p.

Coorientador(a) 1: Raimundo Carlos Silvério Freire.

Orientador(a): João Viana da Fonseca Neto.

Tese (Doutorado) - Programa de Pós-graduação em Engenharia Elétrica/ccet, Universidade Federal do Maranhão, São Luís-ma, 2024.

1. Aprendizado de Máquina. 2. Nó Sensor. 3. Poluentes Em Ambientes Aquáticos. 4. Rede de Sensores Sem Fio. 5. Sistemas Embarcados. I. Carlos Silvério Freire, Raimundo. II. Viana da Fonseca Neto, João. III. Título.

# NÓ SENSOR INTELIGENTE PARA DETECÇÃO E CLASSIFICAÇÃO DE DERIVADOS DE PETRÓLEO EM AMBIENTE AQUÁTICO

Yan Ferreira da Silva

Aprovada em 01/julho/2024

## BANCA EXAMINADORA

**Prof. João Viana da Fonseca Neto**

Dr. em Engenharia Elétrica (Orientador)

**Prof. Raimundo Carlos Silvério Freire**

Dr. em Engenharia Elétrica (Coorientador)

**Prof. Francisco das Chagas de Souza**

Dr. em Engenharia Elétrica (Avaliador Interno)

**Prof. Vicente Leonardo Paucar Casas**

Dr. em Engenharia Elétrica (Avaliador Interno)

**Prof. Mauro Sergio Silva Pinto**

Dr. em Engenharia Elétrica (Avaliador Externo)

**Prof. Ollivier Tamarin**

PhD in Electrical Engineering (Avaliador Externo)

**Prof. António Manuel Trigueiros da Silva Cunha**

Dr. em Engenharia Elétrica (Avaliador Externo)



*Este trabalho é dedicado aos meus pais.*

# Agradecimentos

---

Agradeço primeiramente a Deus pelo dom da vida, da sabedoria e da saúde, sem Ele nada seria possível.

Aos meus Pais, Cleantes da Assunção Teixeira da Silva Sobrinho e Hortência Maria Arruda Ferreira, pelo incentivo, apoio e compreensão ao longo destes quatro anos que foram a base para me manter no foco e não desistir dos meus objetivos e ideais, até porquê sem meus pais eu não seria nada e nem ninguém.

Ao meu professor e orientador João Viana da Fonseca Neto pela orientação e dedicação aplicados neste trabalho. Meu agradecimento sincero pelo acompanhamento, pela compreensão, auxílio e tempo despendido durante todo curso, sempre me motivando em todos os momentos em que precisei e que me mostrou os caminhos a serem seguidos.

Ao Prof. Raimundo Carlos Silvério Freire, pelas trocas de experiências, ensinamentos, conselhos e contribuições para o desenvolvimento deste trabalho.

Aos professores, Francisco das Chagas de Souza, Wendell Ferreira de la Salles, Vicente Leonardo Paucar Casas, Alcione Miranda e Aristófanés Corrêa Silva pelo incentivo, pelos os conhecimentos e ensinamento durante as disciplinas.

Aos meus amigos da Pós Graduação em especial Evandro Martins, Alan de Carvalho, Victor Guimarães, Bruno França, Denis Fabrício, Monik Sousa, Alam Belfort, Antonio Henrique, Christian Carvalho e Gawaine Lisboa, por todos os ensinamentos que compartilhamos, e aos meus companheiros do LABSECI pelos ensinamentos que compartilhamos e momentos de descontração.

Aos meus amigos Daniel Trovão, José Pinheiro de Moura, João Gabriel, Bruno Roberto, Ítalo Diogo Torres, Cassio Fernandes, Amanda de Luna, Marcello Jacintho, Diego Dantas, Pedro Cutrim, Claudyane da Silva, Saulo Bezerra, Eleazar de Carvalho, Alice Maria Costa, Frederico Diniz, Michelle Ribeiro, Lyzette Gonçalves companheirismo, amizade e apoio.

A todos os professores e colaboradores do Programa de Pós-Graduação em Engenharia de Elétrica (PPGEE) e da Universidade Federal do Maranhão (UFMA), que de alguma forma contribuíram com o desenvolvimento deste trabalho e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Fundação de Amparo à Pesquisa e ao Desenvolvimento Científico e Tecnológico do Maranhão (FAPEMA) e o Programa de Recursos Humanos da ANP para o Setor Petróleo, Gás Natural e Biocombustíveis (PRH – ANP) pelo suporte financeiro.

*Aprender uma lição sem dor não tem significado. Isso porque você não pode ganhar algo sem sacrificar outra coisa em troca. Mas, quando você superar isso e fizer da dor a sua, você vai ganhar um coração mais forte que qualquer outra coisa. Sim, um coração de aço.*  
( Hiromu Arakawa, Fullmetal Alchemist)

## RESUMO

Para prevenir e mitigar o impacto ambiental do transporte e extração de petróleo e seus derivados, este documento apresenta a concepção, projeto, desenvolvimento e implementação de um nó sensor para redes de sensores sem fio (RSSF). O sistema proposto é um nó sensor inteligente estático que detecta e classifica poluentes em ambientes aquáticos usando abordagens de aprendizado de máquina e IoT (Internet das Coisas). Nesta tese, é apresentado o desenvolvimento do nó sensor, que consiste em três fases. Na primeira fase, são apresentadas a concepção e modelagem do sistema embarcado, incluindo modelagem matemática do nó, sistema de alimentação, estrutura de comunicação, detecção e classificação de poluentes via aprendizado de máquina e IoT. A implementação do nó sensor estático é apresentada na segunda fase do projeto, que inclui a modelagem funcional da medição, a arquitetura do sistema embarcado e sua estrutura física. Na última etapa, são apresentados os testes de detecção e classificação do nó sensor proposto, incluindo a caracterização e implementação dos sensores. O nó sensor inteligente é avaliado em ambiente fechado por meio da análise de amostras de água do mar com gasolina e diesel, medições de pH e turbidez de água do mar e água doce com gasolina e experimentos por meio de medições diretas e indiretas de água do mar e diesel. Devido aos fatos dos experimentos terem mostrado resultados satisfatórios, o nó sensor proposto é considerado um dispositivo promissor para detectar e classificar poluentes em ambientes aquáticos do mundo real.

**Palavras-Chave:** Aprendizado de máquina, nó sensor, poluentes em ambientes aquáticos, rede de sensores sem fio, sistemas embarcados.

## ABSTRACT

To prevent and mitigate the environmental impact of transporting and extracting oil and its derivatives, the conception, design, development and implementation of a sensor node for wireless sensor networks (WSN) is presented in this Thesis. The proposed system is a static intelligent sensor node that detects and classifies pollutants in aquatic environments using machine learning and IoT (Internet of Things) approaches. The development of the sensor node consists of three phases. In the first phase, the design and modeling of the embedded system includes mathematical modeling of the node, power system, communication structure, detection and classification of pollutants via machine learning and IoT. The implementation of the static sensor node is presented in the second phase of the project, which includes functional modeling of the measurement, the architecture of the embedded system and its physical structure. In the last stage, the detection and classification tests of the proposed sensor node are performed, including the characterization and implementation of the sensors. The intelligent sensor node is evaluated indoors through the analysis of seawater samples with gasoline and diesel, pH and turbidity measurements of seawater and freshwater with gasoline, and experiments through direct and indirect measurements of seawater and diesel. Due to the facts of the experiments have shown satisfactory results, the proposed sensor node is considered a promising device for detecting and classifying pollutants in real-world aquatic environments.

**Keyword:** Machine learning, sensor node, pollutants in aquatic environments, wireless sensor network, embedded systems.

# Lista de Tabelas

2.1	Tabela de substituição para o modelo da célula fotovoltaica . . . . .	24
5.1	Medições com nó sensor do pH, Turbidez da Água do Mar e Potável.	78
5.2	Medição com nó sensor e classificação da Gasolina na Água do Mar.	82
5.3	Medição com nó sensor e classificação do Óleo na Água do Mar. .	87
6.1	Desempenho, métricas para detecção e classificação via rede neural artificial MLP - para combustíveis gasolina e diesel. . . . .	91
6.2	Consumo do sistema de processamento $\mu C$ ESP32 a 3.3 V. . . . .	96
6.3	Consumo de energia dos sensores do nó. . . . .	96

# Lista de Figuras

2.1	Modelo do díodo equivalente a célula fotovoltaica [49, 15]. . . . .	23
2.2	Estrutura Ad Hoc de uma rede de sensores sem fio com nós estáticos e dinâmicos. Fonte: Adaptado de [63] . . . . .	26
2.3	Arquitetura do Nós Sensores, Periféricos e módulos do sistemas funcionais e apoio. . . . .	29
2.4	Representação das topologias mais usadas nas RSSF. Fonte: Adaptado de [63, 24] . . . . .	31
2.5	Grafo da arquitetura de uma rede neural artificial perceptron de multicamadas com duas camadas ocultas. Fonte: Adaptado de[36].	37
3.1	Derramamento 2019 na costa do nordeste- IBAMA Fonte: Adaptado de [55, 39, 23]. . . . .	40
3.2	Zonas sensíveis de derramamento de derivados de petróleo e acidentes Fonte: Adaptado de [39, 3]. . . . .	41
3.3	Arquitetura do Nós Sensores. . . . .	45
3.4	Bloco de organização da alimentação do nó sensor . . . . .	48
3.5	O Sistema de comunicação do nó sensor e as etapas do fluxo de comunicação: (1) nó sensor estático, (2) estação base/ <i>gateway</i> , (3) Sinais armazenados na nuvem, (4) Destino final das medições e estimativas. . . . .	49
3.6	Detecção, classificação do nó estático e rede neural artificial. . . .	51

4.1	Representação do problema de detecção e classificação de poluição em ambiente aquático e solução via RSSF: (a) Zona atingida por derramamento de petróleo e atuação do nó sensor no ambiente; (b) Elementos e métodos de detecção; (c) Informações do nó sensor enviados a estação base para tomada de decisão. . . . .	54
4.2	Etapas da Metodologia para desenvolvimento do Sistema Inteligente de Detecção, classificação de poluentes e derivados de em ambiente aquático. . . . .	57
4.3	Classificador embarcado. . . . .	59
5.1	Abstração do sistema embarcado do nó sensor inteligente. . . . .	65
5.2	Abstração da parte do bloco de energia ( <i>power supply</i> ). . . . .	66
5.3	Abstração da parte do sensoriamento, aquisição de sinais, observação dos fenômenos ambientais. . . . .	67
5.4	Abstração da parte de comunicação externa. . . . .	68
5.5	Abstração dos componentes de controle e processamento do sistema. . . . .	69
5.6	Abstração dos blocos lógicos que compõem o sistema embarcado. . . . .	70
5.7	Protótipo da estrutura do sensor proposto simulado no Fritzing. . . . .	71
5.8	Estrutura do sistema embarcado desenvolvido e simulada via software, primeira parte concentra-se no processamento gerenciamento e coleta de sinal, placa 2, secundária responsável pelo controle de carga/descarga das baterias e gerenciamento energético do sistema embarcado principal. . . . .	72
5.9	Modelagem 3D da Estrutura física do nó sensor para Ambientes Aquáticos . . . . .	74
5.10	Estrutura física do nó sensor/ Protótipo V1 . . . . .	75
5.11	Medição com nó sensor do comparativo do pH água salgada e potável. . . . .	79
5.12	Medição com nó sensor do nível de turbidez da água do mar e potável. . . . .	80
5.13	Medição com nó sensor e classificação da Gasolina. . . . .	81
5.14	Medições com nó sensor e classificação da Gasolina com água do Mar. . . . .	83
5.15	Medições com nó sensor e classificação do Óleo Diesel na água do Mar. . . . .	85
5.16	Medição com nó sensor e classificação do Diesel. . . . .	88

5.17	Posicionamento do nó sensor - Latitude e Longitude. . . . .	89
6.1	Avaliação de desempenho do classificador MLP via matriz de confusão. . . . .	91
6.2	Medidores de medição dos índices acesso ao <i>broker</i> . . . . .	93
6.3	Comportamento dos sinais gerados pelo nó sensor enviados via MQTT para o <i>broker</i> . . . . .	94
6.4	Consumo de energia do nó sensor operando em dois modos. . . . .	98
6.5	Comparativo do consumo total dos dois modos ativados. . . . .	99
A.1	Local de proposta de implantação da RSSF. . . . .	115
A.2	Reserva de proteção ambiental do porto do Itaqui, situada atrás dos berços 105, 106 e 108. . . . .	116
A.3	Vista da reserva de mangues. . . . .	118
A.4	Imagem de satélite do local de implantação da RSSF. . . . .	119
A.5	Projeto da rede de sensores sem fio proposta para cobertura dos berços de atracação 105, 106 e 108. . . . .	121
C.1	Estudo do sensor usando LDR e LED ( <i>Light Emitter Diode</i> ) com brilho de alta intensidade para detecção de partículas na água, a) emissão da luz sem detecção, b) modificação no comprimento de onda da luz azul e possível identificação do corpo estranho . . . .	125
C.2	Prototipação do estudo do sensor para detecção de partículas de poluentes. 1) estrutura de recepção da luz azul com LDRs, 2) estrutura do emissor, 3) estrutura completa de emissão e recepção.	126

# Lista de Abreviaturas e Siglas

ADHDP	<i>Action Dependent Heuristic Dynamic Programming</i> (Programação Dinâmica Heurística Dependente de Ação)
ADP	<i>Approximate/Adaptive Dynamic Programming</i> (Programação Dinâmica Aproximada/Adaptativa)
AM	Aprendizado de Máquina
EKF	<i>Extended Kalman filter</i> (Filtro de Kalman Estendido)
HDP	<i>Heuristic Dynamic Programming</i> (Programação Dinâmica Heurística)
FDP	Função Densidade Probabilidade
IoT	<i>Internet of Things</i> (Internet das Coisas)
MLP	<i>Multilayer Perceptron</i> (Perceptron de Multicamadas)
RSSF	Rede de Sensores Sem Fio
RNA	<i>Redes Neural Artificiais</i>
OCDP	Óleo Combustível e Derivados de Petróleo
SAR	<i>Synthetic-Aperture Radar</i> (Radar de Abertura Sintética)
SE	<i>Sistema Embarcado</i>
DCNN	<i>Deep Convolutional Neural Network</i> (Rede Neural Convolutacional Profunda)
RBF	<i>Radial Basis Function Network</i> (Rede de Funções de Base Radial )
HJB	<i>Hamilton-Jacobi-Bellman</i>
AR	Aprendizagem por Reforço
IA	Inteligência Artificial
PDM	Processo de Decisão Markoviano
SMA	Sistema Multi-Agente
VANT	Veículo Aéreo Não Tripulado

# Conteúdo

<b>1</b>	<b>Introdução</b>	<b>2</b>
1.1	Justificativas . . . . .	7
1.2	Motivação . . . . .	8
1.3	Estado da Arte . . . . .	10
1.4	Objetivos: geral e específico . . . . .	15
1.5	Organização da Tese . . . . .	16
<b>2</b>	<b>Preliminares: Sistemas Embarcados e Aprendizado de Máquina</b>	<b>18</b>
2.1	Conceito Tecnológico . . . . .	18
2.2	Sensores Inteligentes . . . . .	19
2.3	Colheita de energia . . . . .	21
2.3.1	Modelo matemático de uma célula fotovoltaica . . . . .	23
2.4	Rede de sensores sem fio . . . . .	25
2.5	Nós sensores inteligentes e sistemas embarcados para RSSF . . . . .	27
2.5.1	Topologias e protocolos de roteamentos de RSSF . . . . .	30
2.5.2	Aprendizado de Máquina . . . . .	33
2.6	Redes Neurais Artificiais . . . . .	34
2.6.1	Perceptron de Múltiplas Camadas e Algoritmo de Retropropagação . . . . .	36
<b>3</b>	<b>Problema de detecção e classificação de poluentes de derivados de petróleo em região costeira</b>	<b>39</b>
3.1	Problema de detecção e classificação . . . . .	39
3.1.1	Formulação do Problema Ambiental . . . . .	42
3.1.2	Tecnologias disponíveis . . . . .	42
3.2	Concepção e modelagem do sistema embarcado . . . . .	44

3.2.1	Modelagem matemática do nó . . . . .	46
3.2.2	Sistema de alimentação do nó sensor . . . . .	48
3.2.3	Estrutura de comunicação da RSSF . . . . .	49
3.3	Detecção e classificação via aprendizado de máquina e IoT . . . . .	50
3.3.1	Problema de sobrevida de nós . . . . .	51
3.3.2	Problema de cobertura de nó sensor de uma RSSF . . . . .	52
<b>4</b>	<b>Metodologia Proposta</b>	<b>54</b>
4.1	Metodologia para desenvolvimento do sistema inteligente . . . . .	56
4.2	Metodologia do nó sensor inteligente . . . . .	58
4.2.1	Treinamento . . . . .	60
<b>5</b>	<b>Resultados, Projeto de Desenvolvimento do Sistema Embarcado</b>	<b>62</b>
5.1	Projeto e implementação de nós sensores estáticos . . . . .	62
5.2	Modelagem Funcional da Medição . . . . .	63
5.3	Arquitetura do sistema embarcado . . . . .	64
5.3.1	Implementação e virtualização do circuito . . . . .	72
5.4	Estrutura física do nó sensor . . . . .	73
5.5	Testes de Detecção e Classificação . . . . .	75
5.6	Teste de medição de pH e turbidez com água do mar (salgada) e água mineral (potável) . . . . .	76
5.7	Experimentos com Gasolina . . . . .	81
5.8	Experimentos - Medições Direta da $H_2O$ Salgada e Diesel . . . . .	84
5.9	Posicionamento do nó sensor . . . . .	88
<b>6</b>	<b>Resultados dos Experimentos Computacionais e Hardware</b>	<b>90</b>
6.1	Detecção e classificação via RNA para combustíveis . . . . .	90
6.1.1	Medidores inteligentes de qualidade da água . . . . .	92
6.2	Análise, comentários da implementação e testes de consumo de energia . . . . .	95
6.2.1	Teste com o <i>DEEP SLEEP</i> . . . . .	97
<b>7</b>	<b>Considerações e conclusão</b>	<b>101</b>
7.1	Conclusão . . . . .	101
7.2	Trabalhos Futuros . . . . .	102

7.3	Publicações . . . . .	103
7.3.1	Aceito e Publicado . . . . .	103
7.3.2	Artigos publicados com temática relacionada a tese . . . . .	104
<b>Referências Bibliográficas</b>		<b>105</b>
<b>A</b>	<b>Estudo caso 1 - WSN para detecção de resíduos OCDP e outros poluentes em Ambientes Aquáticos</b>	<b>114</b>
A.1	Projeto de Implantação da RSSF . . . . .	119
<b>B</b>	<b>Estudo da modelagem matemática da medição pH</b>	<b>122</b>
B.1	Medição pH . . . . .	122
<b>C</b>	<b>Estudo de um sensor para análise de partículas sólidas de poluentes próxima a lâmina d' água</b>	<b>124</b>
C.1	Análise do uso do LDR e luz azul para um sensor de análise de partículas . . . . .	125

# CAPÍTULO 1

## INTRODUÇÃO

---

A relevância das redes de sensores sem fio (RSSF) para o monitoramento e o controle de atividades industriais, de transporte, agrícolas e aeroespaciais é onipresente na sociedade contemporânea. Nessas redes, os nós sensores desempenham um papel essencial, ou seja, são os principais componentes para realizar medições de determinadas variáveis. Para contribuir com a detecção de poluentes em ambientes aquáticos, este documento apresenta um método inovador para o projeto e o desenvolvimento de nós sensores estáticos para RSSF. O núcleo de processamento das medições e das informações coletadas pelos sensores do nó é baseado em fundamentos teóricos e tecnológicos apoiados por aprendizado de máquina [54, 31] e abordagens de sistemas embarcados [5]. Além disso, um sistema embarcado dedicado para resolver o problema de detecção e classificação de derramamentos de produtos petrolíferos em ambiente marinho e processamento de sinal distribuído em RSSF é apresentado nesta tese. Os métodos de classificação de poluentes são embarcados e avaliados por nó sensor que faz parte de uma rede de sensores com nós estáticos para detectar e rastrear derramamentos de produtos petrolíferos no mar [4].

O desenvolvimento de sistemas embarcados para processamento e comunicação baseia-se em arquiteturas de alto desempenho [17], como o RISK, e na fusão local e distribuída de sinais de sensores. Para detectar e classificar o poluente, seja ele combustível à base de petróleo, os sinais medidos pelos sensores são processados usando técnicas de aprendizado de máquina [73, 10]. O método proposto é avaliado em vazamentos de óleo combustível e derivados de petróleo

[71]. Dadas as aproximações dos modelos propostos e a quantidade de dados disponíveis que são cruciais para a estimativa dos estados de um determinado processo, visando à detecção e ao rastreamento de produtos petrolíferos [4], a garantia de convergência, estabilidade e robustez dos métodos de aprendizado de máquina é uma propriedade do método proposto.

A motivação para a escolha do tema derramamento de óleo em ambiente aquático se deve à sua importância para o meio ambiente, como pode ser visto nas referências [27, 42, 28]. As empresas ligadas ao transporte marítimo e suas características dinâmicas complexas em relação a um rastreamento *online* conciso, os dados são expostos em relatórios técnicos e artigos científicos [6]. As estratégias de estimativa e controle são fundamentais nesse processo para garantir a eficiência energética [1, 37, 72, 34] e a operação segura, para alcançar as propriedades desejadas e para evitar e minimizar os danos causados pelo impacto ambiental [?]. Desta forma, constata-se a necessidade de desenvolver dispositivos para monitorar o meio ambiente.

Este documento apresenta o arcabouço no contexto da RSSF, relacionado a nós sensores, desenvolvendo técnicas de sistemas embarcados, IoT (*Internet of Things*), aprendizado de máquina e colheita de energia. A importância dos sistemas embarcados está em sua penetração na maioria das atividades humanas. As atividades dependem cada vez mais de seus recursos em tempo real, como detecção, processamento, comunicação e ação [43]. Com relação à necessidade de abordar os problemas que surgem devido à complexidade dos sistemas embarcados, os autores [62, 54] afirmam que a complexidade e as aplicações com IoT impõem restrições de projeto que exigem o desenvolvimento de métodos para encontrar o melhor compromisso entre os diferentes objetivos do projeto do sistema embarcado. Um nó sensor de baixo custo para uma RSSF é apresentado em [20], pode detectar, por meio de uma matriz de sensores composta por acelerômetros, giroscópios, Sistema de Posicionamento Global (GPS) e sensores térmicos infravermelhos para medição de filmes de óleo que emitem calor mais lentamente do que a água circundante durante o dia. No entanto, o processo é revertido durante a noite, tornando-o vulnerável às condições de iluminação. Os sinais capturados são processados, e as informações estimadas são transmitidas por telemetria, alertando sobre a ocorrência de um possível derramamento de óleo

e informando a localização e a espessura da mancha. Recentemente, os avanços em *hardware* e *software* orientados para aplicativos de IA (inteligência artificial) em sistemas embarcados e IoT [5] com recursos e energia limitados para uma ampla gama de aplicativos aumentaram a importância de encontrar soluções eficazes para os problemas mencionados [43, 50].

Devido à importância dos sistemas embarcados para a operação e sua capacidade de apoiar a tomada de decisões, são levantadas questões relevantes, como segurança, proteção e confiabilidade, que afetam diretamente a segurança física e de dados. O controle, a validação, o autoteste e a observabilidade dos sistemas embarcados em suas operações programadas ou adquiridas são preocupações importantes para sua aceitação em infraestruturas ou operações críticas. Inclusive, os requisitos de custo, energia e manutenção devem ser considerados, dado o grande número de sistemas embarcados para aplicativos de IoT [43, 71]. As referências citadas também enfatizam a importância dos sistemas embarcados para a transferência de dados para processamento remoto, promovendo uma resposta mais rápida em tempo real e reduzindo a dependência de conexões de dados. Dessa forma, contribui para melhorar a escalabilidade e aumentar a segurança.

Com relação ao projeto do sistema embarcado, as sugestões e técnicas apresentadas nas referências que tratam de modelagem, síntese e análise são consideradas para o projeto e a implementação do nó sensor proposto. Em [17], os autores apresentam a modelagem, a síntese e a verificação para o projeto de sistemas embarcados. Na referência [25], os autores apresentam sistemas embarcados, enfatizando uma abordagem de sistemas ciberfísicos (CPS). Na referência [5, 50], os autores apresentam o projeto de um sistema embarcado, enfatizando os fundamentos dos sistemas ciberfísicos e a IoT. Na referência [79], os autores apresentam os princípios do projeto de sistemas embarcados e da computação distribuída.

Com a aproximação de funções, as abordagens de aprendizado de máquina aliadas com técnicas IoT, propõem-se um sistema embarcado que viabiliza uma integração com o processo, permitindo monitoramento *online* além do uso de diversos sensores sejam eles via *software* ou físico para a realização de medições diretas e indiretas, auxiliando em um processo com menor custo computacional

para estimação. Os métodos estimação são avaliados por meio de estudos de casos, sendo aplicados em redes de sensores com nós estáticos para a detecção e rastreamento de derramamento de derivados de petróleo no mar.

Com a complexidade da realização da classificação dos compostos poluentes na água são propostos métodos baseados em técnicas aprendizado de máquina, tais como: RNA (rede neurais artificiais) e árvore de decisão para a realização da classificação e detecção da presença de gasolina e diesel na água através dos sinais sensores primários de contato com a lamina d' água. A motivação para escolha do tema “derramamento de petróleo em ambiente aquático” é por conta sua importância para o meio ambiente, empresas ligadas ao transporte marítimo e suas características dinâmicas complexas, em relação os dados, são expostos em relatórios técnicos e artigos científicos. Neste processo as estratégias de estimação e controle são fundamentais para garantir a eficiência energética e operação segura, alcançar as propriedades desejadas e impedir e minimizar os danos dos impactos ambientais.

Desde sua descoberta, o petróleo modificou profundamente a economia, sociedade e toda geopolítica mundial e os territórios e das regiões produtoras, ou seja, mais do que a própria formação da indústria petrolífera esta atividade configurou um novo ciclo econômico, que acelerou o crescimento dos países, cidades, principalmente quanto ao processo de urbanização [40, 21]. Junto com todo desenvolvimento vieram também suas problemáticas ligadas ao derramamento de petróleo e seus derivados em ambiente aquáticos, envolvendo transporte por meio de oleodutos, gasodutos e grandes navios (superpetroleiros, em razão do seu gigantesco tamanho, com até 500 metros de comprimento e 70 metros de largura). No que diz respeito aos rios e mares, cerca de 80% da poluição é causado por acidentes, contaminando, assim, suas águas com óleo combustível [20].

Estes derramamentos podem causar danos graves, tais como: intoxicação dos animais que vivem no ambiente afetado, e a contaminação da água, sendo necessário a suspensão da ingestão dessa água [20]. Outro grande problema gerado pelo derramamento de óleo é quando ele ocupa a superfície da água, formando grandes manchas chamadas de processo de emulsificação, o que impede a penetração da luminosidade no interior do meio aquático, causando danos

irreversíveis à flora e fauna desse ambiente, prejudicando toda a cadeia alimentar do ecossistema [57].

Em contrapartida, diversas tecnologias estão sendo desenvolvidas e aplicadas para identificar, mapear e rastrear os focos e áreas com vazamento de óleo combustível ou derivados de petróleo, viabilizando o desenvolvimento de medidas de prevenção, contenção para evitar e minimizar danos ambientais e materiais, assim preservando toda cadeia alimentar [20, 60]. De acordo com [14], estudos mostram que conhecer a espessura da mancha de óleo em diferentes locais, minutos após a ocorrência de um derramamento de óleo, reduz os custos de limpeza guiando a operação, indicando o caminho em tempo real para o tratamento mais eficiente, começando com a localização mais espessa da mancha de óleo [70]. Existem técnicas de medição por contato direto da espessura, em comparação com as técnicas existentes, é mais resistente às condições climáticas e eficaz com diferentes tipos de óleos. Embora a detecção remota, principalmente usando técnicas de SAR (*Synthetic-Aperture Radar*) e LIDAR (*Light Detection and Ranging*), tecnologia óptica de detecção remota, sejam as formas mais comuns de rastreamento de derramamento de óleo, elas apresentam desvantagens, como: resposta atrasada, alto custo, dependência de clima, iluminação, temperatura e condições do mar [61].

Para a solução da problemática de detecção, classificação e rastreamento de alvos com aplicações no mapeamento de áreas sensíveis a derramamento derivados de petróleo em ambiente marinho e processamento de sinais distribuído em RSSF, esta tese tem como objetivo principal o desenvolvimento de uma metodologia de arquitetura de um nó sensor inteligente para RSSF. O nó sensor em conjunto ou outros nós fazem parte de uma rede de sensores sem fio com nós estáticos e móveis colaborativos para mapear falhas em ambientes aquáticos, detectar e classificar derivados de petróleo em regiões costeiras. Esta tese também tem como objetivo desenvolver métodos e algoritmos baseados em aprendizado para a detecção e classificação de derivados de petróleo em ambientes aquáticos.

Os métodos e procedimentos para a solução do problema de detecção e classificação e mapeamento de poluentes e derivados de petróleo em ambientes aquáticos são apresentados e tem como base os principais tópicos do Capítulo 2. A presente metodologia tem como objetivo apresentar um método sistematizado

para o desenvolvimento de sensores inteligentes.

Neste documento é apresentada uma metodologia para o desenvolvimento de um sistema inteligente baseado em sistemas embarcados e aprendizado máquina com estrutura de uma rede de sensores sem fio com nós dinâmicos e estáticos com finalidade de detectar e classificar.

## 1.1 Justificativas

Conforme apresentado nos parágrafos anteriores, apresenta-se nesta seção as justificativas e necessidade do desenvolvimento proposto.

Vários algoritmos e cenários de estimação de estado foram abordados por pesquisadores para os fins de detecção, classificação e rastreamento de alvos.

Conseqüentemente, neste documento, é apresentado o desenvolvimento de metodologias de sistemas embarcados, classificador baseado em aprendizado de máquina afim de preencher as lacunas deixadas por técnicas convencionais de detecção, classificação e processamento de sinais distribuído/paralelo, técnicas de otimização afim de proporcionar o maior tempo de vida do nó sensor em relação ao uso de recursos energéticos. Como também desenvolver algoritmos de observação e estimação de estados pouco explorado por pesquisadores.

Para combater riscos ambientais devido a poluentes derivados de petróleo, é essencial contar com um sistema de monitorização eficiente, de baixo custo e em tempo real, capaz de medir com precisão a espessura e a localização do óleo derramado. Até o momento, os métodos de detecção existentes têm apresentado limitações em atender plenamente a esses requisitos. Portanto, é necessário desenvolver técnicas inovadoras para orientar e acelerar o processo de limpeza de derramamentos de óleo.

A detecção eficaz auxilia no combate à poluição marinha causada por vazamentos de derivados de petróleo podem ser aprimorados por meio do uso de sistemas embarcados e técnicas de aprendizado de máquina. Essas soluções tecnológicas oferecem uma abordagem avançada e eficiente para lidar com a problemática dos derramamentos de óleo no mar, a RSSF é uma alternativa viável para o monitoramento local de áreas degradadas, um estudo dessa viabilidade foi desenvolvido e está disponibilizado no Apêndice A.

Os sistemas embarcados podem ser implantados em embarcações de monitoramento e resposta a derramamentos de óleo, permitindo uma detecção precoce e contínua de vazamentos. Esses sistemas são compostos por sensores especializados que medem parâmetros-chave, como a presença de hidrocarbonetos na água, a fim de identificar possíveis áreas de contaminação. Além do mais, eles podem ser equipados com tecnologias avançadas, como câmeras de alta resolução e radares, que ajudam na localização precisa do derramamento.

O aprendizado de máquina desempenha um papel crucial ao processar os dados coletados pelos sistemas embarcados. Algoritmos de aprendizado são treinados com grandes conjuntos de dados que incluem informações sobre diferentes tipos de derramamentos de óleo, condições ambientais e características da área afetada. Com base nesse treinamento, os algoritmos podem analisar os dados em tempo real e identificar padrões que indicam a presença e a extensão do derramamento.

Além da detecção, as abordagens de aprendizado de máquina também contribui para a resposta eficiente aos vazamentos. Os algoritmos desta abordagem otimizam o planejamento das operações de limpeza, fornecendo informações sobre a melhor rota para as embarcações, a alocação de recursos adequados e as técnicas de recolhimento e dispersão mais eficazes. Resulta em uma resposta mais rápida, precisa e econômica aos vazamentos de derivados de petróleo no mar.

A integração de sistemas embarcados e aprendizado de máquina representam uma solução avançada para enfrentar os desafios dos vazamentos de óleo no mar. Essas tecnologias proporcionam uma detecção e resposta mais rápidas, melhorando a eficiência das operações de limpeza e minimizando os impactos ambientais e socioeconômicos desses eventos. Com uma detecção precoce e uma resposta adequada, é possível reduzir o tempo de exposição do ecossistema marinho à poluição e garantir a preservação da vida marinha e dos recursos costeiros.

## 1.2 Motivação

Esta tese tem por motivação contribuir com questões teóricas e práticas na problemática de detecção, classificação e rastreamento de alvos com aplicação para

derramamento de derivados de petróleo em ambiente aquático, no processamento dos sinais distribuído em RSSF e na sobrevida (parte energética) do nó sensor em ambientes com difícil manutenção. Com o foco no desenvolvimento de um sistema eficaz, realizando a detecção e classificação eficientes, quando comparados com outros métodos disponíveis no mercado. Além do aprimoramento de técnicas de detecção, classificação, processamento paralelo e de sensores baseados em *software*, visando garantir a melhor cobertura espacial do nós e otimiza a quantidade relativa de nós físicos e baseado em *software* no ambiente. Outra motivação é garantia da convergência, estabilidade e robustez para os métodos aprendizado de máquina envolvendo o processo de detecção, classificação e monitoramento ambiental. Frente às aproximações adotadas e quantidade de dados disponíveis que são cruciais para a estimação de estado, visando a detecção e rastreamento do derivado de petróleo. Com a aproximação de funções, as abordagens de aprendizado de máquina, e filtragem estocástica aliadas com técnicas IoT e sistemas embarcados tem como motivação uma integração com o processo, permitindo monitoramento *online* além do uso de diversos sensores sejam eles via *software* ou físico para a realização de medições diretas e indiretas, auxiliando em um processo com menor custo computacional para estimação de estados do ambiente.

Os métodos estimação são avaliados através do estudo de caso, sendo aplicados em redes de sensores com nós estáticos e móveis para a detecção, classificação e monitoramento do derramamento de derivados de petróleo no mar. Para a estimação dos estados e classificação é idealizado a aplicados e uso de técnicas aprendizado de máquina tais como: RNA, ADHDP (*Action Dependent Heuristic Dynamic Programming*), Árvore de decisão.

A motivação para a escolha do tema "derramamento de petróleo em ambiente aquático (aplicação)" deve-se à sua importância para o meio ambiente, para as empresas ligadas ao transporte marítimo e para suas características dinâmicas complexas em relação à detecção e classificação concisa *online*. As técnicas atuais são limitadas e dependem principalmente das condições climáticas, havendo a necessidade de tecnologias que possam realizar essas funções sem depender de fatores climáticos.

## 1.3 Estado da Arte

O monitoramento para a detecção e rastreamento de poluentes em ambientes aquáticos e sobrevida de nós sensores com colheita de energia é o principal problema investigado nesta tese. Os métodos de solução para o problema mencionado baseiam-se nas abordagens de sistemas embarcados, aprendizado de máquina, colheita de energia, IoT e rede de sensores sem fio.

Em [71], é proposto uma RSSF subaquática para detecção e localização de derramamentos provocados durante o processo de extração de petróleo em sistemas submarinos. Para realização do monitoramento, a RSSF é composta por sensores acústicos passivos. Os nós sensor tomam decisões binárias locais com relação à presença/ausência de um vazamento, realizando um teste de energia. Para o monitoramento e tomada de decisões, é proposto uma central de fusão, onde são realizadas análises e baseada em métodos de regra da contagem e regra de Chair-Varshney modificada. A central de fusão realiza a detecção de derramamento e realiza também o rastreamento, fornecendo assim uma posição estimada da fonte do vazamento. Quatro algoritmos de localização que são explorados: estimativa máxima A-Posteriori, estimativa de erro quadrático médio mínimo e dois algoritmos heurísticos baseados em centróide. Os desempenhos de detecção e localização são avaliados em comparação com a regra Clairvoyant Chair-Varshney e com o limite inferior de Cramér-Rao.

O gerenciamento de sensores em sistemas estocásticos multiobjetos é um problema teórico e desafiador, pesquisas orientadas para a temática são apresentadas nesse parágrafo. Em [77] é apresentada uma nova abordagem para o problema de controle multisensor e multialvos dentro da estrutura do processo de decisão de Markov parcialmente observado (POMDP). Os estados de multiobjetos são modelados como um conjunto finito aleatório (RFS) e o método *Generalized Covariance Intersection* para fusão multisensor. Os autores apresentam o desenvolvimento de um algoritmo de controle multissensor rápido para cenários multissensor controláveis (móveis), rastreando múltiplos alvos em movimento com diferentes níveis de observabilidade.

Em [20] é apresentado um nó sensor de uma RSSF de baixo custo capaz de detectar por meio de matriz de sensores como: acelerômetro, giroscópios, GPS (*Global Positioning System*), sensores térmicos infravermelhos baseados filmes de

óleo que emitem calor mais lentamente do que a água circundante durante o dia. No entanto, o processo é revertido durante a noite, tornando-o vulnerável às condições de iluminação. Os sinais capturados são processados e suas informações estimadas são transmitidas por telemetria, alertando a ocorrência de um possível derramamento de óleo e informando a localização e espessura da mancha.

Na referência [12] é apresentado o desenvolvimento de uma RSSF baseada em drones para detectar as concentrações de plumas de poluentes, que excedem os limites críticos ou para delinear as fronteiras de regiões contaminadas em suspensão no ar ou na água. Como a densidade dos sensores implantados no campo pode ser localmente insuficiente para realizar esta tarefa, é necessário adicionar sensores móveis adaptativos à infraestrutura de detecção permanente. Para rastrear e estimar o limite de uma pluma dinâmica, o método proposto pelos autores é constituído de uma rede de sensores estáticos de baixa densidade e de uma heurística de baixo esforço computacional, sendo eficiente em termos de movimentação dos sensores móveis. Como também, o método não demanda informações prévias sobre a pluma nem dados meteorológicos. O método proposto é aplicável para plumas dinâmicas para operar com um pequeno número de sensores estáticos. Ainda, os autores apresentam uma avaliação com variações do método e combinações de parâmetros usando uma pluma simulada com o modelo de dispersão atmosférica.

As RSSF são amplamente aplicadas para monitorar operações de exploração e transporte de petróleo, óleo combustível e gás natural. Desta forma, realizando a detecção de falhas, principalmente vazamentos que ocorrem devido ao mau funcionamento de equipamentos, defeitos de tubos e juntas de tubulações. Em [75], é apresentada a proposta de uma rede de sensores para detectar e localizar vazamentos de metano em operações remotas de petróleo e gás, onde são utilizados os sensores ultrassônicos de vento, GPS, temperatura, monitores de tensão das baterias, relógios em tempo real e técnicas de regressão linear para localização. Afim de detectar possíveis vazamentos, outra aplicação para redes de sensores dentro do setor de petróleo e gás é no monitoramento eficaz de plataforma de perfuração de petróleo para detectar possíveis vazamentos durante sua extração.

Em [81], é apresentada uma arquitetura de rede de sensores para promover a maior precisão no monitoramento e no aumento da área de cobertura dos nós.

Em sua estrutura possui o *software* embarcado que é projetado com base em dispositivo de conversão analógico-digital e arranjo de sensores combinados com tecnologia sem fio e codificação de frequência quádrupla e técnicas de detecção de fase. Os nós sem fio no sistema podem detectar e pré-processar sinais analógicos na faixa de frequência de 0,1 à 200 Hz e sinais de codificador de 90° de diferença de fase. Em seguida, envia os dados por meio do módulo transmissor sem fio para o centro de monitoramento, dando maior precisão no monitoramento e aumentando área de cobertura dos nós.

O uso de VANT (Veículo aéreo não tripulado) como nós móveis em rede de sensores sem fio vem crescendo nos últimos tempos, permitindo uma maior área de cobertura em relação aos nós estáticos, sendo aplicada em estratégias de detecção de rastreamento de alvos. Em [58], é apresentada uma abordagem inspirada em inteligência de enxame para mapear vazamentos de petróleo *offshore* complexos que usa uma equipe colaborativa de pequenos VANT com câmeras acopladas para captura de imagens. Por meio de imagens capturadas pelos drones e inteligência artificial para realizar mapeamento dos pontos de vazamento.

O desenvolvimento de nós dinâmicos com câmeras para capturar imagens vem ganhando mais espaço em aplicações em RSSF. Esses nós móveis são aplicados para detectar, localizar e rastrear vazamentos de petróleo no mar. O uso de câmeras reduz o número de sensores para realizar a mesma função de que um nós com vários sensores para executar a mesma função, apenas com uso de câmeras e algoritmos para analisar extrair os dados necessários. Em [59], é apresentada uma abordagem de sistema multiagentes, onde VANT realizam detecção, localização e mapeamento através de imagens de drones e é proposta uma abordagem distribuída (chamado de PSOil) para mapeamento de derramamento de óleo *offshore*. O planejamento do ponto de parada em voo é alcançado por meio de uma nova técnica inspirada na mecânica do enxame de partículas, empregando uma nova combinação de detecção de anomalias para extração de conhecimento e uma abordagem de grade de ocupação estocástica para o processamento.

Em [82], é apresentada uma rede neural convolucional profunda (DCNN), chamada Rede Convolucional de Derramamento de óleo (OSCNet) para detecção de derramamento de óleo através do SAR. A DCNN faz a classificação para detectar automaticamente derramamentos de óleo na superfície do mar com

radars de abertura sintética. Que geralmente são considerados como parte de uma estrutura de processamento de três etapas, que inclui brevemente segmentação de imagem, extração de recursos e classificação de alvos.

Com os avanços nas tecnologias de sistemas embarcados e técnicas de programação proporcionaram o desenvolvimento de *softwares* que permitiram embarcar algoritmos de aprendizado de máquina em microcontrolares, que são cada vez mais empregados em atividades do cotidiano. Em [65], é fornecida uma revisão abrangente do novo ecossistema TinyML, que é um paradigma integrador de mecanismos baseados em aprendizado de máquina em pequenos objetos alimentados por microcontroladores. O trabalho apresenta o desenvolvimento de novas aplicações e serviços que não necessitam do suporte onipresente de processamento da nuvem, que com baixo consumo de energia e envolve riscos de segurança e privacidade de dados. Para fins de aplicação são apresentados vários *frameworks* TinyML são avaliados e o desempenho de vários algoritmos de aprendizado de máquina embarcados em uma placa arduino Uno, onde é analisado seu desempenho usando técnicas como redes neurais, máquina de vetores de suporte, árvores de decisão ou floresta aleatória em objetos frugais com recursos de *hardware* restritos.

As aplicações de RSSF e aprendizado de máquinas atingem diversos setores e quando são adicionados recursos de IoT para potencializar sua gama aplicações, em [50], é proposto uma rede de sensores vestíveis e aprendizado de máquina para realizar detecção de postura complexa e reconhecimento de atividade humana (*human activity recognition*-HAR) de alta precisão em tempo real. O protótipo apresentado realiza HAR em tempo real, usando dados brutos coletados de três nós sensores de movimento vestíveis sem fio em paralelo. Os sensores comunicam os dados inerciais medidos a um Raspberry Pi 3, executando um classificador pré-treinado, que realiza detecção e classificação de movimento em tempo real. Neste trabalho também é proposto um algoritmo de detecção e classificação baseado em *MultiMapping Spherical Normalization* (MMSN), em combinação com uma máquina de vetores de suporte com Kernel de função de base radial (SVM-RBF).

O rastreamento colaborativo de alvos é uma das aplicações das redes de sensores sem fio nas quais a rede deve contar com a programação do sensor para

equilibrar a precisão do rastreamento. Em [47], os autores apresentam um novo algoritmo de programação multissensor (ADP-MSS) baseado em programação dinâmica adaptativa (ADP) para rastreamento colaborativo de alvos para RSSF. Com base no filtro Kalman estendido (EKF) para prever e estimar o estado do alvo juntamente com uma rede neurais para resolução da equação Hamilton-Jacobi-Bellman (HJB), o algoritmo proposto ADP-MSS agenda vários sensores para cada intervalo de tempo ao longo de um horizonte infinito até atingir com alta precisão o rastreamento. A análise teórica mostra a eficiência da otimização do ADP-MSS e os resultados da simulação demonstram a sua precisão de rastreamento em relação aos alvos observados.

Em [83] é apresentado um método de ADP baseada em medições de sensores (*data driven*), onde os sistemas multiagentes de tempo discreto com dinâmica desconhecida, utilizando aprendizado por reforço. Baseado em sistemas multiagentes de tempo discreto, onde controle ótimo para sistemas multiagentes depende da solução da equação de Hamilton-Jacobi-Bellman, que geralmente é impossível de ser resolvida analiticamente. Para implementar o método de programação dinâmica heurística dependente de ação (ADHDP) online proposto, duas RNAs, 1) RNA crítico e 2) RNA ator. Essas redes são empregadas para aproximar as funções de índice de desempenho iterativo e políticas de controle, respectivamente, em tempo real. São usadas dois exemplos de simulações para demonstrar a eficácia do método proposto e são empregadas para aproximar as funções de índice de desempenho iterativo e as políticas de controle em tempo real.

Em [84] foi aplicado o método de ADHDP de rede de ação paralela para navegação de embarcações não tripuladas, onde este método é fundamentado em controle adaptativo que adota uma aproximação via rede neural RBF (*Radial basis function*) com base na análise de estabilidade de Lyapunov para garantir a estabilidade do sistema. Nas simulações apresentadas pelos autores resultaram que o método ADHDP de rede de ação paralela possui um caráter de controle adaptativo e pode navegar em embarcações não tripuladas com mais precisão e rapidez. Além disso, o método também pode eliminar o *overshoot* do controlador ADHDP ao navegar da embarcação em várias situações.

Os principais pontos que diferenciam essa tese dos trabalhos relacionados neste

estado da artes são: o monitoramento e classificação em tempo real e online do poluente presente no ambiente; o custo de operação do módulo (nó sensor) tendo sua facilidade em ser acoplado estruturas de barcos ou boias náuticas, estrutura adaptável com nós dinâmicos (veículos aquáticos) e nó estáticos; processamento interno de baixo consumo usando uma rede neural do tipo MLP estrutura de energia que tem como objetivo a sobrevivência do nó sensor. Em síntese o diferencial do sistema proposto tem na estrutura estratégias estimação e classificação estados que são fundamentais para garantirem a eficiência energética e operação segura, alcançar as propriedades desejadas e impedir e minimizar os danos dos impactos ambientais com ações rápidas nas tomadas de decisões.

## 1.4 Objetivos: geral e específico

O objetivo geral é apresentar a concepção e desenvolvimento uma metodologia de arquitetura nó sensores para RSSF baseado nas abordagens de sistemas embarcados, aprendizado de máquina e IoT para detecção e classificação de poluentes em ambientes aquáticos.

Os objetivos específicos são:

- Conceber e desenvolver uma arquitetura de um nó sensor baseado nas abordagens de sistemas embarcados, IoT, aprendizado de máquina para ambientes aquáticos;
- Desenvolver uma metodologia de detecção e classificação de combustíveis derivados de petróleo baseada em *hardware*;
- Desenvolver uma formulação matemática para o projeto de nós sensores;
- Desenvolver uma estratégia de classificação baseado em técnicas de aprendizado de máquina para sistemas embarcados com finalidade de classificação de poluentes em ambientes aquáticos;
- Desenvolver uma metodologia de fonte de energia/controlador de carga e descarga de baterias para garantir maior vida útil do nó sensor.

## 1.5 Organização da Tese

Nos Capítulos remanescentes deste documento são apresentados o arcabouço teórico e experimentais para viabilizar a metodologia proposta e os resultados da avaliação do desempenho para diversos cenários.

No Capítulo 2 são apresentados o conteúdo necessário para o desenvolvimento da tese apresentada. Os tópicos abordados estão direcionados para tecnologia envolvendo os conceitos ligados ao *hardware* e sistema de captação e observação do fenômeno físico. Conteúdos que englobam a rede de sensores sem fio, sistemas embarcados, e sensoriamento inteligente.

No Capítulo 3 são apresentadas as problemáticas que englobam os problemas tratados nesta tese, envolvendo o problema de sobrevida do nó sensor, cobertura ótima e classificação de poluentes em ambientes aquáticos. Neste capítulo é apresentado a essência da proposta da concepção e modelagem do sistema embarcado, os tópicos abordados são referentes a problemática, solução geral e particular.

No Capítulo 4 é apresentada a metodologia para concepção e desenvolvimento nós estáticos de RSSF baseados em sistemas embarcados e aprendizado de máquina.

O projeto de desenvolvimento do sistema embarcado é apresentado nos Capítulos 5 e 6. Apresenta-se o processo de desenvolvimento do projeto e implementação de nó sensor estático. Os resultados dos testes para o nó sensor para detecção e classificação de poluentes são apresentados.

No Capítulo 7, apresentam-se as conclusões e considerações sobre a metodologia desenvolvida do sistema proposto, publicações e sugestões trabalhos futuros. Também, são apresentadas as bibliografias utilizadas ao longo do desenvolvimento da pesquisa.

Nesta tese são apresentadas três apêndices que são estudos sobre a aplicação da proposta, modelagem e sensores. No Apêndice A é apresentado um estudo para avaliar a viabilidade da aplicação do nó sensor proposto, apresenta-se o estudo para implantação da detecção de resíduos derivados de petróleo e outros poluentes em Ambientes Aquáticos. Especificamente, apresenta-se um estudo de modelagem e implantação de uma rede de sensores sem fio para monitoramento de remanejamento na descarga de navios petroleiros no porto do Itaqui. No Apêndice

B é apresentado o estudo da modelagem matemática da medição pH. No Apêndice C é apresentado um estudo de um sensor para análise de partículas sólidas de poluentes próxima a lâmina d' água, especificamente apresenta as aplicações de um LDR e luz azul para um sensor de análise de partículas.

# PRELIMINARES: SISTEMAS EMBARCADOS E APRENDIZADO DE MÁQUINA

---

Neste capítulo são apresentados os principais conceitos tecnológicos envolvendo sensores inteligentes, colheita de energia, rede de sensores sem fio, nós sensores inteligentes e sistemas embarcados para RSSF. Conceitos estes buscando o arcabouço para solucionar a problemática de detecção e classificação do derramamento derivados de petróleo em ambiente marinho e processamento de sinais distribuídos em RSSF.

## 2.1 Conceito Tecnológico

A importância dos sistemas embarcados reside na sua penetração na maioria das atividades humanas. Atividades que dependem cada vez mais de sua capacidade de monitoramento em tempo real para, tais como: sensoriamento, processamento, comunicação e atuação [43].

Quanto as necessidades de sanar problemas que surgem devido à complexidade dos sistemas embarcados, os autores [62] afirmam que a complexidade e as aplicações com IoT, impõem restrições de projeto que demandam o desenvolvimento de métodos para encontrar o melhor compromisso entre os diferentes objetivos de projeto do sistema embarcado. Recentemente, os avanços

de *hardware* e *software* que são orientados para aplicações de inteligência artificial (IA) em sistemas embarcados com recursos e energia limitados para uma ampla classe de aplicações, aumentando a importância de encontrar soluções eficazes para os problemas mencionados [43].

Devido à importância dos sistemas embarcados para a operação e capacidade de tomada de decisão, questionamentos relevantes são levantados, tais como: segurança, proteção e confiabilidade que impactam diretamente na segurança física e de dados. Ainda, controle, validação, auto teste e observabilidade de sistemas embarcados de sua operação programada ou adquirida são preocupações significativas para sua aceitação em infraestruturas ou operações críticas. Como também, devem ser considerados os requisitos de custo, energia e manutenção, levando em consideração o alto número de sistemas embarcados esperado para aplicativos de IoT [43]. Ainda na citada referência, ressalta-se a importância em sistemas embarcados, a transferência de dados para processamento remoto, fomentando uma resposta mais rápida em tempo real e reduzindo a dependência de conexões de dados. Desta forma, contribui para melhorar a escalabilidade e aumentar a segurança.

Quanto ao projeto do sistema embarcado as sugestões e técnicas apresentadas nas referências que tratam de modelagem, síntese e análise são consideradas para projeto e implementação do nó proposto, tais como: referência [17], os autores apresentam modelagem, síntese e verificação para o Projeto de Sistemas Embarcados. Na referência [25], os autores apresentam uma introdução aos sistemas embarcados, enfatizando uma abordagem de sistemas ciber-físicos. Os autores apresentam o projeto de sistema embarcado [5]. Enfatizando sistemas embarcados, fundamentos de sistemas ciber-físicos (CPS) e a IoT. Na referência [79], os autores apresentam princípios de projeto de sistemas embarcados e computação distribuída.

## 2.2 Sensores Inteligentes

Os sensores são dispositivos que respondem à estímulos físicos, químicos ou biológicos de maneira específica e geralmente convertem em um sinal elétrico que pode ser interpretado por um observador ou por um instrumento. Estes

elementos são fundamentais para sistemas de medição, monitoramento e controle. Existem vários, estrutura e arquiteturas de sensores disponíveis no mercado, para aplicações no cotidiano [53, 69].

Os sensores, quando combinados com o condicionamento de sinal e um microcontrolador/microprocessador, formam um conjunto integrado que pode ser considerado como instrumentos inteligentes. Atualmente, esses sensores desempenham um papel fundamental no rastreamento de movimento, e os sensores inerciais baseados em MEMS (*micro-electromechanical system*) são amplamente empregados em diversas áreas, incluindo aplicações médicas, IoT, CPS, indústrias e robótica [9, 69].

A sensibilidade dos sensores, especialmente, quando se planeja realizar medições em ambientes hostis a longo prazo, muitas vezes exige disposições especiais para protegê-los, a fim de obter medições confiáveis. Como os sensores são projetados para serem utilizados por períodos prolongados, é importante considerar a coleta de dados e o consumo de energia. Nesse contexto, a tecnologia dos *smart sensors* e *intelligent sensors* atendem a esses requisitos, satisfazendo essas necessidades [53].

Na aplicação de sensoriamento em ambientes insalubres e hostis, os mais recomendados, de acordo com [53], são os *smart wireless sensors*, representam uma evolução em relação aos sensores tradicionais. Isso acontece porque esses sensores possuem processamento independente e são capazes de transmitir dados de forma sem fio. Essa característica representa uma grande vantagem em relação aos sensores tradicionais com fio, que muitas vezes não são uma opção econômica ou viável para esse tipo de aplicação [56].

Os sensores inteligentes são dispositivos que realizam uma série de operações de processamento de sinais do sensor embarcado, com a ajuda de circuitos eletrônicos de microprocessador/microcontrolador, usando recursos computacionais para executar funções internas predefinidas, detectar parâmetros e realizar o processamento e a transmissão dos sinais adquiridos por meio de sistemas de [9, 69].

Os sensores inteligentes são projetados para desempenhar tarefas específicas que requerem operações metrológicas e processamento de sinais diretamente no sensor. Isso é realizado com a ajuda de circuitos de processamento de sinal, um

conversor analógico/digital (CAD) e um microprocessador, conforme destacado por [69]. Entre as operações metrológicas realizadas por sensores inteligentes, estão a calibração, linearização, correção de erros, eliminação de deslocamento, conversão de sinal analógico para digital, e a estimação de parâmetros [80, 56].

Existem diversas técnicas de implementação de sensores inteligentes em nível de *hardware*, dependem de fatores como velocidade a ser mantida, possibilidade de integrar os módulos do sensor com o circuito de processamento e compatibilidade do processamento do sinal, dentre elas podem ser citadas: a) Com base em funções - *smart sensor*, *smart wireless sensor*, sensores convincentes, autoadaptativos, autovalidação; b) Com base em técnicas - suave ou virtual, matemático, simbólico, computacional, integração inteligente, *Very large-scale integration* (VLSI) [9, 80].

## 2.3 Colheita de energia

A otimização do consumo de energia desempenha um papel fundamental para vida útil de dispositivos eletroeletrônicos ativos. Aproveitar ao máximo os recursos disponíveis resulta em um desempenho aprimorado, podendo diminuir despesas e evitar o desperdício de energia. A *Energy in Harvesting* (Colheita de Energia) consiste em uma técnica que permite aproveitar a energia presente no ambiente para abastecer aparelhos elétricos e eletrônicos. Para dispositivos que usam bateria, essa tecnologia pode aumentar significativamente a vida útil da bateria ou até mesmo eliminar a necessidade do seu uso.

A colheita de Energia é uma tecnologia para coletar (ou seja, colher) pequenas quantidades de energia de várias fontes não convencionais, como luz, calor, vibrações e ondas de rádio que ocorrem no entorno imediato do dispositivo. Às vezes, também é chamada de geração de energia ambiental. Diferentemente das instalações solares e eólicas de grande escala, que geram grandes quantidades de energia, os coletores de energia coletam pequenas quantidades de energia de seus arredores imediatos. Quando embarcados a aparelhos celulares ou outros dispositivos pequenos, eles permitem que esses dispositivos gerem sua própria fonte de alimentação [51].

Com a aplicação adequada da coleta de energia, o uso de cabos de alimentação,

a troca de baterias, o carregamento de baterias, o enchimento de tanques de combustível e similares se tornarão desnecessários. Os dispositivos se tornarão verdadeiramente sem fio e independentes de intervenções físicas. Isso é especialmente útil para dispositivos instalados em locais de difícil acesso. Eles podem ser operados a longo prazo sem qualquer preocupação com manutenção. Além disso, existem muitos dispositivos de CPS, IoT e M2M (*Machine to machine*-tecnologia de comunicação entre máquinas, sem nenhuma assistência manual ou interferência humana) em uso que utilizam técnicas de colheita de energia para suprir suas carências energéticas. Conectar cada dispositivo à eletricidade ou substituir as baterias regularmente se tornará cada vez mais difícil. A colheita de energia tem o potencial de eliminar essas necessidades [45].

A aplicação do sistema de coleta de energia determina quais fontes de energia estão disponíveis no ambiente para alimentá-lo. As principais fontes de energia ambiental empregadas para fornecer energia, por exemplo, às redes de sensores sem fio (RSSF) são a energia solar, mecânica e térmica. Os dispositivos autoalimentados (*Self-powered devices*) normalmente têm dimensões reduzidas, pois suas aplicações mais frequentes são como nós em uma RSSF, dispositivos vestíveis e pequenos robôs [45, 51].

Segundo [45] a colheita de energia é um conceito importante para rede de sensores e IoT. Essencialmente, qualquer sistema que represente uma mudança de estado pode converter sua forma de energia em energia elétrica. Em alguns dispositivos este método é a sua única forma de energia, enquanto outros são sistemas híbridos que usam a coleta para aumentar ou estender a vida útil de uma bateria. Por sua vez, a energia coletada pode ser armazenada e usada (com moderação) para alimentar dispositivos de baixo consumo de energia, como sensores na IoT ou nós sensores de uma RSSF. Os sistemas devem ser eficientes na captura e no armazenamento de energia. Portanto, é necessário um gerenciamento avançado de energia. Por exemplo, se um sistema de colheita de energia usar uma técnica de coleta mecânica piezoelétrica embarcada em uma calçada, ele precisará compensar quando não houver tráfego de pedestres suficiente para manter a unidade carregada. A comunicação constante com os sistemas de colheita de energia pode drenar ainda mais a energia. Normalmente, essas implantações de IoT usarão técnicas avançadas de gerenciamento de energia para evitar a perda

total da funcionalidade [51].

### 2.3.1 Modelo matemático de uma célula fotovoltaica

O modelo do processo para fins de obtenção do ponto de máxima potência gerada pela célula solar é representado por um circuito equivalente. Esse modelo auxilia na definição das dimensões do sistema necessário para suprir as necessidades de energia do nó sensor, além de ser parte fundamental para o desenvolvimento de um sistema de controle de alimentação do nó sensor. O esquema de um painel é representado na Figura 2.1.

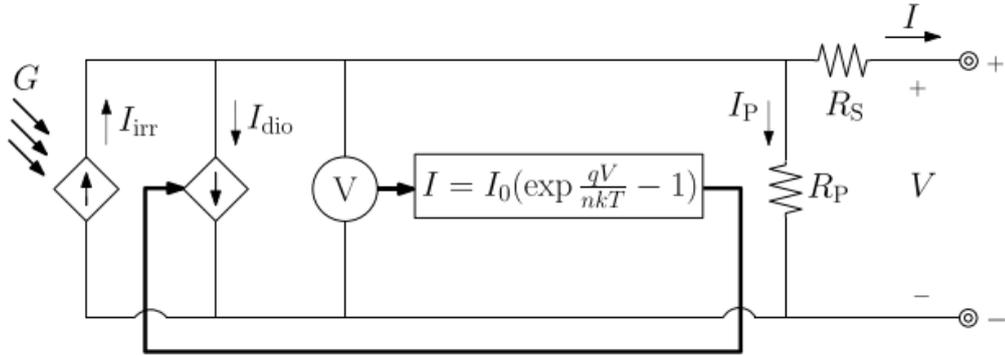


Figura 2.1: Modelo do díodo equivalente a célula fotovoltaica [49, 15].

Na Figura 2.1 é exibido o modelo de díodo anti-paralelo, o mesmo modelo é substituído por fonte de corrente controlada permitindo a representação da ligação das células em paralelo e/ou série em um único circuito com os detalhes de cada célula [16]. Associando ao circuito elétrico da fotocélula, tem-se que a corrente no terminal do painel é dada por

$$I = I_{irr} - I_{dio} - I_p, \quad (2.1)$$

sendo  $I_{irr}$  corrente de irradiância que é gerada pelos raios solares incidentes na célula exposta a luz solar,  $I_{dio}$  é a corrente no díodo anti-paralelo que é responsável pela característica não linear da célula,  $I_p$  por sua é a corrente de derivação devido ao resistor *shunt*  $R_p$ . Do circuito da Figura 2.1, substituindo em (2.1) expressões  $I_{dio}$  para  $I_p$  a corrente no terminal é

$$I = I_{irr} - I_0 \left[ \exp \left( \frac{q(V + IR_S)}{nkT} \right) - 1 \right] - \frac{V + IR_S}{R_p}, \quad (2.2)$$

sendo  $q = 1.602 \times 10^{-19}$  coulombs que é carga elétrica do elétron,  $k = 1.3806503 \times 10^{-23}$  J/K que é a constante de Boltzmann,  $T$  é a temperatura da célula,  $I_0$  trata-se da corrente de saturação do díodo,  $n$  é o fator ideal do díodo,  $R_S$  e  $R_P$  representam os resistores *shunt* em série e paralelo e  $V$  é a tensão no resistor *shunt*  $R_P$ .

Tabela 2.1: Tabela de substituição para o modelo da célula fotovoltaica

Expressão Original	Substituição
$N_P I_{irr}$	$I'_{irr}$
$N_P I_0$	$I'_0$
$\frac{N_S}{N_P} R_S$	$R'_S$
$\frac{N_S}{N_P} R_P$	$R'_P$

Este modelo de relação possibilita a generalização para um grande número de células conectadas em série representadas por  $N_s$  e outra quantidade de células em paralelo representadas por  $N_p$ , para formar um arranjo de matriz de dimensão  $N_S \times N_P$ , assim formando um grupo de gerador de energia elétrica, esse modelo é conhecido como generalizado. Sendo assim, o modelo generalizado assume um arranjo dado por

$$I = I'_{irr} - I'_0 \left[ \exp \left( \frac{q(V + IR'_S)}{N_S n k T} \right) - 1 \right] - \frac{V + IR'_S}{R'_P}, \quad (2.3)$$

sendo que os valores devem ser interpretados conforme Tabela 2.1.

Na relação  $I - V$ , as características de desempenho de uma única célula fotovoltaica e matriz são dadas pelas Equações (2.2) e (2.3), e respectivamente os parâmetros  $I_{irr}$ ,  $I_0$ ,  $R_P$ ,  $R_S$  e  $n$  dependem diretamente da irradiância solar ( $G$ ). A temperatura da célula ( $T$ ) influencia outros parâmetros de referência que são denominados  $G_{ref}$ ,  $T_{ref}$ ,  $I_{irr,ref}$ ,  $I_{0,ref}$ ,  $R_{P,ref}$ ,  $R_{S,ref}$  e  $n_{ref}$ , e descritos nas equações que são dadas por

$$I_{irr,ref} \frac{G}{G_{ref}} (1 + \alpha'_T (T - T_{ref})) \text{ A}, \quad (2.4)$$

$$I_0 = I_{0,ref} \left( \frac{T}{T_{ref}} \right)^3 \exp \left( \frac{E_{g,ref}}{k T_{ref}} - \frac{E_g}{k T} \right) \text{ A}, \quad (2.5)$$

$$R_P = R_{P,ref} \left( \frac{G}{G_{ref}} \right) \text{ Ohms}, \quad (2.6)$$

$$R_S = R_{S,ref} \text{ Ohms}, \quad (2.7)$$

$$n = n_{ref}. \quad (2.8)$$

Em (2.4),  $\alpha'_T$  é o coeficiente de temperatura relativo da corrente de curto-circuito, que representa a taxa de variação da corrente de curto circuito em relação a temperatura da célula solar. A relação fornecida pelos fabricante é dada por

$$\alpha_T = \alpha'_T I_{irr,ref}. \quad (2.9)$$

Em (2.5)  $E_g$  é a energia de *BandGap* (Banda Proibida) para o silício em  $eV$ . A expressão analítica para  $E_g$  são obtidas através do ajuste de curvas a partir de medições experimentais. A expressão utilizada é dada por

$$E_g = 1.17 - 4.73 \times 10^{-4} \times \frac{T^2}{T + 636} \text{ Volts}. \quad (2.10)$$

A relação de  $I - V$  descrita na Equação (2.3) mais divisão dos vários parâmetros constituintes descritos por (2.4) a (2.8) fornecem uma representação detalhada para o desempenho de uma matriz de tamanho arbitrário é usada para dimensionar o suprimento energético e controle carga/descarga do sistema embarcado. Seguindo a metodologia descrita em [15, 16], os parâmetros de referência são específicos para células fotovoltaicas e podem ser obtidos a partir de informações disponíveis nas fichas técnicas dos fabricantes.

## 2.4 Rede de sensores sem fio

De acordo com [63], as redes de sensores sem fio (em inglês *wireless sensor networks* - WSN) são redes de dispositivos com conjuntos de sensores autônomos, podendo ter atuadores ou não, onde a comunicação é realizada por meio de canais sem fio, os nós sensores distribuídos espacialmente para monitorar fenômenos físicos ou ambientais [41, 59]. Os nós sensores são posicionados a certas distâncias do fenômeno a ser observado, o que não é possível com redes de sensores tradicionais. As RSSF são utilizadas no intuito do monitoramento de áreas com difícil acesso ou inóspitas, tais como oceanos, confronto bélicos, desertos, vulcões, lixões, florestas, áreas industriais, etc [24].

Os sensores reunidos formam uma rede sem fio de coleta de dados, processando localmente as informações e disseminando os dados resultantes de um ponto para outro. A rede de sensores sem fio é uma área de estudo que possui ligação direta com outras, dentre eles temos telecomunicação, instrumentação, sistema embarcados, arquitetura de computadores, inteligência computacional e eletrônica [77]. As RSSF têm recursos integrados de computação, armazenamento, rede, sensoriamento e atuação com tecnologias de sensoriamento, computação (processamento local e distribuído) e redes sobrepostas (tecnologias conectadas a transmissão de longa distância). Essas redes são formadas por vários nós sensores (estáticos e móveis) que se comunicam entre si e com a estação base por meio de *links* de rádio sem fio [24], exibidos na Figura 2.2.

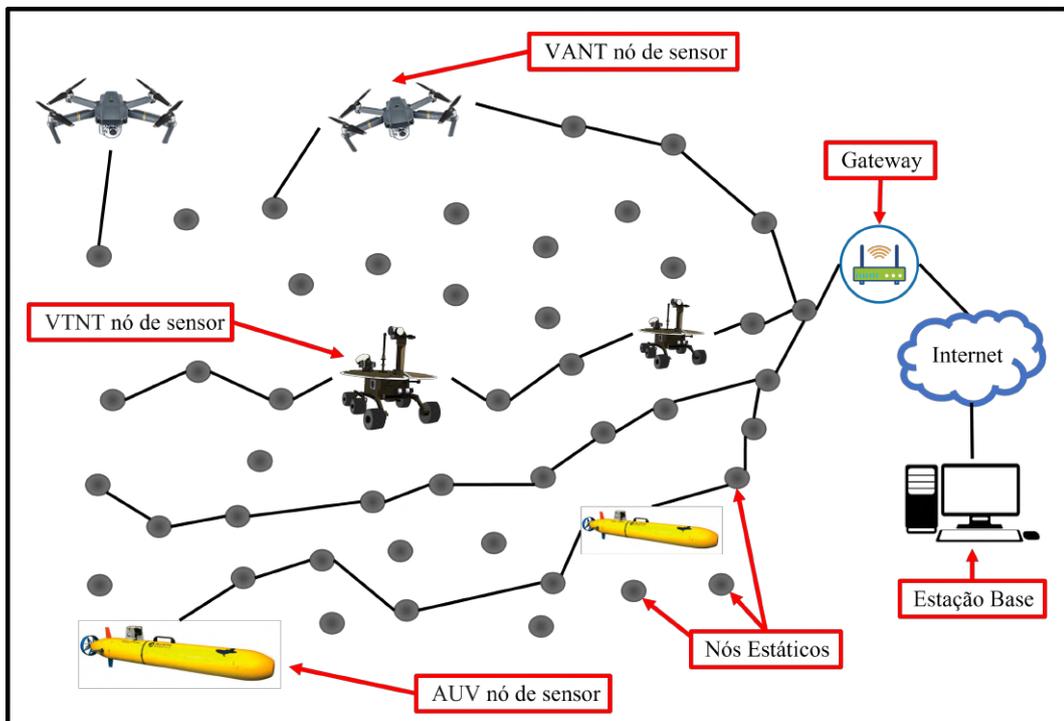


Figura 2.2: Estrutura Ad Hoc de uma rede de sensores sem fio com nós estáticos e dinâmicos.  
Fonte: Adaptado de [63]

Na Figura 2.2 são observados 2 tipos de nós sensores, os que estão de forma estática (fixos, sem deslocamento) e os que estão em movimento que podem ser drones ou um robô autônomo terrestre, esses nós por sua vez comunicam-se entre si (nó sensor tipo *sink*, "coletor com capacidade de roteamento", em uma estrutura

hierárquica ele se trata em nós chaves para RSSF) e com uma estação base através de uma comunicação sem fio [24]. A estação de captação tratamento de sinais e dados (estação base) externa à rede - tem papel de processar os dados e sinais dos nós repassados pelo *gateway* e ficando afastada do ambiente monitorado. Em alguns casos pode se restringir apenas ao *gateway*, tem a função de processamento, armazenamento, supervisão e controle local dos dados adquirido pela rede, onde o usuário (administrador) tem acesso ao processo que esteja supervisionando e extrair os dados/ características de seu interesse [63].

Vale ressaltar que dependendo da aplicação, ambiente a ser monitorado/observado à sua estrutura de comunicação (tecnologia de transmissão dos sinais/dados captados do nós da rede, podendo ser híbrido podendo abordar mais um tipo de tecnologia), tipologia de distribuição da rede, quantidade de sensores empregados em um nó sofrem influencia direta da aplicação e quantidade de nós no ambiente.

Em uma RSSF, os nós sensores são os principais elementos da sua composição. A função do nó é sentir, identificar, processar, relatar e observar estímulos do ambiente [63, 41]. Os principais requisitos para que sejam pequenos, capazes de reprogramação local, baixo consumo e eficientes energeticamente [76]. Os sensores presentes no sistema embarcado de um nó realizam medições de grandezas físicas, biológicas e químicas e convertem essa grandezas em um sinal elétrico que possa ser "lido/interpretado" pelo microcontrolador [69]. Os requisitos comuns para que os sensores sejam integrados a um sistema RSSF devem ser de tamanho pequeno, baixo consumo de energia e baixo custo. Avanços recentes na tecnologia de sistemas microeletromecânicos (MEMS) permitiram o desenvolvimento de sensores com baixo consumo de energia, custo e tamanho [69].

## 2.5 Nós sensores inteligentes e sistemas embarcados para RSSF

Conceitos de Sistemas Embarcados para RSSF são apresentados nesta seção. Aborda-se sensores inteligentes baseados em *software*. Os sensores inteligentes são dispositivos que realizam uma série de operações de processamento de sinal do sensor embarcado, com auxílio de circuito eletrônicos com

microprocessador/microcontrolador, fazendo uso dos recursos computacionais para executar funções internas predefinidas, detectam parâmetros, realizam o processamento e transmissão dos sinais adquiridos através de sistemas de comunicação.

A sensibilidade dos sensores, quanto a aferição à longo prazo, deve ser planejada no intuito de aumentar seu tempo de vida, em ambiente inóspito, se requer a necessidade técnicas para obter medições aceitáveis. Como os sensores são projetados para serem usados por um longo período, a coleta de dados é contínua e deve ser garantida a veracidade dos sinais estimados, e o consumo de energia devem ser levados em consideração. Entretanto, a tecnologia dos *smart sensors*, *intelligent sensors* atendem os requisitos suprindo as necessidades de robustez na medição. Na aplicação do sensoriamento de ambientes insalubres e hostis, os mais recomendados são os *smart wireless sensors*, que é uma evolução do *smart sensor*, pois possuem processamento independente e transmissão dos sinais sem fio. Trata-se de uma grande vantagem sobre os sensores tradicionais com fio, os quais não são uma opção barata e viável para esse tipo de aplicação [9].

Os nós sensores tem em sua composição do seu sistema embarcado pode ter um ou vários sensores (variando de acordo com a sua aplicação), microcontrolador ou microprocessador para processamento de sinal, memória, transceptor de rádio com antena para comunicação com nós vizinhos, energia de alimentação, (pode ter uma ou mais fonte de alimentação), circuitos de suporte e seu encapsulamento, na Figura 2.3 é apresentado o esquemático da estrutura básica de um nó sensor.

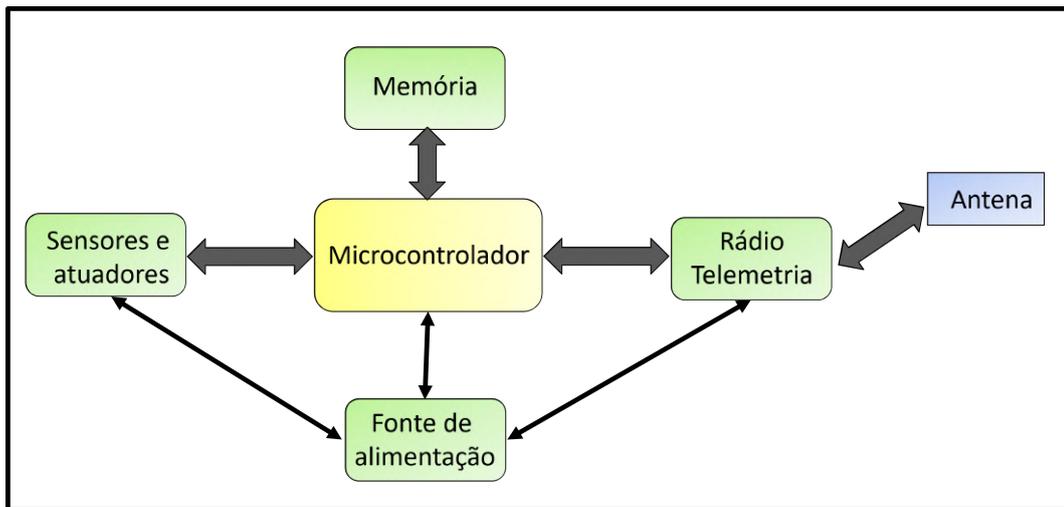


Figura 2.3: Arquitetura do Nós Sensores, Periféricos e módulos do sistemas funcionais e apoio.

Fonte: Adaptado de [63].

A escolha de componentes específicos depende da aplicação para a qual o nó se destina. Enquanto que fenômenos a serem medidos/observados, determina o tipo necessário de sensores, a seleção de sensores, por sua vez, determina o tipo de interface (como conversor analógico-digital) entre sensores/atuadores e microcontrolador/microprocessador [24, 63]. As técnicas de processamentos de sinais, agregação de dados na rede e outros processamentos de dados de aplicativos determinam o tipo de microcontrolador necessário [38]. Aplicações com alto custo computacional e análise de dados distribuídos baseada em nós requerem microprocessadores em vez de microcontroladores, mas com maior eficiência energética e alto desempenho. A escolha do microcontrolador central e armazenamento de dados determina o tipo de dispositivo de memória [24, 63].

O componente de rádio é escolhido com base nos requisitos da aplicação para taxa de dados, alcance, largura de banda, protocolo de comunicação interna para melhor gerenciamento de energia no sistema embarcado [63, 38]. A fonte de alimentação deve ter capacidade suficiente para suportar os componentes do nó podendo vir de duas fontes de energia. Na Figura 2.3 observar-se que a arquitetura da estrutura básica de um nó sensor que esta dividida em:

- Memória: parte do sistema responsável pelo armazenamento das instruções e operações da unidade de operação e controle. Vale ser salientado que as

instruções e dados podem dividir a mesma memória, igual aos computadores pessoais baseados na arquitetura de Von Neumann ou com as memórias separadas e distintas, baseados na arquitetura Harvard, sendo o modelo mais adotado nos SE's (sistemas embarcados) devido a diminuição do processamento computacional;

- **Processamento e Controle:** responsável por executar e controlar (*software/firmware*) responsáveis por realizar o controle físico, realizar as funções lógicas, tomar decisões. Normalmente possui arquitetura clássica similar a dos processadores e controles convencionais (níveis são utilizados microcontroladores e microprocessadores) de computadores pessoais, possuem componentes similares como unidade de lógica/aritmética (ULA), unidade de controle (UC) e registradores;
- **Periféricos:** são responsáveis por realizar a comunicação com meio externo (ambiente, ou planta onde for aplicado), captando informações ou trocando informações com ambiente desejado. Um dos principais periféricos é o conversor AD (analógico/digital), responsável por converter os dados dos sensores em uma sequência de número binário para que a unidade de controle possa realizar o processamento e interpretação dos dados coletados e transmiti-lo para uma estação base ou *sinks*, no caso relacionando a uma RSSF.

### 2.5.1 Topologias e protocolos de roteamentos de RSSF

A topologia de uma rede de sensores assemelha-se a uma rede de computadores assim possuindo características similares, tanto em sua estrutura como na sua transmissão de dados.

A topologia de uma rede de sensores sem fio refere-se a forma que os nós sensores são distribuídos, em uma determinada rede [24]. Os princípios gerais da topologia de uma RSSF são os mesmos de qualquer outra rede sem fio, um exemplo das similaridades entre rede de sensores e computadores. As topologias mais comuns são estrela, malha e a topologia malha-estrela híbrida [63], que são exibidas na Figura 2.4.

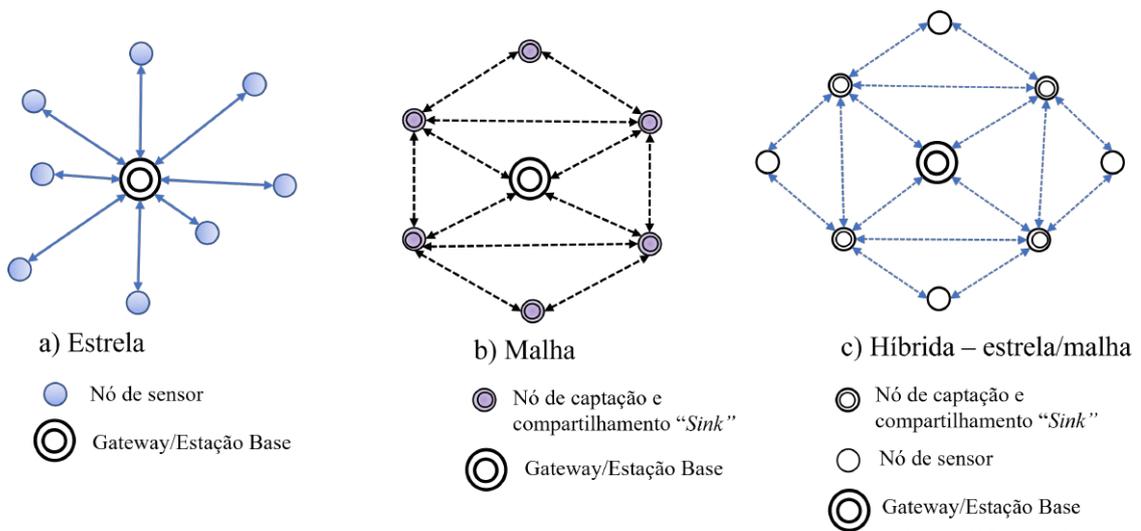


Figura 2.4:  
 Representação das topologias mais usadas nas RSSF.  
 Fonte: Adaptado de [63, 24] .

Na topologia estrela na Figura (2.4-a) os nós sensores estão organizados no formato de uma estrela, com estação base no centro da estrela. Os nós sensores transmitem os dados diretamente para estação base e não realizam a troca de dados entre elas (não interagem), como pode-se observar na Figura (2.4-a). Uma das principais características dessa topologia é um baixo consumo de energia em comparação com as outras. Esta topologia depende apenas de único nó (estação base) para gerenciar a rede. Um ponto negativo é, justamente, depender apenas de um nó sensor de um *gateway*, caso ocorra algum problema em sua estação base, podendo ser uma simples falha ou ruído comprometer toda rede de sensores [63, 24, 38].

A topologia do tipo malha, Figura (2.4-b), nesta configuração topológica permite que os nós sensores se comuniquem entre si. Isto quer dizer, que um *sink* que consiste em um nó sensor pode enviar dados para outro nó fora do intervalo, ele pode usar um nó intermediário como ponte de comunicação com o nó desejado. Um dos pontos positivos desta topologia é que, caso um nó sensor falhe, a comunicação/troca de dados é possível com outros nós dentro do enlace. Porém, um ponto negativo é que essa topologia tem alto consumo de energia devido a transmissão de dados redundantes [63, 24, 38].

A topologia híbrida malha/estrela que pode ser observada na Figura (2.4-c), consiste em uma topologia que tem características das duas topologias. Esta topologia aproveita o baixo consumo de energia presente na formação em estrela e tem o benefício da redundância de dados da topologia em malha, fornecendo a garantia que todos dados cheguem ao seu destino [63, 24, 38].

As topologias estão ligadas diretamente aos protocolos de comunicação, porque com a variação dos números de nós, região que implicará em um protocolo diferente ou que melhor se adequa a topologia/aplicação. Os protocolos de roteamento descrevem como os sinais/dados são transmitidos por toda rede. A maioria dos protocolos de roteamento são classificados como centrados em dados, hierárquicos, baseados em localização ou com reconhecimento de QoS (*Quality of Service* ou Qualidade de Serviço)[38, 63].

Os protocolos centrados em dados, geralmente aplicado em rede de sensores sem fio de grande escala/com grande números de nós cobrindo uma grande região. Com grande número de nós distribuídos aleatoriamente torna inviável consultar sensores usando seus identificadores individuais. Uma abordagem para resolver esse problema é enviar consultas para regiões específicas (conjunto ou *cluster* de nós sensores)[24], de modo que os dados dos sensores daquela região sejam enviados em resposta à consulta. O desafio com essa abordagem é que os dados de vários sensores em uma determinada região contêm muitas redundâncias, devido ao fato que os sensores em qualquer vizinhança provavelmente estão detectando o mesmo evento (os dados do sensor são altamente correlacionados). Os protocolos centrados em dados exploram a nomenclatura baseada em atributos para agregar dados com base nas propriedades dos dados para eliminar redundâncias à medida que os dados são enviados pela rede. Essas abordagens alcançam redução do consumo de energia significativas em RSSF. Exemplos de protocolos centrados em dados incluem, *Sensor Protocols for Information via Negotiation* (Protocolos de sensor para informações via negociação - SPIN), difusão dirigida e roteamento de rumores [24, 63, 38].

Os protocolos hierárquicos, das RSSF são particionadas em *clusters*, cujos os mestres realizam principalmente tarefas de processamento (por exemplo, agregação) e encaminhamento de informações, enquanto que os outros nós realizam as tarefas de detecção dentro dos *clusters*. Os protocolos hierárquicos

têm a vantagem de serem escaláveis devido ao design multicamadas, ao mesmo tempo em que atingem eficiências no consumo de energia. Exemplos de protocolos hierárquicos incluem hierarquia de *clustering* adaptável de baixo consumo energia (LEACH - *low-energy adaptive clustering hierarchy*), coleta eficiente de energia em sistemas de informação de sensores (PEGASIS - *power-efficient gathering in sensor information systems*) e protocolo de rede de sensores de eficiência energética de limiar sensível (TEEN - *threshold-sensitive energy efficient sensor network protocol*) [38, 24].

Os protocolos baseados em localização, são protocolos que usam informações sobre a localização do nó sensor para rotear sinais/dados de maneira eficiente em termos de energia. A distância entre duas localizações de sensores é calculada e sua necessidade de consumo de energia é estimada. Protocolos baseados em localização incluem rede de comunicação de energia mínima (MECN - *minimum energy communication network*), fidelidade adaptativa geográfica (GAF - *geographic adaptive fidelity*) e roteamento com consciência geográfica e energética (GEAR - *geographic and energy aware routing*) [38, 77, 63].

As categorias de protocolos de roteamento de RSSF descritas anteriormente também são consideradas *QoS-Aware* (reconhecimento de QoS - *Quality of Service*), pois segue a linha de otimizar variáveis como o consumo de energia, fator fundamental na determinação da qualidade do serviço de operação de uma RSSF.

## 2.5.2 Aprendizado de Máquina

A evolução da computação, processamento sinais/dados proporcionou avanços no aprendizado de máquina. Iniciando assim uma nova era oportunidade para inserir inteligência computacional dentro dos dispositivos de IoT. Aplicando técnicas de aprendizado de máquina em nós de IoT de baixo custo, como microcontroladores para realização de tarefas como, detecção, tomada de decisões, classificação, regressões, fusão sensorial entre outras [64], sendo aplicados em diversas atividades, tais como monitoramento de áreas ambientais e críticas, qualidade do ar, navegação, medições de energia, redes de sensores sem fio em ambiente industrial para monitoramento de atividades de risco. Esses métodos limitam os recursos de carga útil do dispositivo de computação e exigem a

implantação de *hardware* leve e *pipelines* de inferência. Tradicionalmente, os microcontroladores operam com sinais de sensores estruturados de baixa dimensão por meio de métodos clássicos. Com a evolução dos métodos de aprendizado de máquina, esforços consideráveis estão em andamento para levar ao patamar de embarcar esses algoritmos em dispositivos menos complexos. Desta forma, conduzindo o aprendizado de máquina a outro patamar de aplicação no mundo real [66, 64].

Na taxonomia da Inteligência Artificial, o aprendizado de máquina é reconhecido como uma área ou subconjunto desta. Os métodos de aprendizado de máquina são divididos em três principais categorias: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço [11].

No contexto da proposta apresentada nesta Tese, a RNA atua como o sensor secundário, permitindo a análise (*parsing*) da informação ao longo do processo de medições diretas e indiretas. O aprendizado de máquina fornece conceitos e algoritmos para desenvolver metodologias que analisam sinais (informações) e aprendem com eles para a tomada de decisões. As redes neurais são classificadas como um subconjunto dos algoritmos de aprendizado de máquina.

Segundo [30], As redes neurais são tecnologias de aprendizado projetadas para resolver processos complexos. Uma rede neural típica consiste em um conjunto de algoritmos que modelam dados utilizando neurônios artificiais para aprendizado de máquina. Inspiradas na estrutura do cérebro, as redes neurais são compostas por unidades altamente interconectadas, conhecidas como nós [36].

## 2.6 Redes Neurais Artificiais

As RNAs, também conhecidas como modelos conexionistas, representam uma área da inteligência artificial que tem crescido significativamente nos últimos anos. Elas podem ser caracterizadas como modelos computacionais com capacidade de adaptação, generalização, aprendizagem, agrupamento, organização e estimativa de dados [11]. Segundo [35], uma RNA é um processador altamente paralelo, composto por unidades de processamento simples chamadas "neurônios", que possuem a capacidade intrínseca de armazenar e utilizar conhecimentos adquiridos a partir de experiências.

As redes neurais são estruturas complexas compostas por uma vasta interconexão de células computacionais simples, conhecidas como "neurônios" ou "unidades de processamento". Dotadas de um "algoritmo de aprendizagem", sua função primordial é ajustar os pesos sinápticos de maneira ordenada para alcançar os objetivos propostos. Além disso, essas redes destacam-se pela capacidade de resolver problemas complexos, aproveitando o processamento paralelo e distribuído da informação, enquanto também são capazes de generalizar os resultados obtidos por meio da aprendizagem [35] [11].

As RNA tem inspiração nas redes neurais biológicas, constituídas de neurônios separados por camadas. Estes neurônios processam informações e estão conectados por pesos sinápticos, sendo na maioria das vezes sistemas adaptativos que modificam sua estrutura através de informações, que fluem pela rede durante a etapa de aprendizado. Inspirados nessa arquitetura complexa, vários modelos matemáticos de neurônios artificiais foram desenvolvidos, refletindo o conhecimento biológico sobre o funcionamento do cérebro humano [35][32].

Os sistemas neurais realizam o reconhecimento de padrões por meio de interconexões entre um grande número de células, chamadas neurônios. Essa extensa rede de conexões neurais paralelas confere ao sistema de processamento de informações humano características como adaptabilidade, sensibilidade ao contexto, tolerância a erros, grande capacidade de memória e responsividade em tempo real. Essas qualidades do cérebro humano oferecem um modelo alternativo à arquitetura mais comum de processamento de sinal serial e processador único. Embora cada neurônio humano processe informações em uma escala de tempo relativamente lenta (na ordem de milissegundos), o processamento global de informações no cérebro humano é concluído em algumas centenas de milissegundos. A rapidez do processamento cerebral sugere que a computação biológica ocorre por meio de um pequeno número de etapas seriais, cada uma delas sendo acontecendo em paralelo. As redes neurais artificiais buscam imitar o poder perceptivo ou cognitivo dos seres humanos usando o paradigma de processamento paralelo [44].

## 2.6.1 Perceptron de Múltiplas Camadas e Algoritmo de Retropropagação

As RNAs são modelos computacionais inspirados no sistema nervoso central, ou seja, capazes de realizar o aprendizado de máquina (*machine learning*) e reconhecimento de padrões. O tipo mais simples de rede neural artificial foi proposto em 1958 por Frank Rosenblatt [36][11]. Para superar as limitações práticas do perceptron de única camada, foi desenvolvida uma nova estrutura de rede neural chamada perceptron multicamada (MLP). Segundo [36], uma MLP possui três características distintivas que: a) Cada modelo de neurônio na rede inclui uma função de ativação não linear que é diferenciável; b) A rede contém uma ou mais camadas ocultas dos modos de entrada e saída; c) A rede possui um alto grau de conectividade, sua extensão é determinada pelos pesos sinápticos da rede. Uma modificação na conectividade da rede requer uma mudança na estrutura das conexões sinápticas ou dos seus pesos. Através da combinação destas características, juntamente com a habilidade de aprender via treinamento, que a perceptron de múltiplas camadas deriva seu poder computacional. Um método eficaz para o treinamento dos perceptrons multicamadas é o algoritmo de retropropagação que é considerado um marco no desenvolvimento da rede neural [11].

Uma MLP treinada com o algoritmo de retropropagação pode ser considerada como um meio prático para executar um mapeamento de entrada-saída não linear de natureza geral. Sendo  $m_0$  o número de nós na camada entrada de uma MLP e  $M = m_L$  o número de neurônios na camada escondida, então a relação de entrada de saída e uma RNA de múltiplas camadas é definida com o mapeamento  $m_0$  como entrada em um espaço euclidiano dimensional e  $M$  como saída, que é infinitamente diferenciável continuamente quando a função de ativação é igualmente diferenciável continuamente. O teorema da aproximação universal para um mapeamento não linear de entrada e saída é diretamente aplicável as redes perceptrons de múltiplas camadas, a Figura 2.5 exhibe a estrutura típica de grafos de uma rede MLP [36].

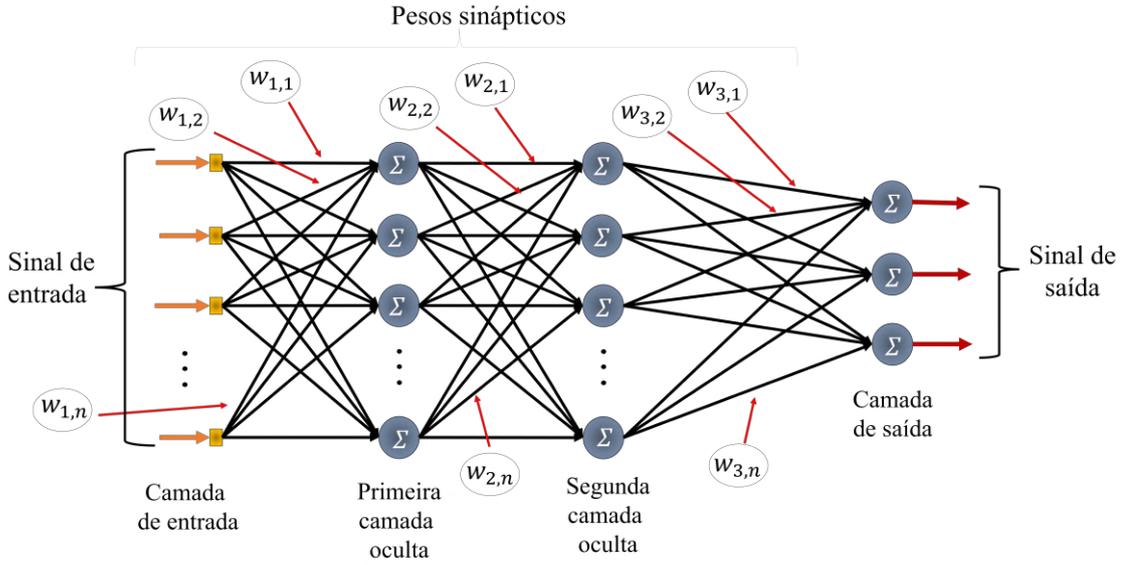


Figura 2.5: Grafo da arquitetura de uma rede neural artificial perceptron de multicamadas com duas camadas ocultas. Fonte: Adaptado de[36].

A Figura 2.5 exibi o grafo da estrutura de uma MLP com duas camadas ocultas e uma camada de saída. Para preparar o cenário para uma descrição do perceptron multicamada em sua forma geral, a rede mostrada interconectada, isto é, um neurônio em qualquer camada da rede está conectado a todos os neurônios (nós) na camada anterior. O fluxo de sinal se propaga através da rede progredindo em uma direção para a frente, da esquerda para a direita e camada por camada [35]. Porém para realizar o cálculo do número mínimo de camadas ocultas de uma MLP é necessário aplicar teoria universal da aproximação para um mapeamento não linear de entrada e saída, que pode ser declarado da seguinte forma.

Seja  $\varphi(\cdot)$  uma função não constante, com limites, e uma função monotônica contínua positiva. Seja  $I_m$  uma unidade dimensional. O espaço de funções contínuas de  $I_m$  escreve-se  $C(I_m)$ , que é dada por

$$F(x_1, \dots, x_{m_0}) = \sum_{i=1}^{m_1} \alpha_i \varphi \left( \sum_{j=1}^{m_0} w_{ij} x_j + b_i \right). \quad (2.11)$$

Assim para cada  $\varepsilon > 0$  e cada função  $f \in C(I_m)$ , tem uma constante  $N$ , constantes reais  $v_i, b_i \in \mathbb{R}$  e vetores reais  $w_i \in \mathbb{R}^m$  onde  $i = 1, \dots, N$  tal que possa definir na Equação (2.12), como uma realização aproximada da função  $f$ , onde  $f$

é independente de  $\varphi$ , ou seja

$$|F(x_1, \dots, x_{m_0}) - f(x_1, \dots, x_{m_0})| < \varepsilon, \quad (2.12)$$

para todos  $x \in I_m$ , então para todos os  $x_1, x_2, \dots, x_m$  que estão no espaço de entrada.

Pode-se notar que a função tangente hiperbólica usada como não linearidade em um modelo neural artificial para a construção de uma MLP é de fato uma função não constante. Portanto, satisfaz as condições impostas à função  $\varphi(\cdot)$  a seguir nota-se que a Equação (2.11) representa a saída de uma rede perceptron de multicamadas e também chamado de aproximador universal de funções [36]. O teorema universal da aproximação é um teorema existencial, no sentido em que fornece a justificação matemática para a aproximação de uma função contínua arbitrária em oposição à representação exata [11].

A correção  $\Delta w_{ji}(n)$  aplicada a  $w_{ji}(n)$  é definida pela regra delta, que é dada por

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)}, \quad (2.13)$$

sendo  $\eta$  é o parâmetro da taxa de aprendizagem do algoritmo retropropagação.

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n), \quad (2.14)$$

sendo o gradiente local  $\delta_j(n)$  é definido por

$$\delta_j(n) = e_j(n) \varphi'_j(v_j(n)). \quad (2.15)$$

Observa-se que o gradiente aponta para as modificações necessárias nos pesos, o gradiente local representado por  $\delta_j(n)$ , para o neurônio de saída  $j$  é igual ao produto do sinal de erro  $e_j(n)$  correspondente para aquele neurônio pela derivação  $\varphi'_j(v_j(n))$  da função de ativação associada, isto é, o algoritmo de treinamento de retropropagação, que é fundamental para o desenvolvimento do treinamento de redes neurais MLP.

## CAPÍTULO 3

# PROBLEMA DE DETECÇÃO E CLASSIFICAÇÃO DE POLUENTES DE DERIVADOS DE PETRÓLEO EM REGIÃO COSTEIRA

---

Neste capítulo são abordadas os principais problemas envolvendo detecção e classificação de poluentes em ambientes aquáticos, área de cobertura do nó sensor e sua sobrevida. Estes problemas impactam diretamente na estrutura e longevidade da cobertura de uma RSSF.

### 3.1 Problema de detecção e classificação

O monitoramento do mar por meio de sensoriamento remoto desempenha um papel crucial na detecção e combate à poluição marinha causada por derramamentos derivados de petróleo (em grande parte combustíveis) ocasionado por acidentes, mitigando os riscos ambientais e socioeconômicos associados. Os derramamentos de combustíveis representam um sério risco ambiental, causando danos significativos à vida marinha, ecossistemas costeiros e recursos pesqueiros, como podem ser visto na Figura 3.1. Além disso, esses eventos têm impactos socioeconômicos negativos, afetando a saúde das comunidades costeiras, a indústria do turismo, atividade pesqueira e atividades econômica de portos.

Para combater esses riscos, é essencial contar com um sistema de monitorização eficiente, de baixo custo e em tempo real, capaz de medir com precisão a espessura e a localização do poluente derramado. Até o momento, os métodos de detecção existentes têm apresentado limitações em atender plenamente a esses requisitos. As limitações estão relacionadas ao fatores climáticos, classificação realizada de modo externa (coleta local das amostras e enviadas para laboratórios), custo de operação e monitoramento não extensivo, sendo identificada após horas, dias até mesmo meses [55]. Portanto, o desenvolvimento de técnicas para o monitoramento e detecção dos poluentes na água são necessárias.

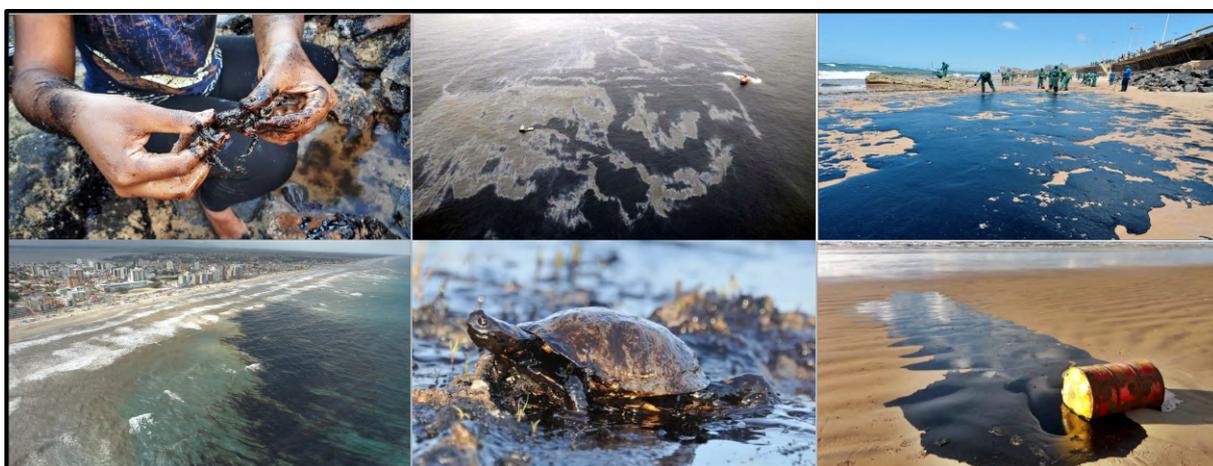


Figura 3.1: Derramamento 2019 na costa do nordeste- IBAMA Fonte: Adaptado de [55, 39, 23].

Segundo [55] existem graves problemas na estrutura de monitoramento de crimes ambientais envolvendo vazamento de petróleo e seus derivados são exibidos na Figura 3.1. A extração de petróleo no Brasil é feita por meio das reservas desse recurso natural, que se encontram em bacias sedimentares localizadas, tanto no continente, quanto na plataforma continental. A exploração acontece em campos *onshore* e *offshore*, respectivamente, nas bacias continentais e marinhas são vistas na Figura 3.2- a), b), c), essa áreas de exploração são sensíveis a derramamento, uma vez que as correntes marinhas rapidamente espalham os poluentes por toda costa além de ameaça a fauna e flora marinha.

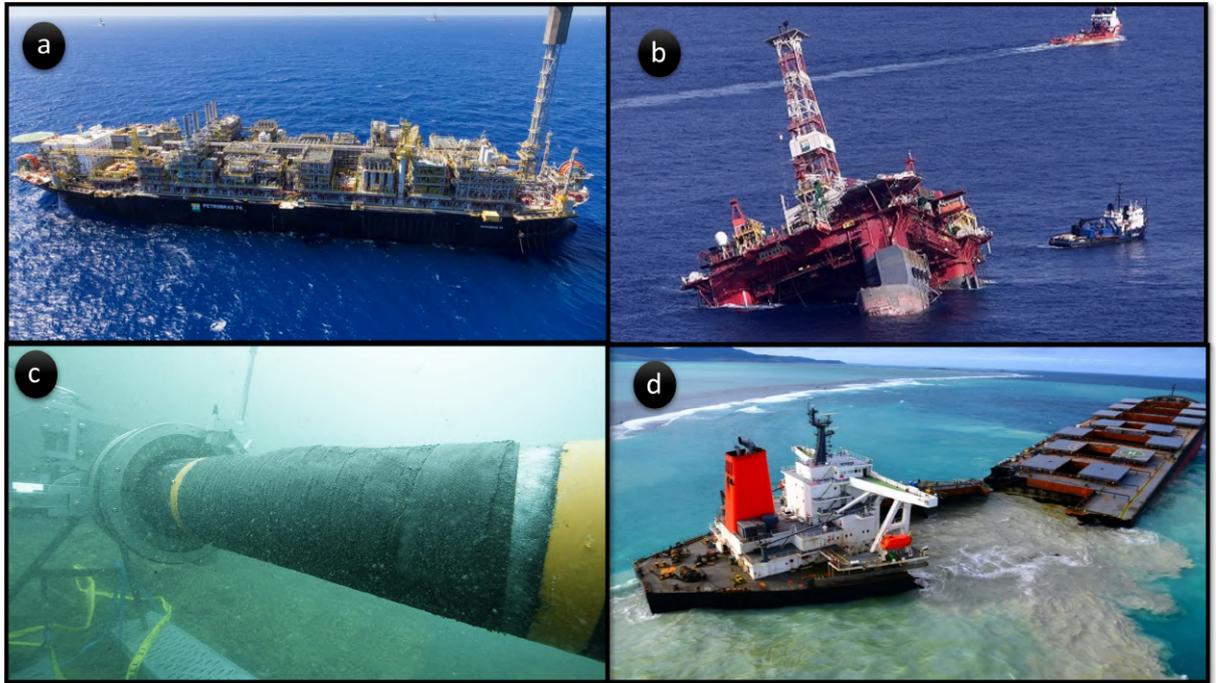


Figura 3.2: Zonas sensíveis de derramamento de derivados de petróleo e acidentes Fonte: Adaptado de [39, 3].

De acordo com [55, 23], o Brasil não possui um sistema operacional permanente para monitoramento de derramamento de óleo no mar, sejam esses acidentes ocasionados na prospecção do petróleo em mar, por fratura de dutos submarinos e naufrágio navios. Na Figura 3.2 são exibidos locais de zonas sensíveis de acidentes com derramamento [3], (por exemplo a plataforma P-36 da Petrobras, foi a maior plataforma semi-submersa de produção de petróleo no mundo, antes de seu naufrágio em março de 2001, veja Figura 3.2- b).

Porém, vários países têm sistemas de monitoramento de derramamento de petróleo no mar, utilizando tecnologias avançadas para detecção e resposta rápida a incidentes ambientais. O Estados Unidos tem NOAA (*National Oceanic and Atmospheric Administration*), utiliza satélites, aviões, drones e boias para monitoramento e resposta a derramamentos. O Canadá também possui sistema, o *Environment and Climate Change Canada* monitora derramamentos de petróleo com o uso de satélites e sensores aéreos, a Noruega tem dois sistemas, *Norwegian Coastal Administration* que emprega satélites, aviões e navios para monitorar derramamentos de petróleo no Mar do Norte e o *Kystverket* que utiliza uma

rede de radares costeiros e sistemas de vigilância para detecção precoce. Outros países que também possuem tecnologia de monitoramento são Reino Unido, Japão e Rússia. Esses países combinam tecnologias de satélite, aeronaves de vigilância, drones, sensores marítimos e redes de radar para uma vigilância eficaz dos derramamentos de petróleo em suas águas territoriais [73]. Visando propor um sistema de monitoramento *online*, no Apêndice A é apresentada uma RSSF para monitoramento de regiões costeiras aplicada a um porto com grande movimentação de carga derivados de petróleo.

### 3.1.1 Formulação do Problema Ambiental

O derramamento de óleos e derivados de petróleo (combustíveis) nas regiões costeiras causa grandes danos ao habitat e representa sérias ameaças a todos os organismos vivos que vivem na costa, que sobrevivem de pescas ou atividade econômica, esses efeitos ambientais são vistos na Figura 3.1. Os efeitos potenciais da contaminação por derivados de petróleo e poluentes tóxicos na biota variam de espécies para espécies, até mesmo provocando a extinção de vários seres vivos e doenças para os humanos.

### 3.1.2 Tecnologias disponíveis

A detecção de vazamentos de derivados de petróleo no mar apresenta desafios significativos, exigindo abordagens precisas e eficientes. Diversas técnicas têm sido exploradas para lidar com essa problemática complexa. A seguir são descritos algumas delas, juntamente com referências relevantes.

A detecção térmica infravermelha é uma abordagem comum, baseada na diferença de emissão de calor entre os filmes de óleo e a água circundante durante o dia. No entanto, essa técnica é suscetível às condições de iluminação e apresenta limitações na precisão das medições ao longo do tempo devido à mudança na composição química do óleo. O estudo mencionado em [67] discute a dependência da inércia térmica e das diferenças de temperatura entre óleo e água na identificação de locais de derramamento de óleo usando o *Advanced Spaceborne Thermal Emission and Reflection Radiometer* (ASTER) da NASA. No entanto, a transição de quente para frio do óleo não é nitidamente definida, afetando a

precisão das medições [48].

O sensoriamento por radar é outra técnica de sensoriamento remoto utilizada para detectar derramamentos de óleo no mar. Essa abordagem se baseia no retroespalhamento do sinal de micro-ondas transmitido pelo radar, mas é influenciada por condições atmosféricas, como vento e mar agitado. Um estudo realizado em [29] propõe uma solução completa para aquisição, processamento e monitoramento rápidos de derramamentos de óleo, utilizando imagens de radar de abertura sintética (SAR). No entanto, as imagens SAR podem ser afetadas por ondas curtas presentes na superfície da água do mar e pela alteração da viscosidade da água devido ao óleo derramado [13]. Além disso, as informações obtidas por meio do SAR não fornecem uma estimativa precisa da espessura do derramamento de óleo.

Técnicas baseadas em ultrassom também têm sido exploradas para a detecção de óleo no mar. Essas abordagens aproveitam características acústicas do óleo, como a reflexão do coeficiente e o atraso de tempo de uma onda ultrassônica entre os limites ar-óleo e óleo-água. O Instituto de Materiais Industriais do *National Council Research* Canadá desenvolveu um sistema de sensoriamento remoto ultrassônico a laser para medir a espessura do óleo [7]. No entanto, a presença de correntes oceânicas introduz imprecisões nessas medições.

Outra abordagem promissora é o uso de fluorossensores a laser, como o *Scanning Laser Environmental Airborne Fluorosensor* [20]. Esses dispositivos exploram a fluorescência diferencial dos diferentes tipos de óleo em comprimentos de onda específicos. A análise dos espectros de fluorescência, por meio de técnicas como análise de componentes principais, permite a detecção da presença de óleo. No entanto, esses dispositivos podem ser limitados por seu tamanho, peso e custo elevados [20].

A imagem hiperespectral também tem sido aplicada na detecção de óleo no mar, permitindo a construção de bibliotecas de assinaturas espectrais para diferentes tipos de óleo. Além disso, técnicas multiespectrais têm sido utilizadas para estimar a espessura do óleo com base nas proporções de comprimentos de onda específicos no espectro de absorção do óleo. No entanto, é importante ressaltar que a precisão absoluta dessas estimativas é desafiadora devido às variações nas propriedades da água do mar e nas condições de iluminação [26].

Em conclusão, o monitoramento de derramamentos de óleo no mar requer abordagens tecnológicas avançadas e precisas. As técnicas de detecção mencionadas anteriormente são apenas algumas das muitas abordagens exploradas na literatura científica. Cada uma delas apresenta vantagens e limitações específicas, e a escolha da técnica mais adequada depende das características do ambiente, dos recursos disponíveis e dos requisitos de precisão e eficiência.

As RSSF também desempenham um papel importante no monitoramento de desastres no mar. Essas redes podem ser utilizadas para monitorar e fornecer informações em tempo real sobre condições oceânicas, desastres naturais e atividades humanas que afetam o ambiente marinho. O coração da RSSF para realização de tarefas é o nó sensor, para esta aplicação ele tem o objetivo de detectar concentrações de poluentes que excedem limites críticos ou para delinear os limites de regiões contaminadas na água do mar. Como a densidade de sensores implantados no campo pode ser localmente insuficiente para a execução de tarefas dedicadas, é necessário adicionar sensores móveis adaptativos à infraestrutura de sensoriamento permanente. Apresenta-se à proposta de um método de sistema embarcado para nós estáticos em formato de (boias fixas) e como nó dinâmico os robôs-USV (*Unmanned Surface Vehicle* - veículo de superfície não tripulado), também conhecido como "*drone boat*" para realização do monitoramento remoto, realização da estimação dos estados de detecção e classificação dos poluentes presentes na água, a partir das medições (diretas e indiretas) dos sensores primários.

## 3.2 Concepção e modelagem do sistema embarcado

A fase de concepção do projeto do nó sensor é um dos pontos fundamentais. Durante esta fase, as especificações do projeto na fase das abstrações da arquitetura proposta e dos componentes que constituem o nó são apresentadas, tais como: os tipos de sensores e microcontrolador, observando o seu consumo de energia e poder de processamento. Estas especificações impactam diretamente na arquitetura do sistema embarcado. Outro ponto crucial é a escolha da tecnologia de rádio para transmissão e recepção dos sinais, tendo influência direta

no dimensionamento do sistema de alimentação da placa, a escolha adequada garante maior vida para o nó sensor.

O diagrama de blocos da Figura 3.3, (que é uma customização da Figura 2.3), representa a arquitetura do nó sensor proposto, destacando os blocos funcionais em torno da unidade de processamento e controle (CPU) com os subsistemas principais e auxiliares do nó sensor, tais como: energia, computação, interfaces e comunicação.

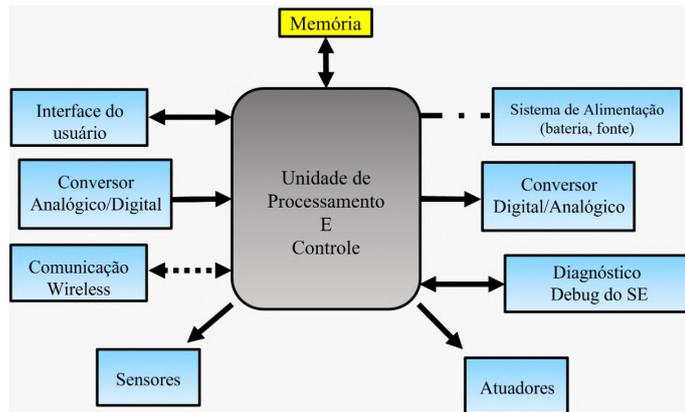


Figura 3.3: Arquitetura do Nós Sensores.

Fonte: Adaptado de [63].

Na Figura 3.3 é apresentada a arquitetura básica de um nó sensor inteligente RSSF. Além da estrutura clássica do sensor, ela inclui uma interface para o sistema de atuação. Ele não é um sistema passivo que observa o ambiente, mas é acionado por decisões predefinidas tomadas durante a programação ou por um usuário remoto.

O projeto e a modelagem do sistema embarcado são discutidos nesta seção, destacando a composição das camadas físicas da RSSF e a arquitetura dos nós sensores. No entanto, são destacados os principais elementos teóricos e tecnológicos que compõem o desenvolvimento da metodologia de projeto e implementação de nós sensores estáticos. Os principais elementos são o modelo matemático, o sistema de energia do nó, a estrutura de comunicação e a detecção e classificação por meio do aprendizado de máquina e IoT. Além disso, cada elemento é apresentado individualmente, destacando a funcionalidade para o desenvolvimento do nó sensor.

Nesta secção a concepção e modelagem do sistema embarcado são abordadas, destacando-se a composição das camadas físicas da RSSF e arquitetura dos nós sensores. Ainda, ressalta-se os principais elementos teóricos e tecnológicos que compõem o desenvolvimento da metodologia proposta e implementação de nós sensores estáticos. Os principais elementos são o modelo matemático, sistema de alimentação do nó, estrutura de comunicação e a detecção e classificação via aprendizado de máquina e IoT. Cada elemento é apresentado de forma individual, ressaltando a funcionalidade para o desenvolvimento do nó sensor.

### 3.2.1 Modelagem matemática do nó

Para melhor entendimento e compreensão é desenvolvido um modelo matemático da estrutura física que é baseado na teoria dos conjuntos e mapeamentos. Esta modelagem permite a sistematização para o desenvolvimento teórico e experimental do sistemas embarcado proposto.

Inicialmente, estabelece-se que a estrutura do conjunto de nós de uma RSSF que é dada por

$$WSN_{nds} = \{sn_1, sn_2 \dots sn_i \dots sn_n\}, \quad (3.1)$$

sendo  $sn_i$  ( $i = 1, \dots, n$ ) o  $i$ -ésimo nó da rede de sensores  $WSN_{nds}$  com  $n$  nós. A estrutura física de uma RSSF com  $n$  nós sensores é representada pelo conjunto  $WSN_{nds}$ .

Em termos de estrutura física, o  $i$ -ésimo nó da rede de sensores com  $n$  nós é formado por um conjunto finito de elementos que representam os sistemas funcionais principais e auxiliares da arquitetura do nó sensor da Figura 3.3. Os periféricos, módulos funcionais são expressos em termos de um conjunto que estão conectados ao elemento gerenciador dos serviços ou tarefas que são executadas para realizar o objetivo de nó. Especificamente, os nós são projetados para executar a tarefa de detecção e classificação de poluentes no meio ambiente.

De acordo com o exposto no parágrafo anterior, a abstração da estrutura física do  $i$ -ésimo nó da rede  $WSN_{nds}$  com  $n$  nós que representa a arquitetura do nó sensor da Figura 3.3 é dada por

$$sn_i = \{sp_1, sp_2, \dots, sp_j, \dots, sp_k\}, \quad (3.2)$$

sendo  $sp_j$  o  $j$ -ésimo grupo do  $i$ -ésimo nó ( $sn_i$ ) da rede  $WSN_{nds}$  com  $k$  grupos, cada grupo possui diferentes características ou funcionalidades que representam a arquitetura apresentada na Figura 3.3.

Para o elemento  $sp_j$  do grupo, os elementos do  $j$ -ésimo grupo são formados pelo conjunto finito que é dado por

$$sp_j = \{sp_{j_1} sp_{j_2} \dots sp_{j_m} \dots sp_{j_p}\}, \quad (3.3)$$

sendo  $sp_{j_m}$  o  $m$ -ésimo elemento do grupo  $j$  com  $p$  elementos.

De forma unificada, as relações entre os conjuntos (3.1), (3.2) e (3.3) são sintetizadas em termos de operações de conjuntos. A nova representação da estrutura física da rede sensores e dos seus nós é dada por

$$WSN_{nds} = \left\{ \bigcup_{j=1, m=1}^{k, p} sp_{j_m} \subseteq_{i=1}^n sn_i \right\}. \quad (3.4)$$

O modelo matemático representado pelo conjunto (3.4), estabelece a base estrutural completa de uma rede sensores que tem arquitetura dada na Figura 3.3. Ao contrário das relações (3.2) e (3.3) que proporcionam representações detalhadas dos grupos e dos seus elementos do conjuntos, respectivamente, que perfazem a  $WSN_{nds}$  representada por (3.1).

As saídas resultantes das estimativas e tarefas executadas pelos nós da rede de sensores são mapeamentos das informações dos conjuntos (3.1), (3.2) e (3.3) que são sintetizados pelo conjunto (3.4). Consequentemente, a saída do nó  $i$ -ésimo nó sensor da rede é dada por

$$\hat{y}_q(sp_{j_m}) = f_{nds} \left( \bigcup_{j=1, m=1}^{k, p} sp_{j_m} \right), \quad (3.5)$$

sendo  $\hat{y}_q(sp_{j_m})$  a  $q$ -ésima saída estimada ou filtrada do nó sensor  $sn_i$  da rede  $WSN_{nds}$  com  $n$  nós.

### 3.2.2 Sistema de alimentação do nó sensor

O diagrama de blocos da Figura 3.4 representa a alimentação da lógica de operação do nó sensor da rede. O sistema de alimentação é composto por três partes principais que funcionam de forma independente da unidade central de controle do sistema embarcado exibido na Figura 3.4 que corresponde os itens enumerados de (1) a (3), sendo (1) mini células fotovoltaicas, (2) controladora de carga/descarga de baterias com controle de alimentação do sistema embarcado e (3) - *pack* com 2 baterias Li-Po (íon de polímero) de 3,7 V com 1400mAh cada. A parte da central de processamento é representada por (4), a parte de sensoriamento (5) com suas subdivisões (5.1) sensores de contato com líquidos, (5.2) sensoriamento interno. A parte de transmissão do sinal é representado por (6), trata-se da etapa final de transmissão.

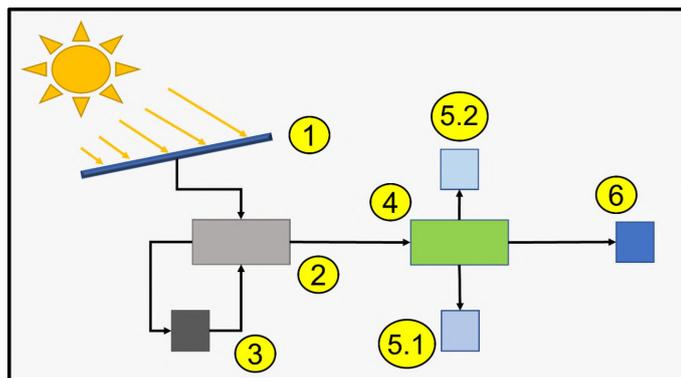


Figura 3.4: Bloco de organização da alimentação do nó sensor

Na composição do sistema de alimentação das baterias são usadas mini células fotovoltaicas, fazendo o uso do fornecimento da energia proveniente do sol. Também é levado em consideração, o difícil acesso ao *hardware*, após sua instalação, dificultando manutenção dos nós sensores. Almejando maior vida útil do nó, projetando-se um sistema de alimentação longevidade do sistema, operando durante o dia as mini células que fornecem a energia e são recarregadas em paralelo ao *pack* de baterias (trabalhando apenas para suprir quedas no fornecimento) e na ausência do sol o uso das baterias é de 100%, exibido na Figura 3.4. Em sua estrutura possui um microcontrolador (ATtiny85) responsável pelo o controle das cargas e fornecimento de energia do sistema embarcado, junto a unidade contra

com sensor de tensão/corrente, sensor cargas, conversores de tensão e a unidade de controle do sistema de alimentação funciona como sistema sub-atuado que tem comunicação direta com unidade de controle central do sistema embarcado (ESP32).

### 3.2.3 Estrutura de comunicação da RSSF

A estrutura de comunicação de uma RSSF e de um nó sensor inteligente é importante para garantir a comunicação estável, assegurando que os sinais/dados observados e estimados são enviados ao destino. O diagrama de blocos da Figura 3.5 representa a estrutura comunicação da RSSF e suas etapas. A malha de comunicação possui 3 etapas, sendo a etapa final os sinais/dados pré processados do nó sensor, sendo acessíveis ao usuários via uma *software* de processamento, banco de dados ou interface homem-máquina do usuário final.

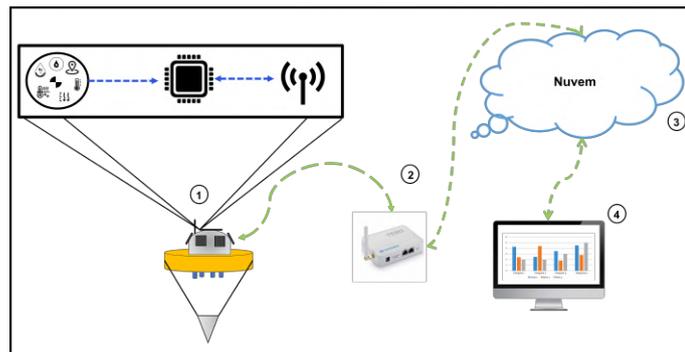


Figura 3.5: O Sistema de comunicação do nó sensor e as etapas do fluxo de comunicação: (1) nó sensor estático, (2) estação base/*gateway*, (3) Sinais armazenados na nuvem, (4) Destino final das medições e estimativas.

Representado na Figura 3.5, o fluxo de comunicação tem início na etapa (1) que é nó sensor, os primeiros sinais de medições dos sensores que são lidos, processados pelo microcontrolador. Os fluxos dos sinais de medições são pré processados na unidade de controle e outras variáveis são estimadas e sofrem compressão, seguindo para o módulo de comunicação, sem fio (no caso da implementação são utilizados o módulo LoRa 433 MHz e Wi-fi 5 GHz embutido no próprio microcontrolador). A comunicação do nó sensor para a base é usado um protocolo de rádio frequência de longa distância(LoRaWAN) para conexão

direta com a estação base/*gateway* (2). Os sinais/dados passam por compressão e encaminhados para a nuvem (3) representada na Figura 3.5, usando protocolo MQTT (*Message Queuing Telemetry Transport*). O *gateway* transforma e os envia para o *server*(servidor)/nuvem, onde são armazenados os sinais/dados estimados, viabilizando ao destino final (4), o acesso aos dados e monitoramento em tempo real de um dado perímetro por meio de medições e estimativas das grandezas envolvidas.

### 3.3 Detecção e classificação via aprendizado de máquina e IoT

Os nós sensores inteligentes possuem uma característica que os diferencia dos *smart sensors*, isto é, o uso de técnicas de processo de sinais e o uso de aprendizado de máquina para classificação, fusão e estimação de estados. Estas abordagens viabilizam grande quantidade de aplicações e novas possibilidades de integração com outras técnicas, tal como: IoT. Desta forma, novos desafios ou fronteiras para o desenvolvimento de teoria, algoritmos, *hardware* e aplicações da metodologia de aprendizado de máquina e sistemas embarcados, são observados.

A associação de dispositivos com a operação de detecção e classificação do nó sensor em uma RSSF é apresentada na Figura 3.6, destacando a RNA que executa as tarefas de detecção e processamento de sinais localmente dos sensores do nó.

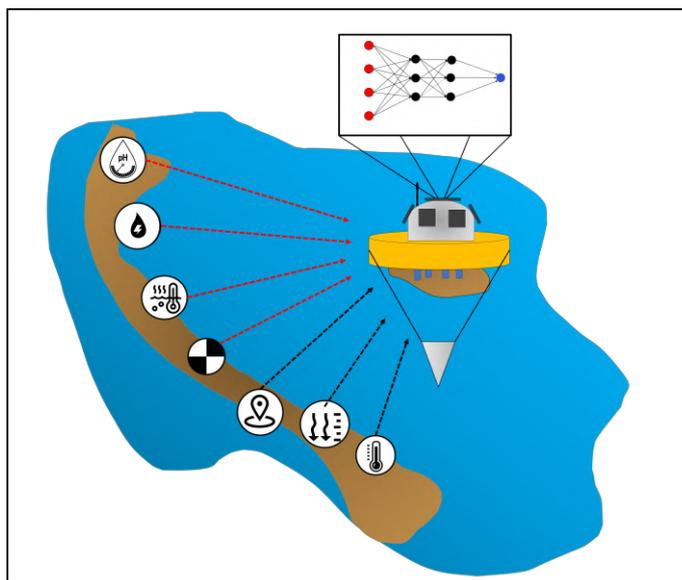


Figura 3.6: Detecção, classificação do nó estático e rede neural artificial.

A estrutura de medição é baseada na medição dos índices de pH, turbidez, temperatura da água e condutividade elétrica são os principais estados observados. Ressalta-se que nos primeiros testes, o sensor de condutividade não é usado com conjunto com todos os sensores, esses sinais de medição são fundamentais para a primeira análise do ambiente.

Na Figura 3.6 exibiu as variáveis observadas, com os principais estados a serem observados conectados em vermelho como entrada para a RNA do tipo perceptron multicamada. A rede neural realiza a classificação do composto presente na água, se é gasolina ou óleo diesel com base nas medições de pH, temperatura do líquido (em comparação com o ambiente), turbidez e condutividade. A rede neural consiste em um MLP com 4 camadas, incluindo uma camada de entrada e 2 camadas ocultas com 3 neurônios cada e uma na saída, que é o classificador. O TensorFlow Lite e a API TinyML são usados para treinamento supervisionado, e os algoritmos desenvolvidos são programados em Micropython.

### 3.3.1 Problema de sobrevida de nós

Os sensores inteligente, *smart sensors* (SS) e RSSF (ou o conjunto de SS) são dispositivos amplamente aplicados em diversas atividades do dia a dia, sendo

indispensável na sociedade contemporânea. Estes dispositivos juntos aos *edge devices* (dispositivos de borda) movimentam uma indústria de bilhões dólares, em sua grande maioria aliados a técnicas de IoT são usados em áreas muito remotas (monitoramento de eventos ou ações com baixa intervenção humana). Um dos grandes fatores de problemática do uso desses dispositivos é sua vida útil, a manutenção e a forma de alimentação em sua maioria das vezes é feita por meio de baterias. Para um maior prolongamento, se faz necessário do emprego de técnicas que aumentem sua longevidade do ponto de vista energético.

O gerenciamento de energia é um tópico muito amplo e abrange *software e hardware*. O importante de entender a função do gerenciamento de energia em uma implantação bem-sucedida de um sistema embarcado, CPS (*cyber physical system*/ sistema ciberfísico) e IoT e como gerenciar a energia de forma eficiente para dispositivos remotos e dispositivos para promover a longa duração de sua vida útil. Para esse problema é viável aplicar técnicas de colheita energia para sobrevida dos nós sensores.

### **3.3.2 Problema de cobertura de nó sensor de uma RSSF**

O desafio da cobertura, como um problema fundamental em uma variedade de aplicações em redes de sensores sem fio (RSSF), tem sido objeto de estudo por mais de uma década. Devido à sua simplicidade e facilidade de análise, a abordagem de cobertura completa é amplamente adotada em muitos estudos teóricos. No entanto, a necessidade de cobertura total pode ser reduzida para um requisito parcial, evitando assim o uso excessivo de sensores. Além disso, em certas situações, a cobertura total não é a representação fidedigna ou a mais eficiente de aplicações do mundo real, devido as suas restrições robustas e características determinísticas. Nesse sentido, uma abordagem mais adequada é introduzir incerteza nos problemas de cobertura. Ao analisar as características dos problemas de cobertura parcial ou probabilística e compará-los com os problemas de cobertura total, esta proposta visa fornecer uma visão dos problemas de cobertura não determinística, referidos como problemas de cobertura com propriedades incertas [74][46][19][52] [78].

A cobertura é um importante indicador da Qualidade de Serviço (QoS) de uma RSSF. Ela é um dos problemas fundamentais para o desenvolvimento de

uma RSSF. Há várias maneiras para abordar o problema de cobertura, porém o objetivo principal é determinar quão bem um conjunto de nós sensores monitora uma determinada região [63][46] [74].

A cobertura de sensoriamento é frequentemente relacionada a quantidade e como posicionar os nós sensores de modo a RSSF tenha a máxima cobertura sobre a região de interesse. Uma cobertura incompleta em RSSF (cobertura com buracos) significa que há regiões dentro da área de interesse que não estão sendo monitoradas pela rede. O problema de posicionamento ideal dos nós sensores é normalmente associado ao de cobertura, afim de se obter a região de interesse coberta ao máximo. A ideia principal é espalhar os nós o máximo possível para melhorar a cobertura de detecção [63][24][46] [74].

O problema da cobertura está ligado diretamente com o alcance de detecção do sensor e o alcance de comunicação do nó sensor. Existem diversos modelos para se determinar esses dois parâmetros, dentre eles o modelo mais simples é o modelo de disco binário, confinando a sensibilidade do nó sensor dentro de um determinado disco e fomentando as aplicações dos métodos estatístico, filtragem estocástica e inteligência computacional para otimizar a precisão e sensibilidade [68] [19].

# METODOLOGIA PROPOSTA

A metodologia proposta para o desenvolvimento do sistema inteligente baseado em modelos matemáticos, algoritmos, *software* e *hardware* para o monitoramento de alvos em ambiente aquático, é apresentada neste capítulo. Na Figura 4.1 é apresentada a estrutura do problema juntamente com sua solução do desenvolvimento da metodologia. No intuito de apresentar uma proposta generalizada para o projeto e implementação, os procedimentos para o desenvolvimento do sistema inteligente e suas aplicações são apresentadas de forma sistematizada.

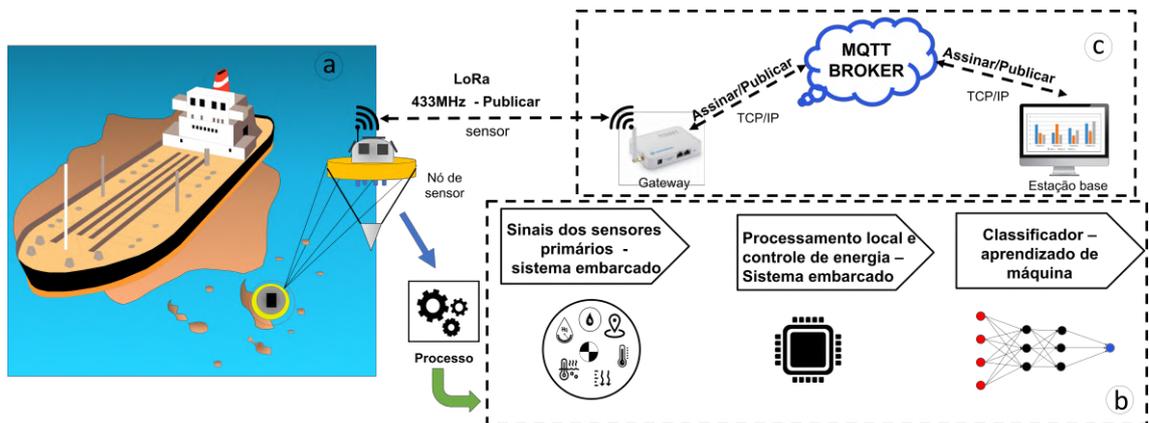


Figura 4.1: Representação do problema de detecção e classificação de poluição em ambiente aquático e solução via RSSF: (a) Zona atingida por derramamento de petróleo e atuação do nó sensor no ambiente; (b) Elementos e métodos de detecção; (c) Informações do nó sensor enviados a estação base para tomada de decisão.

Na Figura 4.1 é apresentada a estrutura do processo de detecção e classificação. Na primeira etapa (a) tem-se a instalação do nós sensores próximos as áreas de riscos, costa ou estrutura embarcações. Na primeira etapa após o derramamento do derivado de petróleo no mar, o nó sensor em sua arquitetura/estrutura realiza a aquisição do sinais de qualidade da água (*define-se "sinais de qualidade" como medições com sensores de pH, temperatura, turbidez e condutividade para avaliar a qualidade da água, a computação dos sinais aferidos são transformados em índices que permite avaliar a qualidade da água*) através dos sensores de contato com água, no próprio sistema embarcado, sendo realizado por meio de um microcontrolador/microprocessador, como sendo o pré-processamento do sinal para que ocorra a segunda etapa.

A segunda etapa (b), dentro do sistema embarcado consiste no gerenciamento dos sinais e processamento no microprocessador através de programação do *firmware* para ocorra a classificação através de uma rede neuronal artificial embarcada, a etapa de detecção e classificação ocorre de forma simultânea. Ressalta-se para que esse processamento seja viável em decorrência dos processamentos serem feitos de forma síncrona, usando um microprocessador de 2 núcleos com uma frequência que deve variar entre 160 e 240 MHz, com resolução de 32 bits, são usadas *threads* para que o processamento paralelo aconteça simultaneamente com controle do sistema de energia.

O sistema de energia tem um microcontrolador dedicado para a função do controle de carga e descarga das baterias, porém funciona como sistema sub-atuado, operando como escravo do microcontrolador central, favorecendo um menor consumo de energia do sistema. Após a classificação realizada pela RNA, a informação do resultado é encaminhada para o *gateway* através de um protocolo de longa distância com um transreceptor presente no sistema embarcado. Por sua, vez esses sinais são transportados para uma nuvem/*broker* através de um protocolo MQTT, onde são armazenados e enviado/ disponibilizados para estação base/usuário final. Na estação base é possível acessar os sinais dos índices de qualidade da água e classificação de forma *online*/tempo real.

Inicialmente, a metodologia no contexto de sistema multiagentes é ilustrada por uma sequência de etapas, envolve desde a caracterização do problema nas

formas de descrição, formulação e solução até a avaliação da proposta, conforme apresentado na Figura 4.1. Definido o método de solução proposto para o problema, o próximo passo é definir a arquitetura do nó sensor os sensores presentes na sua composição de acordo com dada referência para realizar a captação dos sinais da composição, estrutura biológica, físico-química presentes próximo a lâmina d'água ambiente do aquático. A metodologia proposta para o desenvolvimento do sistema inteligente tem como base a modelagem matemática do nó sensor, arquitetura do nó sensor, pré processamento dos sinais, estrutura de transmissão/conexão, processamento dos sinais e dados gerados pelo nó e classificador inteligente por meio de aprendizado de máquina.

Os métodos e procedimentos para a solução do problema de detecção, classificação e mapeamento de poluentes e derivados de petróleo em ambientes aquáticos são apresentados com base nos principais tópicos do Capítulo 1. A presente proposta tem como objetivo apresentar uma metodologia sistematizada para o desenvolvimento de sensores inteligentes.

## **4.1 Metodologia para desenvolvimento do sistema inteligente**

A metodologia para o desenvolvimento do sistema proposto envolve os paradigmas de aprendizado de máquina, identificação de sistema dinâmicos, programação dinâmica adaptativa, processamento e fusão de sinais através de filtragem e dispositivos para medição e processamento que são associados para realizar a detecção e identificação do tipo de poluentes e em consequência o mapeamento da área. As principais etapas da metodologia para desenvolvimento do sistema inteligente são ressaltadas na Figura 4.2. Os conteúdos de sistemas embarcados, IoT, sistema multiagente, processamento de sinais e aprendizado de máquina são conhecimentos fundamentais para o desenvolvimento da proposta.

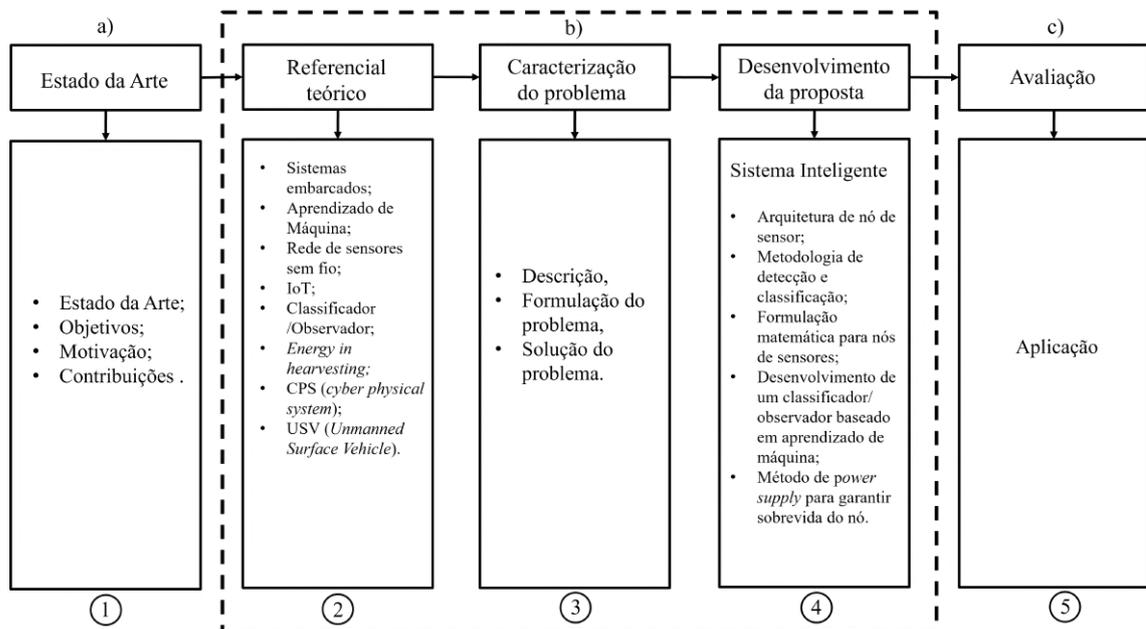


Figura 4.2: Etapas da Metodologia para desenvolvimento do Sistema Inteligente de Detecção, classificação de poluentes e derivados de em ambiente aquático.

O desenvolvimento do sistema inteligente está agrupado em cinco blocos e três etapas que são elas: a) Estudos preliminares, b) desenvolvimento teórico e implementação da proposta, e bloco de avaliação do sistema exibida na Figura 4.2. Nos parágrafos a seguir são apresentadas as descrições das etapas para o desenvolvimento da proposta.

Na etapa de estudos preliminares é levantado o estado arte apresentados nos Capítulos 1 e 3. Ainda, as fases desta etapas estão fundamentadas nos conceitos detecção, classificação rastreamento de poluentes, fornecem a base teórica que são apresentados no Capítulo 2.

A etapa de desenvolvimento teórico e implementação da proposta é constituída da concepção, formulação matemática, implementação computacional em *software* e *hardware* do sistema inteligente. A descrição, formulação e solução do problema são apresentadas de forma sistemática, sendo direcionada para o desenvolvimento de um sistema detecção, medição e monitoramento que é apoiado em aprendizado de máquina, sistemas embarcados e dispositivos eletrônicos.

A metodologia para o desenvolvimento do sistema inteligente baseado em *software* e *hardware* para o monitoramento e rastreamento dos alvos em ambiente

aquático, nesta aplicação voltado para poluentes e derivados de petróleo. No intuito de apresentar uma proposta generalizada para o projeto e implementação, os procedimentos para o desenvolvimento do sistema inteligente e suas aplicação são apresentadas de forma sistematizada para que a metodologia possa ser replicada sem grandes adaptações ou customizações.

Os métodos e procedimentos para a solução do problema de detecção, rastreamento e mapeamento de poluentes e derivados de petróleo em ambientes aquáticos são apresentados, tendo por base os principais tópicos do Capítulo 2. A presente metodologia tem como objetivo apresentar um método sistematizado para o desenvolvimento de sensores inteligentes.

Nesta tese é apresentada uma metodologia desenvolvimento do protótipo de um sistema inteligente baseado na estrutura de uma rede de sensores sem fio com nós dinâmicos e estáticos com finalidade de detecção, rastreamento e monitoramento.

## 4.2 Metodologia do nó sensor inteligente

O sensor proposto é dividido em duas partes, *hardware* e *software*. Na Figura 4.3 pode ser observado a sua estrutura física em conjunto com o algoritmo baseado em aprendizado de máquina. O classificador proposto é baseado em aprendizado de máquina, é uma rede neuronal artificial do tipo MLP. O sinais de entrada do classificador provém dos sensores de contato de contato com água.

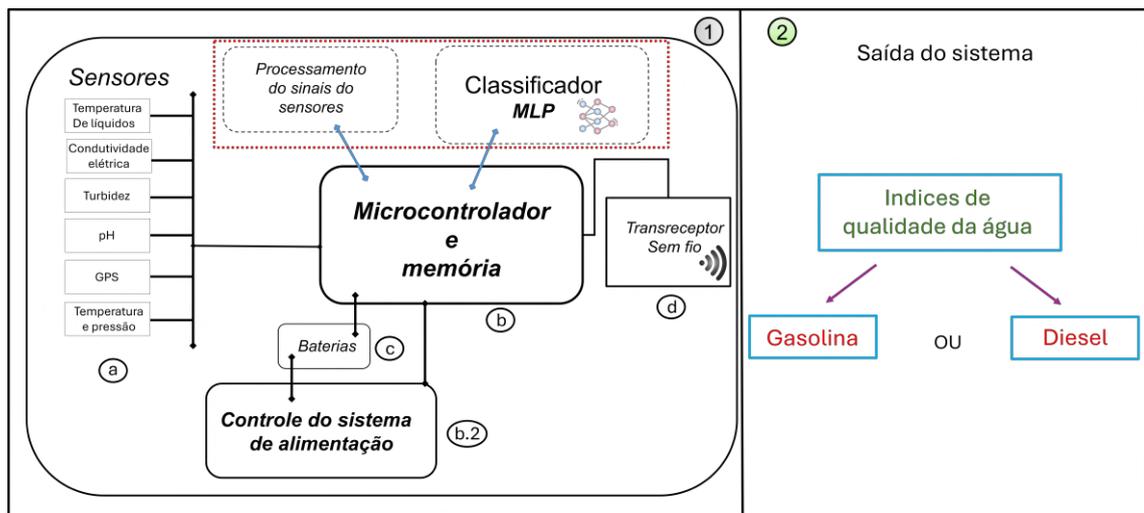


Figura 4.3: Classificador embarcado.

A Figura 4.3 está separada em duas partes, 1) estrutura sistema embarcado e 2) saída do sistema. A parte 1) consiste na estrutura do sistema embarcado e do classificador embarcado na placa. Em a) corresponde aos os sensores responsáveis pela medições local; b) microcontrolador central responsável pelo processamento dos sinais captados pelos sensores e classificador baseado em rede neuronal (a parte tracejada representa da parte lógica do sistema); b.2) parte responsável pelo controle de carga/ descarga e gestão de recursos energéticos de sobrevida do nó porém intercomunicada com microcontrolador central. A parte das baterias é indicado por c), e do transreceptor por d). Como resultado tem-se a parte 2) que é saída do sistema inteligente, onde obtém-se os índices de qualidade da água e identificação do poluente presente na água podendo ser gasolina ou diesel.

Na Figura 4.3, a função do classificador é realizar análise dos sinais lidos pelos sensores e identificar se a presença da gasolina e óleo diesel na água do mar, também informa os índices de qualidade da água e o posicionamento do nó. Os sinais de entrada usados para alimentar o classificador inteligente são pH, temperatura da água, turbidez, condutividade do líquido que são observados pelos sensores de contatos com a água. Outros sensores são de uso interno tais como: GPS, pressão atmosférica, temperatura interna. A estrutura da MLP proposta é desenvolvida através do TinyML, é uma tecnologia, *framework* que possibilita a execução de modelos de aprendizado de máquina em dispositivos

de baixo consumo (microcontroladores), como sensores, e dispositivos inteligentes (IoT), como pode ser observado na Figura 4.3.

Na sua estrutura do TinyML contém uma série de bibliotecas e ferramentas para a implementação de algoritmos de aprendizado de máquina em microcontroladores de baixo consumo de energia. As estruturas TinyML podem ser categorizadas em três famílias diferentes. A primeira abordagem que é a mais comum, refere-se à conversão de modelos treinados para adaptá-los às restrições dos sistemas embarcados. A segunda abordagem tem objetivo integração de bibliotecas de ML dentro dos sistemas embarcados, proporcionando o treinamento local e capacidades de análise. A terceira abordagem depende da disponibilidade de um coprocessador dedicado que dá apoio a unidade de computação principal em tarefas específicas de aprendizado de máquina. Esta estratégia permite melhorar o desempenho computacional, embora seja a abordagem menos comum à medida que o preço e a complexidade das plataformas de processamento aumentam notavelmente [65].

A construção do algoritmo classificador é dividido em duas etapas:

- Etapa I - Construção do modelo: A construção do modelo é apenas uma das partes de uma aplicação de aprendizado de máquina, sendo ela embarcada ou não definir. Esta etapa necessita de uma base de dados com as entradas necessárias para a construção do modelo proposto. Além dos dados, diferentes técnicas podem ser avaliadas, escolhendo a com melhor acurácia/precisão;
- Etapa II - Realização do *deploy* no microcontrolador: O *deploy* do modelo é a ação de exportar o modelo treinado/construído no computador para o sistema embarcado.

### 4.2.1 Treinamento

O método para o treinamento previsto é o "*backpropagation*" (retropropagação), que é um método amplamente utilizado para treinar redes neurais artificiais.

A retropropagação é um algoritmo de otimização que ajusta os pesos da rede neural com base no erro calculado entre as previsões do modelo e os rótulos reais

dos dados. Pontos-chave sobre a estratégia de treinamento:

- Retropropagação: Durante cada iteração do treinamento, o algoritmo calcula o gradiente da função de perda em relação aos pesos da rede. Esse gradiente é usado para ajustar os pesos na direção que reduz o erro de predição.
- Otimização: O otimizador, especificado pelo parâmetro **'solver'**, determina como os ajustes de peso são realizados. O *scikit-learn* oferece opções, incluindo **'adam'**, **'lbfgs'** e **'sgd'** (descida de gradiente estocástica).
  - a - **'adam'**: Um otimizador baseado em métodos de primeira ordem e estimação adaptativa de momentos,
  - b - **'lbfgs'**: Um otimizador baseado em métodos Quasi-Newton de segunda ordem,
  - c - **'sdg'**: Descida de gradiente estocástica, um método de otimização por gradiente (a opção aplicada no desenvolvimento do algoritmo).
- Função de Ativação: A função de ativação nas camadas ocultas, especificada pelo parâmetro **'activation'**, também desempenha um papel crucial. Funções comuns incluem **'relu'**, **'logistic'** e **'tanh'**.
- Regularização: O modelo também pode ser regularizado usando parâmetros como **'alpha'** para controle da penalidade **L2** e **'beta1'**, **'beta2'** para o otimizador **'adam'**.

## CAPÍTULO 5

# RESULTADOS, PROJETO DE DESENVOLVIMENTO DO SISTEMA EMBARCADO

---

Os resultados da execução da metodologia proposta são apresentadas neste Capítulo. Neste capítulo, são apresentados os resultados envolvendo o desenvolvimento do primeiro protótipo e algoritmo. A modelagem matemática do nó é apresentada na Secção 5.2, arquitetura do nó sensor na Secção 5.3, modelagem da sua estrutura em *software* e montagem na Secção 5.4, principais testes realizados com água do mar e água potável para calibração dos sensores na Secção 5.5, testes prático de detecção e classificação com gasolina na Secção 5.7 e diesel na Secção 5.8.

### 5.1 Projeto e implementação de nós sensores estáticos

O núcleo da metodologia proposta para projeto e implementação de nós estáticos de sensores é apresentada nesta seção. A modelagem do sistema embarcado para um nó sensor estático é apresentada na Secção 3.2 e aplicada no desenvolvimento da metodologia proposta. Projeto do nó sensor com sua estrutura de medição e a sua construção são apresentados.

Para o projeto do nó sensor com sua estrutura de medição e a construção do nó sensor, escolha dos sensores é baseada na CONAMA 357/05 [2] que "Dispõe sobre a classificação dos corpos de água e diretrizes ambientais para o seu enquadramento, bem como estabelece as condições e padrões de lançamento de efluentes" e no IQA (ÍNDICE DE QUALIDADE DAS ÁGUAS - *National Sanitation Foundation* [18]).

## 5.2 Modelagem Funcional da Medição

A modelagem da estrutura de medição é baseada nos Conjuntos (3.2) e (3.3). Para o desenvolvimento do sistema embarcado proposto, a aplicação apresentada nesta seção, a estrutura física do nó sensores é representada por

$$sn = \{sp_{C_1}, sp_{C_2}, sp_{C_3}, sp_{in_1}, sp_{in_2}\}. \quad (5.1)$$

De acordo com o Conjunto (5.1), os sensores internos são divididos em  $k$  grupos. Por exemplo, cada nó pode ser dividido em dois grupos de sensores  $sp_C$  (sensores de contato com líquidos) e  $sp_{in}$  sensores internos do nó.

A generalização da estrutura física da rede de sensores é dada por

$$WSN_{nds} = \{sp_C \cup sp_{in} \subseteq sn\}. \quad (5.2)$$

O modelo matemático específico para o sistema embarcado do nó sensores é representado pela relação (5.2), estabelecendo a base estrutural dos sensores de captação de cada nó, formando a estrutura de medição da RSSF que faz parte de um sistema de detecção, processamento e envio de sinais da  $WSN_{nds}$ .

Customizando as relações do Conjunto (5.1) para estrutura de medição, a estrutura do nó proposto é dada por

$$sp_c\phi_c = \{Temp_{Liq}, Cond_{Liq}, pH_{Liq}, Turb_{Liq}\}. \quad (5.3)$$

No Conjunto (5.3),  $sp_{in}\phi_{in}$  representa as variáveis de estados observado por meio das medições diretas e indiretas, onde as variáveis observadas são do tipo de sensores  $sp_C$  temperatura do líquido ( $Temp_{Liq}$ ), condutividade elétrica do líquido ( $Cond_{Liq}$ ), potencial hidrogeniônico do líquido ( $pH_{Liq}$ ) e turbidez ( $Turb_{Liq}$ ), a representação dos grupos de sensores é dada por

$$sp_{in}\phi_{in} = \{Pres_{Env}, Temp_{Env}, Lat_{in}, Long_{in}\}, \quad (5.4)$$

sendo as variáveis de estados, a pressão relativa do ambiente ( $Pres_{Env}$ ), temperatura do ambiente interno do sensor ( $Temp_{Env}$ ) e as coordenadas latitude ( $Lat_{in}$ ) e longitude ( $Long_{in}$ ). No Conjunto (5.4), esse conjunto de estados é gerado pelos conjuntos de sensores  $sp_{in}\phi_{in}$ .

Combinando as medições realizadas pelo nó sensores com técnicas de aprendizado de máquina, tem-se como resultado a estimação de novos estados apresentados pelo mapeamento que é dado por

$$\hat{y}(sp_c\phi_c) = \{gasolina, diesel, poluentes\}. \quad (5.5)$$

Os resultados são apresentados pelo conjunto  $\hat{y}(sp_c\phi_c)$ , são os estados observados e classificados/identificação dos poluente. Desta forma, podendo detectar no ambiente a presença de gasolina, óleo diesel ou outros poluentes não listado (corpo estranho).

### 5.3 Arquitetura do sistema embarcado

A metodologia para o desenvolvimento do *hardware* do nó sensor inteligente baseia-se no modelo funcional do nó sensor, apresentado na Seção 3.2, e no padrão IEEE 1451.2. A Figura 5.1 apresenta a arquitetura do sistema embarcado, destacando os componentes de sua estrutura física, como o sistema de fornecimento de energia, a comunicação RSSF e os sensores. O sistema embarcados gerencia os sensores de contato com a água, que são usados para medir a temperatura do líquido, o potencial hidrogeniônico (pH) da água e

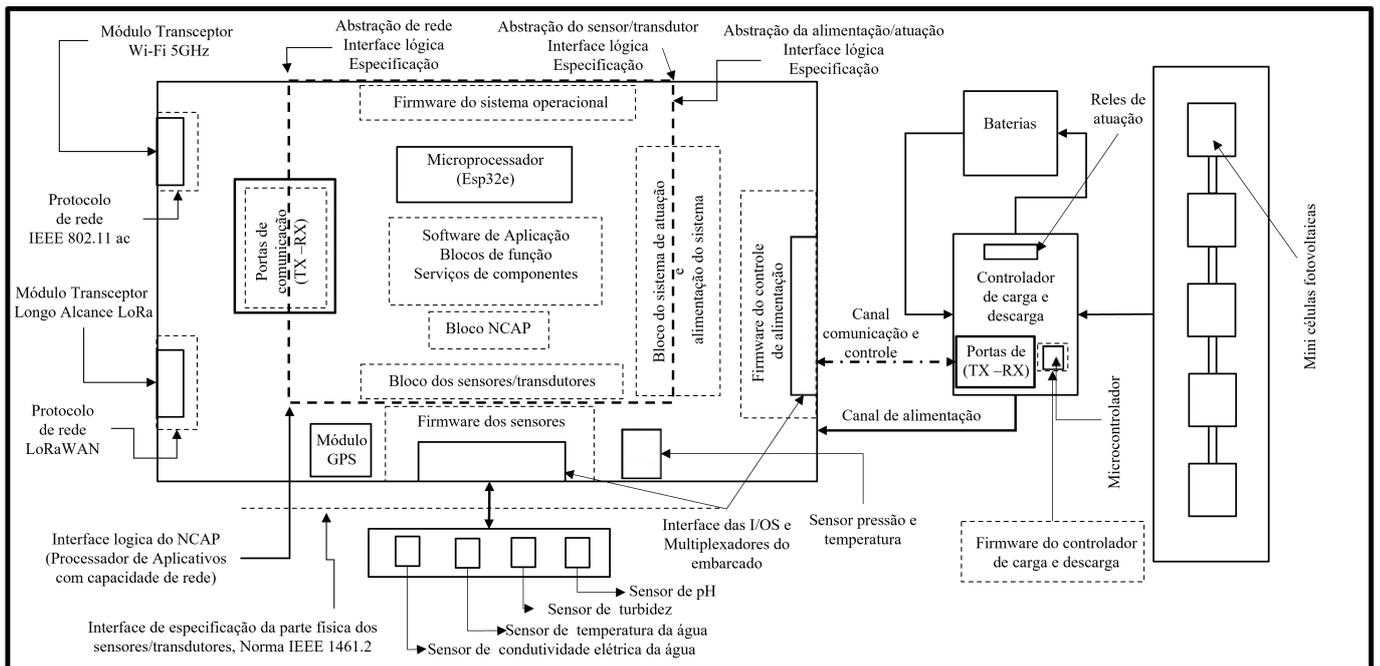


Figura 5.1: Abstração do sistema embarcado do nó sensor inteligente.

a turbidez, permitindo a detecção e a classificação do composto presente no ambiente aquático.

A arquitetura do nó sensor proposto da Figura 5.1 é dividida em três blocos, sendo um bloco de aquisição sinais por sensores de contato com líquidos, segundo bloco de alimentação e controle de cargas (responsável pelo gerenciamento energético do sistema). No bloco principal estão agrupados os elementos de processamento e interface de conexão para a transmissão dos sinais.

A Figura 5.1 está dividida em duas partes, as linhas tracejadas simbolizam a parte lógica e as contínuas correspondem a parte física do sistema embarcado, também a estrutura do sistema e a rede de aquisição dos sinais distribuídos.

Para fins de melhor entendimento a abstração do sistema embarcado exibido na Figura 5.1 foi subdividida em cinco partes, correspondentes a abstração da parte do bloco de energia exibida na Figura 5.2, sensoriamento, comunicação externa, blocos lógicos do embarcado.

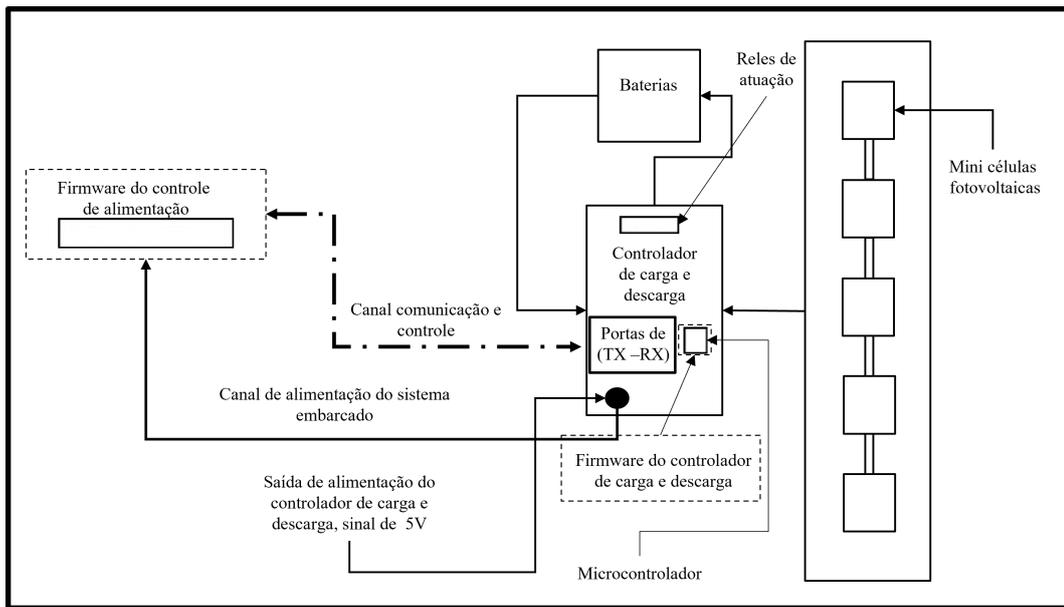


Figura 5.2: Abstração da parte do bloco de energia (*power supply*).

A estrutura do sistema embarcado proposto possui um subsistema, que é responsável pela alimentação do dispositivo exibido na Figura 5.2. O subsistema é responsável pela parte de suprir a necessidade de energia de todo o sistema embarcado do nó sensor, na composição da sua estrutura possui microcontrolador, responsável pela realização das funções de controle na atuação na alimentação (controle da carga/descarga das baterias e também pelo controle síncrono de alimentação do nó, alimentando o sistema durante o dia tanto diretamente com os painéis como a energia das baterias). O subsistema alimentação é responsável gerenciamento o fornecimento de energia das placas fotovoltaicas para o sistema embarcado (promovendo a colheita de energia através dos painéis), porém todas as tomadas de decisões e instruções à respostas são determinadas pelo controlador central.

O controle desempenhado pelo microcontrolador é programado de forma externa e independente, porém, obedece a hierarquia e matem comunicação com controlador central da placa. Na estrutura do sistema de energia possui também um sensor para cargas de bateiras, reles para traquear funções de energia, conversores de tensão fazendo a conversão da energia coletada pelos painéis para uma tensão de 5 V. Tem comunicação TX1-RX1 com microcontrolador principal

que pode reprogramar seus ganhos dependendo da necessidade energética do sistema (todas as tomadas de decisões e instruções não pré-estabelecidas são determinadas pelo controlador central).

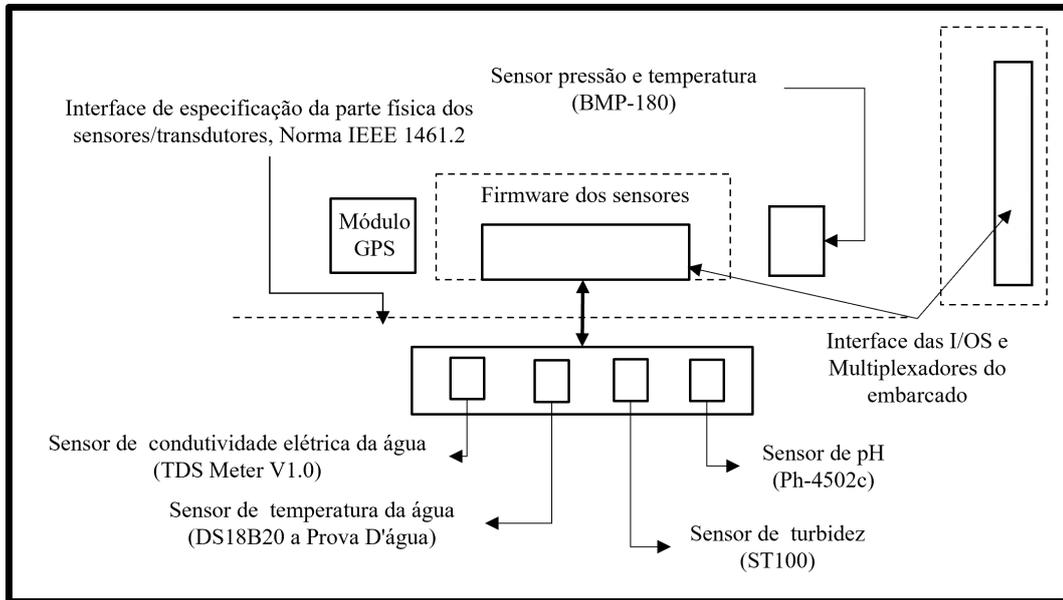


Figura 5.3: Abstração da parte do sensoriamento, aquisição de sinais, observação dos fenômenos ambientais.

Na Figura 5.3, exibi a parte da estrutura do sensoriamento, em sua composição tem sensores de contato com água para observação do ambiente e sensores internos (para aferição de índices internos como posição no ambiente, temperatura interna e pressão). A classe dos sensores de contato é denominada em decorrência da estrutura física que entra em contato com água (a parte da sonda) porém a estrutura equivalente a estrutura física eletrônica tais como, multiplexadores e chips dos sensores está na parte do corpo do sistema embarcado. As partes tracejadas correspondem a parte lógica do sensoriamento, o *firmware* dos sensores para aquisição dos sinais coletado, sejam estes de contato ou de medição interna.

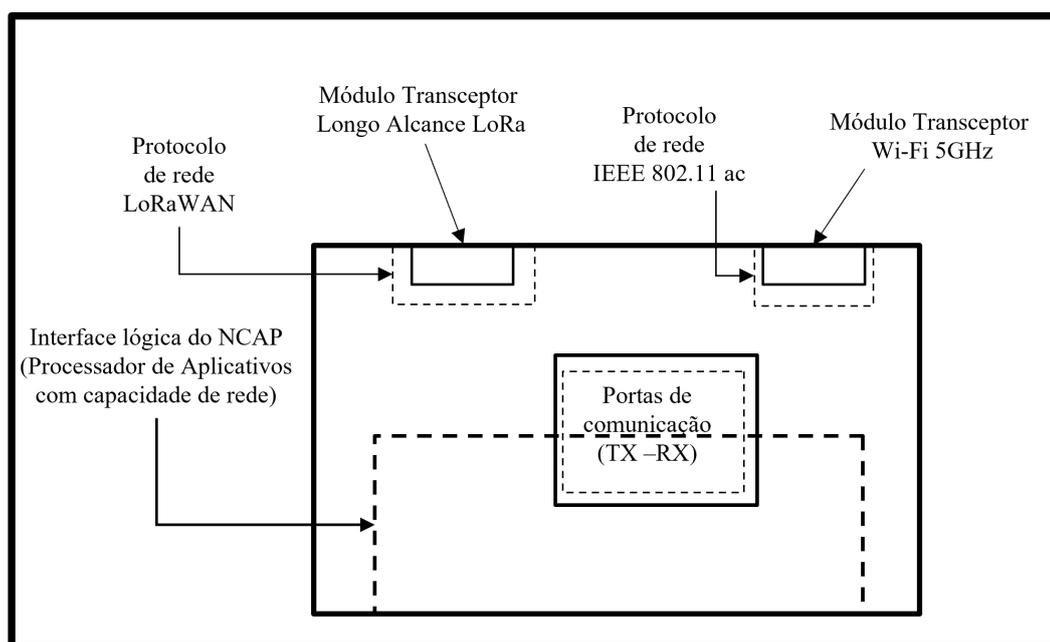


Figura 5.4: Abstração da parte de comunicação externa.

A Figura 5.4 exibi a parte responsável pela da comunicação externa com o ambiente, seja ele com outro nó sensor ou estação base. As comunicações internas e externas são realizadas pelas portas TX-RX (Chip ESP32 possui mais de um par das portas de comunicação), tendo embarcado no próprio chip Wi-Fi que opera em 2,4 e 5 GHz com protocolo de comunicação 802.11ac. Para transmissão via LoRa que usa a frequência de 433 MHz para comunicação (protocolo de longa distância) faz o uso das portas TX-RX tradicionais, exibidas na Figura 5. A comunicação da placa pode ser feita entre nós sensores através dessas duas tecnologias de comunicação (o Wi-fi possui restrição de distância chegando no máximo a 30 metros) a LoRa com protocolo de comunicação de baixo consumo de energia e longo alcance da transmissão ponto à ponto em até 22 km.

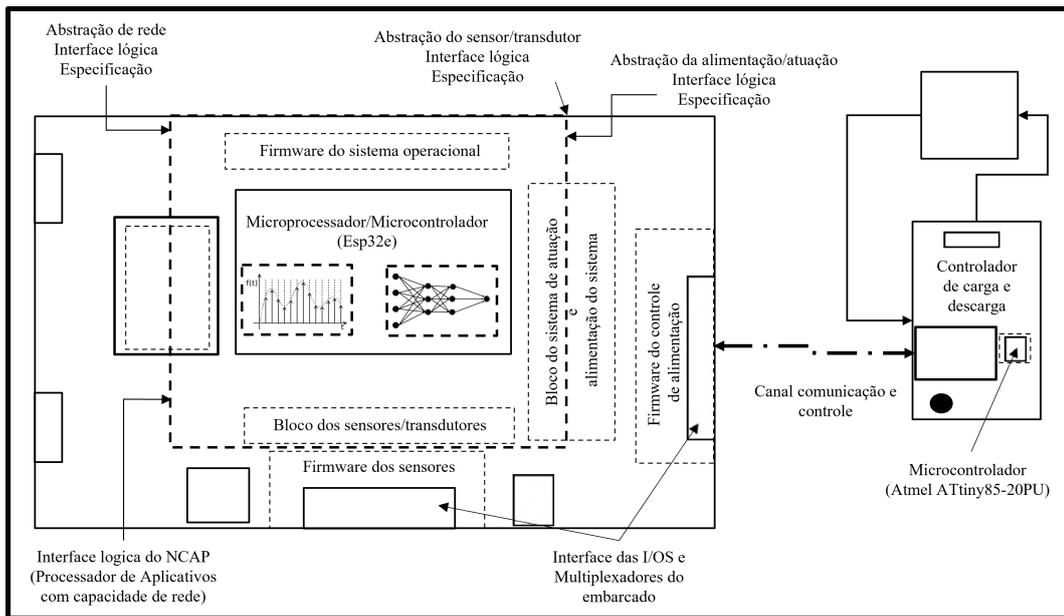


Figura 5.5: Abstração dos componentes de controle e processamento do sistema.

Na Figura 5.5 é exibido a parte do sistema de controle e processamento de sinais do sistema. A parte central do sistema embarcado como principal unidade de processamento é a ESP32e, responsável pelo gerenciamento de todo recursos embarcado (apenas supervisionando as atividades de energia que fica em cargo de outro microcontrolador dedicado), abrigando os algoritmos de processamento dos sinais dos sensores, classificador baseado em aprendizado de máquina e *watchdog* de otimização de consumo de energia. Todos recursos da placa estão ligados diretamente a unidade de processamento central. No sistema proposto o microcontrolador central realiza comunicação através das portas TX1-RX1 com microcontrolador (ATtiny85) do subsistema de alimentação, essa distribuição de tarefas entre o processador central e do sistema de energia visa diminuir a sobrecarga de funções da unidade central, impactando diretamente no consumo de energia e diminuição dos riscos de falhas por sobrecarga de instruções/ações.

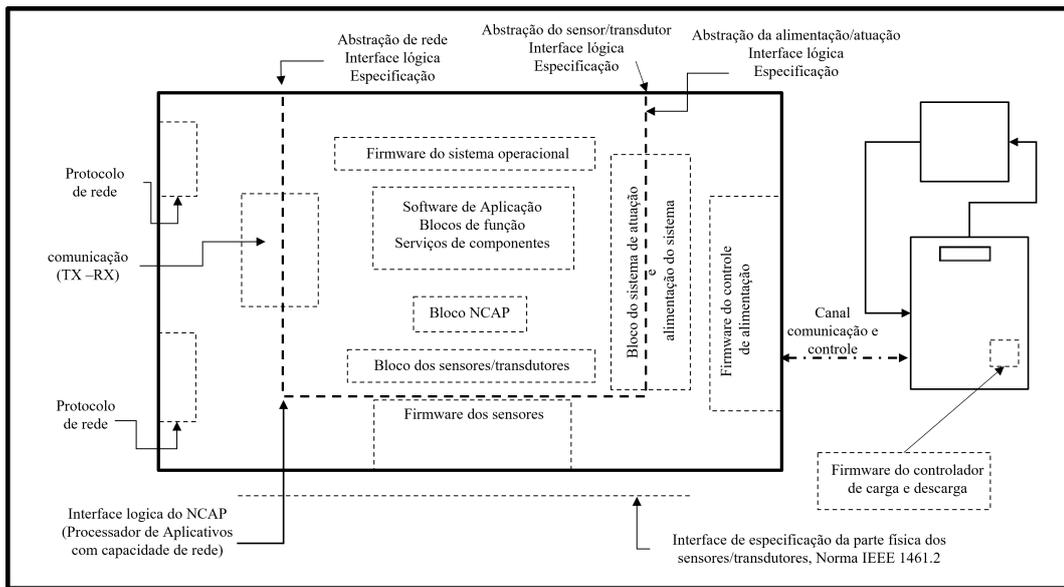


Figura 5.6: Abstração dos blocos lógicos que compõem o sistema embarcado.

Na Figura 5.6 é exibido a estrutura lógica que está em linhas tracejadas, engloba toda parte fundamental para o funcionamento da estrutura do nó sensor. Os principais componentes embarcados na estrutura são o NCAP (*Network Capable Application Processor* - parte da estrutura que realiza comunicações entre o STIM a rede), o *Smart Transducer Interface Module* (STIM) e a interface de comunicação entre os sensores e microcontrolado/microprocessador, introduzindo as funções lógicas e de reprogramação *online* a partir de uma IDE ( ou Ambiente de Desenvolvimento Integrado). A interface programável por *software* tem compatibilidade e suporte com as interfaces de comunicação compatíveis com NCAP e STIM na mesma estrutura do sistema embarcado, sendo esta responsável por compilar os algoritmos com capacidade de captar e processar sinais no próprio dispositivo, além de permitir conexão com outros dispositivos através de técnicas de IoT via protocolo 1451.1.

O esquema de ligação e comunicação são evidentes na Figura 5.7, onde microcontrolador (1) faz comunicação direta com o transreceptor (11), sistema e alimentação (2).

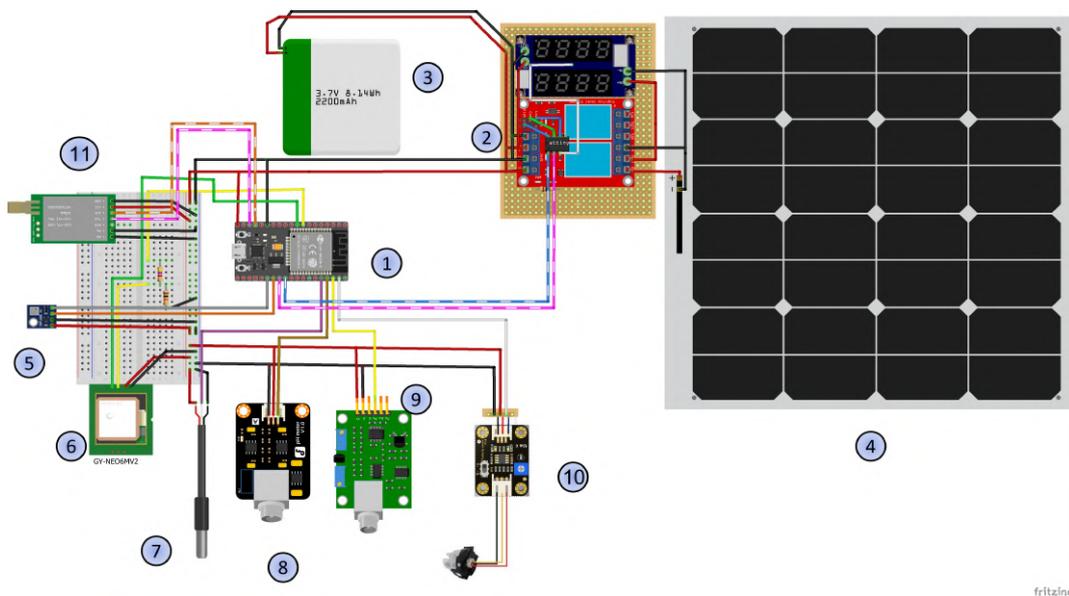


Figura 5.7: Protótipo da estrutura do sensor proposto simulado no Fritzing.

A estrutura do protótipo é simulada no *software*- Fritzing, o esquema de conexão é exibido na Figura 5.7, complementando de forma visual a estrutura exibida na Figura 5.1. Na Figura 5.7, os principais componentes da estrutura são numerados para facilitar a descrição e assimilação com a figura anterior. O item (1) ESP32 é responsável pelo processamento dos sinais, controle de comunicação e controle de todo dispositivo. O item (2) é o sistema responsável pela alimentação vindo dos mini painéis fotovoltaicos (4) e o controle de carga e descarga das baterias de 2200 mAh (3), atuando como subsistema da placa.

O conjunto de sensores exibidos nas Figuras 5.1 e 5.7 estão divididas em duas classes, sensores de contatos de superfície de líquidos e internos. Os sensores de contato de líquidos são incumbidos pela realização das medições e observações no nível da lâmina d'água, os sensores usados na aplicação são: sensor DS18B20 de temperatura (7), módulo TDS V1.0 condutividade de líquidos (8), para medição do pH é usado o sensor ph4502C (9) e para turbidez é usado o ST100 (10). Na parte interna estão o módulo GPS (6) fica responsável pela localização do nó estático e também um meio de determinar se o nó está ativo ou teve deslocamento ocasionado por algum fator externo. Outro sensor interno, o sensor BMP180 (5) responsável pela aferição pressão a nível do mar e temperatura ambiental. O transreceptor (11) escolhido é o módulo RF *wireless* LoRa(*Long Range*) 433 MHz

transmissor e receptor de rádio frequência, caracterizando por um baixo consumo de energia e comunicação a longas distâncias.

### 5.3.1 Implementação e virtualização do circuito

Para o desenvolvimento do protótipo a placa é elaborada, desenvolvida em ambiente virtual, para suprir a necessidade da prototipação do sistema embarcado para gerar um modelo simulado em *software* para confecção/impressão do layout proposto.

A estrutura do sistema embarcado é dividida em duas estruturas, o corpo principal (1), e a outra (2) responsável pela alimentação do sistema embarcado, são exibidos na Figura 5.8.

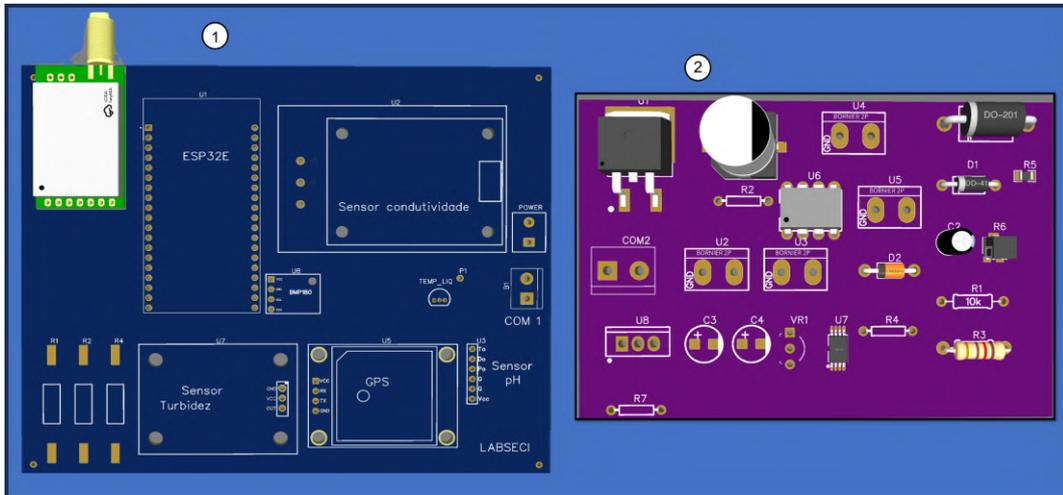


Figura 5.8: Estrutura do sistema embarcado desenvolvido e simulada via software, primeira parte concentra-se no processamento gerenciamento e coleta de sinal, placa 2, secundária responsável pelo controle de carga/descarga das baterias e gerenciamento energético do sistema embarcado principal.

Na Figura 5.8 é exibido 2 estruturas que compõem a arquitetura do sistema inteligente proposto, como resultado da abstração proposta do sistema embarcado na Figura 5.5, que tem como resultados as duas estruturas do embarcado (1) parte principal, responsável pelo processamento, captação e classificação, (2) parte de controle energético do sistema inteligente que é conectada a baterias e painel fotovoltaico.

A distribuição dos componentes do sistema embarcado foi feita de forma sistemática, de tal forma que cada componente foi alocado de acordo com seu tamanho e função, desta forma otimizando o espaço também facilitando na substituição de componentes defeituoso, *layout* facilita na manutenção do dispositivo.

Outra facilidade e melhoria do layout proposto é que no esquema (1) da Figura 11, o microcontrolador está próximo a parte central, facilitando a comunicação com os demais componentes e com um canal de comunicação (COM 1) com outra parte do sistema embarcado (2) com a porta (COM 2). O sensor de temperatura e pressão BMP180 (que realiza o monitoramento da temperatura interna do sensor está na parte central), outra vantagem desse tipo de distribuição é pensando na dispersão de energia térmica gerada pelos componentes eletrônicos diminuindo a formação de ilhas de calor, salientando que o nó sensor terá exposição direta ao sol em decorrência do local que será implantado (MAR/regiões costeiras).

A separação do sistema embarcado inteligente em dois módulos, se deu em decorrência da estrutura projetada para o protótipo destinado para nós fixos e dinâmicos, tendo o corpo principal o modulo (1) da Figura 11 flexível de adaptação em outras fontes de energia uma vez que possui alimentação 5 V e módulos de conversão interna também para 3.3 V, sendo adaptável em diversas aplicações não ficando restrito apenas a energia vindo de baterias/painéis solares, *setup* flexível para ser acoplado em estruturas externas.

## 5.4 Estrutura física do nó sensor

A estrutura proposta é baseada nos estudos realizados e pesquisa bibliográfica, acessos a materiais práticos. Na modelagem e testes de estrutura do nó sensor são realizadas no *software* Autodesk Inventor®. Na Figura 5.9 é apresentado o modelo simulado em ambiente computacional.

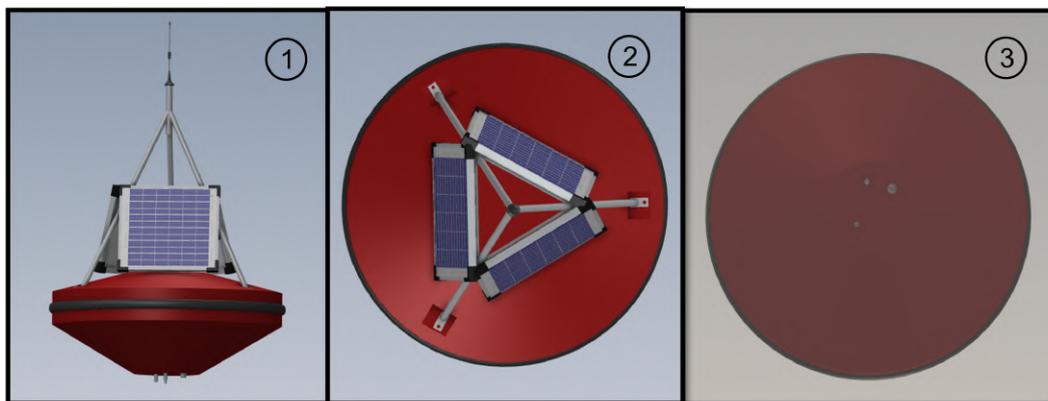


Figura 5.9: Modelagem 3D da Estrutura física do nó sensor para Ambientes Aquáticos

Na Figura 5.9 é apresentada estrutura física do nó em 3 vistas, na sua estrutura física em fibra de vidro (FV), o uso desse material é em decorrência de suas propriedades físico-químicas. A estrutura proposta foi baseada nos estudos feitos e relação a estabilidade, flutuabilidade e resistência (boias oceânicas), a estrutura circular em formato de disco é menos suscetiva a impactos diretos das ondas e tem maior estabilidade com marés altas, a estrutura aliada a contra pesos assemelhasse a dinâmica de um pêndulo evitando que a estrutura seja virada com ondas. A cor vermelha segue o padrão da marinha brasileira que determina cores chamativas (vermelhas e laranja) para identificação por embarcações no meio do mar. A fibra de vidro não derrete/deteriora na presença de combustíveis, também suas propriedades mecânicas que possui uma certa resistência a atrito, salinidade e efeitos de grande exposição ao sol. A estrutura de FV simulada possui as mesmas propriedades de flutuação de uma boia salva vidas circular classe 1 que possui as seguintes características -Diâmetro: 700mm - Peso: 2,5kg - Para embarcações de mar aberto e plataformas. - Carga de ruptura mínima: 500kg. - Confeccionada com tinta de proteção UV e preenchimento interno de poliuretano expandido. - Material imputrescível, resistente a fungos, água do mar, água doce, petróleo e seus derivados. Cabo de polipropileno de 10mm trançado na boia, fixo em quatro pontos. Para Alimentação são utilizados 3 painéis fotovoltaico 20 W (dimensões 45x35x2cm), para recarregar às baterias, distribuídos sob uma da estrutura do nó.

Na Figura 5.10 é apresentada a estrutura física concebida do nó sensor

proposto, primeiro protótipo, para os experimentos de detecção. A Figura 5.10 está dividida em 5 partes, cada uma delas remete uma perspectiva do protótipo intitulado "V1".

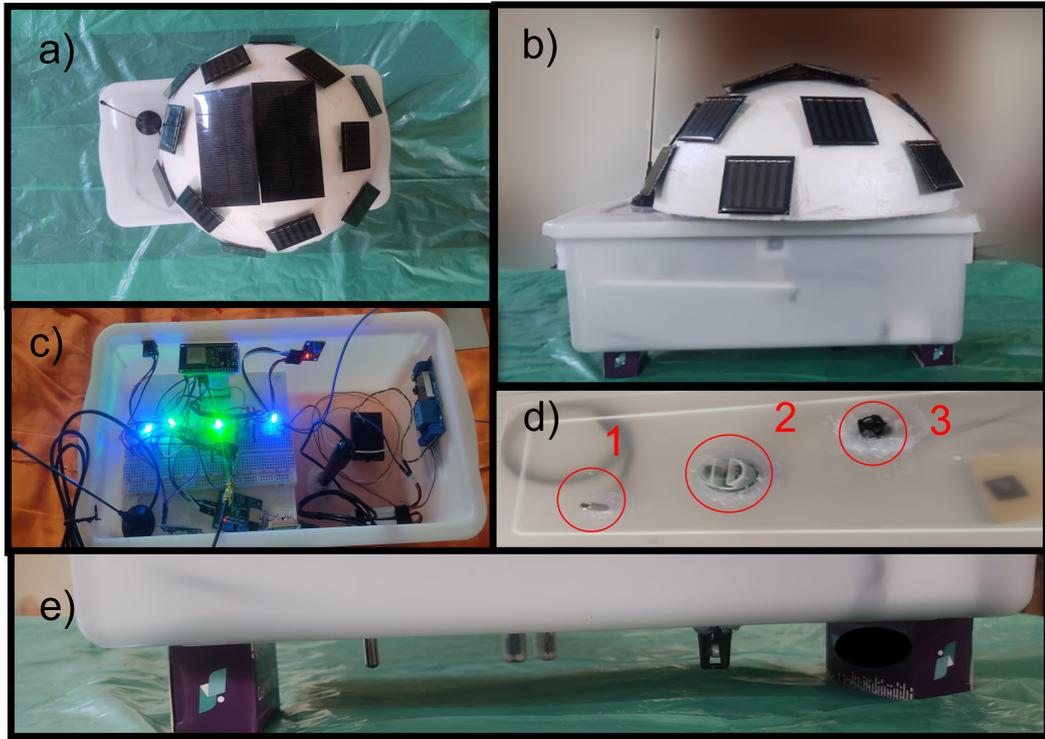


Figura 5.10: Estrutura física do nó sensor/ Protótipo V1

Na Figura 5.10, as perspectivas (a) e (b) representam as mini células fotovoltaicas responsáveis por suprir o fornecimento energético do nó sensor são distribuídas em uma semiesfera de 180 graus, ao lado observa-se a antena de comunicação. A vista (c) apresenta a parte interna do sistema embarcado, observa-se o microcontrolador, sensores interno e controle de carga e descarga da bateria. As vistas (d) e (e) exibem os sensores de contato de superfície de líquidos, sendo (1) o sensor de temperatura, (2) o sensor de turbidez e (3) o sensor de pH.

## 5.5 Testes de Detecção e Classificação

A descrição do procedimento e os resultados dos testes *indoor* de detecção e classificação para uma avaliação interna do nó do sensor são apresentados nesta

seção. Os testes mediram o pH e a turbidez da água do mar e da água doce. Os resultados dos experimentos com gasolina e óleo diesel são apresentados para avaliar o desempenho dos algoritmos na detecção e classificação.

Nos testes realizados no Laboratório de Sistemas Embarcados e Controle Inteligente (LabSECI) da Universidade Federal do Maranhão (UFMA), é possível detectar e classificar o combustível presente na água. Os sensores de contato com a água são usados para testar o pH, a turbidez e a temperatura. As variáveis observadas são a temperatura do líquido, o pH e a turbidez do líquido dada em NTU (*Nephelometric Turbidity Unit*, que significa que o instrumento está medindo a luz dispersa da amostra em um ângulo de 90 graus em relação à luz incidente). Também é possível observar os parâmetros dos componentes internos do sistema embarcado via técnicas de IoT, como pressão ao nível do mar, temperatura do líquido, temperatura interna e coordenadas de localização do GPS.

## 5.6 Teste de medição de pH e turbidez com água do mar (salgada) e água mineral (potável)

Os primeiros testes e a calibração dos sensores são realizados em laboratório, foram usados para instrumentos certificados para aferição e calibração do nó sensor. Nesses primeiros ensaios, são medidos os níveis de pH e turbidez da água potável (água mineral) e da água salgada/mar, coletadas na praia da Ponta d'Areia, na Baía de São Marcos, São Luís, Maranhão, Brasil.

Para a realização da calibração dos sensores presentes no nó sensor foram usados instrumentos de aferição, os seguintes medidores foram utilizados: a) medidor modelo KP-AA008 mede total de substâncias sólidas e nutrientes na água, faz medições de condutividade TDS (*Dissolved Solids*-sólidos totais dissolvidos),  $E_c$  (*Electrical Conductivity*-) água  $\mu\text{S}/\text{cm}$  e PPM (*Parts Per Million*-partes por milhão) e tem em sua estrutura um termômetro para aferição da temperatura da água. As especificações técnicas do KP-AA008 com range de operação para de condutividade 0 a 9999  $\mu\text{S}/\text{cm}$ , TDF de 0 a 9999 ppm, Celsius: 0,1 a 80°C, Fahrenheit: 32 a 176 °F e precisão aproximadamente 2%; b) medidor de pH digital com escala de medição que varia 0,0 a 14,0 pH, resolução de 0,1 pH (1%), uma modelagem matemática da medição do pH é apresentada no Apêndice B; c)

sonda multiparâmetro que realiza medições dos de pH(0-14), Sólidos dissolvidos totais medindo escala variando 0-200000 ppm, faixa de operação EC 0-200000  $\mu$ /cm, salinidade de 0 -20%, ORP(Oxirredução Oxidante Água Antioxidante)  $\pm$  1999 mV, faixa de medição oxigênio dissolvido na água 0-2400 ppb. Com os instrumentos foi realizada a calibração e testes de medições do nó sensor proposto. Visando a medição das partículas sólidas dissolvidas na água é apresentado um estudo do projeto de um sensor óptico para análise de partículas sólidas de combustíveis dispersos em água Apêndice C.

A Tabela 5.1 apresenta os resultados do primeiro teste do nível de pH (potencial de hidrogênio) das amostras de água analisadas. O pH mede o grau de acidez ou alcalinidade da água, sendo 7 o valor neutro. Valores acima de 7 indicam um aumento no grau de alcalinidade e abaixo de 7 (até 0), um aumento no grau de acidez do meio. Algumas substâncias têm seus efeitos tóxicos atenuados ou amplificados em pHs extremos, como os presentes em resíduos químicos.

Tabela 5.1: Medições com nó sensor do pH, Turbidez da Água do Mar e Potável.

Medições	Água			
	Mar		Potável	
	pH	Turbidez (NTU)	pH	Turbidez (NTU)
1º	7,14	2888	5,54	2446
2º	7,08	2893	5,52	2486
3º	7,04	2896	6,08	2864
4º	7,10	2892	6,15	2481
5º	7,11	2885	6,10	2905
6º	7,06	2868	6,07	2482
7º	7,04	2895	6,17	2397
8º	7,01	2890	6,11	2348
9º	7,09	2881	6,13	2406
10º	7,11	2885	6,08	2406
11º	7,14	2885	6,07	2484
12º	7,15	2890	6,07	2484
13º	7,14	2878	6,10	2863
14º	7,16	2881	6,11	2500
15º	7,17	2889	6,11	2548
16º	7,76	2898	6,11	2460
17º	7,76	2795	6,14	2479
18º	7,74	2714	6,06	2456

Nos primeiros experimentos são utilizados o sensor ph4502, 2000ml de água do mar, foram realizadas 18 medições em um intervalo de 30 segundos. Os resultados das medições do pH da água do mar e água mineral são apresentados na Figura 5.11. Na Tabela 5.1, observa-se que a variações do pH estão entre 7,01 e 7,76. Estas variações ocorrem devido a sedimentos dissolvidos na água, ocasionado pela desembocadura de dois rios na Baía de São Marcos. O pH médio das praias de

São Luís é entre 7 à 8.

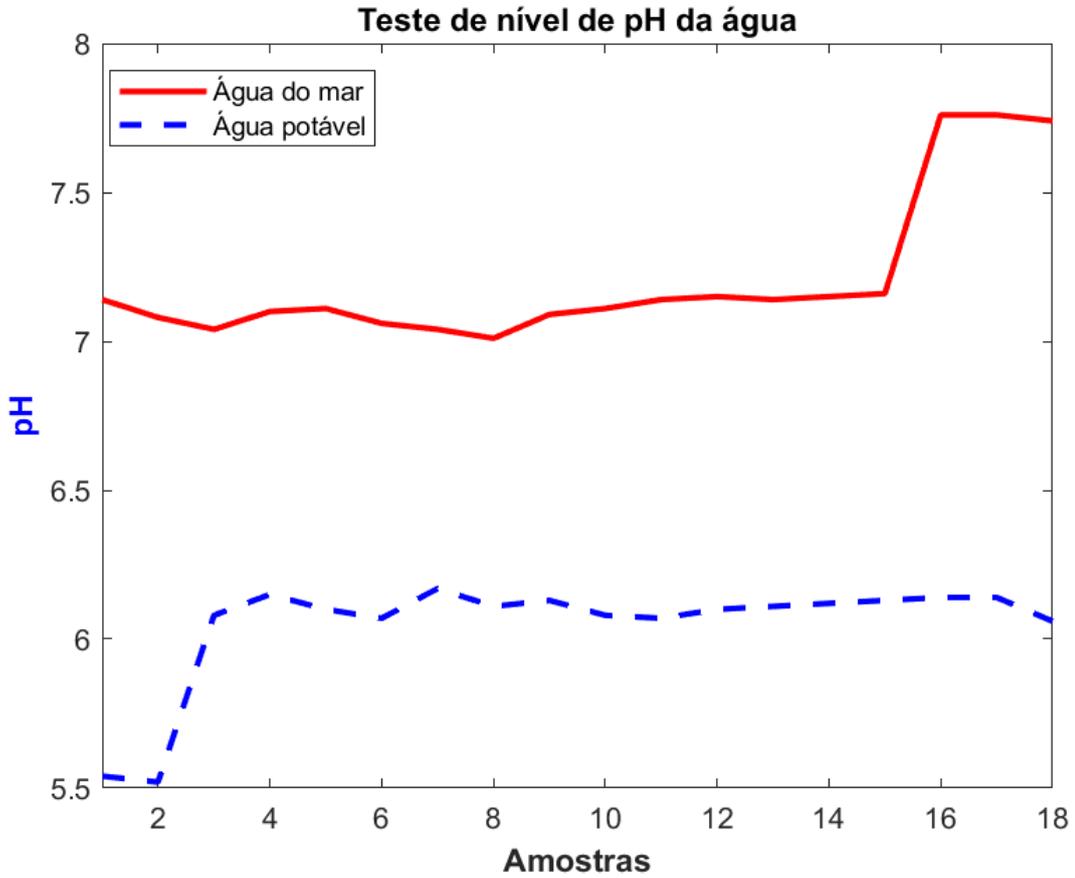


Figura 5.11: Medição com nó sensor do comparativo do pH água salgada e potável.

Os testes das medições do pH da água potável é realizado com 2000ml de água potável (filtrada mineral) são apresentados na Tabela 5.1 e Figura 5.11, as medições resultantes do nível pH da água potável que ficaram entre 5,52 e 6,17, estabilizando a medição em 6,07. Seguindo o padrão de 18 medições com intervalo de 30 segundos, o sensor levou alguns minutos para ser calibrado devido à variação mínima.

Sabendo que as soluções ácidas possuem um pH que varia de 0 à 7, constata-se que água mineral possui caráter ácido e água do mar possui um caráter tendendo mais para o neutro.

Outro parâmetro aferido é a turbidez. A calibração do sensor ST100 é realizada inicialmente para a medição da turbidez. A turbidez mede a dificuldade de um feixe de luz passar por uma determinada quantidade de água, dando-lhe uma

aparência turva. Essa medição é realizada com um turbidímetro ou nefelômetro, que compara a dispersão de um feixe de luz que passa pela amostra água, com um feixe de igual intensidade que passa por uma suspensão padrão. Quanto maior a dispersão, maior a turbidez. Os valores são normalmente expressos em Unidades Nefelométricas de Turbidez (*Nephelometric Turbidity Unit*) - UNT/NTU ou em mg/l de SiO<sub>2</sub> (miligramas por litro de sílica). O turbidímetro de mesa ao lado pode medir a turbidez em três escalas: 0 - 20, 0 - 200 e 0 - 1.000 NTU, sendo que na escala 0 - 20 a resolução é de 0,01 NTU. As principais causas da turbidez da água são a presença de matéria sólida em suspensão (silte, argila, sílica, coloides), matéria orgânica e inorgânica finamente dividida, organismos microscópicos e algas. Além de reduzir a penetração da luz solar na coluna d'água, a turbidez inibe a fotossíntese das algas. Devido à sensibilidade do sensor, os gráficos foram plotados usando uma escala de 1.000 vezes.

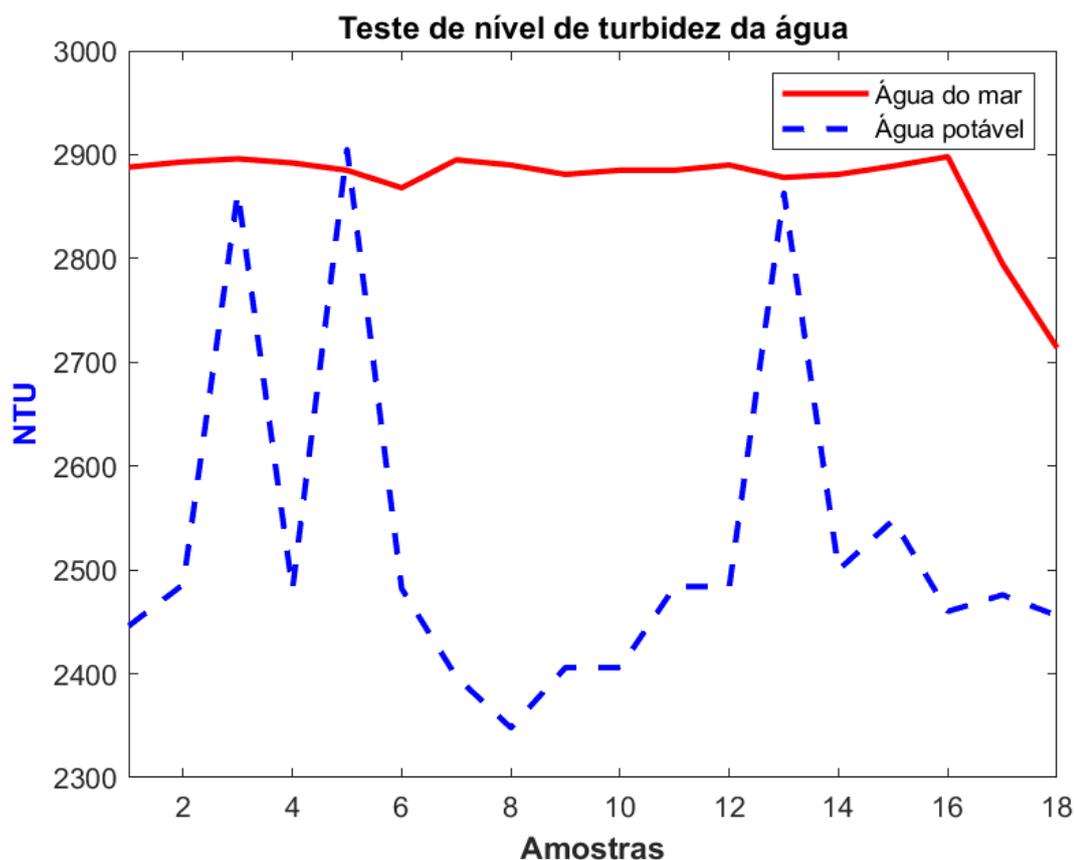


Figura 5.12: Medição com nó sensor do nível de turbidez da água do mar e potável.

Nas medições das amostras de água doce mostradas na Tabela 5.1, três picos de amplitudes são vistos entre os 3, 5 e 13, o comportamento desempenhado pelas medições é exibido na Figura 5.12. Esse ruído ocorre porque o sensor ST100 é um sensor óptico infravermelho que é muito sensível a grandes fontes de luz e interfere em algumas medições. Além da água doce ter maior transparência que a água do mar (o número de partículas é mínimo), tendo assim maior incidência de luz, o recipiente onde a água doce é armazenada é transparente, sofrendo mais com o ruído externo de lâmpadas, luz solar e telas de computador.

## 5.7 Experimentos com Gasolina

A segunda etapa das medições é realizada com todos sensores embarcados no protótipo do nó. Para realização dos testes com a gasolina apresentados na Tabela 5.2, 250 ml de água do mar e 100 ml de gasolina comum são utilizados, na Figura 5.13 são apresentados os primeiros testes experimentais com combustíveis-gasolina.



Figura 5.13: Medição com nó sensor e classificação da Gasolina.

Um dos primeiros testes de detecção e classificação foi com a gasolina, na Figura 5.13 são exibidos resultados práticos dos primeiros ensaios e medições realizadas na IDE Arduino (*software* de código aberto usado para escrever e

fazer *upload* de código para com compatibilidade com uma grande diversidade de microcontroladores).

Tabela 5.2: Medição com nó sensor e classificação da Gasolina na Água do Mar.

Medições	Gasolina - Água do Mar				
	pH	Turbidez (NTU)	Temp.	T-Interna	Pressão hPa
1º	7,34	2948	22,25	22,9	1005,40
2º	7,37	2942	22,37	22,8	1005,40
3º	7,63	2950	22,25	22,9	1005,40
4º	7,63	2952	22,25	22,9	1005,40
5º	7,47	2964	22,25	23,1	1005,40
6º	7,44	2958	22,25	22,9	1005,40
7º	7,44	2958	22,25	22,9	1005,40
8º	7,31	2956	22,25	22,6	1005,40
9º	7,50	2952	22,25	22,9	1005,40
10º	7,52	2940	22,25	22,9	1005,40
11º	7,56	2948	22,25	22,9	1005,40
12º	7,44	2952	22,25	22,9	1005,40
13º	7,50	2950	22,25	22,9	1005,40
14º	7,42	2956	22,25	22,9	1005,40
15º	7,43	2944	22,25	22,9	1005,40
16º	7,41	2943	22,25	22,9	1005,40
17º	7,41	2953	22,25	23,2	1005,40
18º	7,38	2946	22,25	23	1005,40

Na Tabela 5.2 e na Figura 5.14 são apresentados os resultados da detecção e classificação. Para realização da classificação é considerado que a turbidez da gasolina está entre 2,36 e 2,42 NTU e seu pH entre 6,5 e 7, em condições ambientais com a temperatura variando 18 à 40 °C. Observa-se que o comportamento dos índices de turbidez, gerados a partir das medição da presença de gasolina sobe

a lâmina d'água do mar contida no frasco, com uma variação de entre 2,948 à 2,964 NTU. Os picos de variações na medições ocorrem devido grande quantidade sedimentos presentes na amostra de água do mar. Para as medições do pH da gasolina com água do mar apresentados na Tabela ocorre variações de pH entre 7,31 e 7,65, tornando-se estável com o valor de 7,39. Durante o teste de pH não houve problemas com a sua medição.

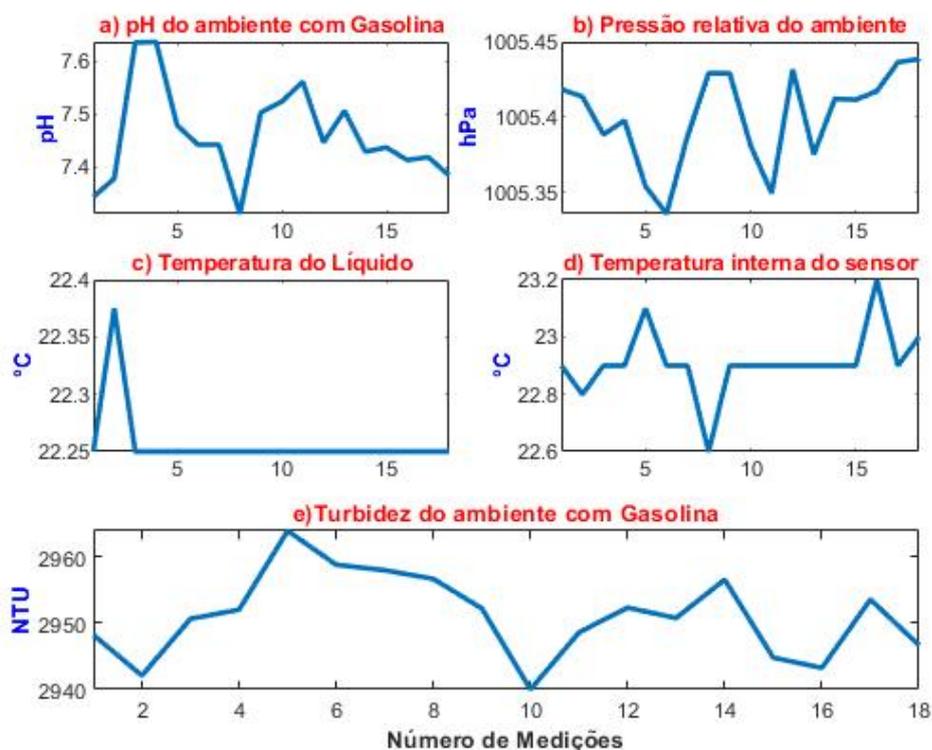


Figura 5.14: Medições com nó sensor e classificação da Gasolina com água do Mar.

Diferente da Tabela 5.2 que viabiliza uma análise quantitativa das medições. Uma uma visão qualitativa do comportamento das variáveis medidas da água salgada com gasolina é viabilizada por meio dos gráficos da Figura 5.14. Estes gráficos representam o conjunto de 18 medições de a) pH do ambiente com gasolina, b) Pressão relativa do ambiente, c) Temperatura do líquido, d) Temperatura interna do sensor, e) Turbidez do ambiente.

Conforme a apresentado na Figura 5.14, não há variações significativas na medição da temperatura do líquido, pois se trata de um ambiente controlado,

onde a temperatura do líquido permanece quase igual à temperatura ambiente (laboratório), com diferença de 2°C no líquido. A temperatura interna do nó sensor apresenta uma variação maior devido à presença de componentes eletrônicos e dissipação de calor interna, mas essa variação é de apenas 0,4 graus.

## 5.8 Experimentos - Medições Direta da $H_2O$ Salgada e Diesel

Uma visão qualitativa do comportamento das variáveis medidas da água salgada com óleo diesel é apresentada por meio dos gráficos da Figura 5.15. Os gráficos apresentados são provenientes de medições diretas dos sensores de pH, pressão, temperaturas e turbidez. Cada gráfico é plotado para conjunto de 18 medições realizadas pelo nó sensor proposto e implementado, conforme apresentado na Figura 5.10, para os experimentos de detecção. As amostras de água do mar misturada com diesel tem um volume de 250ml de água do mar e para um volume 120ml de óleo diesel.

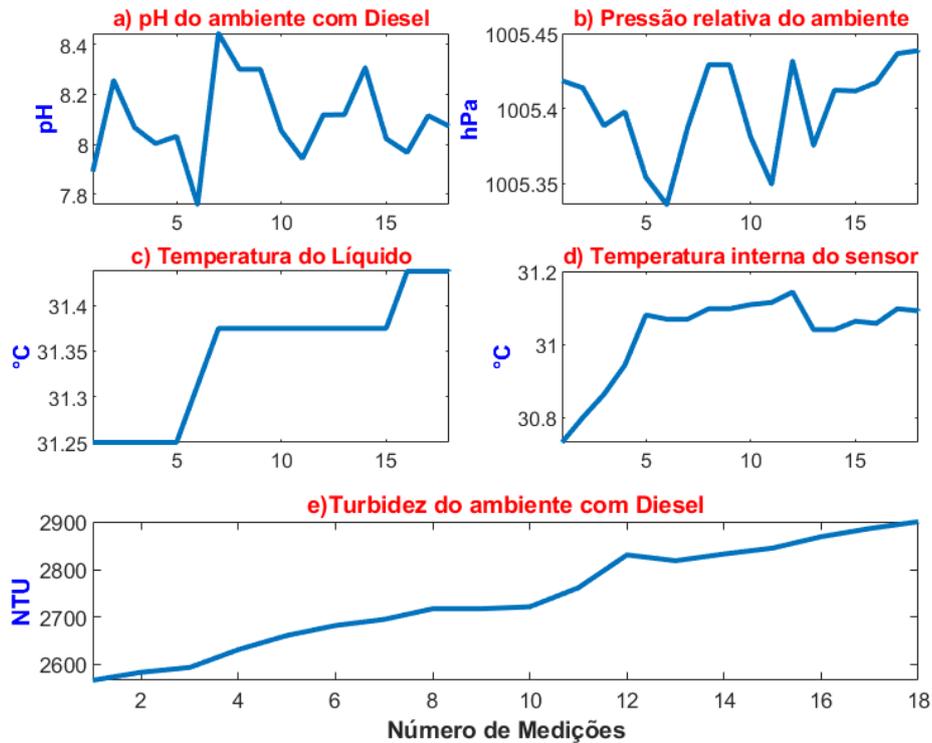


Figura 5.15: Medições com nó sensor e classificação do Óleo Diesel na água do Mar.

Para a detecção e classificação do diesel é considerado os seguintes parâmetros, como característica possui turbidez entre 2,28 (2280) e 2,35 (2399)NTU, e o pH de 5,8 à 6,5 em condições ambientais. Considerando esses valores e levando em consideração a pressão ao nível do mar é possível classificar o diesel.

Conforme observado nos gráficos da Figura 5.15 é apresentada uma análise do sensor para realizar medições. No gráfico a) da Figura 5.15, são exibidos os resultados das medições do pH do ambiente com óleo Diesel do pH, os valores do pH estão entre 7,9 e 8,4. Os valores obtidos são diferentes do seu estado natural (antes de ser contaminado/entrar em contato com água), se dá por conta da absorção das moléculas de água pelo diesel e a penetração da luz no ambiente.

Em relação as medições relacionadas a pressão interna apresentadas na apresentados na Tabela 5.3, as medições da pressão são relativas ao nível do mar. A pressão relativa se mantém em 1005.48 hPa. A pressão do nível do mar de São Luís - Maranhão de acordo com o Portal do Governo é em média de 1014

hPa. Essa diferença entre a média e o valor medido se dá pelo erro de precisão do sensor, que é de 5% e também pelo fato que a pressão relativa leva em conta a temperatura ambiente, quanto maior a temperatura, menor é a pressão relativa calculada.

No gráfico b) da Figura 5.15, as medições da pressão relativa do ambiente são apresentadas, as medições são relativas ao nível do mar. A pressão relativa se mantém em 1005,48 hPa. A pressão do nível do mar de São Luís - Maranhão de acordo com o Portal do Governo é em média de 1014 hPa. Essa diferença entre a média e o valor medido é dado pelo erro de precisão do sensor, que é de 5% e também pelo fato que a pressão relativa leva em conta a temperatura ambiente, quanto maior a temperatura, menor é a pressão relativa calculada.

Nos gráficos c) e d) da Figura 5.15, as variações da temperatura do líquido e da parte interna do sensor são apresentadas. As variações são mínimas em decorrência do experimento ter sido realizado em ambiente controlado. Na realização dos teste no mar essas circunstâncias tendem a mudar, uma vez que a temperatura da água mar e combustível tem condutividade térmicas diferentes, sofrendo influência de exposição aos raios solares e correntes marinhas.

Tabela 5.3: Medição com nó sensor e classificação do Óleo na Água do Mar.

Medições	Óleo Diesel - Água do Mar				
	pH	Turbidez (NTU)	Temp.	T-Interna	Pressão hPa
1º	7,8	2566	31,25	30,73	1005,40
2º	8,25	2583	31,25	30,80	1005,40
3º	8,06	2593	31,25	30,86	1005,40
4º	8	2631	31,25	30,94	1005,40
5º	8,03	2661	31,25	31,08	1005,40
6º	7,75	2682	31,31	31,06	1005,40
7º	8,44	2695	31,37	31,06	1005,40
8º	8,30	2717	31,37	31,09	1005,40
9º	8,30	2717	31,37	31,09	1005,40
10º	8,05	2721	31,37	31,10	1005,40
11º	7,94	2761	31,37	31,11	1005,40
12º	8,11	2831	31,37	31,14	1005,40
13º	8,11	2818	31,37	31,04	1005,40
14º	8,30	2833	31,37	31,04	1005,40
15º	8,02	2845	31,37	31,06	1005,40
16º	7,96	2869	31,43	31,05	1005,40
17º	8,11	2886	31,43	31,09	1005,40
18º	8,07	2901	31,43	31,09	1005,40

No gráfico e) Figura 5.15, turbidez do ambiente medida no teste com o diesel está entre 2,550(2550) à 2,950(2950) NTU são apresentadas. Da mesma forma que acontece com turbidez da gasolina na Tabela 5.2, os valores obtidos das medições sofrem perturbações ocasionadas por fonte de iluminação externa. Porém, não altera o resultado final da classificação.

Com o auxílio da Tabela 5.3, nos próximos parágrafos, os resultados dos experimentos de desempenho do sistema em medir as grandezas são interpretados.

A Tabela 5.3 viabiliza uma análise quantitativa das medições, ressaltando resultados discrepantes, máximos, mínimos e valor médio das medições. Desta forma, a detecção é uma tarefa que é realizada para variações nos padrões de pH, turbidez e temperatura do ambiente que é localmente monitorado pelo nó sensor, que as medições e parte da estrutura de como foram feitos os primeiros ensaios é exibido na Figura 5.16.

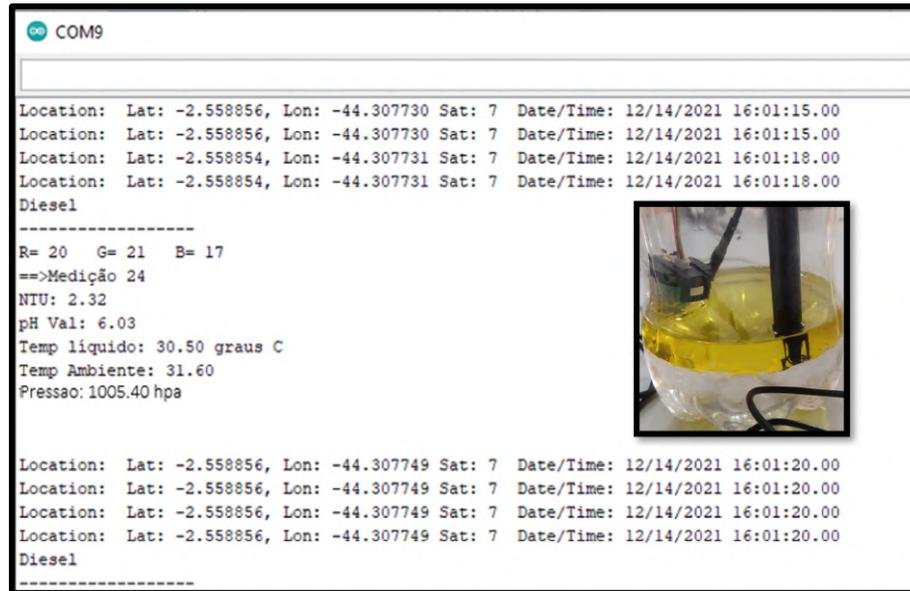


Figura 5.16: Medição com nó sensor e classificação do Diesel.

As amostras de água do mar misturada com diesel, na Figura 5.16 são apresentados os resultados dos primeiros ensaios e medições realizadas na IDE Arduino, onde é possível observar todas as grandezas sendo exibidas em tempo real.

## 5.9 Posicionamento do nó sensor

As coordenadas de longitude e latitude do nó sensor é apresentada na Figura 5.17.

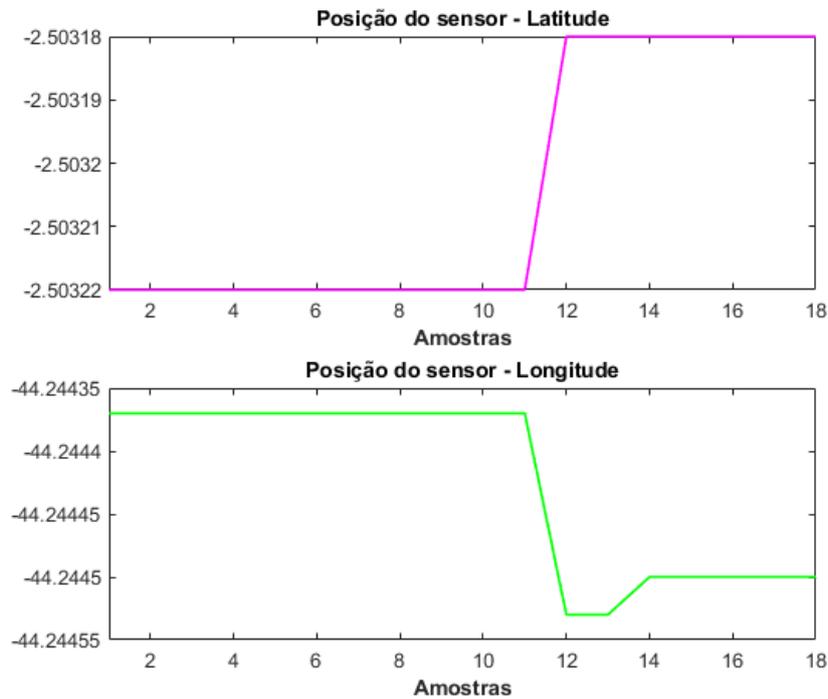


Figura 5.17: Posicionamento do nó sensor - Latitude e Longitude.

Estas coordenadas correspondem a localização do Lab SECI, onde é realizado o desenvolvimento dos testes e medições. Observando-se os gráficos exibidos na Figura 5.17, percebe-se que os gráficos possuem oscilações. Contudo, nota-se uma variação dos valores apenas nos milésimos da unidade nos dois resultados, essas variações acontecem em decorrência do pareamento do GPS e deslocamento do nó sensor pelo ambiente. No contexto, esta localização é aplicada para verificar se a posição dos nós da RSSF estão no local correspondente com localização, ou seja, se estão alocados conforme as especificações do projeto.

# RESULTADOS DOS EXPERIMENTOS COMPUTACIONAIS E HARDWARE

---

Neste capítulo são apresentados os resultados referente ao uso do classificador, baseado em RNA, e a influência do processamento e classificação no sistema embarcado. Também é realizada uma análise do consumo do nó sensor e um comparativo com o consumo de energia dos sistemas eletrônicos baseado nas informações do fabricante.

## 6.1 Detecção e classificação via RNA para combustíveis

A etapa de classificação é realizada por meio de uma RNA embarcada no dispositivo. A Tabela 2 apresenta os parâmetros e as métricas dos testes de rede neural multicamadas para a detecção e classificação de gasolina e diesel. Para realizar a classificação, são considerados a turbidez, o pH, a temperatura natural da água e a temperatura dos principais tipos de gasolina e diesel encontrados no mercado, além do pH "natural" da água do mar. As amostras de água do mar são coletadas na praia da Ponta d'Areia, em São Luís-MA. Dessa forma, é possível desenvolver um classificador baseado em uma rede neural MLP com 4 neurônios na camada de entrada e duas camadas ocultas, cada uma com 3 neurônios, com um algoritmo de treinamento *backpropagation*. O treinamento supervisionado é realizado com um conjunto de 1984 x 4 amostras. A taxa de aprendizado é

$\eta = 0,0001$ , e os pesos iniciais da rede são variáveis aleatórias dadas por uma distribuição gaussiana com média zero e variância igual a 1. Vale salientar que o conjunto de testes é realizado com 100 medições para cada combustível presente na água do mar.

Tabela 6.1: Desempenho, métricas para detecção e classificação via rede neural artificial MLP - para combustíveis gasolina e diesel.

<b>Classificador MLP - Parâmetros e Métricas</b>			
<b>Teste</b>	<b>Acurácia(%)</b>	<b>Época</b>	<b>Erro Médio</b>
1	83	100	$8 \cdot 10^{-5}$

Para uma melhor avaliação do modelo, é apresentada uma matriz de confusão, conforme apresentado na Figura 6.1. O objetivo da matriz de confusão é ajudar na avaliação dos modelos de aprendizado de máquina para classificação [22, 33].

<b>Matriz de confusão - Classificação da presença de combustível na água</b>				
		<b>Positivo</b>	<b>Negativo</b>	
<b>Classes</b>	Presença de Combustível	Verdadeiro Positivo 54	Falso Negativo 7	<b>Sensibilidade</b> 0,88
	Água s em Combustível	Falso Positivo 10	Verdadeiro Negativo 29	<b>Especificidade</b> 0,74
	<b>f-Score</b>	<b>Precisão</b>	<b>Taxa de Alarmes Falsos</b>	<b>Acurácia</b>
	0,86	0,84	0,26	0,83

Figura 6.1: Avaliação de desempenho do classificador MLP via matriz de confusão.

De acordo com os resultados obtidos, é possível classificar-se corretamente que 54 amostras continham presença de combustível e prever que 29 amostras não continham combustível, apenas água. Classificou-se erroneamente 7 amostras como combustível e 10 como água. A análise da matriz de confusão permitiu uma precisão de 83%, predizendo corretamente 83 dos 100 casos. A sensibilidade é de 88%, representando a probabilidade de detectar a presença de combustível na água. A especificidade é de 74%, representando a probabilidade de identificar corretamente a ausência de um evento, uma vez que ele está ausente. A

taxa de alarme falso é de 26% (aproximadamente 1/4 das estimativas), que é a probabilidade de classificar erroneamente se a presença de combustível é verdadeira ou falsa. Levando em conta que o valor mais alto possível de um F-score, próximo a 1, indica precisão e sensibilidade satisfatórias, e o valor mais baixo possível é 0; se a precisão ou a sensibilidade for zero, a classificação é insatisfatória/ruim. Conseqüentemente, devido ao fato de que o valor da métrica F-score atingiu 86%, pode-se dizer que o classificador MLP proposto apresentou boa precisão e sensibilidade.

### 6.1.1 Medidores inteligentes de qualidade da água

Para fins de monitoramento após a realização da classificação feita *indoor* no nó as informações dos índices de qualidade da água e classificação ficam armazenados em um *broker*/nuvem chamado de *Thingspeak*, onde o usuário pode fazer o mapeamento e monitoramento online dos índices e classificação de forma *online*/tempo real através da nuvem, que é alimentada pelos sinais provindos do nó de sensor exibidos no formato de medidores e gráficos nas Figuras 6.2 e 6.3.

Como resultados da medições, na Figura 6.2 é exibido os medidores 4 medidores de monitoramento de índices de qualidade da água, são eles: temperatura que tem uma faixa de medição de -15 à 125 °C, divididas em faixas de temperaturas variando com as cores, sendo -15 à 1 °C faixa preta (temperaturas mais baixas/regiões polares, as temperaturas podem ser próximas a 0 °C, pouco provável e incomum que ocorra no ambiente, onde os testes foram realizados uma vez que o local geográfico próximo a costa, servindo como parâmetros de alerta), 1 à 16 °C faixa azul (temperatura mais comum dos oceanos em regiões costa próximas aos trópicos).

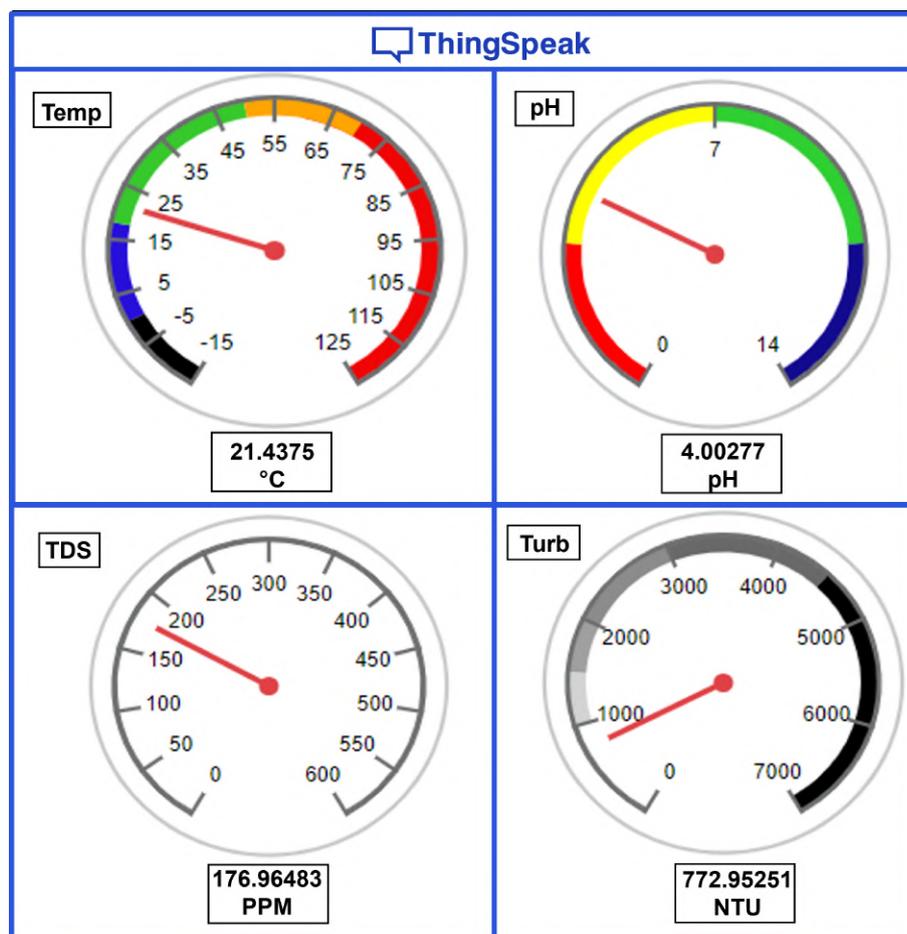


Figura 6.2: Medidores de medição dos índices acesso ao *broker*.

A faixa de operação verde varia 16 à 50 °C (faixa de temperatura comum, em regiões tropicais, as temperaturas da superfície do oceano atlântico em regiões proximais a linha do equador normalmente podem variar de cerca de 25 à 30°C, durante os meses mais quentes podem chegar até 33 °C, pensando em medição a faixa de operação foi considerada até 50 °C, por conta da característica de alguns poluentes reterem energia térmica provocando maior aumento da temperatura daquela região), 50 à 70 °C (faixa laranja, zona crítica, caracterizando problemas ambientais sérios e de grande risco a vida fauna marinha) e 70 à 125 °C (faixa vermelha catastrófico, indicando o comprometimento de toda vida marinha local).

Outro índice apresentado nos medidores na Figura 6.2 é o pH que possui uma variação 0 à 3 muito ácido (cor vermelha), 3 à 7 (ácido tendendo para o neutro, cor amarelo), 7 à 10 (verde - neutro) e 10 à 14 (azul escuro - neutro). Vale ressaltar que

as características do pH do ambiente vão influenciar muito, dependem de vários fatores tais como, quantidade material orgânico e inorgânicos presente na água, foz de rios próximos a regiões costeira/oceânicas.

O sensor TDS (*Total Dissolved Solids/Sólidos Totais Dissolvidos*), medir a concentração de sólidos dissolvidos em uma solução, geralmente expressa em partes por milhão (ppm) ou miligramas por litro (mg/L). A medição de TDS é frequentemente usada como um indicador da qualidade da água, uma vez que níveis elevados de TDS podem indicar a presença de contaminantes ou minerais em excesso na água potável. A faixa utilizada pra medição é escala de PPM, com faixa de operação de 0 à 600.

O índices de turbidez do ambiente é dado em NTU (*Nephelometric Turbidity Unit*) é uma medida comum de turbidez em uma amostra de água. Turbidez se refere à quantidade de partículas sólidas em suspensão na água que podem causar a dispersão ou absorção da luz. Quanto maior o número de NTU, mais turva é a água. Foi usado uma escala de cinza que 0 à 7000 NTU (os índices de concentração de turbidez mais baixos são próximos da escala da faixa branca valores de 0 à 1000 e com maior turbidez promovendo baixa visibilidade em decorrência da quantidade de partículas solidas próximos de 45000 à 7000 faixa preta). O comportamento das medições com índices também podem ser monitorados em formato de gráficos, armazenando as medições em nuvem, que são exibidos Figura 6.3.

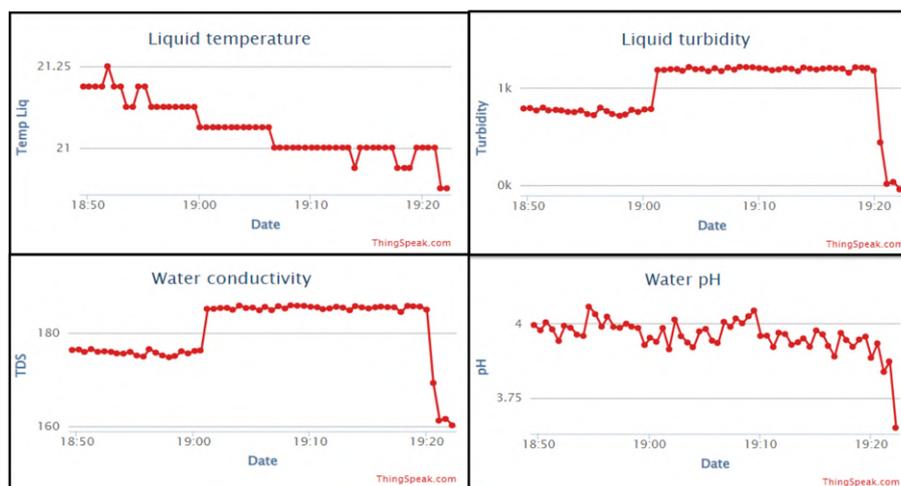


Figura 6.3: Comportamento dos sinais gerados pelo nó sensor enviados via MQTT para o broker.

As medições são realizadas e enviadas com intervalo de 15 segundos e enviadas para o *broker*. Nos gráficos exibidos na Figura 6.3 é possível acompanhar de forma *online*/tempo real o comportamento das medições realizadas durante o dia, vale ressaltar que esse dados enviados são salvos e podem ser exportados para outras plataformas no formato de arquivo em XML, permitindo uma maior gama de tratamento dos sinais e permitindo o uso das medições para outros fins.

## 6.2 Análise, comentários da implementação e testes de consumo de energia

Os resultados dos experimentos são satisfatórios, considerando a dificuldade de diferenciar os combustíveis. Para aprimorar o sensor, um dos principais parâmetros a serem observados é a condutividade elétrica do líquido. A gama de combustíveis e poluentes são detectados e classificados a partir da implementação do novo sensor na próxima geração de nós.

Durante os testes, surgiram dificuldades com relação às condições dos combustíveis devido ao odor e ao risco de contaminação da amostra, bem como ao risco de danificar os sensores que são usados nos testes devido à estrutura química dos combustíveis utilizados. As medições diretas e indiretas foram consistentes com as especificações, sendo possível atingir os objetivos de classificar e detectar a presença de combustível na água. Também embarcar um algoritmo baseado em aprendizado de máquina que realizou a classificação de diesel e gasolina embarcado no nó sensor. Uma das contribuições esperadas é a classificação interna do composto presente na água.

A relação de consumo de energia do nó é baseada em seus componentes e em seu uso durante um período de tempo. Portanto, na Tabela 6.2, apresenta-se os valores (*Ultra-Low-Power*), sem operações de transmissão de sinal, somente processamento interno e com transmissão de sinal via *Bluetooth* e *Wi-Fi* de acordo com a folha de dados), bem como os testes realizados comparando o consumo teórico com o consumo real em uma temperatura ambiente que varia de 26°C a 32°C. O microcontrolador utilizado é o ESP32 NodeMcu - DevKit v1, com uma CPU: Xtensa® Dual-Core 32-bit LX6 com 448 kBytes de memória ROM, 520 kBytes de memória RAM, 4 MB de memória *flash* e *clock* máximo de 240 MHz.

Tabela 6.2: Consumo do sistema de processamento  $\mu C$  ESP32 a 3.3 V.

Consumo Fabricante			Consumo em testes reais	
Modo: <i>Ultra baixo consumo</i>	Bluetooth ligado	Wi-Fi ligado	Processamento interno	Wi-Fi ligado
10 $\mu A$	75 mA	240 mA	75 mA	150 mA
33 $\mu W$	247 mW	700 mW	247 mW	495 mW

O consumo do nó sensor para o teste real é realizado com processamento interno (somente funções lógicas e o algoritmo MLP funcionando internamente), resultando em um consumo de 75 mA-247 mW. Isso é obtido com um intervalo de taxa de envio de amostra de 15 s para cada amostra processada. A execução da captura e do processamento do sinal consome de 150 mA-495 mW. Foram usados os mesmos critérios de amostragem e intervalo de captura, e o sinal transmitido a um servidor de armazenamento de dados. Dessa forma, é realizado um teste de consumo de energia e envio em um intervalo de 15 s para transmissão de sinal via *Wi-Fi*. É importante observar que não foram realizados testes usando o modo ultra baixo consumo; no entanto, a próxima etapa envolverá a implementação do novo modo de consumo.

Testes comparativos de consumo para os sensores do nó foram realizados e são apresentados na Tabela 6.3. A tabela exhibe a magnitude observada e o consumo de cada sensor de acordo com as especificações do fabricante. É importante observar que a tabela não considera perdas e ganhos relacionados a fenômenos térmicos.

Tabela 6.3: Consumo de energia dos sensores do nó.

Sensor	Medição	Consumo de energia	
		Fabricante	Real
ST100	Turbidez	30 mA-99 mW	30 mA-99 mW
ph4502c	pH	151 mA-500 mW	151 mA-500 mW
BMP180	Pressão atmosférica e temperatura ambiente	5 $\mu A$ -16.5 $\mu W$	5 $\mu A$ -16.5 $\mu W$
TDS V1.0	Condutividade elétrica	6 mA-19.8 mW	6 mA-19.8 mW
DS18B20	Temperatura líquidos	3 $\mu A$ -9.9 $\mu W$	3 $\mu A$ -9.9 $\mu W$
GY-NEO6MV2	Localização	45 mA-148.5 mW	45 mA-148.5 mW

Os resultados dos testes apresentados na Tabela 6.3 mostraram que os sensores apresentam um comportamento consistente com o descrito na ficha de dados. O

único componente que apresentou comportamento diferente do especificado é a tecnologia de radiofrequência LoRa. De acordo com o fabricante, esperava-se um consumo de 120 mA-100 mW, mas nos testes de comunicação envolvendo transmissão e recepção de dados, o consumo é de cerca de 400 mW (valor arredondado).

Os componentes com maior consumo foram o módulo de comunicação LoRa 433 MHz, que segundo seu fabricante tem um consumo de 120 mA - 100mW para *broadcast*, mas nos testes aplicados é possível atingir um consumo de 120 mA-396 mW, e outro componente com maior consumo é o sensor de pH devido à complexidade e robustez de seu circuito secundário. Esse circuito não apenas mede o pH, mas também avalia a temperatura do líquido. O consumo total é de aproximadamente 1120 mW a 1200 mW, com consumo em *standby* de apenas 50 mW, que é passivo e recebe informações da estação base. Em todos os testes em operação, é aplicada uma tensão de 3,3 V para todos os componentes do sistema embarcado.

### 6.2.1 Teste com o *DEEP SLEEP*

Afim de propor maior longevidade do nó sensor e sabendo que o maior consumo da ESP32 não é proveniente do processamento interno e sim do radio de comunicação, para sobrevida do nó sensor se torna imprecisável o uso de técnicas que amenizem o consumo de energia de forma geral e otimizem o consumo. Levando em consideração uma maior sobrevida do nó e maior autonomia da bateria foram realizados testes de autonomia usando dois modos, um sem o modo "*Deep sleep*"(sono profundo) outro teste usando função "*Deep sleep*", que são exibidos nas Figuras 6.4 e 6.5. O microcontrolador ESP32 possui um modo de economia de energia, chamado "*Deep sleep*". Nesse modo, as CPUs(*central processing unit*), a maior parte da RAM e todos os periféricos digitais com clock estão desligados. As únicas partes do chip que ainda podem ser ligadas são: controlador RTC(*real clock time*), periféricos RTC (incluindo o coprocessador ULP-*Ultra Low Power*) e memórias RTC. Para realizar o despertar desse modo é através do *timer*, o controlador RTC tem em sua estrutura um cronometro que é usado para ativar o chip apos o período de predefinido em milissegundos, no teste foram usados o período de 30000 milissegundos (de forma usual 30 segundos).

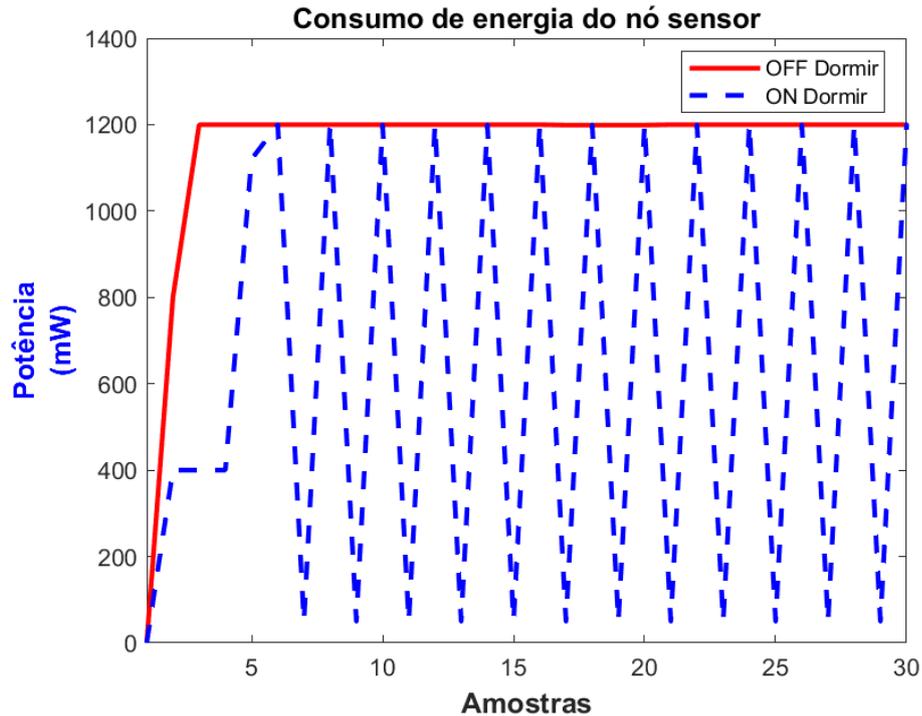


Figura 6.4: Consumo de energia do nó sensor operando em dois modos.

Na Figura 6.4 são exibidos os comportamentos dos sinais de consumo dos dois modos, o sinal na cor vermelha o modo *sleep* não se encontra ligado (*Status OFF*), o a primeira medição é realizada de 800 mW, nesse pontos são realizados os primeiros testes do sistema embarcado, é realizada uma rotina em formato de *checklist* de funções, requisitos, teste de memória, processamento, sensores e o primeiro teste de conexão para poder realizar a comunicação com e a estação base para o pareamento e começar a transmitir os primeiros sinais. As outras 29 amostras dos sinais de consumo ficaram em 1200 mW. Porém, nos teste realizados com a função "*Deep Sleep- ON*", o ciclo de rotinas para entrada no modo *deep* é realizada duas vezes, além dos testes feitos no *checklist* de funções também é realizado o teste de despertar, com um consumo de 400 mW para os primeiros testes após é feito um teste de envio de mensagem padrão com a estação base afim de testar o *link* de comunicação, onde foi registado um consumo 1120 mW essa porém a comunicação e envio e recebido de informação estabilizado em 1200 mW com comunicação com envio de todos os sinais de medição e classificação, com função ativa é possível observar que o estado do sistema embarcado no modo

"*Deep Sleep- ON*", quando não é enviado os sinais, o sistema tem um consumo de 50 mW, diferentemente de quando o modo não esta ativo a comunicação em envio e recebido de requisição é feito constantemente. Na Figura 6.5 é exibido o consumo dos dois modos de operação, onde é possível observar o comportamento crescente do modo de operação sem o uso do *Deep sleep*.

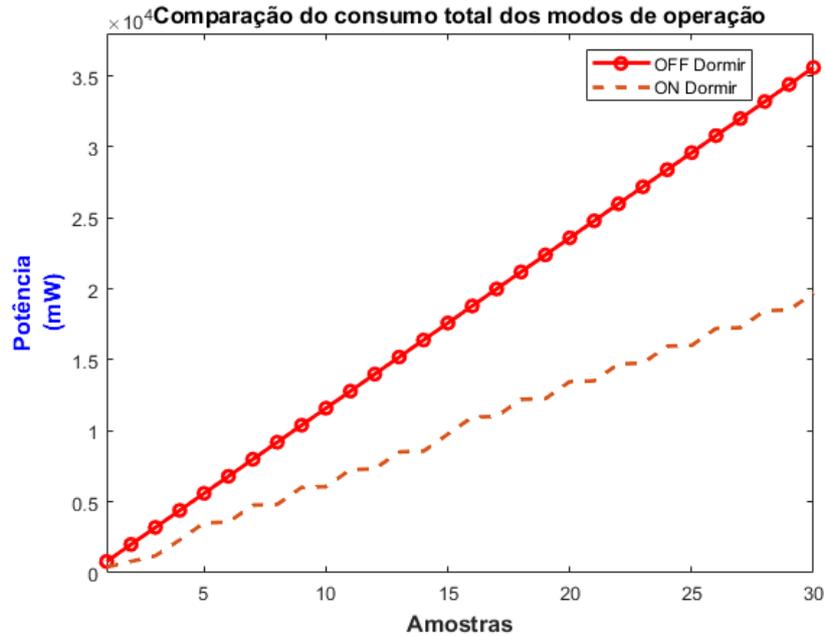


Figura 6.5: Comparativo do consumo total dos dois modos ativados.

Na Figura 6.5 é exibido o comportamento do consumo em relação ao tempo e amostras aferidas durante um período. O consumo total de 30 amostras no modo *Sleep OFF* foi 35600 mW e com o modo *Sleep ON* foi 19720 mW, a redução do consumo de energia foi 44,7% e com mesma qualidade de transporte de sinal mesma quantidade de informação. Vale ressaltar com monitoramento sendo realizado no modelo *DEEP SLEEP*, o consumo é reduzido, porém sua função passa de *status* de tempo real para *online*, porque o monitoramento será constante entretanto os pacotes de sinais serão enviado em um ciclo de 30 em 30 segundos para o teste de consumo. Em aplicações em região costeira, o ciclo de envio dos sinais e comunicação é realizado em até 60 segundos, cada envio dos sinais, caso o sistema seja lento, dependendo da variação de temperatura da água, correntes marítimas esses critérios podem serem adotados como padrão de envio

para estação base.

# CONSIDERAÇÕES E CONCLUSÃO

---

Neste capítulo são apresentadas as considerações finais da tese, incluindo a conclusão, publicações e trabalhos futuros.

## 7.1 Conclusão

Neste trabalho foi apresentada uma metodologia para concepção e projeto de nós sensores de RSSF, baseado em abordagens de sistemas embarcados, redes neurais do tipo MLP, e IoT. A metodologia proposta e desenvolvida foi aplicada para detecção de poluentes em ambientes aquáticos, constatou-se que o nó sensor estático proposto e desenvolvido apresentou resultados satisfatórios para detectar e a classificar a presença de compostos químicos em ambiente controlado. A metodologia desenvolvida foi embasada na elaboração de um modelo matemático para medições indiretas baseado em teoria de conjuntos e mapeamento que impactou diretamente no desenvolvimento de um classificador inteligente.

A classificação foi realizada de forma individual, sendo a medição e a detecção do processo que teve elevação do índices de variáveis observadas. Desta forma, o processamento distribuído nos núcleos do microcontrolador contribuiu para um menor esforço computacional que levou a um menor consumo de energia e aumentou o tempo de sobrevivência do nó. Vale ressaltar que uso do processamento distribuindo dentro núcleos do processador do nó influenciou em uma melhor resposta de detecção e classificação do algoritmo de redes neurais artificiais do tipo MLP embarcado.

Uma das principais contribuições foi na classificação *indoor* do composto presente na água. A classificação foi realizada de forma individual, porém pode ser realizada em agrupamento de nós próximo ativando apenas os nós da região de detecção que possuem elevação do índices de variáveis observadas. Consequentemente o processamento distribuído dos nós contribui para um menor esforço computacional levando a um menor consumo de energia, impactando no aumento da sobrevida dos nós.

O uso do processamento distribuindo dentro núcleos do processador de cada nó influencia em uma melhor resposta da rede detecção e classificação dos algoritmos de aprendizado de máquina (redes neurais artificiais - RBF e MLP- multilayer perceptron), não fazendo necessidade a transferência dos dados para que essa classificação seja feita externa a RSSF.

## 7.2 Trabalhos Futuros

1. Implementação um novo *watchdog* para ser integrado e testado para monitorar falhas nas leituras e nas comunicações baseado em lógica fuzzy e controle ótimo, combinados com um algoritmo de baixo consumo de energia, gerenciará os gastos com energia de forma mais eficiente;
2. Desenvolvimento de um controle baseado em controle ótimo e ADHP para realizar o controle de carga/descarga das baterias e o gerenciamento energético do sistema embarcado de forma mais eficiente;
3. Desenvolver novos algoritmos de classificação baseados em lógica fuzzy, árvore de decisão e outras técnicas de inteligência artificial, comparar sua eficiência relacionando precisão, exatidão e custo energético de operação e avaliar seu desempenho;
4. Confeção e desenvolvimento de um nó dinâmico aéreo(Drone) e marinho (*Unmanned surface vehicle* - embarcação autônoma) para monitoramento de locais restritos e difícil acesso;
5. Implementação de novos sensores, observação de novos estados dos índices de qualidade do ambiente;

6. Aprimoramento do modelo matemático proposto nesta tese, afim de elucidar e contribuir com os problemas de cobertura espacial de nós em RSSF (aumento do range de operação, garantir a estabilidade de conexão com estação base);
7. Propor métodos e algoritmos de rastreamento dos derivados de petróleo no mar baseado e inferência bayesiana para identificação do ponto inicial do derramamento e seu alcance.
8. Associar as técnicas desenvolvidas ao um sistema multiagente de uma RSSF afim de uma maior cobertura do ambiente com nós dinâmicos aéreos e aquáticos.

## 7.3 Publicações

### 7.3.1 Aceito e Publicado

**Artigo:** Conception and Design of WSN Sensor Nodes Based on Machine Learning, Embedded Systems and IoT Approaches for Pollutant Detection in Aquatic Environments

Periódico: IEEE Access 2023

Autores: Yan Ferreira da Silva, Raimundo Carlos Silvério Freire e João Viana da Fonseca Neto

**Artigo:** Smart Sensor Based On The IEEE 1451 Standard For Monitoring Coastal Areas Sensitive To Fuel Leakage

Periódico: International Journal of Advances In Engineering And Technology 2024.

Autores: Yan Ferreira da Silva, Victor Guimarães Furtado e João Viana da Fonseca Neto

**Artigo:** Detection of Disturbances in the Aquatic Environment via Deep Learning and Artificial Neural Network Integrated with Statistical Methods

Periódico: International Journal of Advances In Engineering And Technology 2024.

Autores: Monik S. Sousa, Alan de C. Araújo, Yan F. da Silva, Aristófanés C. Silva, Alcione M. dos Santos, João V. da Fonseca Neto.

### **7.3.2 Artigos publicados com temática relacionada a tese**

**Artigo:** Projeto de um Controlador Ótimo para Posicionamento de um Painel Fotovoltaico via Aprendizado por Reforço

Evento: CBA 2024

Autores: Alan Pablo Silva Belfort, Yan Ferreira da Silva e João Viana da Fonseca Neto

**Artigo:** Smart WSN Based On Machine Learning For Monitoring Work Environments

Periódico: International Journal of Advances In Engineering And Technology 2024

Autores: Yan Ferreira da Silva, Victor Guimarães Furtado e João Viana da Fonseca Neto

**Artigo:** Rede de Sensores Sem Fio e Aprendizado de Máquina para Monitoramento da Qualidade de Ambientes de Estudo

Evento: SBAI 2023

Autores: Victor Guimarães Furtado, Yan Ferreira da Silva e João Viana da Fonseca Neto

# Bibliografia

- [1] Kofi Sarpong Adu-Manu, Nadir Adam, Cristiano Tapparello, Hoda Ayatollahi, and Wendi Heinzelman. Energy-harvesting wireless sensor networks (eh-wsns): A review. *ACM Trans. Sen. Netw.*, 14(2), apr 2018.
- [2] CONSELHO NACIONAL DO MEIO AMBIENTE-CONAMA. Resolução conama n° 357, de 17 de março de 2005, 18 de março de 2005.
- [3] Gás Natural e Biocombustíveis ANP Agência Nacional do Petróleo. Análise do acidente com a plataforma p-36. 2001.
- [4] Zunaira Asif, Zhi Chen, Chunjiang An, and Jinxin Dong. Environmental impacts and challenges associated with oil spills on shorelines. *Journal of Marine Science and Engineering*, 10(6):762, 2022.
- [5] Peter Marwedel (auth.). *Embedded System Design: Embedded Systems Foundations of Cyber-Physical Systems, and the Internet of Things*. Embedded Systems. Springer, 4th ed. edition, 2021.
- [6] Abdul-Lateef Balogun, Shamsudeen Temitope Yekeen, Biswajeet Pradhan, and Khamaruzaman B. Wan Yusof. Oil spill trajectory modelling and environmental vulnerability mapping using gnome model and gis. *Environmental Pollution*, 268:115812, 2021.
- [7] Michael Belov, Yulia Vsyakova, and Victor Gorodnichev. Optical method of detection of oil contamination on water surface in uv spectral range. *Light & Engineering*, pages 88–96, 10 2019.
- [8] A.M. Bernabeu, M. Plaza-Morlote, D. Rey, M. Almeida, A. Dias, and A.P. Mucha. Improving the preparedness against an oil spill: Evaluation of

the influence of environmental parameters on the operability of unmanned vehicles. *Marine Pollution Bulletin*, 172:112791, 2021.

- [9] Manabendra Bhuyan. *Intelligent Instrumentation: Principles and Applications*. CRC Press, 2013.
- [10] Christopher M. Bishop. *Pattern Recognition and Machine Learning*. Information science and statistics. Springer, 1st ed. 2006. corr. 2nd printing edition, 2006.
- [11] Christopher M. Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006.
- [12] Juliane Brink. Boundary tracking and estimation of pollutant plumes with a mobile sensor in a low-density static sensor network. *Urban Climate*, 14:383–395, 2015. New Sensing Technologies and Methods for Air Pollution Monitoring.
- [13] Jihong Chen, Weipan Zhang, Zheng Wan, Sifan Li, Tiancun Huang, and Yijie Fei. Oil spills from global tankers: Status review and future governance. *Journal of Cleaner Production*, 227:20–32, 2019.
- [14] Asif Z. Chughtai, R. Study fate of pollutants due to oil spill in sea water through multimedia environmental modeling. *Int. J. Environ. Sci. Technol*, 18:761–770, july 2020.
- [15] Yan Ferreira da Silva, Anselmo Cardoso de Paiva, and João Viana da Fonseca Neto. Smart wireless sensor baseado na norma ieee 1451 para rastreamento e estimação de irradiância solar. *SBAI*, 1(1), 2021.
- [16] Yan Ferreira da Silva, Ernesto Franklin Marçal Ferreira, Monik Silva Sousa, Anselmo Cardoso de Paiva, and João Viana da Fonseca Neto. Sensor inteligente para estimação do Ângulo e irradiação solar via redes neuronais artificiais. *SBAI*, 2019.
- [17] Andreas Gerstlauer Gunar Schirner (auth.) Daniel D. Gajski, Samar Abdi. *Embedded System Design: Modeling, Synthesis and Verification*. Springer, 1 edition, 2009.

- [18] Agência Nacional de Águas. Indicadores de qualidade - Índice de qualidade das Águas (iqa), 22 de junho de 2015.
- [19] Dina S. Deif and Yasser Gadallah. Classification of wireless sensor networks deployment techniques. *IEEE Communications Surveys and Tutorials*, 16(2):834–855, 2014.
- [20] Hovig Denkilkian, Agop Koulakezian, Rostom Ohannessian, Milad S. Chalfoun, Mohamad Khaled W. Joujou, Ali Chehab, and Imad H. Elhajj. Wireless sensor for continuous real-time oil spill thickness and location measurement. *IEEE Transactions on Instrumentation and Measurement*, 58(12):4001–4011, 2009.
- [21] André dos Santos Alonso Pereira. Geopolítica do petróleo brasileiro - a estratégia de internacionalização da petrobras na américa do sul (2007-2017). page 203, 2019.
- [22] Russell C. Eberhart and Yuhui Shi. *Computational Intelligence: Concepts to Implementations*. Morgan Kaufmann, 1 edition, 2007.
- [23] Raíssa Ebrahim-MARCOZERO. Um crime sem culpados, punições nem multas. 2020.
- [24] Ibrahiem M. M. El Emary (Editor); S. Ramakrishnan (Editor). *Wireless sensor networks: From theory to applications*. 2013.
- [25] Sanjit Arunkumar Seshia Edward Ashford Lee. *Introduction to embedded systems: a cyber-physical systems approach*. MIT Press, 2nd edition, 2017.
- [26] Sahar El-Rahman and Ali Zolait. Hyperspectral image analysis for oil spill detection: a comparative study. *International Journal of Computing Science and Mathematics*, 9, 01 2018.
- [27] Merv Fingas and Carl E. Brown. A review of oil spill remote sensing. *Sensors*, 18(1), 2018.
- [28] Oscar Garcia-Pineda, Gordon Staples, Cathleen E. Jones, Chuanmin Hu, Benjamin Holt, Villy Kourafalou, George Graettinger, Lisa DiPinto, Ellen

- Ramirez, Davida Streett, Jay Cho, Gregg A. Swayze, Shaojie Sun, Diana Garcia, and Francisco Haces-Garcia. Classification of oil spill by thicknesses using multiple remote sensors. *Remote Sensing of Environment*, 236:111421, 2020.
- [29] Olga Nickolaevna Gershenzon, Vladimir Eugenyevich Gershenzon, and Sergey Vladimirovich Osheyko. Integral solution for oil spill detection using sar data. In *2007 3rd International Conference on Recent Advances in Space Technologies*, pages 361–365, 2007.
- [30] Ian Goodfellow, Yoshua Bengio, and Aaron Courville. *Deep Learning*. MIT Press, 2015.
- [31] Ian Goodfellow, Yoshua Bengio, and Aaron Courville. *Deep Learning*. Adaptive Computation and Machine Learning series. The MIT Press, draft edition, 2016.
- [32] Stephen Grossberg. Nonlinear neural networks: principles, mechanisms, and architectures. *Neural networks - Elsevier*, 1(1):17–61, 1988.
- [33] Aurélien Géron. *Hands on Machine Learning with Scikit Learn Keras and TensorFlow*, volume 2nd Edition. O’Reilly Media, early release edition, 2019.
- [34] Lars Haulin. A state-based method to model and analyze the power consumption of embedded systems, 2018.
- [35] Simon Haykin. *Redes neurais: princípios e prática*. Bookman, 2nd edition, 2001.
- [36] Simon O. Haykin. *Neural Networks and Learning Machines*. Prentice Hall, 3 edition, 2008.
- [37] Ruben Hidalgo-Leon, Javier Urquizo, Christian E. Silva, Jorge Silva-Leon, Jinsong Wu, Pritpal Singh, and Guillermo Soriano. Powering nodes of wireless sensor networks with energy harvesters for intelligent buildings: A review. *Energy Reports*, 8:3809–3826, 2022.
- [38] Andreas Willig Holger Karl. Protocols and architectures for wireless sensor networks. 2007.

- [39] IBAMA. Plano nacional de contingência para incidentes de poluição por Óleo em Águas sob jurisdição nacional (pnc). 2020.
- [40] Jusbrasil. Poluição e contaminação ambiental: a extração de petróleo e seus reflexos no meio ambiente. 2020.
- [41] Taieb Znati Kazem Sohraby, Daniel Minoli. Wireless sensor networks: Technology, protocols, and applications. 2007.
- [42] Panagiota Keramea, Katerina Spanoudaki, George Zodiatis, Georgios Gikas, and Georgios Sylaios. Oil spill modeling: A critical review on current trends, perspectives, and challenges. *Journal of Marine Science and Engineering*, 9(2), 2021.
- [43] Christos Koulamas and Mihai T. Lazarescu. Real-time embedded systems: Present and future. *Electronics*, 7(9), 2018.
- [44] Klein Lawrence. *Sensor and data fusion: a tool for information assessment and decision making*. SPIE Press, 2012.
- [45] Perry Lea. *IoT and Edge Computing for Architects: Implementing edge and IoT systems from sensors to clouds with communication systems, analytics, and security, 2nd Edition*. Packt Publishing, 2 edition, 2020.
- [46] Dieyan Liang, Hong Shen, and Lin Chen. Maximum target coverage problem in mobile wireless sensor networks. *Sensors*, 21(1), 2021.
- [47] Fen Liu, Wendong Xiao, Shuai Chen, and Chengpeng Jiang. Adaptive dynamic programming-based multi-sensor scheduling for collaborative target tracking in energy harvesting wireless sensor networks. *Sensors*, 18(12), 2018.
- [48] Eduardo Loos, Leslie Brown, Gary Borstad, Todd Mudge, and Mar Alvarez. Characterization of oil slicks at sea using remote sensing techniques. pages 1–4, 10 2012.
- [49] F. Mancilla-David, F. Riganti-Fulginei, A. Laudani, and A. Salvini. A neural network-based low-cost solar irradiance sensor. *IEEE Transactions on Instrumentation and Measurement*, 63(3):583–591, March 2014.

- [50] Q. Mascaret, G. Gagnon-Turcotte, M. Biemann, C. L. Fall, L. J. Bouyer, and B. Gosselin. A wearable sensor network with embedded machine learning for real-time motion analysis and complex posture detection. *IEEE Sensors Journal*, 22(8):7868–7876, 2022.
- [51] Markus; Spies Peter Mateu, Loreto; Pollak. *Handbook of energy harvesting power supplies and applications*. CRC Press, 2015.
- [52] Shaimaa M. Mohamed, Haitham S. Hamza, and Iman Aly Saroit. Coverage in mobile wireless sensor networks (m-wsn): A survey. *Computer and Communications*, 110:133–150, 2017.
- [53] Subhas Chandra Mukhopadhyay. *Intelligent Sensing, Instrumentation and Measurements*. Smart Sensors, Measurement and Instrumentation 5. Springer-Verlag Berlin Heidelberg, 1 edition, 2013.
- [54] Subhas Chandra Mukhopadhyay, Sumarga Kumar Sah Tyagi, Nagender Kumar Suryadevara, Vincenzo Piuri, Fabio Scotti, and Sherali Zeadally. Artificial intelligence-based sensors for next generation iot applications: A review. *IEEE Sensors Journal*, 21(22):24920–24932, 2021.
- [55] Fundação Joaquim Nabuco. 5 fatos que não te contaram sobre a poluição por óleo no litoral do nordeste. 2019.
- [56] Christoffer Heckman Alessandro Roncone Nikolaus Correll, Bradley Hayes. *Introduction to Autonomous Robots: Mechanisms, Sensors, Actuators, and Algorithms*. The MIT Press, 2022.
- [57] Ejofodomi OA. Ground robotic oil spill surveillance (gross) system for early detection of oil spills from crude oil pipelines. *Journal of Applied Mechanical Engineering*, 06, 01 2017.
- [58] Philip Odonkor, Zachary Ball, and Souma Chowdhury. A Distributed Intelligence Approach to Using Collaborating Unmanned Aerial Vehicles for Oil Spill Mapping. Volume 2A: 43rd Design Automation Conference, 08 2017. V02AT03A009.

- [59] Philip Odonkor, Zachary Ball, and Souma Chowdhury. Distributed operation of collaborating unmanned aerial vehicles for time-sensitive oil spill mapping. *Swarm and Evolutionary Computation*, 46:52–68, 2019.
- [60] Emilio Ernesto Paladin. Modelagem matemática e simulação numérica de trajetórias de derrames de petróleo no mar. Master’s thesis, Universidade Federal de São Carlos, São Carlos-SP, 2000.
- [61] Vaidehi Paravastu, Shobana Manoharan, and M. Manimaraboopathy. A proposal of an automatic sensor system for petroleum detection. In *2013 International Conference on Green Computing, Communication and Conservation of Energy (ICGCE)*, pages 335–338, 2013.
- [62] Andy D. Pimentel. Exploring exploration: A tutorial introduction to embedded systems design space exploration. *IEEE Design & Test*, 34(1):77–90, Feb 2017.
- [63] Abdul Serwadda (auth.) Rastko R. Selmic, Vir V. Phoha. Wireless sensor networks: Security, coverage, and localization. 2016.
- [64] Swapnil Sayan Saha, Sandeep Singh Sandha, and Mani Srivastava. Machine learning for microcontroller-class hardware - a review. *IEEE Sensors Journal*, pages 1–1, 2022.
- [65] Ramon Sanchez-Iborra and Antonio F. Skarmeta. Tinymml-enabled frugal smart objects: Challenges and opportunities. *IEEE Circuits and Systems Magazine*, 20(3):4–18, 2020.
- [66] Ramon Sanchez-Iborra and Antonio F. Skarmeta. Tinymml-enabled frugal smart objects: Challenges and opportunities. *IEEE Circuits and Systems Magazine*, 20(3):4–18, 2020.
- [67] Stephen Scheidt, Michael Ramsey, and Nicholas Lancaster. Determining soil moisture and sediment availability at white sands dune field, new mexico, from apparent thermal inertia data. *Journal of Geophysical Research: Earth Surface*, 115(F2), 2010.

- [68] Ravi Sharma and Shiva Prakash. Coverage problems in wsn: A survey and open issues. pages 829–834, 2018.
- [69] Sabrie Soloman. *Sensors Handbook, Second Edition*. 2 edition, 2009.
- [70] Susana Beatrís Oliveira Szewczyk. Processos envolvidos em um derramamento de óleo no mar. In *SEMENGO ANAIS*, pages 1–19, Porto Alegre, Brasil, 2006.
- [71] Gianluca Tabella, Nicola Paltrinieri, Valerio Cozzani, and Pierluigi Salvo Rossi. Wireless sensor networks for detection and localization of subsea oil leakages. *IEEE Sensors Journal*, 21(9):10890–10904, 2021.
- [72] Yen Kheng Tan. *Energy Harvesting Autonomous Sensor Systems: Design, Analysis, and Practical Implementation*. CRC Press, 2013.
- [73] Shamsudeen Temitope Yekeen and Abdul-Lateef Balogun. Advances in remote sensing technology, machine learning and deep learning for marine oil spill detection, prediction and vulnerability assessment. *Remote Sensing*, 12(20), 2020.
- [74] Frantz Tossa, Wahabou Abdou, Keivan Ansari, Eugène C. Ezin, and Pierre Gouton. Area coverage maximization under connectivity constraint in wireless sensor networks. *Sensors*, 22(5), 2022.
- [75] Theodore G. van Kessel, Muralidhar Ramachandran, Levente J. Klein, Dhruv Nair, Nigel Hinds, Hendrik Hamann, and Norma E. Sosa. Methane leak detection and localization using wireless sensor networks for remote oil and gas operations. pages 1–4, 2018.
- [76] Anuradha Pughat Vidushi Sharma. *Energy-efficient wireless sensor networks*, volume 1. CRC Press, 2017.
- [77] Xiaoying Wang, Reza Hoseinnezhad, Amirali K. Gostar, Tharindu Rathnayake, Benlian Xu, and Alireza Bab-Hadiashar. Multi-sensor control for multi-object bayes filters. *Signal Processing*, 142:260–270, 2018.

- [78] Yang Wang, Shuang Wu, Zhiyin Chen, Xiaofeng Gao, and Guihai Chen. Coverage problem with uncertain properties in wireless sensor networks: A survey. *Computer Networks*, 123:200–232, 2017.
- [79] Marilyn Wolf. *Computers as Components: Principles of Embedded Computing System Design*. The Morgan Kaufmann Series in Computer Architecture and Design. Elsevier Science;Morgan Kaufmann, 3rd edition edition, 2012.
- [80] Hiro Yamasaki, editor. *What are the intelligent sensors*, volume 3 of *Handbook of Sensors and Actuators*. Elsevier Science B.V., 1996.
- [81] Yan Yu, Siyue Huang, Jie Wang, and Jinping Ou. Design of wireless logging instrument system for monitoring oil drilling platform. *IEEE Sensors Journal*, 15(6):3453–3458, 2015.
- [82] Kan Zeng and Yixiao Wang. A deep convolutional neural network for oil spill detection from spaceborne sar images. *Remote Sensing*, 12(6), 2020.
- [83] Huaguang Zhang, He Jiang, Yanhong Luo, and Geyang Xiao. Data-driven optimal consensus control for discrete-time multi-agent systems with unknown dynamics using reinforcement learning method. *IEEE Transactions on Industrial Electronics*, 64(5):4091–4100, 2017.
- [84] Jiayi Wen Guichen Zhang Yihua Liu Zhijian Huang, Xinze Liu. Adaptive navigating control based on the parallel action-network adhdp method for unmanned surface vessel. *Advances in Materials Science and Engineering - Hindawi*, 2019(8):4091–4100, 2019.

## APÊNDICE A

# ESTUDO CASO 1 - WSN PARA DETECÇÃO DE RESÍDUOS OCPD E OUTROS POLUENTES EM AMBIENTES AQUÁTICOS

---

Neste estudo caso 1 é apresentada a RSSF para detecção e monitoramento resíduos OCPD e outros poluentes presente nas águas da região costeira da ilha de São Luís capital do Maranhão. O local escolhido para este estudo de caso foi o porto do Itaqui que faz parte do complexo portuário São Luís com os terminais de Ponta da Madeira, da Vale, o Terminal da Alumar.

A localização do Porto do Itaqui limita-se com o Distrito Industrial na região metropolitana de São Luís, no litoral oeste da Ilha (Baía de São Marcos) que pode ser observada na Figura A.1, a 11 km do centro da cidade. O espaço ocupado pela EMAP (Empresa Maranhense de Administração Portuária) ocupa uma área de 5.100.000 m<sup>2</sup>. O Porto do Itaqui localiza-se entre os paralelos 02°34'S e 02°36'S e os meridianos 44°21'W e 44°24W, próximo ao limite entre as regiões Nordeste e Norte do Brasil.

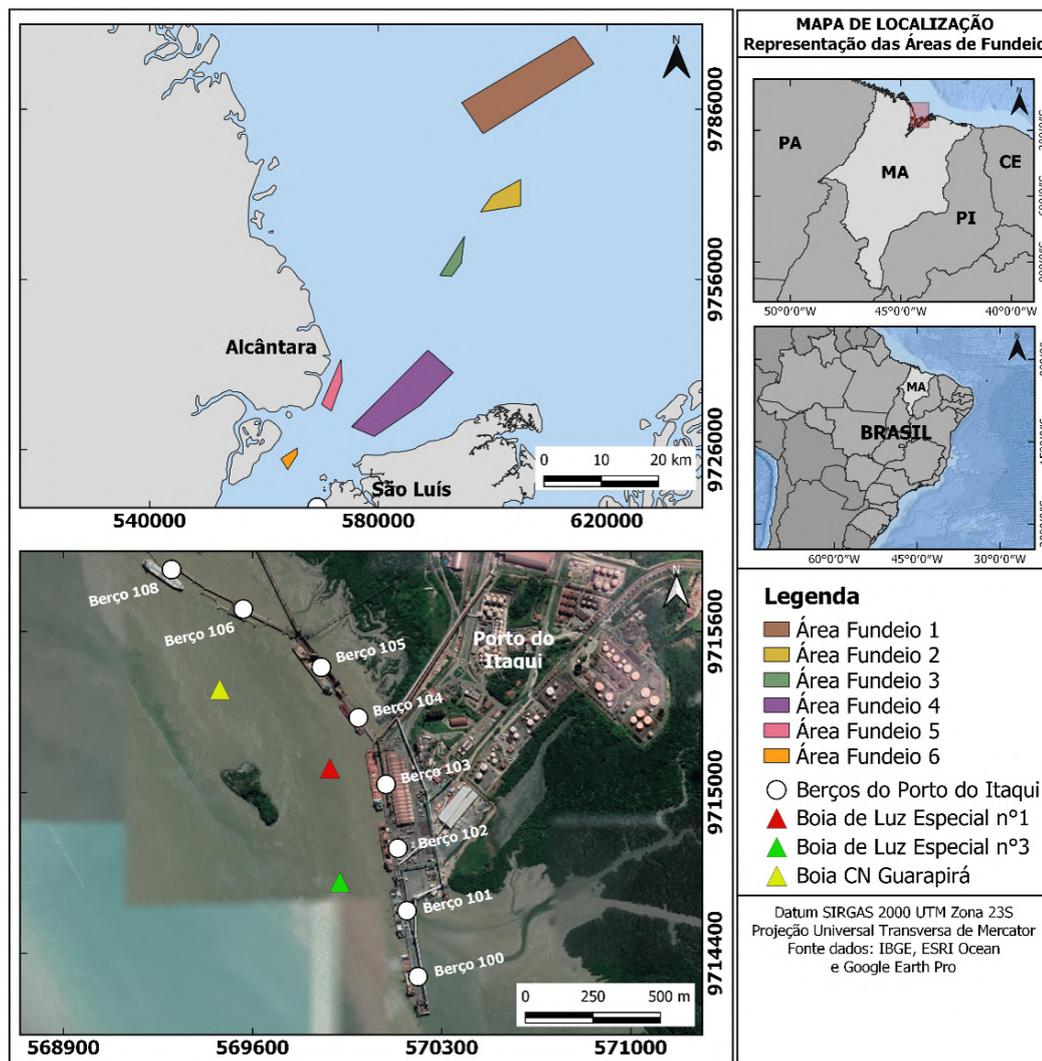


Figura A.1: Local de proposta de implantação da RSSF.

A escolha do porto do Itaqui foi feita em decorrência de ser um dos portos mais movimentados do Brasil, com um movimentado de 6,7 milhões de toneladas no quatro trimestre de 2021. O porto conta com 9 berços que possibilitam a movimentação de grandes navios e está conectado a duas grandes ferrovias, a Transnordestina e a Estrada de Ferro Carajás, utilizadas para escoar a produção de granéis sólidos, líquidos e celulose. O Itaqui tem 3 berços de atracação de navios petroleiros/graneis Líquidos (sendo eles 105,106 e 108 exibidos na Figura A.1) com estrutura para carga e descarga de diesel, gasolina e biocombustíveis. O porto também conta com sete tanques para armazenamento de diesel, gasolina, etanol

anidro e biodiesel com capacidade nominal de 20 mil m<sup>3</sup>. Ainda na Figura A.1 é possível observar as áreas fundeio, distribuição das boias de sinalização e os berços de atracação do porto do Itaqui.

O levantamento deste estudo de caso foi viabilizado através de um contato direto com CCMAR(Centro de Ciências do Mar-UFMA) e EMAP (Empresa Maranhense de Portos), foi possível nota pontos sensíveis com risco de vazamento de poluente proveniente de derivados de petróleo e outros poluentes. Esse levantamento foi realizado para o desenvolvimento e aplicação do protótipo e a necessidade do monitoramento da grande área que cobre os berços 105, 106 e 108 além dos mananciais da reserva de proteção ambiental ambiental, que é exibida na Figura A.2.



Figura A.2: Reserva de proteção ambiental do porto do Itaqui, situada atrás dos berços 105, 106 e 108.

Uma das grandes questões que circunda o interesse do estudo de caso está em torno da reserva/área de Proteção do berçário natural (regulamentadas pela LEI

No 9.985, DE 18 DE JULHO DE 2000 - Regulamenta o art. 225, 1o, incisos I, II, III e VII da Constituição Federal, institui o Sistema Nacional de Unidades de Conservação da Natureza e dá outras providências) próximo ao porto (região de mangue) circulado de amarelo na Figura A.2 região mais sensível a acidentes envolvendo (Derivados de Petróleo).

A reserva ambiental exibida na Figura A.2 é um berçário da vida marinha, fica próxima aos berços de carga e descarga de combustíveis, sendo área sensível de grande risco de acidentes. Então com estudo desenvolvidos tem-se a necessidade de um monitoramento constante das áreas entorno do porto. No caratê de acidentes, até a realização das visitas ao porto do Itaquí (que foram entre os dias 7 e 9 de julho de 2021), o último acidente correu na primeira semana do mês de junho de 2021 no dutos de distribuição (exibidos na Figura A.3), onde foram recolhidos 271 litros de óleo combustível na barreira de contenção o resto do material foi levado pela maré em direção a baía de São Marcos durante a vazamento, a equipe de contenção levou 9h para tomar ciência do ocorrido.



Figura A.3: Vista da reserva de mangues.

Outra questão que oferece riscos é a tubulação próxima aos berços de atracação é exposta (presente na Figura A.3) e outra ela fica embutida em galerias da estrutura do porto com risco eminente de rompimento por conta da salinidade e umidade do ambiente (BEM HOSTIL). Outros pontos levantados nesse estudo de caso foi que segundo a EMAP os acidentes não são constantes, porém não foi isso que constatamos. Existe grande necessidade do monitoramento dessa grande área que envolve todo porto o Itaqui, porém os sensíveis são derramamento de combustíveis são os que foram listados. Outra deficiência é o formato das medições do nível de poluentes, que fica em cargo das operadoras dos berços, que realizam contratação de empresa que fazem as aferições. EMAP também realiza suas medições de forma semestral no nível de poluentes (contratação de uma empresa

especializada para elaboração do relatório, anual ou de acordo com o CONAMA). O monitoramento em das áreas sensíveis do porto fica em cargo da equipe de meio ambiente que tem suas problemáticas em relação a dispositivo e tecnologias envolvidas (consideradas muito rudimentares e alguns pontos não existe nenhum tipo de medição).

## A.1 Projeto de Implantação da RSSF

A escolha dos pontos de implantação foram escolhidos em decorrência a regiões que tiveram recentes derramamentos, correntes marinhas que passam próximo ao porto. Na Figura A.4 exibe o esquema proposto da RSSF .



Figura A.4: Imagem de satélite do local de implantação da RSSF.

Para o monitoramento *online* dos parâmetros da água e estimação medições

indiretas de outras variáveis que contribuem para detecção e classificação. Uma das contribuições da rede de sensores sem fio inteligente é no monitoramento dos parâmetros críticos, análise constante do ambiente que é realizado apenas em laboratório ou semestralmente. A distribuição proposta de uma rede sensores de ponto a ponto, que pode é exibida na Figura A.4, com suas conexões em ambiente simulado.

A RSSF proposta foi projetada e simulada no CupCarbon, uma plataforma de simulação de RSSF e IoT. Ele permite aos usuários modelar, simular e visualizar cenários de redes de sensores sem fio em ambientes urbanos. O CupCarbon é útil para projetar e otimizar a implantação de redes, facilitando a análise de cobertura, consumo de energia, desempenho de protocolos de comunicação e outros aspectos relacionados à RSSF e IoT.

A estrutura da RSSF conta com 14 nós no total, sendo 13 nós de captação e um *sink/gateway* com nível de processamento, responsável por receber as medições processar, checar se ocorre perda de sinal e mantém estabilidade da rede sobre um protocolo de comunicação. A realização de integração dos sinais processados e transformado em dados encaminhados para uma nuvem, que é disponibilizado para um processamento mais refinado na estação base. A Figura A.5 exibi a estrutura de comunicação e cobertura de mais nítida do nó, e cobertura de observação do nós.



Figura A.5: Projeto da rede de sensores sem fio proposta para cobertura dos berços de atracação 105, 106 e 108.

Como citado nos capítulos anteriores, a estrutura de comunicação nós é híbrida, possui dois sistemas de comunicação tendo como principal objetivo estabilidade da comunicação, cobertura de observação e menor consumo de energia. Neste caso a comunicação proposta para transporte de sinais adquiridos pelos nós até o nó *gateway* é tecnologia LoRa que opera a grandes distâncias em uma frequência de 433 Mhz de baixo consumo e opera com Wifi 2.4 Ghz e 5 Ghz.

## APÊNDICE B

# ESTUDO DA MODELAGEM MATEMÁTICA DA MEDIÇÃO pH

---

### B.1 Medição pH

Para determinação dos valores dos índices de pH do estado da água, o sensor de pH (ph4502C) tem em sua estrutura um circuito conectado a uma sonda de contato com líquidos. Para a realização de medições, o sensor tem eletrodos de referência, dependendo do nível concentração do pH no ambiente, que emitem diversos níveis de tensões diferentes. A medição do pH não ocorre de forma direta, mas sim através de uma medição indireta, onde são realizadas observações dos níveis de tensões do pH. As variações uniformes do pH estão entre 0 e 14. Portanto, para converter os valores de tensão para escala de pH a equação da reta ( $y = mx + b$ ) é adequada para realizar esta conversão. Para calcular a inclinação  $m$  da equação da reta, é necessário a obtenção dos valores de tensão correspondentes de pelo menos dois valores de pH. Os primeiros pares de valores de medição são conhecidos, correspondem aos valores de calibração, pH = 7 e U = 2,5 V (os respectivos valores provem do fluido de calibração que está presente na sonda). Para aferir a tensão em outro valor de pH, por exemplo, pH = 4. Calcula-se o coeficiente angular  $m$  da seguinte forma:

$$m = \frac{\Delta \text{ Volt}}{\Delta \text{ pH}} = \frac{V(\text{pH} = 7) - V(\text{pH} = 4)}{7 - 4} \quad (\text{B.1})$$

Para um pH = 4, a medição de uma tensão de 3,0 V, tem-se que

$$m = \frac{2,5 - 3,0}{7 - 4} = -0,167 \quad (\text{B.2})$$

Para aumentar a precisão, considera-se a calibração de dois pontos, nesta situação, a tensão do pH = 10 e calcula-se o valor médio de  $m$  em conformidade. Uma compreensão do cálculo de  $m$  é importante para compreender como os valores de tensão são convertidos em valores de pH.

$$m = \frac{\Delta \text{ Volt}}{\Delta \text{pH}} = -0,167 \quad (\text{B.3})$$

$$-0,167 = \frac{2,5 - \text{ Volt}}{7 - \text{ pH}} \quad (\text{B.4})$$

$$0,167 = \frac{\text{ Volt} - 2,5}{\text{pH} - 7} \quad (\text{B.5})$$

$$\text{pH} - 7 = \frac{\text{ Volt} - 2,5}{0,167} \quad (\text{B.6})$$

A constante  $b$  na equação para a equação da reta, inicialmente é desconsiderada. Em situações de desvios sistemáticos, pode-se configurá-la manualmente para qualquer valor.

## APÊNDICE C

# ESTUDO DE UM SENSOR PARA ANÁLISE DE PARTÍCULAS SÓLIDAS DE POLUENTES PRÓXIMA A LÂMINA D' ÁGUA

---

O estudo de um sensor óptico para a análise de partículas sólidas na água é de grande importância em diversas áreas, incluindo ambiental, industrial e de saúde pública. Para o monitoramento da qualidade da água a detecção de contaminantes é necessário. Um sensor óptico pode detectar e quantificar partículas sólidas, como sedimentos, microplásticos, algas e outros contaminantes. Isso é essencial para garantir que a água esteja dentro dos padrões de qualidade estabelecidos por órgãos reguladores. Os sensores ópticos auxiliam no monitoramento da presença de poluentes como derivados de petróleo e também fitoplâncton, zooplâncton e outros organismos aquáticos, contribuindo para estudos de ecossistemas aquáticos.

O uso de sensores sensores ópticos para auxílio da detecção de poluentes em ambientes aquáticos podem atuar da seguintes forma: Turbidímetros que medem a turbidez da água, que é um indicativo da presença de partículas em suspensão; Espectrofotômetros analisam a absorção e a dispersão de luz em diferentes comprimentos de onda, fornecendo informações detalhadas sobre a composição das partículas.

## C.1 Análise do uso do LDR e luz azul para um sensor de análise de partículas

Um LDR (*Light Dependent Resistor*), ou fotocélula, é um componente de resistência que varia de acordo com a intensidade da luz incidente sobre ele. Em termos de comportamento sob luz azul e submerso em água, vários fatores influenciam seu desempenho.

O espectro de absorção da água absorve mais a luz vermelha e infravermelha do que a luz azul. Portanto, a luz azul penetra mais profundamente na água. Isso significa que a luz azul terá menos atenuação do que outras cores quando submersa, favorecendo assim o desenvolvimento de um sensor que use a luz azul como emissor e o LDR como receptor, conforme é exibido na Figura C.1.

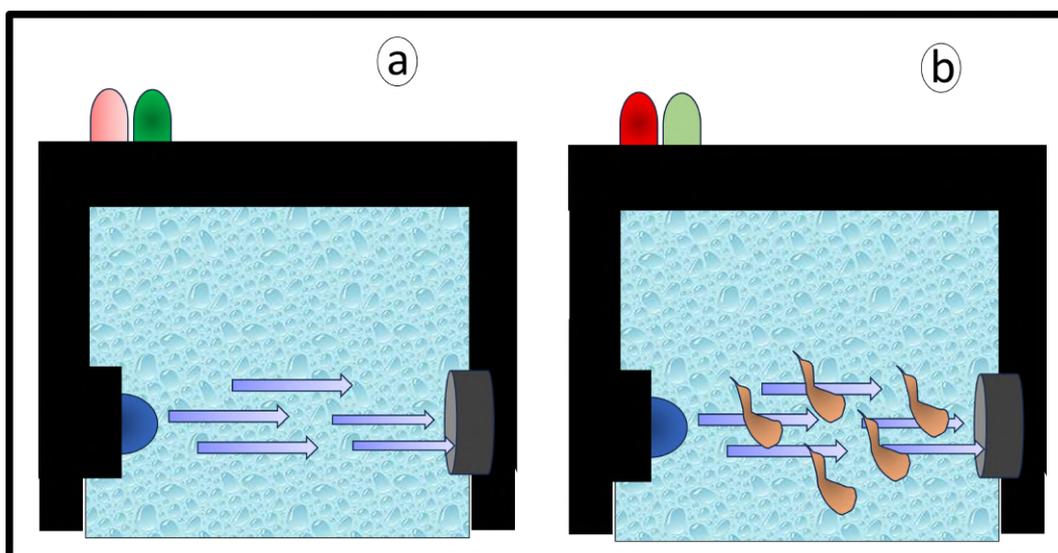


Figura C.1: Estudo do sensor usando LDR e LED (*Light Emitter Diode*) com brilho de alta intensidade para detecção de partículas na água, a) emissão da luz sem detecção, b) modificação no comprimento de onda da luz azul e possível identificação do corpo estranho .

Na Figura C.1 é exibida a estrutura do estudo de um sensor que faz uso de LEDs de alta intensidade de cor azul e LDR para a medição/verificação do material particulado em ambiente aquático. Um ponto sensível do desenvolvimento desse sensor é a sensibilidade espectral do LDR é geralmente mais sensíveis à luz visível, mas a sensibilidade pode variar dependendo do tipo

específico de material fotossensível utilizado (como sulfeto de cádmio - CdS). A maioria dos LDRs têm uma maior sensibilidade na faixa do verde ao amarelo do espectro visível, mas ainda responderão à luz azul.

Refração e reflexão na interface ar-água, quando a luz passa do ar para a água, ela sofre refração, o que pode alterar a direção e a intensidade da luz incidente no LDR. A parte da luz é refletida na superfície da água, reduzindo a intensidade da luz que atinge o LDR submerso.

Difusão na água dependendo da turbidez da água (quantidade de partículas em suspensão), a luz azul pode ser espalhada, diminuindo a intensidade da luz direta que atinge o LDR, mas pode aumentar a quantidade de luz difusa.

Portanto, um LDR submerso em água e exposto à luz azul provavelmente terá uma resistência menor do que no escuro, pois a luz azul penetra bem na água e pode ser detectada pelo LDR. No entanto, a resposta exata dependerá da intensidade da luz azul, da pureza da água, da profundidade de submersão e das características específicas do LDR. Para uma medição precisa, seria necessário realizar experimentos com as condições específicas de interesse. Como resultado dos primeiros ensaios foi projetado um sensor com 3 LDRs do tipo GL12528 de 12mm para a recepção da luz azul e 3 LEDs (*Light Emitter Diode*) de alto brilho azul (com luminosidade: 20000 MCD e corrente máxima: 30 mA), a estrutura é exibida na Figura C.2.



Figura C.2: Prototipação do estudo do sensor para detecção de partículas de poluentes. 1) estrutura de recepção da luz azul com LDRs, 2) estrutura do emissor, 3) estrutura completa de emissão e recepção.

Na Figura C.2 são apresentados os primeiros ensaios da proposta do sensor, onde tem-se a parte emissora e receptora, para a leitura do LDR e emissão da

luz foi utilizado um arduino Mega2560. Durante o levantamento e estudos, a estratégia viável mostrou-se viável e de baixo custo para aferição de resíduos com alta intensidade. Porém para uma melhor afirmativa, faz-se necessário um estudo mais elaborado do desenvolvimento de um sensor baseado neste conceito.