

UNIVERSIDADE FEDERAL DE PELOTAS
Centro de Desenvolvimento Tecnológico
Programa de Pós-Graduação em Computação



Dissertação

**RealSense: Uma Abordagem Explorando Aprendizado de Máquina no
Monitoramento de Temperatura e Umidade em Sistemas de Compostagem**

Paulo César Sedrez Moncks

Pelotas, 2020

Paulo César Sedrez Moncks

RealSense: Uma Abordagem Explorando Aprendizado de Máquina no Monitoramento de Temperatura e Umidade em Sistemas de Compostagem

Dissertação apresentada ao Programa de Pós-Graduação em Computação do Centro de Desenvolvimento Tecnológico da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Felipe de Souza Marques
Coorientador: Prof. Dr. Adenauer Correa Yamin

Pelotas, 2020

Universidade Federal de Pelotas / Sistema de Bibliotecas
Catalogação na Publicação

M737r Moncks, Paulo César Sedrez

RealSense : uma abordagem explorando aprendizado de máquina no monitoramento de temperatura e umidade em sistemas de compostagem / Paulo César Sedrez Moncks ; Felipe de Souza Marques, orientador ; Adenauer Corrêa Yamin, coorientador. — Pelotas, 2020.

80 f. : il.

Dissertação (Mestrado) — Programa de Pós-Graduação em Computação, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, 2020.

1. Sensor de umidade. 2. Autoajuste de sensores. 3. Umidade em compostagem. I. Marques, Felipe de Souza, orient. II. Yamin, Adenauer Corrêa, coorient. III. Título.

CDD : 005

Paulo César Sedrez Moncks

RealSense: Uma Abordagem Explorando Aprendizado de Máquina no Monitoramento de Temperatura e Umidade em Sistemas de Compostagem

Dissertação aprovada, como requisito parcial, para obtenção do grau de Mestre em Ciência da Computação, Programa de Pós-Graduação em Computação, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas.

Data da Defesa: 27 de fevereiro de 2020

Banca Examinadora:

Prof. Dr. Felipe de Souza Marques (orientador)

Doutor em Computação pela Universidade Federal do Rio Grande do Sul.

Prof. Dr. Ricardo Matsumura Araujo

Doutor em Computação pela Universidade Federal do Rio Grande do Sul.

Prof. Dr. Erico Kunde Correa

Doutor em Biotecnologia pela Universidade Federal de Pelotas.

Dedico esta e todas as minhas conquistas à minha família, minha esposa Luciane e meus filhos Rodrigo e Juliana, sem vocês, nada importaria.

AGRADECIMENTOS

Engana-se quem acredita que consegue fazer algo sozinho. Todas as pessoas que encontramos são importantes em nossa caminhada. Mesmo que algumas nos mostrem o caminho e outras nos desviem da jornada.

Agradeço a todas as pessoas que caminharam comigo ao longo de toda minha vida, pois direta ou indiretamente, me fizeram chegar até aqui, indicando que é possível ir mais longe.

Agradeço em especial a meus familiares e amigos que, incondicionalmente, acreditam e me fazem acreditar em mim.

Aos meus orientadores, professores Drs. Felipe de Souza Marques e Adenauer Correa Yamin, por fazerem parte deste rol de pessoas. Espero continuar usufruindo de toda amizade, conhecimento, dedicação e paciência de vocês.

À equipe do Nepers (Núcleo de Educação, Pesquisa e Extensão em Resíduos e Sustentabilidade), da UFPel, em especial ao professor Dr. Erico Kunde Correa, à professora Dra. Luciara Bilhalva Correa e ao Me. Lucas Guidone, por me receberem e apoiarem nos ensaios laboratoriais. Vocês foram uma fonte de conhecimento e motivação fundamental para a conclusão deste trabalho.

E, finalmente, a todos aqueles que me inspiraram a seguir em frente, meus sinceros agradecimentos.

As maiores vitórias ainda estão por vir.

Existem três classes de pessoas que são infelizes: a que não sabe e não pergunta, a que sabe e não ensina e a que ensina e não faz. — BUDA

RESUMO

MONCKS, Paulo César Sedrez. **RealSense: Uma Abordagem Explorando Aprendizado de Máquina no Monitoramento de Temperatura e Umidade em Sistemas de Compostagem**. Orientador: Felipe de Souza Marques. 2020. 80 f. Dissertação (Mestrado em Ciência da Computação) – Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, Pelotas, 2020.

A compostagem, enquanto "reciclagem dos resíduos orgânicos", é uma forma de recuperar os nutrientes e levá-los de volta ao ciclo natural, enriquecendo o solo para agricultura e diminuindo a necessidade de aquisição de adubo industrializado. É também uma maneira de minimizar o lixo produzido, destinando corretamente um resíduo que se acumularia nos lixões e aterros, gerando mau-cheiro, liberando gás metano e chorume, o qual, enquanto líquido, tem potencial para contaminar o solo e as águas. Ressalte-se que, hoje, cerca de 60% do lixo no país é composto por resíduos orgânicos, cujo depósito em lixões geram severos impactos negativos ao meio ambiente e à saúde pública. Ao longo do processo de compostagem, por se tratar de uma decomposição aeróbia, existem variações de temperatura e umidade, e se não houver monitoramento e controle sobre estas variáveis, as reações bioquímicas não ocorrerão adequadamente. Existem estudos direcionados a diferentes tipos de solos que utilizam métodos não destrutivos para aferir o teor de umidade de forma rápida e precisa, como os baseados em sensores capacitivos. Particularmente, se tratando de compostagem, percebe-se a necessidade de estudos mais aprofundados, que considerem as significativas mudanças nos seus aspectos constitutivos ao longo de um único ciclo de produção e, somando-se a isto, as características individuais de substratos de cada leira. Considerando este cenário, este trabalho tem como objetivo central a concepção de uma proposta de *hardware* e *software* denominada RealSense, que explora técnicas de aprendizado de máquina para o autoajuste de um sensor capacitivo, considerando seu uso em compostagens de diferentes naturezas. O foco é qualificar o monitoramento da umidade, provendo um maior controle das proporções dos diferentes resíduos e dos materiais aeradores, obtendo como resultado uma melhor atividade para os organismos microscópicos que ajudam na decomposição e, conseqüentemente, gerando um adubo mais adequado. A avaliação do resultado teve a Gravimetria como base para validação do modelo proposto. Com a análise dos resultados foi possível concluir que a técnica proposta se mostrou rápida e confiável na medição de umidade em compostagem, alcançando um coeficiente de correlação de 0.9939 entre o teor de umidade e a predição.

Palavras-chave: Sensor de Umidade. Autoajuste de Sensores. Umidade em Compostagem.

ABSTRACT

MONCKS, Paulo César Sedrez. **RealSense: An Approach to Explore Machine Learning in Compost Monitoring**. Advisor: Felipe de Souza Marques. 2020. 80 f. Dissertation (Masters in) – , Federal University of Pelotas, Pelotas, 2020.

Composting, as in "recycling of organic waste", is a way to recover nutrients and return them to their natural cycle, enriching the soil for agriculture and reducing the need for industrialized fertilizers. It is also a method to minimize waste, by properly disposing a material that would accumulate in dumps and landfills, creating foul odor and releasing methane gas and leachate, a liquid with the potential to contaminate soil and water. About 60% of the waste in the country today is composed of organic waste, which is deposited in dumps, generating a severe negative impact on the environment and public health. Throughout the composting process, being it an aerobic decomposition, there are variations in temperature and humidity. Without proper monitoring and control over these variables, biochemical reactions will not occur properly. There are studies targeting different types of soil using non-destructive methods to quickly and accurately measure humidity content, such as those based on capacitive sensors. Particularly in the case of composting, there is a need for further studies, considering the significant changes in its constitutive aspects over a single production cycle, adding to this the individual substrate characteristics of each windrow. Therefore, this work aimed to conceptualize a hardware and software proposal called RealSense, which explores machine learning techniques for the self-tuning of a capacitive sensor, considering its use in composting of different natures. The aim is to qualify the monitoring of humidity, providing greater control of proportions of different waste and aerator materials, resulting in a better activity for microscopic organisms that aid in decomposition and, consequently, generating a more suitable fertilizer. The evaluation of results considered the gravimetric analysis as validation basis for the proposed model. Through the analysis of the results, it was possible to conclude that the proposed technique is a fast and reliable way of measuring moisture in compost. It reached a correlation coefficient of 0.9939 between moisture content and the prediction.

Keywords: Humidity Sensor. Sensor Self-Calibration. Humidity in Compost.

LISTA DE FIGURAS

Figura 1	Teste de mão	21
Figura 2	Tipos de sondas	23
Figura 3	Modelo não-linear de um neurônio artificial	27
Figura 4	Outro modelo não-linear de um neurônio artificial	28
Figura 5	Função sigmóide	29
Figura 6	Problema de separação linear e não-linear	31
Figura 7	Arquitetura de uma MLP com duas camadas ocultas	31
Figura 8	Algoritmos de aprendizagem e métodos suportados pelo Auto-WEKA	34
Figura 9	Topologia rede neural Elman	39
Figura 10	Rede de sensores sem fio para monitoramento e controle de compostagem	45
Figura 11	Visão do nodo sensor	50
Figura 12	Sensor capacitivo	53
Figura 13	Sensor Termopar PT100	53
Figura 14	Sensor DHT22	53
Figura 15	Limite de inserção no composto	55
Figura 16	Indicador de nível de bateria	55
Figura 17	Configuração Wi-fi	56
Figura 18	Exemplo das amostras nos recipientes	60
Figura 19	Exemplo de amostras em placa de Petri	60
Figura 20	Recorte arquivo de treinamento	61
Figura 21	Seleção de atributos Auto-WEKA	63
Figura 22	Resultado do teste do modelo gerado (IBK)	66
Figura 23	Resultado do teste do modelo gerado (MLP)	67
Figura 24	Gráfico Comparativo Gravimetria X IBK X MLP	67

LISTA DE TABELAS

Tabela 1	Propriedades físicas de alguns materiais	22
Tabela 2	Trabalhos relacionados e suas principais características	48
Tabela 3	Comparativo ESP-07 X Arduino UNO R3	52
Tabela 4	Cronograma da coleta de dados	59
Tabela 5	Comparação de resultados entre IBK e MLP	67
Tabela 6	Comparativo Gravimetria X Sensor X Teste de Mão	68

LISTA DE ABREVIATURAS E SIGLAS

AP	Access Point
API	Application Programming Interface
CMS	Compost Monitoring System
FDR	Frequency Domain Reflectometry
GNU	General Public License
IA	Artificial Intelligence
IBL	Instance-based Learning
IDE	Integrated Development Environment
KNN	k-Nearest Neighbor
LMBP	Levenberg Marquardt Backpropagation
MCU	Microcontroller Unit
MLP	Multilayer Perceptron
MLR	Multiple Linear Regression
NEPERS	Núcleo de Educação, Pesquisa e Extensão em Resíduos e Sustentabilidade
NIRS	Near-infrared Reflectance Spectroscopy
PCA	Principal Component Analysis
PMEs	Pequenas e Médias Empresas
RFB	Radial Basis Function
RNA	Rede Neural Artificial
SOC	System-On-Chip

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Objetivos	16
1.2	Organização do Texto	17
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Importância do Controle da Umidade na Compostagem	19
2.2	Métodos de Determinação da Umidade em Compostagem	20
2.2.1	Métodos Diretos de Determinação da Umidade	21
2.2.2	Métodos Indiretos de Determinação da Umidade	21
2.3	Métodos de Calibração de Sensores Capacitivos	23
2.4	Autoajuste de Sensores	24
2.5	Aprendizado de Máquina	24
2.5.1	Tipos de Aprendizagem	25
2.5.2	Categorização de Acordo com a Saída	25
2.5.3	Seleção de Atributos	25
2.6	Redes Neurais Artificiais	26
2.6.1	Modelo de Neurônio Artificial	27
2.6.2	Função de Ativação Sigmóide	28
2.6.3	Principais Arquiteturas de RNAs	29
2.6.4	Perceptron de Múltiplas Camadas	30
2.7	Software Weka	32
2.7.1	Framework Central	32
2.7.2	Auto-WEKA	33
2.8	Considerações Finais do Capítulo	35
3	TRABALHOS RELACIONADOS	36
3.1	Soil water content measurement with a high-frequency capacitance sensor	36
3.2	Calibração de um sensor capacitivo para estimativa da umidade em três classes de solos	37
3.3	Effective calibration of low-cost soil water content sensors	37
3.4	Algoritmos para Autoajuste de Sensores Utilizando Redes Neurais	38
3.5	Self-calibration and optimal response in intelligent sensors design based on artificial neural networks	39
3.6	An artificial neural network approach to the estimation of stem water potential from frequency domain reflectometry soil moisture measurements and meteorological data	40

3.7	Calibration of Soil Water Content Data from EnviroSCAN System using Artificial Neural Network	41
3.8	Rapid measurement and control of the moisture content of compost using near-infrared spectroscopy	42
3.9	Low-cost automatic station for compost temperature monitoring . . .	43
3.10	Smart Compost Monitoring System using Open Source Technologies	44
3.11	Intelligent composting assisted by a wireless sensing network	44
3.12	Comparação entre os Trabalhos Relacionados	46
3.13	Considerações sobre o Capítulo	49
4	REALSENSE: CONCEPÇÃO DO NODO SENSOR	50
4.1	Visão Geral do Nodo Sensor	50
4.1.1	Módulo de Processamento e Comunicação Selecionado	51
4.1.2	Sensores Selecionados	52
4.1.3	Ambiente e Linguagem de Desenvolvimento do Nodo Sensor	54
4.1.4	Funcionalidades Concebidas para Nodo Sensor	54
4.2	Validação do Nodo Sensor	56
4.3	Considerações Finais do Capítulo	57
5	REALSENSE: CONCEPÇÃO DA ABORDAGEM DE AUTOAJUSTE	58
5.1	Metodologia Aplicada na Coleta e Preparação dos Dados	58
5.2	Avaliação de Técnicas para Autoajuste Utilizando Aprendizado de Máquina	61
5.2.1	Etapas da Avaliação de Técnicas de Aprendizado de Máquina Explorando o Auto-WEKA	62
5.2.2	Técnica de Aprendizado de Máquina Selecionada para o RealSense . .	63
5.3	Considerações Finais do Capítulo	64
6	ANÁLISE DOS RESULTADOS OBTIDOS	65
6.1	Implementação da Técnica de Aprendizado de Máquina Selecionada	65
6.2	Validação do RealSense e Resultados Comparativos	65
6.3	Considerações Finais do Capítulo	68
7	CONSIDERAÇÕES FINAIS	69
7.1	Principais Conclusões	69
7.2	Dataset Produzido no Desenvolvimento da Pesquisa	71
7.3	Trabalhos Futuros	71
	REFERÊNCIAS	73
	APÊNDICE A TABULAÇÃO DOS DADOS DO COMPOSTO 1	77
	APÊNDICE B TABULAÇÃO DOS DADOS DO COMPOSTO 2	78
	APÊNDICE C TABULAÇÃO DOS DADOS DO COMPOSTO 3	79

1 INTRODUÇÃO

A preocupação com o destino adequado dos resíduos sólidos orgânicos — originados de material animal ou vegetal — iniciou a partir da constatação que estes resíduos biológicos geravam um ambiente propício à proliferação de vetores e disseminação de doenças. A ênfase das preocupações, então, era dada à saúde pública.

A atenção na minimização do impacto ambiental com a correta destinação final dos resíduos, por sua vez, começou a ser foco das atenções de todo o mundo a partir da segunda metade do século XX, quando estudos apontaram problemas ambientais frequentes, como a poluição e contaminação da água e do solo em virtude da inadequada disposição de resíduos industriais que, por consequência, geram riscos à saúde e ao meio ambiente (PHILIPPI JR; ROMERO; BRUNA, 2014).

Existem também outros aspectos a serem levados em consideração a esta questão dos resíduos, em especial aos orgânicos, que hoje constituem cerca de 60% do resíduo brasileiro, sendo dispostos em sua grande maioria de forma inadequada, deixando de voltar ao ciclo produtivo através de adubo, possível a partir de processos de compostagem. Segundo o Banco Mundial, o Brasil é o quarto país do mundo em área agriculturável (WORLDBANK, 2016), e de acordo com a Associação Nacional para Difusão de Adubos, o país importou, em 2017, 26.305.488 toneladas de fertilizantes, o que representa US\$ 7,781 bilhões, com uma elevação de 20,17% frente ao ano anterior (ANDA, 2018).

A forte dependência das importações de fertilizantes e/ou matérias-primas destinadas à produção destes fertilizantes constitui, na atualidade, a principal fragilidade do agronegócio brasileiro (ESALQ/USP, 2018).

A degradação de matéria orgânica é influenciada pela aeração, nutrientes e umidade. A temperatura também tem relevância, influenciando na rapidez do processo de biodegradação e na eliminação de patógenos, consequentes da atividade biológica (FERNANDES; SILVA, 1999).

Neste sentido, denomina-se compostagem o processo controlado de decomposição microbiana, de oxidação e oxigenação de uma massa heterogênea de matéria orgânica no estado sólido e úmido (KIEHL, 2004 *apud* VALENTE *et al.*, 2009).

Do ponto de vista operacional, a preocupação central consiste em corrigir os teores limites (máximos e mínimos), ou seja, manter os parâmetros determinantes do sucesso da compostagem em uma faixa ideal de controle, de forma a não sacrificar a velocidade de degradação e a decorrente qualidade do produto final.

A água é fundamental para a vida microbiana, sendo o teor de umidade um dos principais parâmetros que devem ser monitorados durante a compostagem para que o processo se desenvolva satisfatoriamente (FERNANDES; SILVA, 1999).

Em seu trabalho, LÓPEZ *et al.* (2014) afirma que determinar os níveis de umidade em compostagem é mais desafiador do que no solo. As causas são:

- a) A faixa de níveis de umidade nas situações de compostagem é muito mais ampla do que nos solos;
- b) As condições dentro de uma leira de compostagem variam muito de um local para o outro;
- c) A umidade retida por materiais orgânicos é difícil de detectar devido ao arranjo complexo dos poros.

Foram encontrados na literatura estudos direcionados ao monitoramento da umidade de diferentes tipos de solos que utilizam formas não destrutivas, de resposta rápida e de boa precisão, como sensores capacitivos que, contudo, necessitam de calibração para cada tipo de solo. Como exemplo pode-se citar os trabalhos de GARDNER; DEAN; COOPER (1998), GEESING; BACHMAIER; SCHMIDHALTER (2004), MENDES (2006), GUIMARÃES *et al.* (2010), CRUZ *et al.* (2010), FREITAS (2014), PIZETTA *et al.* (2017) e BOGENA *et al.* (2017).

Estes aspectos constituem a motivação central deste trabalho, tendo em vista a importância social, econômica e ambiental da compostagem para a sociedade.

1.1 Objetivos

O objetivo geral desta dissertação consiste na concepção de uma proposta de *hardware* e *software*, denominada RealSense, que permita o autoajuste do sensor a ser utilizado na medição do teor de umidade em compostagens.

Como objetivos específicos destacam-se:

- criação de um modelo, a partir da avaliação do emprego de um algoritmo de aprendizagem de máquina, onde espera-se encontrar um equilíbrio entre as leituras de um sensor capacitivo ao longo do processo de compostagem, permitindo que um mesmo sensor possa ser empregado, não só durante os ciclos de uma leira, mas como entre leiras de diferentes composições, sem necessidade de calibração específica em laboratório;

- concepção de um *hardware* para monitoramento de temperatura e umidade, adequado ao processo associado à produção de compostagem;
- facilitar a gestão do processo de compostagem, evitando a necessidade de enviar amostras para determinar o teor de umidade em laboratório;
- compartilhar a base de dados produzida durante os esforços de estudo e pesquisa da dissertação, promovendo a realização de outros trabalhos nesta área, entendida como estratégica na atualidade;
- divulgar o trabalho realizado junto à comunidade científica pela publicação em eventos e/ou revistas da área.

Na perspectiva de uma contribuição acadêmica, é importante registrar que foram encontrados na literatura alguns trabalhos que visam automatizar o controle dos parâmetros da compostagem, como nos trabalhos de LÓPEZ *et al.* (2014), JORDÃO *et al.* (2017) e VRETTOS; KAZAMIAS; LEKKAS (2017), que dão ênfase ao monitoramento da temperatura, percebendo-se com isso a carência de pesquisas no que tange ao monitoramento do teor de umidade da compostagem através de sensores.

Em uma perspectiva de contribuição à sociedade, espera-se prover condições para um controle mais eficiente das proporções do resíduo e dos materiais aeradores, propiciando uma melhor atividade para os organismos microscópicos que ajudam na decomposição, gerando um adubo mais adequado.

1.2 Organização do Texto

O capítulo 1 introduz o problema do monitoramento do teor de umidade na compostagem de resíduos orgânicos, elucidando as principais dificuldades e objetivos, contextualizando, assim, o problema tratado neste trabalho.

O capítulo 2 apresenta métodos utilizados na determinação da umidade, aspectos gerais do aprendizado de máquina, introdução ao *software* Weka, e concebe uma visão geral das abordagens propostas para autoajuste de sensores capacitivos e a aplicação de aprendizado de máquina nesta tarefa. Inclui também um breve resumo sobre redes neurais artificiais.

No capítulo 3 faz-se um levantamento das soluções adotadas na tentativa de resolver o problema de calibração dos sensores, considerando tanto aplicações no solo quanto em pilhas de compostagem.

Na sequência, o capítulo 4 traz uma visão geral da concepção do Nodo Sensor e da validação das principais funcionalidades, abordando *hardware* e *software*.

O capítulo 5 por sua vez discorre sobre a concepção da abordagem de autoajuste, a definição da metodologia aplicada na coleta dos dados e a avaliação de técnicas de aprendizagem de máquina.

O capítulo 6 apresenta uma análise dos resultados obtidos com o RealSense.

E por fim, no capítulo 7 estão sumarizadas as principais conclusões obtidas durante a concepção do RealSense. É também dado destaque à disponibilização do *dataset* produzido por consequência dos trabalhos de campo realizados, bem como são elencados os trabalhos futuros entendidos como prioritários para o avanço das pesquisas relacionadas ao RealSense.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são introduzidos tópicos de estudo e pesquisa relevantes para o desenvolvimento desta dissertação, apresentando métodos utilizados na determinação da umidade e discutindo aspectos gerais do aprendizado de máquina. É realizada, então, uma introdução ao *software Weka*, e apresentada uma visão geral das abordagens propostas para autoajuste de sensores capacitivos, além da exploração de aprendizado de máquina nesta tarefa. Também é apresentado, resumidamente, o estudo realizado sobre redes neurais artificiais.

2.1 Importância do Controle da Umidade na Compostagem

KIEHL (2004) *apud* VALENTE *et al.* (2009) afirma que a compostagem é um processo controlado de decomposição microbiana, através da oxidação e oxigenação de uma massa heterogênea de matéria orgânica no estado sólido e úmido. Ela compreende uma fase inicial rápida mesofílica, que se caracteriza por células microbianas em estado de latência, porém com uma intensa atividade metabólica, apresentando uma elevada síntese de DNA de enzimas. Posteriormente, ocorre uma fase de bioestabilização, para finalmente atingir a terceira fase, onde ocorre a humificação ou maturação, acompanhada da mineralização de determinados componentes da matéria orgânica, como nitrogênio, fósforo, cálcio e magnésio, que passam da forma orgânica para a inorgânica, ficando disponíveis às plantas.

Por ser um processo biológico, os fatores mais importantes que influem na degradação da matéria orgânica são a aeração, os nutrientes e a umidade. A temperatura também é um fator importante, principalmente no que diz respeito à rapidez do processo de biodegradação e à eliminação de patógenos, que é consequência da atividade biológica (FERNANDES; SILVA, 1999).

Sabe-se que a água é fundamental para a vida microbiana, e o teor ótimo de umidade para que o processo de compostagem se desenvolva de forma satisfatória, está entre 50 e 60% (FERNANDES; SILVA, 1999).

O ajuste da umidade pode ser feito pela criteriosa mistura de componentes ou pela

adição de água. Na prática, se verifica que o teor de umidade depende também da eficácia da aeração e das características físicas dos resíduos (estrutura, porosidade). Elevados teores de umidade (>65%) fazem com que a água ocupe os espaços vazios do meio, impedindo a livre passagem do oxigênio. Se o teor de umidade de uma mistura é inferior a 40%, a atividade biológica é inibida (FERNANDES; SILVA, 1999).

Do ponto de vista operacional, a preocupação básica consiste em corrigir os teores limites (máximos e mínimos), ou seja, manter os parâmetros determinantes do sucesso da compostagem em uma faixa ideal de controle, de forma a não sacrificar a velocidade de degradação e a qualidade do produto final (FERNANDES; SILVA, 1999).

Em uma pesquisa de 2010 com empresas europeias, em sua maioria com poucos funcionários (58% com menos de 5 funcionários e mais de 90% com menos de 30), LÓPEZ *et al.* (2014) identificou que a maioria dos compostores (73%) atende o mercado agrícola. Quanto às condições de medição, 90% medem a temperatura do composto, mas quase a metade faz manualmente. As medições são feitas em uma posição da pilha e no máximo em três profundidades diferentes. Para 70% dos entrevistados, uma frequência de medição de temperatura de 1 por hora ou menos é suficiente. Aqueles que medem com mais frequência, fazem isso porque já possuem sistemas automatizados de medição de temperatura. Apenas 43% das plantas realizam medições regulares de umidade e a frequência de medição é tipicamente entre uma vez por dia e uma vez por semana.

LÓPEZ *et al.* (2014) salienta ainda que, quando perguntados sobre como eles melhorariam as medições de temperatura e umidade, as respostas foram focadas na melhoria das medições automatizadas, no local, em vários pontos de pilha e no aumento de frequência de medição.

Com relação a visão futura, LÓPEZ *et al.* (2014) identificou que mais de 80% dos compostores esperam melhorar a qualidade de seus produtos através de um melhor monitoramento da temperatura e umidade (principalmente para otimizar a aeração/viragem e certificar o produto final). A grande maioria indicou que estaria disposta a investir nos próximos cinco anos pelo menos €10.000,00 na modernização das suas instalações (42% indicaram um investimento esperado superior a €100.000,00 no mesmo período).

2.2 Métodos de Determinação da Umidade em Compostagem

A revisão de literatura apontou dois tipos principais de métodos para determinação da umidade em compostagem, cada um com suas características de precisão e/ou facilidade de uso.

2.2.1 Métodos Diretos de Determinação da Umidade

Dentre os diversos métodos existentes para determinar o teor de umidade em compostagem, os mais frequentemente utilizados são o método estufa ou gravimétrico — considerado padrão — e o teste de mão.

Gravimetria

O método padrão de estufa, ou gravimétrico, consiste em colocar amostras em placas de petri (recipiente cilíndrico, achatado, de vidro ou plástico, utilizado por profissionais de laboratório) em alíquotas de 10-30g. Cada amostra é pesada e procede-se com a anotação do peso individual. Após isso, a mesma é colocada para secar em estufa a 105°C por 24 horas. Posteriormente as amostras são colocadas para resfriar em dessecador até atingir temperatura ambiente, para posterior pesagem em balança analítica (precisão 0,0001) (CORRÊA; CORRÊA; PAZ, 2018). A necessidade de secar a amostra no forno torna este método pouco prático e inviável de se fazer no campo, sendo conhecido como um método laboratorial e, conseqüentemente, de resposta lenta.

Teste de Mão

O teste de mão consiste basicamente em pegar com a mão um pouco de material do interior da leira e comprimi-lo com bastante força, conforme Figura 1. O ponto ideal da umidade é quando a água começa a verter entre os dedos, sem escorrer (NUNES, 2009).



Figura 1 – Teste de mão - Fonte: (NUNES, 2009)

2.2.2 Métodos Indiretos de Determinação da Umidade

Métodos indiretos inferem o teor de água a partir da medição da variação de propriedades químicas ou físicas do solo. Existem vários métodos indiretos possíveis, cada qual com suas dificuldades e limitações. Algumas medições são mais qualitativas do

que quantitativas e requerem calibração e bom conhecimento do tipo de solo e condições locais. A molécula da água possui uma permissividade elétrica relativamente alta se comparada com a maioria dos componentes do solo e, portanto, mudanças na quantidade podem ser devidamente medidas (JOHNSON, 2007).

Dentre os diversos métodos não destrutivos verificou-se que o sensor capacitivo de umidade do solo seria o mais indicado para este trabalho, visto que é amplamente utilizado em pesquisas, tem baixo custo e pode ser facilmente encontrado no comércio brasileiro.

O sensor capacitivo monitora o teor de água do solo com base na variação do dielétrico. Seu princípio de funcionamento tem comportamento similar a um capacitor de placas planas, portanto um campo elétrico é formado entre suas placas. Tal campo é alterado quando um material é inserido entre as placas, causando uma variação nas características capacitivas do conjunto, mantendo-se enquanto esse material permanecer dentro do campo. O material que preenche o espaço entre as placas de um capacitor é chamado de dielétrico e varia de acordo com sua composição (Tabela 1).

A desvantagem na utilização de sondas dielétricas consiste na necessidade de calibração individual para garantir medições precisas do teor de água no solo (KIZITO *et al.*, 2008).

Tabela 1 – Propriedades físicas de alguns materiais - Adaptado de (ANNAN, 2001)

Material	Constante Dielétrica
Ar	1
Água Destilada	80
Água Doce	80
Areia Seca	3.0 - 5.0
Areia Saturada	20 - 30
Calcário	4.0 - 8.0
Folhelho	5.0 - 15.0
Argila	5.0 - 40.0
Granito	4.0 - 6.0

O arranjo das sondas varia de sensor para sensor (Figura 2) e pode ser isolado do solo por um tubo de acesso ou por revestimento dielétrico, dependendo das exigências do circuito de medição (JOHNSON *et al.*, 2006).

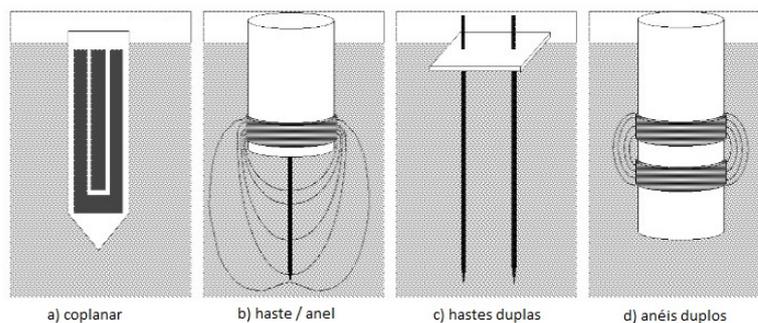


Figura 2 – Tipos de sondas - Fonte: Adaptado de (JOHNSON *et al.*, 2006)

2.3 Métodos de Calibração de Sensores Capacitivos

Sensores capacitivos costumam ser vendidos, calibrados de fábrica, para medir a umidade relativa do ar. Estudos demonstram que, para serem efetivos na medição da umidade do solo, os sensores capacitivos necessitam de calibração exclusiva de acordo com as diferentes características físico-química de cada solo.

O método comumente encontrado na literatura para a devida calibração é a aplicação de análises estatísticas de regressão, buscando o melhor coeficiente de determinação (R^2) a partir da relação entre a umidade real e a medição do sensor. Uma vez obtidos os dados do sensor e os de referência, o segundo normalmente através da gravimetria, é gerado um diagrama de dispersão e ajustada uma reta de regressão, com uma equação que pode ser utilizada para estimar valores de umidade do solo a partir dos valores medidos pelo sensor. Este método utilizado para encontrar a equação é chamado de Análise de regressão. Como explica FRANK (2015), a análise da regressão é uma metodologia estatística que utiliza a relação entre duas ou mais variáveis quantitativas (ou qualitativas) de tal forma que uma variável pode ser predita a partir da outra.

A correlação ou o coeficiente de correlação mede a tendência de duas variáveis mudarem em função de seu relacionamento. Esse coeficiente atribui valores entre -1 e 1 para determinar o grau de correlação. Quando encontramos números próximos a 1 a correlação é considerada positiva, e quando encontramos números próximos a -1 a correlação é dita negativa. Quanto mais próximo dos extremos maior o grau de correlação e quanto mais próximo a zero menor o grau de correlação. Valores entre 0.7 a 0.9, positivos ou negativos, indicam uma correlação forte, já valores acima de 0.9, positivos ou negativos, indicam uma correlação muito forte (BOSLAUGH; WATTERS, 2008).

Neste trabalho usaremos o coeficiente de correlação como métrica do grau de aproximação entre os valores previstos e os valores observados no conjunto de testes.

Atualmente, existem dois métodos para calibrar esses sensores dielétricos. O primeiro método relaciona o sinal de saída (OS) diretamente aos valores volumétricos de

conteúdo de água. O segundo método é um procedimento em duas etapas, conforme empregado por BOGENA *et al.* (2017). Neste método, o sinal de saída é primeiramente relacionado à permissividade relativa aparente K_a , utilizando soluções padrão com permissividade relativa conhecida. K_a é então relacionada ao teor volumétrico da água.

2.4 Autoajuste de Sensores

OLIVEIRA; AMARAL; AMARAL (2009) afirmam que o avanço da microeletrônica permitiu o desenvolvimento de sensores inteligentes, isto é, sensores com microcontroladores ou microprocessadores embarcados dotados de *softwares* específicos que são capazes de executar uma grande variedade de funções.

Uma das funções mais úteis que pode ser agregada a um sensor inteligente é a de minimizar os erros sistemáticos de medição sem ajuda de nenhum dispositivo externo. A linearização do sinal de saída dos sensores e o processo de calibração são os principais itens envolvidos na definição dos recursos de um sensor inteligente; como exemplo podemos citar a capacidade de ser usado ou aplicado a diferentes variáveis (RIVERA *et al.*, 2007). Logo, é possível concluir que a capacidade de autoajuste em um sensor é uma característica fundamental, pois facilita a manutenção do seu estado metrológico.

A pesquisa de OLIVEIRA; AMARAL; AMARAL (2009) mostrou várias possibilidades de uso de rede neurais artificiais em sensores como: Predição da deriva (variação dos erros sistemáticos ao longo do tempo) de instrumentos entre calibrações utilizando redes neurais para previsão de séries temporais, técnicas de autoajuste (*self-calibration*), detecção de falhas, monitoramento e verificação de calibração, linearização de características de um transdutor ou compensação dos distúrbios causados por outras grandezas de influência.

2.5 Aprendizado de Máquina

Aprendizado de máquina é uma subárea da IA (Inteligência Artificial), e pode ser interpretado como sendo a aquisição de descrições estruturais a partir de exemplos, podendo prever o que acontecerá em novas situações a partir de dados que descrevem o que aconteceu no passado. Essa descrição estrutural suporta explicação, entendimento e previsão (WITTEN *et al.*, 2016).

O paradigma do aprendizado de máquina pode ser visto como "programação por exemplo", e embora seja uma subárea da IA, o aprendizado de máquina também se cruza amplamente com outros campos, especialmente a estatística (SINGH, 2019). Um dos objetivos é generalizar a partir de suas experiências. Generalizar, neste caso,

seria a habilidade de prever novos exemplos depois de ter experimentado um conjunto de dados de aprendizado.

2.5.1 Tipos de Aprendizagem

Problemas de reconhecimento de padrões, nos quais os dados de treinamento compõem exemplos de entradas juntamente com os valores de saída esperados, são conhecidos como problemas de aprendizado supervisionado. Em outros problemas, os dados de treinamento consistem em entradas sem o valor correspondente de saída, e o objetivo deste tipo de aprendizado não supervisionado é descobrir grupos de dados semelhantes. Existe ainda o aprendizado por reforço, que busca otimizar a assertividade de um agente com base em *feedbacks* que ele recebe do meio onde está inserido. O algoritmo de aprendizado não recebe exemplos de resultados ideais, em contraste com o aprendizado supervisionado, mas deve descobri-los por um processo de tentativa e erro (BISHOP, 2006).

2.5.2 Categorização de Acordo com a Saída

Conforme Russell, Stuart J.; Norvig (2013), o aprendizado de máquina apresenta também outra categorização quando se considera a saída y desejada:

- a) Quando y for de um conjunto finito de valores (como ensolarado, nublado ou chuvoso), o problema da aprendizagem será chamado de classificação;
- b) Se houver apenas dois valores, será chamado de classificação booleana ou binária;
- c) Quando a saída for um número (como temperatura ou umidade), o problema de aprendizagem é chamado de regressão (tecnicamente, a solução de um problema de regressão é encontrar uma expectativa condicional ou valor médio de y porque a probabilidade de acharmos exatamente o número de valor real certo para y é 0).

2.5.3 Seleção de Atributos

Adicionar atributos irrelevantes em um conjunto de dados geralmente "confunde" os sistemas de aprendizado de máquina (WITTEN *et al.*, 2016). Em várias situações, existem muitos atributos para os esquemas de aprendizado, e alguns deles são claramente irrelevantes ou redundantes. Os dados precisam ser pré-processados para selecionar um subconjunto dos atributos a serem utilizados no aprendizado. Os próprios métodos de aprendizado tentam selecionar os atributos adequadamente e ignoram os irrelevantes ou redundantes, mas, na prática, seu desempenho pode frequentemente ser aprimorado mediante uma pré-seleção. Experimentos mostram que

a adição de atributos inúteis faz com que o desempenho de esquemas de aprendizagem se deteriore (WITTEN *et al.*, 2016).

Ao selecionar um bom subconjunto de atributos, há duas abordagens diferentes. Uma é fazer uma avaliação independente com base nas características gerais dos dados; a outra é avaliar o subconjunto usando o algoritmo de aprendizado de máquina que acabará sendo empregado para o aprendizado. O primeiro é chamado de método de filtro, porque o conjunto de atributos é filtrado para produzir o subconjunto mais promissor antes que o aprendizado comece. O segundo é o método *wrapper*, porque o algoritmo de aprendizado é envolvido no procedimento de seleção (WITTEN *et al.*, 2016).

2.6 Redes Neurais Artificiais

Muitos dos trabalhos encontrados na literatura que buscam o autoajuste de sensores, e que serviram de base para esta pesquisa, apresentaram como solução a técnica estatística de regressão ou foram baseados na aplicação de redes neurais artificiais.

De acordo com HAYKIN (2011), uma rede neural é um processador paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos: o conhecimento é adquirido pela rede a partir do seu ambiente, através de um processo de aprendizagem, e as forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Para BRAGA; CARVALHO; LUDEMIR (2007), RNAs (Redes Neurais Artificiais) são sistemas paralelos e distribuídos (Perceptron), compostos por unidades de processamento simples (nodos) que calculam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede. Características como a capacidade de aprender, generalizar a informação aprendida, auto-organização e processamento temporal, fazem das RNAs uma ferramenta computacional extremamente poderosa e atrativa para solução de problemas complexos.

O procedimento usual na solução de problemas passa inicialmente por uma fase de aprendizagem, em que um conjunto de exemplos é apresentado para a rede, a qual extrai automaticamente as características necessárias para representar a informação fornecida, aprende com essas informações e posteriormente sugere um resultado. Ainda segundo BRAGA; CARVALHO; LUDEMIR (2007), as RNAs são capazes

de atuar como mapeadores universais de funções multivariáveis, com custo computacional que cresce apenas linearmente com o número de variáveis. A capacidade da RNA de reconhecer padrões não apresentados após o período de treinamento é denominada de generalização.

2.6.1 Modelo de Neurônio Artificial

HAYKIN (2011) define neurônio como uma unidade de processamento de informação que é fundamental para a operação de uma rede neural. A descrição matemática do modelo de neurônio¹ resultou em um modelo com n terminais de entrada x_1, x_2, \dots, x_n (que representam os dendritos) e apenas um terminal de saída y (representando o axônio). Para emular o comportamento das sinapses, os terminais de entrada do neurônio têm pesos acoplados w_1, w_2, \dots, w_n , cujos valores podem ser positivos ou negativos. O efeito de uma sinapse particular i no neurônio é dado por $x_i w_i$. Os pesos determinam em que grau o neurônio deve considerar sinais de disparo naquela conexão. O diagrama de blocos da Figura 3 mostra o modelo de um neurônio que forma a base para o projeto de redes neurais artificiais.

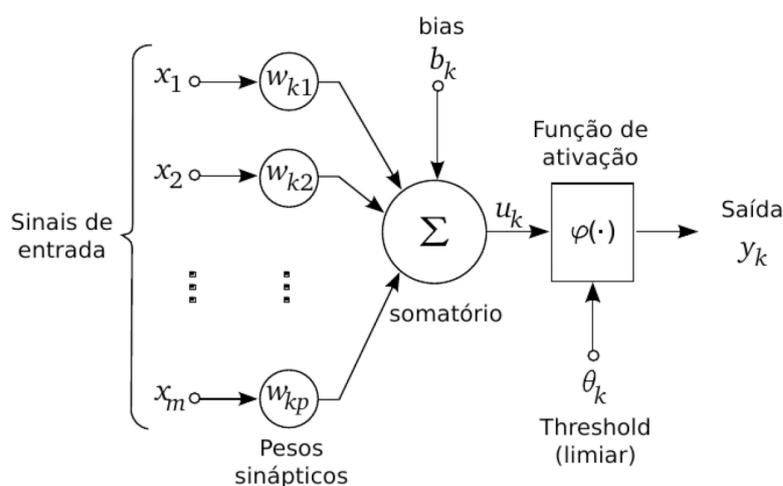


Figura 3 – Modelo não-linear de um neurônio artificial - Fonte: baseado em (HAYKIN, 2011)

Neste modelo (Figura 3) identificamos três elementos básicos:

- Conjunto de *sinapses ou elos de ligação*: cada uma caracterizada por peso ou força própria. Um sinal x_i na entrada da sinapse j conectada ao neurônio k é multiplicada pelo peso sináptico w_{kj} . O peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores positivos ou negativos. As operações descritas aqui constituem um *combinador linear*;
- Somador*: para efetuar a soma ponderada dos sinais de entrada;

¹Originalmente proposto por McCulloch e Pitts em 1943 (BRAGA; CARVALHO; LUDEMIR, 2007).

c) *Função de ativação*: Limita o intervalo permissível de amplitude do sinal de saída a um valor finito. O intervalo normalizado da amplitude de saída é escrito como o intervalo unitário fechado $[0,1]$ ou alternativamente $[-1,1]$.

O modelo apresentado na Figura 3 apresenta ainda um *bias* aplicado externamente, representado por b_k . O *bias* tem a função de aumentar, se positivo, ou diminuir, se negativo, a entrada líquida da função de ativação.

Em termos matemáticos, um neurônio k é descrito pelo par de equações 1 e 2:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$

$$y_k = \varphi(u_k + b_k) \quad (2)$$

onde x_1, x_2, \dots, x_n são os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{kn}$ são os pesos sinápticos do neurônio k ; u_k é a saída do combinador linear devido aos sinais de entrada; b_k é o *bias*; φ é a função de ativação; e y_k é o sinal de saída do neurônio. O uso do *bias* b_k tem o efeito de aplicar uma *transformação afim* à saída u_k do combinador linear na Figura 3, como mostrado por:

$$v_k = u_k + b_k \quad (3)$$

Na Figura 4, o efeito do *bias* é levado em conta de duas maneiras: (1) adicionando-se um novo sinal de entrada fixo em $+1$ e (2) adicionando-se um novo peso sináptico igual ao *bias* b_k .

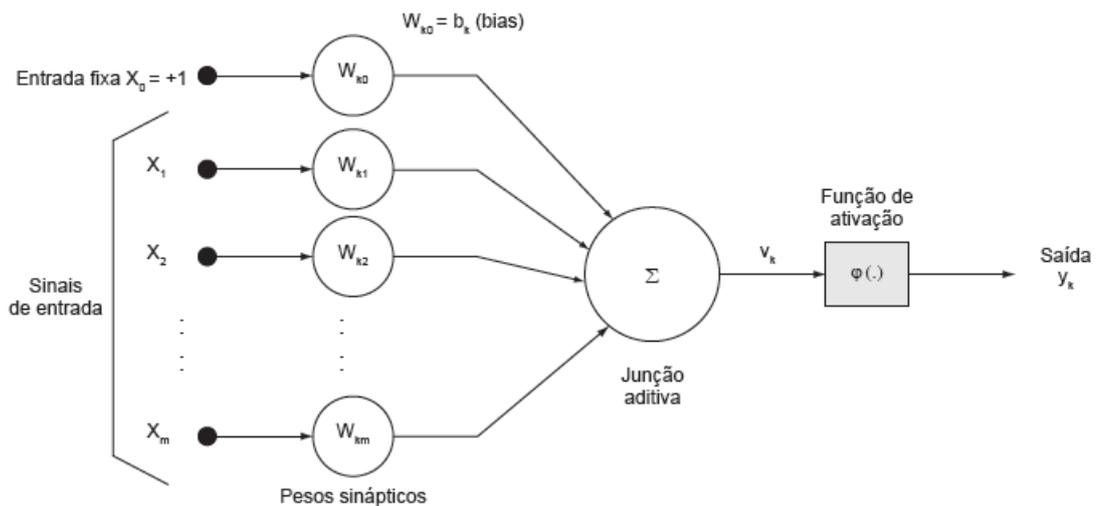


Figura 4 – Outro modelo não-linear de um neurônio artificial - Fonte: baseado em (HAYKIN, 2011)

2.6.2 Função de Ativação Sigmóide

Segundo HAYKIN (2011), a função Sigmóide é a forma mais comum de função de ativação utilizada na construção de RNAs. Seu gráfico tem a forma de S (Figura 5)

e é descrito como uma função estritamente crescente que exibe um balanceamento adequado entre o comportamento linear e não-linear.

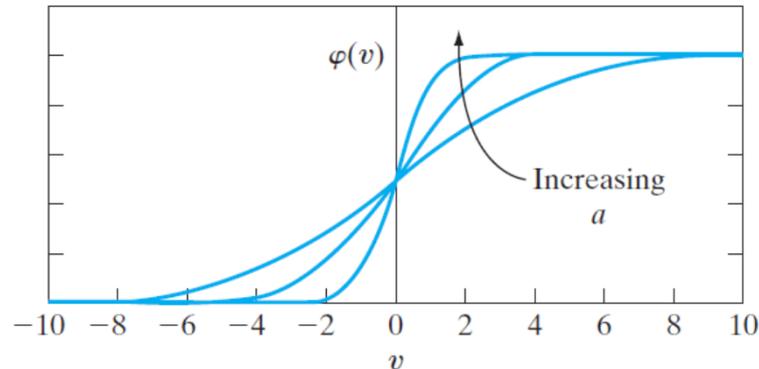


Figura 5 – Função sigmóide - Fonte: (HAYKIN, 2011)

Um bom exemplo de função sigmóide é a função logística, matematicamente representada pela equação 4, onde a é o parâmetro de inclinação da função sigmóide. Variando-se o parâmetro a , obtemos funções sigmóides com diferentes inclinações.

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (4)$$

A função de ativação definida na equação 4 se estende no intervalo de 0 a +1, porém ela também pode se estender de -1 a +1, tornando-se assim antissimétrica em relação a origem. A equação 5 é chamada de função sinal.

$$\varphi(v) = \left\{ \begin{array}{ll} 1 & \text{se } v > 0 \\ 0 & \text{se } v = 0 \\ -1 & \text{se } v < 0 \end{array} \right\} \quad (5)$$

Para a forma correspondente de uma função sigmóide, pode-se utilizar a função tangente hiperbólica, descrita pela equação 6.

$$\varphi(v) = \tanh(v) \quad (6)$$

2.6.3 Principais Arquiteturas de RNAs

Segundo BRAGA; CARVALHO; LUDEMIR (2007), a definição da arquitetura de uma RNA é um parâmetro importante na sua concepção, uma vez que ela restringe o tipo de problema que pode ser tratado pela rede. Redes com uma camada única de nodos, por exemplo, só conseguem resolver problemas linearmente separáveis. Redes recorrentes, por sua vez, são mais apropriadas para resolver problemas que envolvem processamento temporal. Fazem parte da definição da arquitetura os seguintes parâmetros: número de camadas da rede, número de nodos em cada camada, tipo de

conexão entre os nodos e topologia da rede.

a) Quanto ao número de camadas

- (a) Redes de camada única: só existe um nó entre qualquer entrada e qualquer saída;
- (b) Redes de múltiplas camadas: existe mais de um neurônio entre alguma entrada e alguma saída.

b) Quanto ao tipo de conexão

- (a) *Feedforward*, ou acíclica: a saída de um neurônio na i -ésima camada de rede não pode ser usada como entrada de nodos de camadas de índice menor ou igual a i ;
- (b) *Feedback*, ou cíclica: a saída de algum neurônio na i -ésima camada de rede é usada como entrada de nodos em camadas de índice menor ou igual a i . Redes cuja saída final (única) é ligada às entradas comportam-se como autômatos reconhedores de cadeias, onde a saída que é realimentada fornece o estado do autômato. Se todas as ligações são cíclicas, a rede é denominada autoassociativa. Estas redes associam um padrão de entrada com ele mesmo, e são particularmente úteis para recuperação ou "regeneração" de um padrão de entrada.

c) Quanto à conectividade

- (a) Rede fracamente ou parcialmente conectada;
- (b) Rede completamente conectada.

2.6.4 Perceptron de Múltiplas Camadas

HAYKIN (2011) expõe que redes com uma única camada de nós conseguem resolver problemas linearmente separáveis. Já as redes com mais de uma camada podem resolver problemas não-linearmente separáveis (Figura 6).

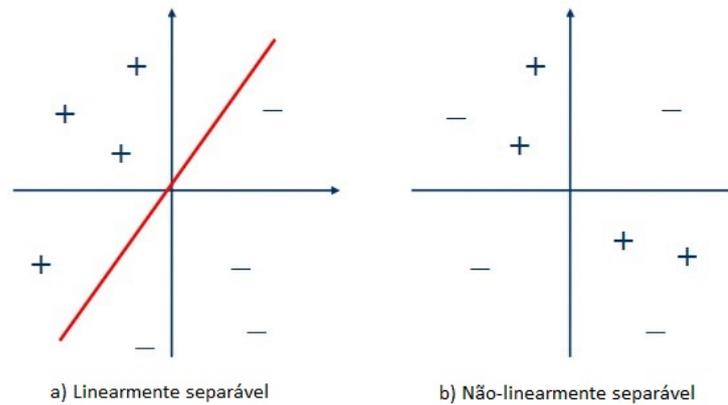


Figura 6 – Problema de separação linear e não-linear - Fonte: Elaborada pelo autor

MLP (*multilayer perceptron*) ou *perceptrons de múltiplas camadas*, consiste de um conjunto de unidades sensoriais que constituem a *camada de entrada*, uma ou mais *camadas ocultas* e uma *camada de saída* (Figura 7). Uma rede de uma camada intermediária pode implementar qualquer função contínua, com duas camadas intermediárias, permitindo a aproximação de qualquer função. A MLP tem sido aplicada com sucesso para resolver diversos problemas difíceis através de treinamento com um algoritmo conhecido como algoritmo de retropropagação de erro (*error back-propagation*) (HAYKIN, 2011).

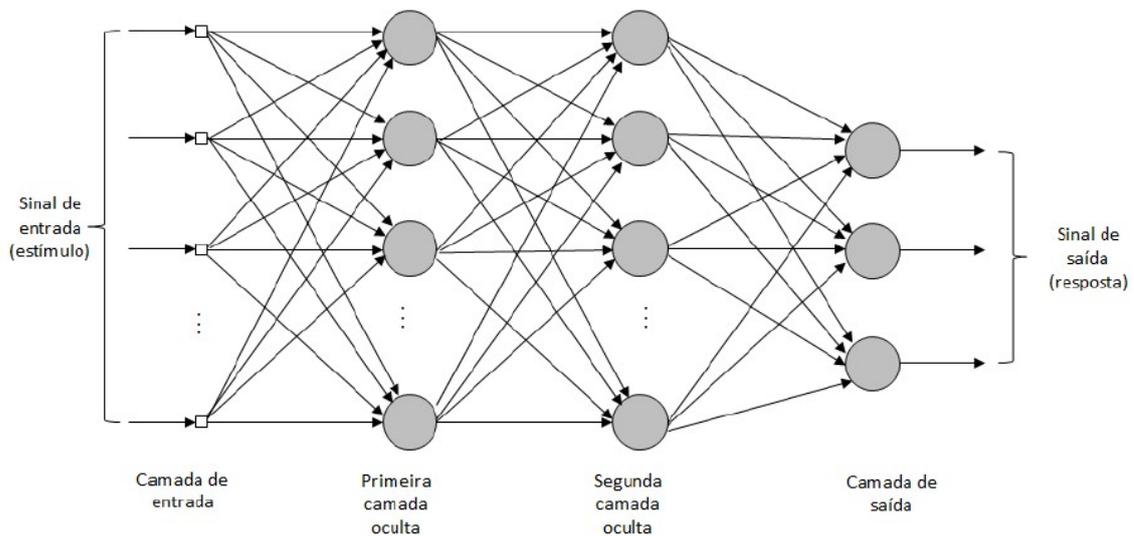


Figura 7 – Arquitetura de uma MLP com duas camadas ocultas - Fonte: baseado em (HAYKIN, 2011)

Este tipo de treinamento é composto basicamente por dois passos:

- a) A propagação consiste em aplicar um vetor de entrada à camada de entrada, sendo propagado pela rede até gerar uma saída. A saída ideal é subtraída da

saída real, gerando um sinal de erro. Os pesos sinápticos se mantêm fixos nesta etapa;

- b) A retropropagação consiste em propagar o sinal de erro no sentido contrário das conexões sinápticas, ajustando os pesos sinápticos para que a saída real seja mais próxima da saída desejada.

O algoritmo para treinar os neurônios em uma rede multicamadas é um tanto complexo e difícil de visualizar. Para exemplificar matematicamente o algoritmo de treinamento deve-se observar se o neurônio em questão está na camada oculta ou se está na camada de saída. As amostras podem ser apresentadas à rede neural artificial de duas formas:

- Sequencial: é fornecida uma amostra à rede e, após os passos de propagação e retropropagação, os pesos são alterados e assim sucessivamente a cada nova amostra de dados;
- Por lote: é apresentado um conjunto de dados e os pesos são ajustados somente após todos os dados serem apresentados à rede.

2.7 Software Weka

Segundo WITTEN *et al.* (2016), a experiência mostra que nenhum esquema de aprendizado de máquina é adequado a todos os problemas de mineração de dados. O *software* Weka (Waikato Environment for Knowledge Analysis) foi projetado para que se possa testar rapidamente os métodos existentes em novos conjuntos de dados de maneira flexível.

2.7.1 Framework Central

O Weka fornece amplo suporte para todo o processo de mineração de dados, incluindo a preparação dos dados de entrada, a avaliação estatística dos esquemas de aprendizado e a visualização dos dados de entrada e do resultado do aprendizado.

Além de uma ampla variedade de algoritmos de aprendizado, inclui diversas ferramentas de pré-processamento. Esse *kit* de ferramentas diversificado e abrangente é acessado por meio de uma interface comum, para que seus usuários possam comparar diferentes métodos e identificar os mais adequados para o problema em questão.

O Weka, desenvolvido na Universidade de Waikato, na Nova Zelândia, foi escrito em linguagem Java e distribuído sob os termos da GNU General Public License. Ele roda em praticamente qualquer plataforma e foi testado nos sistemas operacionais Linux, Windows e Macintosh. Ele fornece uma interface uniforme para muitos algoritmos de aprendizado diferentes, juntamente com métodos para pré e pós-processamento

e para avaliar o resultado dos esquemas de aprendizado em qualquer conjunto de dados (WITTEN *et al.*, 2016).

Neste trabalho foi utilizada a versão 3.9.3 do Weka.

2.7.2 Auto-WEKA

Existem muitos algoritmos diferentes de aprendizado de máquina. Levando-se em consideração os parâmetros de cada um, chegamos a um número incrivelmente grande de alternativas possíveis (KOTTHOFF *et al.*, 2017).

O Auto-WEKA se propõe a automatizar a tarefa de seleção do algoritmo de aprendizado e de definição de seus parâmetros, ajudando os usuários a identificarem com maior eficiência os algoritmos de aprendizado de máquina e as configurações dos parâmetros apropriados para suas aplicações, obtendo assim o melhor desempenho.

Na Figura 8 são apresentados todos os algoritmos de aprendizado suportados pelo Auto-WEKA e os seletores de recursos — também conhecidos como seletores de atributos — com o número de hiperparâmetros.

Base Learners			
BayesNet	2	NaiveBayes	2
DecisionStump*	0	NaiveBayesMultinomial	0
DecisionTable*	4	OneR	1
GaussianProcesses*	10	PART	4
IBk*	5	RandomForest	7
J48	9	RandomTree*	11
JRip	4	REPTree*	6
KStar*	3	SGD*	5
LinearRegression*	3	SimpleLinearRegression*	0
LMT	9	SimpleLogistic	5
Logistic	1	SMO	11
M5P	4	SMOreg*	13
M5Rules	4	VotedPerceptron	3
MultilayerPerceptron*	8	ZeroR*	0
Ensemble Methods			
Stacking	2	Vote	2
Meta-Methods			
LWL	5	Bagging	4
AdaBoostM1	6	RandomCommittee	2
AdditiveRegression	4	RandomSubSpace	3
AttributeSelectedClassifier	2		
Feature Selection Methods			
BestFirst	2	GreedyStepwise	4

Figura 8 – Algoritmos de aprendizagem e métodos suportados pelo Auto-WEKA, juntamente com o número de hiperparâmetros. Todos apoiam a classificação; aqueles marcados com asterisco também suportam regressão - Fonte: (KOTTHOFF *et al.*, 2017)

Nem todos os algoritmos são aplicáveis a todos os conjuntos de dados (por exemplo, devido à incapacidade de um classificador em lidar com dados ausentes). Para um determinado conjunto de dados, a implementação do Auto-WEKA considera automaticamente apenas o subconjunto de algoritmos aplicáveis. A seleção de recursos é executada como uma fase de pré-processamento antes de criar qualquer modelo.

2.8 Considerações Finais do Capítulo

Como pode ser observado pelas diferentes áreas de conhecimento abordadas neste capítulo, a concepção do RealSense constitui um esforço multidisciplinar, que conta com a agregação de várias especificidades da área de computação, as quais de forma sinérgica são associadas a esforços de estudo relacionados às áreas eletrônica e ambiental.

No próximo capítulo são discutidos trabalhos relacionados ao RealSense, sendo sumarizadas suas perspectivas de pesquisa e funcionalidades.

3 TRABALHOS RELACIONADOS

Diversos esforços têm sido empregados ao longo do tempo em estudos de aplicação de aprendizado de máquina no autoajuste de sensores. A grande maioria dos estudos encontrados na literatura se debruça sobre sensores de temperatura. Os trabalhos encontrados que tratam de sensores de umidade do solo focam na busca de soluções de calibração em diferentes níveis de profundidade, não em solos de composição diferentes — o que seria mais próximo a este estudo, que busca calibrar um sensor capacitivo de umidade a diferentes tipos de compostos.

Neste capítulo é apresentado um levantamento das soluções adotadas na tentativa de resolver o problema de calibração de sensores, considerando tanto aplicações no solo quanto em pilhas de compostagem. Segundo o que foi encontrado na literatura, a maior parte dos trabalhos de calibração de sensores de umidade apresentam aplicação da técnica estatística de regressão, sendo que os trabalhos que utilizaram aprendizado de máquina na calibração foram baseados na aplicação de redes neurais artificiais.

Todos os trabalhos relacionados contribuíram de maneira significativa para esta pesquisa, sendo que alguns mereceram maior destaque por fornecerem informações mais conclusivas e/ou abordarem aprendizagem de máquina, característica que os aproxima mais deste estudo.

3.1 Soil water content measurement with a high-frequency capacitance sensor

No trabalho de GARDNER; DEAN; COOPER (1998) foi utilizada uma sonda de capacitância manual com duas hastes paralelas de aço inoxidável de 100mm, formando um capacitor. O capacitor formado pelas duas hastes é parte de um circuito oscilador e a frequência de oscilação varia com o valor do capacitor, portanto, depende das propriedades dielétricas do meio ao redor das hastes. A maior parte do trabalho foi conduzido usando quatro tipos de solos. Utilizando equações de regressão linear, percebeu-se uma diferença de comportamento entre as misturas, verificando

que solos com presença de argila e superfícies coloidais orgânicas sofrem alterações de leituras. Os autores concluem que seu trabalho indica que a calibração para solos individuais é necessária para obter medidas de teor absoluto de água usando esse sistema de capacitância.

3.2 Calibração de um sensor capacitivo para estimativa da umidade em três classes de solos

PIZETTA *et al.* (2017) buscaram, em seu trabalho, calibrar um sensor capacitivo Eletrodex para três tipos de solos diferentes (Argissolo Vermelho distrófico, Latossolo Vermelho distroférico e Nitossolo Vermelho eutroférico). Para a calibração do sensor, foram ajustadas as equações lineares nos três solos estudados, uma vez que identificou-se que este tipo de equação apresentava o melhor ajuste. A curva de calibração apresentou-se razoável para o Argissolo e Latossolo¹, em que a equação explicou 70% e 72% da variação da umidade do solo, respectivamente. Já para o Nitossolo, a equação explicou apenas 48% da variação da umidade do solo, apresentando ajuste ruim. Sugeriu-se que uma possível razão para o sensor não ter apresentado bom desempenho neste trabalho pode ser devido ao fato dos solos deste experimento possuírem teor considerável de argila. Os autores concluem que as equações de calibração do sensor avaliado não estimaram a umidade volumétrica do solo de forma satisfatória nos intervalos de umidade avaliados em nenhum dos solos estudados, e o sensor apresentou desempenho comprometido para o Argissolo e Nitossolo quando submetido à calibração no maior nível de umidade.

3.3 Effective calibration of low-cost soil water content sensors

BOGENA *et al.* (2017) propuseram-se a utilizar o sensor de baixo custo SMT100 e apresentar um método de calibração eficaz, demonstrando o aumento na precisão quando utilizada uma calibração específica em vez de uma única calibração “universal”. Em um primeiro momento, os autores verificaram a sensibilidade do sensor a mudanças de temperatura. Para correção, a permissividade dielétrica aparente foi modelada usando o Modelo de Índice de Refração Complexo:

$$\Theta = 100 \times \frac{K_a^\beta - (1 - \eta) \times K_s^\beta - \eta K_{air}^\beta}{K_{water}(T)^\beta - K_{air}^\beta} \quad (7)$$

onde η é a porosidade do solo, β é um fator de forma que é assumido como 0.5, K_a é a permissividade dielétrica aparente medida e K_{water} , K_{solid} e k_{air} são a permissividade de água, sólidos e ar, respectivamente. A permissividade de K_{solid} e a porosidade do

¹Ver: (EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA, 2018).

solo foram assumidas como 3.5 e 0.38, respectivamente. A permissividade dielétrica do ar (K_{air}) é 1, e a da água (K_{water}) é uma função da temperatura T que foi calculada pela equação:

$$K_{water} = 78.54 \times [1 - 4.579 \times 10^{-3} (T - 25) + 1.19 \times 10^{-5} (T - 25)^2 - 2.8 \times 10^{-8} (T - 25)^2] \quad (8)$$

A frequência de oscilação medida pelo sensor SMT100 precisa ser convertida em uma permissividade dielétrica aparente K_a . A resposta do sensor (contagem) foi relacionada ao K_a usando o seguinte modelo empírico:

$$K_a = \gamma + \frac{1}{\alpha + \frac{\beta}{(18000 - counts)/5000}} \quad (9)$$

onde α , β e γ são parâmetros de ajuste. O erro médio quadrático entre o K_a previsto e a permissividade de referência conhecida foi utilizado para quantificar a precisão das funções empíricas. Além disso, foram apresentados os resultados da calibração em termos de conteúdo de água no solo equivalente, calculados usando a relação de polinômios empíricos de permissividade.

Neste estudo, foram usados cinco padrões para a calibração do sensor (ar, esferas de vidro e três misturas de 2-isopropoxietanol (i-C3E1) e água desionizada com uma fração de volume definida de i-C3E1). A permissividade dos cinco meios de referência varia de 1 (ar) a 34,8, cobrindo a maioria dos valores de permissividade dielétrica encontrados em solos naturais. Por fim, foi comparada a precisão de uma calibração "universal" com a precisão que pode ser obtida usando a calibração específica do sensor, e os resultados mostraram que uma calibração específica melhorou fortemente a precisão.

3.4 Algoritmos para Autoajuste de Sensores Utilizando Redes Neurais

No trabalho de OLIVEIRA; AMARAL; AMARAL (2009), é proposto o desenvolvimento de um algoritmo para autoajuste de sensores inteligentes a partir do uso de Redes Neurais Artificiais. Através de dados gerados em uma calibração, o algoritmo aprende a corrigir os desvios encontrados. A título de exemplo foi utilizado um sensor do tipo Pt-100, que é uma termoresistência de Platina — o sufixo numérico corresponde à sua resistência elétrica quando submetida a uma temperatura de 0°C.

Foi utilizada a rede de *Elman*, que tem estrutura de rede neural com características recorrentes, ou seja, a saída de um neurônio pode ser uma entrada para outro de uma camada precedente ou, no caso de autorealimentação, para o próprio neurônio. As redes recorrentes, chamadas de redes com memória, não possuem organização

rígida e seus neurônios possuem liberdade para se ligar a qualquer outro neurônio.

Os autores escolheram uma topologia utilizando os polinômios para termoresistências e uma rede neural Elman. Nesta topologia, durante a fase de treinamento, os erros que os pontos de calibração possuem em relação ao polinômio padronizado são apresentados para o treinamento da rede neural. Durante a fase de utilização, o valor de entrada é apresentado ao polinômio e à rede neural simultaneamente, e a saída do sistema é o somatório da saída de ambas, conforme Figura 9.

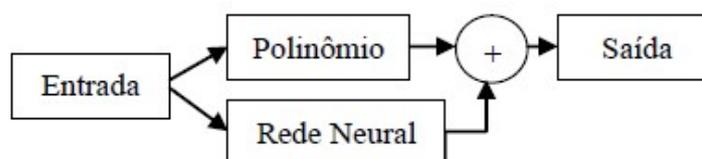


Figura 9 – Topologia rede neural Elman - Fonte: (OLIVEIRA; AMARAL; AMARAL, 2009)

Observando os resultados obtidos nas simulações no Matlab[®], foi possível verificar que essa rede teve um excelente comportamento, convergindo para um resultado muito próximo da curva apresentada no aprendizado. Conclui-se o estudo afirmando que a vantagem que este método pode apresentar em relação ao método estatístico tradicional é a facilidade de implementação deste algoritmo em sistemas embarcados como transmissores e termômetros, criando instrumentos autoajustáveis. Somando-se a isto, considerou-se também a capacidade de absorver desvios de modelagem dos polinômios utilizados, devido à capacidade de generalização das redes neurais artificiais.

3.5 Self-calibration and optimal response in intelligent sensors design based on artificial neural networks

No trabalho de RIVERA *et al.* (2007), foi descrita uma nova metodologia baseada em redes neurais artificiais para calibração automática de sensores inteligentes não lineares. Além de detalhes experimentais completos, resultados e análise do estudo, o trabalho descreve a implementação da RNA em uma unidade microcontroladora (MCU).

Para ilustrar a capacidade do método de construir sistemas de calibração automática e reconfiguráveis, foi projetado um sistema de medição de temperatura. O sistema é baseado em um termistor, que apresenta um dos piores comportamentos de não linearidade, e também é encontrado em muitas aplicações do mundo real devido ao seu baixo custo.

A metodologia envolveu análise de várias topologias de rede e algoritmos de trei-

namento, como RBF (*Radial Basis Function*) e MLP (*Multilayer Perceptron*). Embora afirmem que os RBF são bons sistemas de aproximação de funções, o MLP foi selecionado por ser mais simples do que o RBF, justificando também que a rede RBF é mais exigente em termos computacionais.

Buscando um algoritmo de treinamento com as melhores características de tempo de treinamento e erro mínimo, decidiu-se avaliar o *backpropagation*, *backpropagation* com *momentum* e os algoritmos LMBP (*Levenberg Marquardt Backpropagation*). O algoritmo de Levenberg-Marquardt apresentou um tempo de convergência mais rápido e também o menor erro. Considerou-se que esse método funciona muito bem na prática e é considerado o algoritmo mais eficiente para treinar RNA de tamanho médio.

A rede neural artificial foi testada com diferentes níveis de sinais de entrada não-lineares. O método proposto foi comparado com os métodos de linearização por partes e polinomial usando *software* de simulação. A comparação foi obtida usando diferentes números de pontos de calibração e vários níveis não lineares do sinal de entrada.

O desempenho da RNA foi comparado com um termômetro de linha UDC3000 da Honeywell, um termopar tipo K (-29 a 538°C) com uma precisão de $\pm 0,02\%$, tirando 50 medidas em uma faixa de 0 a 100°C a cada 2°C, usando um sistema de forno para alterar a temperatura. Foi possível observar que a porcentagem máxima de erro de não-linearidade relativa é de aproximadamente 0,7%, abaixo de 1%, conforme previsto pela simulação. Segundo os autores, o método proposto acabou por ter uma melhor precisão global do que os outros dois métodos (linearização por partes e polinomial).

3.6 An artificial neural network approach to the estimation of stem water potential from frequency domain reflectometry soil moisture measurements and meteorological data

MARTÍ; GASQUE; GONZÁLEZ-ALTOZANO (2013) descrevem uma aplicação de redes neurais artificiais para estimar o potencial hídrico da umidade do solo em diferentes profundidades e variáveis meteorológicas, considerando um conjunto limitado de dados. O experimento foi conduzido com árvores cítricas 'Navelina' enxertadas em tangerina 'Cleópatra', realizado no período de julho de 2009 a outubro de 2010 em um terreno irrigado por gotejamento comercial de 1 ha em Senyera, Valência (Espanha).

Foram utilizadas Análise de Componentes Principais (PCA) e regressão linear múltipla (MLR) para avaliar as relações entre observações e propor outros modelos para permitir uma análise comparativa. A equação de regressão ótima do potencial hídrico do caule considerou temperatura, umidade relativa, radiação solar e umidade do solo a 50 cm como variáveis de entrada, com um coeficiente de determinação de 0,852.

O teor volumétrico de água através do perfil do solo foi monitorado em tempo real contínuo usando uma sonda de capacitância multisensor (ENVIROSCAN, Sentek Sensor Technologies) baseada em FDR (*frequency domain reflectometry*).

A sonda foi colocada dentro de um tubo de acesso de PVC instalado dentro da área irrigada das árvores para registrar diferentes variações dinâmicas em uma ampla faixa de conteúdo de água do solo dentro da zona coberta pelo sensor FDR, a 10, 30, 50 e 70 cm de profundidade.

O conjunto completo de dados consiste em 46 pontos de dados correspondentes a 46 medições semanais entre 17/07/2009 e 31/10/2010. Os dados foram organizados como uma matriz de 46 semanas por 10 variáveis (temperatura, U, umidade relativa do ar, radiação solar, dia do ano, leitura do sensor a 10cm, leitura do sensor a 30cm, leitura do sensor a 50cm, leitura do sensor a 70cm e potencial hídrico). PCA e MLR foram usados para estudar as relações entre observações e variáveis, respectivamente, bem como selecionar as entradas para alimentar os modelos.

A equação preditiva ótima considerou temperatura, umidade relativa, radiação solar e umidade do solo a 50 cm como variáveis de entrada. A RNA escolhida para o trabalho foi *feedforward* multicamada com retropropagação. Para o treinamento foi utilizado o algoritmo Levenberg-Marquardt, que segundo os autores, é o mais adequado para lidar com minimização de problemas mal condicionados.

O desempenho dos modelos de RNA confirmou as conclusões retiradas da análise de regressão. Em comparação com os modelos de regressão correspondentes, as RNAs apresentaram uma precisão de desempenho consideravelmente maior (com um coeficiente de determinação ótimo de 0,926), onde entende-se que esse desempenho é devido a uma maior capacidade de mapeamento de entrada-saída.

3.7 Calibration of Soil Water Content Data from EnviroSCAN System using Artificial Neural Network

Já AL-GHOBARI *et al.* (2016) apresentam um estudo no qual uma rede neural artificial (RNA) foi utilizada para calibrar o teor de água do solo com um sensor de capacitância EnviroSCAN, e os resultados foram comparados com uma análise de regressão usando dados de campo em diferentes profundidades em solos franco-argilosos arenosos.

O sensor de capacitância EnviroSCAN é um sistema completo de monitoramento contínuo da água no solo, considerado por muitos produtores e pesquisadores como o principal dispositivo de monitoramento de irrigação do mundo. O EnviroSCAN consiste em uma rede de sondas que suportam uma série de sensores de água do solo.

O estudo foi realizado em uma fazenda pertencente ao colégio de alimentos e Ciências Agrícolas, da Universidade King Saud, em Riad, na Arábia Saudita.

As sondas foram acondicionadas em um tubo de acesso de PVC, e foram instaladas a 10, 20, 30, 40 e 60 cm de profundidade.

A arquitetura da RNA utilizada neste estudo foi *backpropagation* multicamadas, com uma única camada oculta. Uma abordagem de tentativa e erro foi usada para determinar a quantidade ótima de neurônios na camada oculta (foram examinados de 2 a 14 neurônios). O melhor modelo de RNA foi selecionado com base no maior coeficiente de correlação e menor erro de treinamento. No caso de uma ou duas entradas, as melhores arquiteturas de RNA possuíam quatro neurônios na camada oculta. Para a função de ativação optou-se por sigmóides e hiperbólicos (tanh).

Concluíram que a rede neural *feedforward* pode ser um método de calibração eficaz para determinação do conteúdo de água do solo usando um sensor de capacitância EnviroSCAN. Um melhor desempenho dos modelos RNA pode ser observado em comparação com equações de calibração de análise de regressão. Os ajustes das equações de calibração usando modelos de RNA apresentaram variação de 0,9715 a 0,9928 para as profundidades estudadas. Esse resultado foi melhor que o obtido pela análise de regressão, que obteve coeficiente de determinação de 0,9525 a 0,9724 para as respectivas profundidades.

3.8 Rapid measurement and control of the moisture content of compost using near-infrared spectroscopy

Em 1999, SUEHARA *et al.* (1999) propuseram o uso de espectroscopia de infravermelho próximo (*NIRS*) no controle do teor de umidade de rejeitos de tofu. Tofu é um alimento tradicional japonês feito de soja, consumido habitualmente no leste da Ásia.

Para formular uma equação de calibração, foi realizada uma análise de regressão linear múltipla pelo método dos mínimos quadrados entre os dados espectrais do infravermelho (número da amostra = 50) e o teor de umidade obtido pelo método de secagem (gravimetria) C_{act} , para prever o teor de umidade C_{pre} usando a seguinte equação de calibração:

$$C_{pre} = a_0 + \sum_{i=1}^m a_i \cdot A_i \quad (10)$$

onde $A_i = d^2 \log(1/R_i)$, e a_0 e a_i representam o coeficiente de regressão. O subscrito i ($i=1, 2, \dots, m$) representa um número ordinal do comprimento de onda usado na análise de regressão. A segunda derivação e a análise de regressão foram realizadas usando um *software* chamado NSAS fornecido pela empresa Nireco. Os valores do coeficiente de correlação simples e do erro padrão de calibração foram 0,987 e 1,33x, respectivamente. Para validar a equação de calibração obtida, foi utilizado um conjunto de amostras ($n = 35$) não utilizados na formulação da equação de calibração, o qual

foi comparado com os valores obtidos pelo método de secagem, e foi observada boa concordância entre os resultados do método de secagem e os do método NIRS. O coeficiente de correlação simples e o erro padrão de predição foram de 0,979 e 1,85X, respectivamente. Em seguida, o método NIRS foi aplicado a uma situação prática em que o teor de umidade foi medido e controlado durante a fermentação do composto, e também obteve bons resultados. O estudo indicou que o NIRS é um método útil para medição e controle do teor de umidade no composto de rejeitos de tofu.

3.9 Low-cost automatic station for compost temperature monitoring

JORDÃO *et al.* (2017) se detiveram ao monitoramento de um dos parâmetros considerados fundamentais na compostagem, a temperatura. Tiveram como objetivo desenvolver uma estação automática — a qual denominaram CMS (Sistema de Monitoramento de Compostagem) — de US\$ 150, capaz de monitorar a cada cinco minutos a temperatura do ar em dois pontos diferentes de uma leira de compostagem. Para tanto, os autores fizeram uso de uma plataforma de prototipagem Arduino / Genuino modelo UNO, um relógio digital de quartzo DS1307 e um cartão SD de 2 GB. O sensor de temperatura escolhido foi o DS18B20 à prova d'água. Segundo o fabricante, a incerteza instrumental deste sensor é de $\pm 0.5^{\circ}\text{C}$ (-10 a + 85°C) e a taxa máxima de amostragem é de 750 milissegundos.

A curva de calibração foi obtida a partir de um modelo de regressão linear com coeficientes ajustados pelo método do mínimo quadrado, e após coleta e análise dos dados, os autores chegaram às seguintes conclusões:

- a) Os resultados da calibração e teste na pilha de compostagem demonstraram sua eficiência operacional em comparação com as opções convencionais, reduzindo o número de visitas do operador e aumentando a resolução espacial e temporal da medição de temperatura.
- b) O instrumento também foi capaz de suportar condições ambientais adversas, como alta umidade e temperaturas extremas ($> 70^{\circ}\text{C}$).
- c) As incertezas expandidas das medições dos sensores foram satisfatórias e compatíveis com a demanda operacional e ambiental da compostagem.
- d) O CMS também provou ser de baixo custo para construção (US\$ 150,00) e manutenção.
- e) O *software* livre e o *hardware* de código livre permitem que o usuário tenha controle total na configuração do CMS.

3.10 Smart Compost Monitoring System using Open Source Technologies

VRETTOS; KAZAMIAS; LEKKAS (2017) propuseram um sistema inteligente de monitoramento de compostagem usando tecnologias de código aberto, onde fizeram uso de três sensores de temperatura do modelo DS18B20 da Maxim, um sensor de umidade/temperatura DHT11 da Adafruit para a medição da umidade do ar, bem como um sensor resistivo de umidade do solo de baixo custo da SparkFun. Neste estudo, os autores informam apenas que a precisão dos sensores foi testada usando equipamentos de medição de laboratório, e na medida que problemas foram localizados, os sensores foram substituídos ou ajustados. Os autores concluem que o sistema foi considerado suficiente para monitorar os processos de compostagem, contudo não apresentam quais problemas teriam ocorrido com os sensores e nem quais soluções foram aplicadas para corrigi-los, inclusive não fazendo nenhuma menção quanto a calibração dos sensores.

3.11 Intelligent composting assisted by a wireless sensing network

LÓPEZ *et al.* (2014) apresentam em seu trabalho um projeto intitulado *Compo-ball*, o qual teve orçamento de mais de €2.500.000,00, coordenado pela Iris Technology Solutions - Espanha, vinculado à Universitat Politècnica de Catalunya - Barcelona - Espanha, financiado majoritariamente por associações distribuídas em 10 países da União Europeia entre os anos de 2010 e 2013. Estiveram envolvidas neste projeto equipes de pesquisa acadêmica e do setor, além de várias pequenas e médias empresas (PMEs) e associações de PMEs no campo da compostagem.

O estudo descreve o monitoramento do processo de compostagem por meio de uma rede de sensores sem fio que permite a medição de temperatura e umidade em tempo real em vários pontos da pilha de compostagem.

A validação e os testes foram acompanhados de atividades de demonstração e treinamento para a indústria europeia de compostagem. Todas essas atividades foram acompanhadas de discussões e ações destinadas a proteger adequadamente a Propriedade Intelectual e desenvolver um plano de negócios adequado para a exploração dos resultados.

Resumidamente, o projeto envolve nodos sensores espalhados dentro da pilha/leira de compostagem. Este nodo conta com um sensor de temperatura, um sensor de umidade, uma bateria, um módulo de recarga, uma antena e um sistema de comunicação sem fio, todos gerenciados por um microcontrolador e encapsulados em um material inerte e resistente. Os dados adquiridos pelos nodos são transmitidos através

de uma conexão de radiofrequência a um *hub* de pilha (dispositivo localizado perto de cada pilha, que recupera as medições de todos os nodos dentro dela), e depois para um sistema de *gateway* que armazena dados de todas as pilhas e os transmite via internet para uma estação central onde são processados. Operadores de usinas de compostagem podem então monitorar os valores de temperatura e umidade em diferentes pontos das usinas de compostagem a partir de qualquer computador ou dispositivo com disponibilidade de internet (Figura 10).

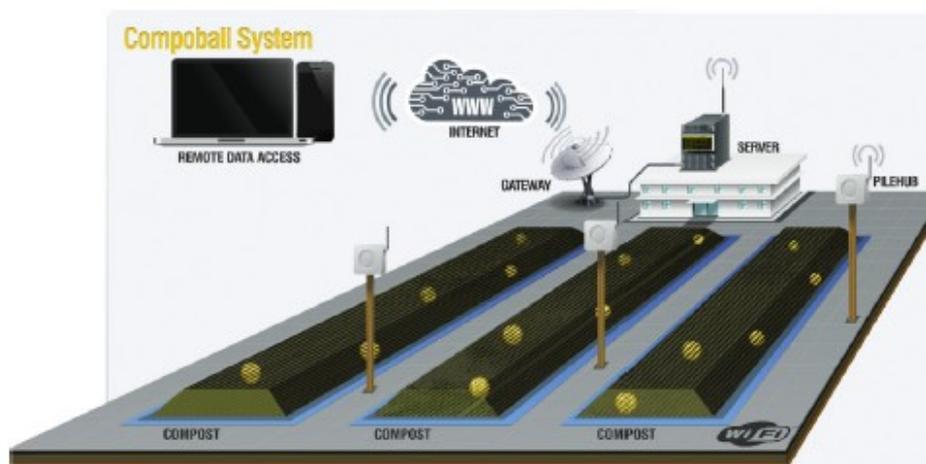


Figura 10 – Rede de sensores sem fio para monitoramento e controle de compostagem
- Fonte: (LÓPEZ *et al.*, 2014)

Os autores afirmam que determinar os níveis de umidade em compostagem é mais desafiador do que no solo. As causas seriam:

- a) A faixa de níveis de umidade nas situações de compostagem é muito mais ampla do que nos solos;
- b) As condições dentro de uma leira de compostagem variam muito de um local para o outro;
- c) A umidade retida por materiais orgânicos é difícil de detectar devido ao arranjo complexo dos poros.

Sobre o sensor de umidade escolhido para o trabalho, os autores relatam que foi utilizado um do tipo capacitivo, informando que o circuito de condicionamento usado é baseado em um oscilador com frequência fixa e as mudanças na permissividade são medidas como mudanças na fase entre o sinal do oscilador e o sinal nos eletrodos. Essas mudanças na fase são diretamente proporcionais às mudanças na permissividade do material e têm uma boa correlação com as mudanças de umidade do composto quando o oscilador está trabalhando a 50 MHz. As mudanças no sinal dos eletrodos

são atenuadas pelo material de proteção, exigindo um maior esforço na definição da localização dos eletrodos dentro do nó.

Sobre o tema calibração, informam que foi executada a calibração do sensor de temperatura e do sensor de umidade, e que esta etapa exigiu a coleta de material de compostagem para medição de umidade usando o método de secagem do aquecedor (gravimetria), feito fora do local e exigindo cerca de 24 horas. Afirmam ainda que os sensores de umidade e temperatura são confiáveis e que exigem calibração mínima.

Concluem a apresentação do trabalho com uma abordagem sobre custos, onde informam que o custo do sistema previsto depende do tamanho das pilhas. Para uma pilha que requer 20 bolas (aproximadamente uma pilha de 100 m), o custo por pilha seria de cerca de € 2.500,00, e que este custo ocorre apenas uma vez; todo o *hardware* pode ser reutilizado em até 500 processos de compostagem (o limite seria o número de ciclos da bateria). Cada fábrica também teria um custo adicional de € 1.000,00 para o computador *gateway*, mas esse custo seria o mesmo se a fábrica monitorar 1 ou 10 pilhas. Embora essa estrutura de custos pudesse ser considerada cara, se um laboratório externo fosse usado, principalmente para medições de umidade, facilmente esse valor seria atingido.

3.12 Comparação entre os Trabalhos Relacionados

Dentre os trabalhos citados, podemos destacar que as pesquisas de GARDNER; DEAN; COOPER (1998), PIZETTA *et al.* (2017), BOGENA *et al.* (2017) e MARTÍ; GASQUE; GONZÁLEZ-ALTOZANO (2013) trataram sobre calibração de sensores de umidades especificamente para solo, sendo que PIZETTA *et al.* (2017) propuseram calibração genérica para 3 tipos de solos e não obtiveram sucesso. AL-GHOBARI *et al.* (2016) e MARTÍ; GASQUE; GONZÁLEZ-ALTOZANO (2013) saíram da proposta de buscar uma equação de regressão linear e propuseram o uso de Redes Neurais Artificiais, mas visando atender calibração para profundidades diferentes de um mesmo tipo de solo.

OLIVEIRA; AMARAL; AMARAL (2009) e RIVERA *et al.* (2007) apresentaram proposta de uso de RNA com o propósito de auto-ajustar sensores, contudo trabalharam somente com sensores de temperatura.

SUEHARA *et al.* (1999), JORDÃO *et al.* (2017), VRETTOS; KAZAMIAS; LEKKAS (2017) e LÓPEZ *et al.* (2014) trataram de monitoramento de compostagem, sendo que todos se debruçaram na calibração do sensor para um único tipo de composto. É preciso dar destaque para o trabalho de LÓPEZ *et al.* (2014), que pode ser considerado o estado da arte em monitoramento de compostagem. Esse trabalho contou com aporte de mais de 2,5 milhões de euros da comunidade europeia, e diz que, por razões mercadológicas, foram mantidos aspectos de confidencialidade na publicação. Embora

não fale da calibração dos sensores, relata que tanto o sensor de temperatura quanto de umidade deram bons resultados, mas que é preciso uma calibração mínima, e esse é um dos pontos que o difere desta dissertação.

Na Tabela 2 apresentamos os autores e as principais características das soluções propostas. Percebe-se que o RealSense, última linha da tabela, representa uma abordagem inédita, monitorando temperatura e umidade em compostagens de diferentes naturezas e explorando técnicas de *Machine Learning*.

Tabela 2 – Trabalhos relacionados e suas principais características

Autor	Fatores Monitorados		Objetivo		Sensor de Umidade	Dif. Substratos	Método	Obs.
	Temp.	Umid.	Solo	Comp.				
Gardner		X	X		Capacitivo		Reg. Linear	
Pizzeta		X	X		Capacitivo	X	Reg. Linear	Não obteve sucesso
Bogena		X	X		Capacitivo		Reg. Linear	
Martí		X	X		Frequency Domain Reflectometry (FDR)		RNA	Profundidades diferentes
Ghobari		X	X		Capacitivo		RNA	Profundidades diferentes
Suehara		X		X	Espectroscopia de Infravermelho Próximo (NIRS)		Reg. Linear	
Jordão	X			X			Reg. Linear	
Vrettos	X	X		X	Resistivo		Não Inf.	
López	X	X		X	Capacitivo		Não Inf.	Necessário calibração
Oliveira	X						RNA	
Rivera	X						RNA	
Moncks	X	X		X	Capacitivo	X	ML	

3.13 Considerações sobre o Capítulo

Este capítulo registra os trabalhos de pesquisa identificados como relacionados à proposta RealSense.

Estes trabalhos foram centrais para definição dos esforços de pesquisa a serem realizados, bem como para sistematização das contribuições decorrentes do trabalho desenvolvido.

A principal diferença do RealSense com relação aos trabalhos relacionados se concentra na capacidade de autoajuste do sensor de umidade através de técnicas de aprendizado de máquina, permitindo que o mesmo seja utilizado em compostagens de diferentes naturezas.

Um registro dos avanços da proposta RealSense em relação aos trabalhos relacionados está sumarizado no Capítulo 7, onde estão as considerações finais deste trabalho.

Considerando o estudo dos conceitos relacionados a esta dissertação, resumidos no Capítulo 2, e a discussão dos trabalhos relacionados, bem como a interação com a comunidade envolvida com o Nepers (Núcleo de Educação, Pesquisa e Extensão em Resíduos e Sustentabilidade da UFPel), foi concebida a proposta RealSense, a qual será apresentada nos Capítulos 4 e 5.

4 REALSENSE: CONCEPÇÃO DO NODO SENSOR

Neste capítulo será discutida a concepção da abordagem RealSense, particularmente os aspectos relacionados às funcionalidades do Nodo Sensor. Neste sentido, são apresentados os diferentes componentes de *hardware/software*, bem como as características operacionais necessárias para o monitoramento das condições de umidade e temperatura da compostagem.

4.1 Visão Geral do Nodo Sensor

O *hardware* proposto consiste em um equipamento acoplado em uma haste de PVC (Figura 11), onde a leitura dos sensores é feita manualmente ou de 10 em 10 minutos de forma automática, sendo apresentada em *display*, gravada em cartão SD e enviada a um servidor da Internet através de conexão Wi-Fi (quando houver conectividade).

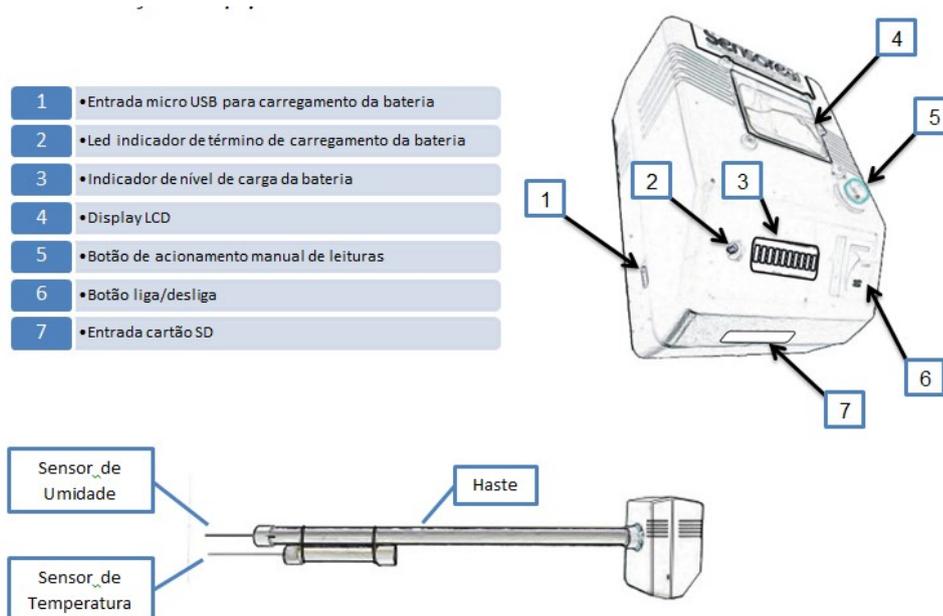


Figura 11 – Visão do nodo sensor - Fonte: Elaborada pelo autor

Características gerais consideradas para a concepção do Nodo Sensor:

- Empregar redundância tripla para os locais de armazenamento para garantir a coleta dos dados sem perdas;
- Prover alimentação do equipamento por bateria de lítio, que em testes propiciou 3 (três) dias de autonomia ao equipamento quando no modo automático e ligado 24 horas por dia;
- Oportunizar uma coleta maior de dados com o propósito de alimentar as entradas do algoritmo de aprendizado de máquina que pretende-se testar, adicionando um sensor de temperatura do solo e um sensor de umidade e temperatura relativa do ar.

4.1.1 Módulo de Processamento e Comunicação Selecionado

Durante a escolha de um microcontrolador para um projeto é preciso saber de antemão algumas informações, identificando se ele possui todos os recursos necessários ao que se pretende desenvolver. Existem diversos microcontroladores disponíveis no mercado, sendo que os mais facilmente encontrados no mercado brasileiro e os mais utilizados em prototipação são o Arduino e os baseados na ESP8266.

O Nodo Sensor deste trabalho tem como premissas básicas ser portátil, de baixo custo, fazer leituras de pelo menos 3 sensores diferentes, apresentar dados em *display* LCD, gravar dados em cartão SD e enviar dados pela internet.

Nesta linha, pressupõe-se que o microcontrolador deva ter pequenas dimensões, baixo consumo, valor acessível, portas de entrada/saída suficientes para os sensores e periféricos necessários, e conectividade para transmissão dos dados.

Era intenção fazer um comparativo entre outras soluções com funções Wi-Fi nativas ou adaptadas, mas não se encontrou soluções de baixo custo que permitissem comparativos úteis a este projeto.

Na Tabela 3 é apresentado um comparativo entre Arduino UNO R3 e a ESP-07, uma das versões da família ESP8266, que são microcontroladores de baixo custo.

Tabela 3 – Comparativo ESP-07 X Arduino UNO R3

Característica	ESP8266-07	Arduino UNO R3
Dimensões	2.12 X 1.6 X 0.32 cm	7.6 X 1.9 X 6.4 cm
Processador	Tensilica L106 32-bit	ATMega 328
Clock	80 - 160 MHz	16 MHz
RAM	130 KB	2 KB
Flash	512 KB	32 KB
GPIO	9	12
ADC	1	6
Alimentação	3.3 VDC	7 - 12 VDC
Wi-fi	Sim	Não
Barramentos	SPI - I2C - UART - I2S	SPI - I2C - UART
Custo	R\$ 28,90	R\$ 54,90

Como módulo de processamento e comunicação foi selecionada a ESP-07, que é um *System-On-Chip* (SOC) fabricado pela Ai-thinker. O SOC dispõe de tamanho reduzido, baixo consumo, baixo custo, quantidade de conectores GPIO suficientes para integração de todos periféricos desejados ao projeto e conectividade Wi-Fi nativa, características determinantes para o desenvolvimento do Nodo Sensor.

4.1.2 Sensores Selecionados

Os sensores adotados para uso no RealSense tiveram sua seleção considerando sua ampla adoção no cenário nacional e internacional, o que constitui um fator significativo para reprodutibilidade dos esforços de estudo e pesquisa desenvolvidos, a despeito do aporte de recursos disponíveis, pelos diferentes segmentos da comunidade científica nacional.

Conforme levantamento bibliográfico executado, verificou-se que o sensor capacitivo de umidade do solo seria o mais indicado para este trabalho, visto que é amplamente utilizado em pesquisas similares à concepção do RealSense.

Optou-se pelo modelo coplanar CS12 apresentado na Figura 12, que é fabricado em material resistente a corrosão, o que é oportuno para uso em compostagens, bem como apresenta uma ótima relação custo/benefício e pode ser facilmente encontrado no comércio brasileiro.

Embora alguns estudos tratem de uma fase de pré-calibração, onde a leitura do sensor (analógica) é feita no ar e totalmente submerso em água para buscar os limites que seriam considerados 0 e 100%, neste trabalho optou-se por uma outra abordagem, mantendo os respectivos valores analógicos para correlacionar com a umidade de referência adquirida pelo método padrão estufa.



Figura 12 – Sensor capacitivo - Fonte: Elaborada pelo autor

Para a medição de temperatura, o sensor escolhido foi o PT100, que é um Termopar tipo sonda, fabricado em aço inoxidável (Figura 13).



Figura 13 – Sensor Termopar PT100 - fonte: Elaborada pelo autor

Já para a medição da temperatura e umidade relativa do ar, utilizou-se o DHT22, sensor fabricado pela empresa Sparkfun (Figura 14).

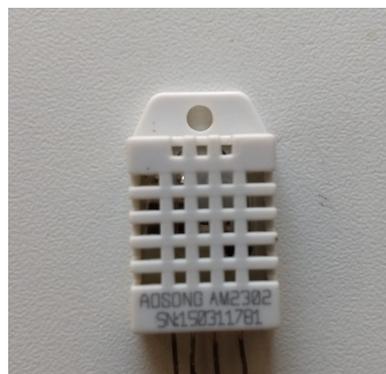


Figura 14 – Sensor DHT22 - Fonte: Elaborada pelo autor

4.1.3 Ambiente e Linguagem de Desenvolvimento do Nodo Sensor

A Espressif disponibiliza em seu site ferramentas integradas de desenvolvimento específicas para o ESP8266, entretanto são ferramentas difíceis de usar para quem não conhece profundamente programação para microcontroladores. A plataforma de desenvolvimento arduino, conhecida como Arduino IDE (ARDUINO, 2019), é um ambiente de desenvolvimento integrado gratuito, desenvolvido em Java e que suporta linguagens C e C++, sendo necessário definir apenas duas funções para que o programa funcione:

- `setup()`: Inserida no início para configurações;
- `loop()`: Chamada para repetir um bloco de comandos.

Desde 2016, esta IDE fornece suporte direto às placas da família ESP8266, contando com distribuições Windows e Linux, além de inúmeras bibliotecas prontas que aumentam consideravelmente a produtividade do programador. Desta forma, esta foi a ferramenta escolhida para o desenvolvimento deste trabalho, e o *software* foi concebido em linguagem C++.

4.1.4 Funcionalidades Concebidas para Nodo Sensor

Durante o desenvolvimento do protótipo, buscou-se oferecer ao usuário final um equipamento de fácil manuseio, robusto, confiável, de leitura rápida e alta precisão. Abaixo relatamos as principais características concebidas para operação do Nodo Sensor:

- a) operação portátil que tem por princípio a inserção da base da haste do Nodo Sensor no composto até o nível previamente definido (Figura 15);
- b) opção de ligar e desligar o Nodo Sensor a qualquer momento por chave eletromecânica (item 6 da Figura 11);
- c) leitura instantânea ao pressionar o botão 5 conforme apresentado na Figura 11;
- d) indicação da umidade e temperatura apresentada no *display* LCD (item 4 da Figura 11);
- e) gravação no cartão SD (item 7 da Figura 11) de data, hora, umidade e temperatura;
- f) conexão por uma rede Wi-Fi configurada previamente, e em caso de sucesso na conexão, transmissão dos dados pela internet para o servidor thingspeak. Em caso de insucesso da conexão, os dados não serão transmitidos;

- g) modo de baixo consumo, para preservar a bateria, quando não estiver em procedimento de leitura e/ou transmissão de dados;
- h) opção de configuração para fazer leituras automáticas a cada 10 minutos, apresentando, gravando e enviando os dados, desde que permaneça no estado de "ligado". Este recurso é importante para monitoramento periódico sem a necessidade de interferência humana;
- i) entre leituras automáticas é possível fazer outras leituras de forma manual, pressionando o botão de leitura (item 5 da Figura 11). O procedimento após o acionamento do botão será o mesmo, apresentando, gravando e enviando os dados, e posteriormente entrará no modo *sleep* por mais 10 minutos.



Figura 15 – Limite de inserção no composto - Fonte: Elaborada pelo autor

Uma barra gráfica (Figura 16) indica o nível de bateria do equipamento. Seu funcionamento só será percebido quando o equipamento estiver ligado. Quando totalmente acesa, indica que a bateria está totalmente carregada. Quando somente as luzes vermelhas estiverem acesas, indica que a bateria está chegando no seu limite e precisa ser carregada. Quando toda a barra gráfica estiver apagada, indica que a bateria está totalmente descarregada, necessitando ser colocada em carga para o funcionamento do equipamento. Mantendo o equipamento ligado, a bateria dura em torno de 5 (cinco) dias.



Figura 16 – Indicador de nível de bateria - Fonte: Elaborada pelo autor

O procedimento de carregamento da bateria deve ser executado com o equipamento no modo "desligado". Com a bateria totalmente descarregada, o processo de carregamento demora em torno de 3 horas, e deverá ser utilizado um carregador 5V 1A. Quando a carga da bateria estiver completa, um led verde acenderá indicando que o carregador pode ser retirado.

O equipamento oferece comunicação Wi-Fi para envio das leituras ao servidor thingspeak. Em caso de ainda não ter havido configuração inicial, ou o equipamento

estiver num ambiente onde não alcança a rede previamente configurada, ele entrará no modo ponto de acesso (AP). De qualquer dispositivo com acesso a redes Wi-Fi, basta conectar neste AP e acessar pelo navegador o IP padrão 192.168.4.1, e proceder com a configuração (Figura 17).

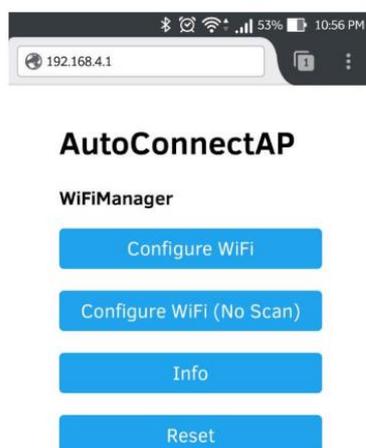


Figura 17 – Configuração Wi-Fi - Fonte: Elaborada pelo autor

O nome da rede e a senha ficarão gravados na memória do equipamento, portanto este procedimento só precisará ser executado uma única vez. Toda vez que o equipamento for ligado, buscará esses dados na memória interna e tentará conexão. Caso não seja possível uma conexão, o equipamento automaticamente entrará no modo AP (*Access Point*), permitindo que o procedimento acima seja repetido para configurar uma nova rede.

4.2 Validação do Nodo Sensor

As leituras dos sensores, tanto do DHT22 quanto do PT100, foram devidamente validadas em laboratório, utilizando instrumentos calibrados disponíveis na infraestrutura do grupo de pesquisa do Centro de Engenharias da Universidade Federal de Pelotas.

Com relação ao CS12, foi mantida a leitura analógica original, sem nenhum tipo de calibração, na expectativa que um algoritmo de aprendizado de máquina fizesse a correlação entre esta leitura e o valor de referência obtido pelo método gravimétrico. Durante os vários testes, nos certificamos apenas que havia variação da leitura conforme inserido em amostras com índices conhecidos de umidade de valores diferentes.

O conjunto de *hardware* e *software* passou por vários testes de forma incremental até chegarmos no modelo final

Como resultado, obteve-se um protótipo totalmente funcional, apresentando as leituras em *display*, gravando em SD Card e enviando os dados monitorados para um

servidor através da Internet.

4.3 Considerações Finais do Capítulo

Este capítulo apresenta a concepção do Nodo Sensor considerando expectativas funcionais levantadas junto a empresas do setor e também junto a uma equipe de pesquisadores da área de engenharia ambiental.

Um dos aspectos considerado importante para a concepção do Nodo Sensor foi definido como sendo o baixo custo, de modo a facilitar a aquisição e consequente difusão da solução entre os diversos setores interessados.

Nesta perspectiva, consideradas as especificações técnicas do sensor de umidade selecionado, e dada sua característica anti-corrosão, destaca-se que o CS12 tem um custo de aquisição pelo menos 200 vezes mais baixo que o NIRS, e cerca de 20 vezes mais baixo que o FDR, equipamentos utilizados em alguns dos trabalhos relacionados apresentados no capítulo 3.

Uma vez que o Nodo Sensor foi devidamente concebido, os esforços de estudo foram direcionados ao autoajuste do sensor capacitivo de umidade para contemplar seu uso nos mais diversos tipos de compostos. Esses esforços são discutidos no capítulo 5 a seguir.

5 REALSENSE: CONCEPÇÃO DA ABORDAGEM DE AUTO-AJUSTE

Concebido o Nodo Sensor, considerando expectativas funcionais de empresa com forte atuação no sul do Brasil no setor de compostagem, bem como a discussão realizada na Seção 2.1, que abrange necessidades de empresas europeias, este capítulo discute a concepção do autoajuste do sensor capacitivo empregado na abordagem RealSense.

O mecanismo de autoajuste do RealSense é baseado em algoritmo de aprendizagem de máquina. Para tanto, como primeiro procedimento, foi realizada uma coleta de dados, a qual foi empregada nas diferentes etapas do processo: aprendizado, testes e avaliação de resultados.

5.1 Metodologia Aplicada na Coleta e Preparação dos Dados

Para coleta de dados foram selecionados 3 (três) tipos de compostos diferentes, os quais são referenciados a partir daqui conforme segue:

- a) *Composto 1* = Serragem + Cama de Aviário + Biossólido¹
- b) *Composto 2* = Serragem + Resíduo de Tabaco + Biossólido
- c) *Composto 3* = Serragem + Casca de Arroz + Biossólido

Conforme possibilidade de ocupação da estufa disponibilizada para este trabalho, a coleta dos dados foi estabelecida entre os dias 8 e 17 de Abril de 2019 (Tabela 4), tornando possível fazer as leituras e executar a gravimetria no mesmo dia, evitando assim qualquer situação de aquisição ou perda de umidade pelo composto, o que comprometeria o estudo.

¹ Produto do tratamento de efluentes do sistema de abate de suínos.

Tabela 4 – Cronograma de execução da Coleta de Dados

	Dias*	Data					
		08/04	09/04	10/04	15/04	16/04	17/04
Composto 1	1	X					
	20	X					
	40	X					
	60		X				
	80		X				
	100		X				
	120			X			
Composto 2	1			X			
	20			X			
	40				X		
	60				X		
	80				X		
	100				X		
	120					X	
Composto 3	1					X	
	20					X	
	40					X	
	60						X
	80						X
	100						X
	120						X

**Dias de compostagem da leira*

Foram coletadas amostras dos 3 compostos em 7 diferentes fases do processo de compostagem (1, 20, 40, 60, 80, 100 e 120 dias). Cinco alíquotas de cada amostra, com volume de 250 mL, foram coladas em recipientes plásticos e mantidas na bancada em repouso por 30 minutos, para alcançar a temperatura ambiente antes da inserção dos sensores (Figura 18), completando 105 amostras. Em cada amostra foram feitas 3 (três) leituras dos sensores para extrair a média. A cada troca de recipiente, os sensores foram limpos com pincel, até não se observar resquícios da amostra já lida.



Figura 18 – Exemplo das amostras nos recipientes - Fonte: Elaborada pelo autor

A temperatura de cada uma das 105 amostras foi verificada com termômetro de mercúrio ($\pm 0.5^{\circ}\text{C}$), a fim de validar as medições do termopar, e o teor de umidade de referência foi determinado pelo método de estufa no Laboratório de Resíduos e Sustentabilidade (NEPERS/Centro de Engenharias/UFPel). Para este procedimento, de cada amostra foram coletadas pequenas alíquotas de 10-30 g em duplicata e acondicionadas em placas de petri, onde secaram em estufa a 105°C por 24 horas (Figura 19). Após a secagem, as amostras foram colocadas para resfriar em dessecador até atingir temperatura ambiente, e posteriormente pesadas em balança analítica (precisão 0,0001) (CORRÊA; CORRÊA; PAZ, 2018).



Figura 19 – Exemplo de amostras em placa de Petri - Fonte: Elaborada pelo autor

Os dados tabulados dos 3 compostos estão representados nos apêndices A, B e C, respectivamente. Todos atributos são referentes as leituras dos sensores, com exceção do atributo "Dias", são do tipo numérico e equivalem a:

- Dias: Número de dias decorridos desde o início da montagem da leira de compostagem (informação atribuída manualmente);
- Temp_sensor: Temperatura adquirida pelo termopar;
- Umid_sensor: Umidade adquirida pelo sensor capacitivo;
- Temp_ar: Temperatura adquirida através do DHT22;

- Umid_ar: Umidade adquirida através do DHT22;
- Umid_lab: Resultado da gravimetria.

Os dados foram separados em dois arquivos do tipo arff (*Weka Attribute-relation Format*) — formato utilizado pelo Weka (WAIKATO, 2019), conforme exemplo apresentado na Figura 20 — um para fase de treinamento e outro para fase de testes do modelo.

```
@relation sensor

@attribute Dias numeric
@attribute Temp_sensor numeric
@attribute Umid_sensor numeric
@attribute Temp_ar numeric
@attribute Umid_ar numeric
@attribute Umid_lab numeric

@data
80,23,645,24,65.03,26.02
40,26,581,25,66.97,26.43
60,23.67,612,24,65.07,18.72
20,25.33,502,25,57.2,46.34
60,24,621,24,64.8,19.74
20,26,520,25,64.97,48.15
80,23.67,648,24,64.17,24.98
1,25.33,576,24,57.3,45.35
100,24.67,590,24,63.57,21.91
80,23.33,644,24,65.27,26.57
120,25.67,639,24,58.57,18.22
40,26,577,25,67.23,28.47
40,26,562,25,66.93,27.91
100,24,632,24,66.13,30.91
40,26,620,24,57.87,25.68
```

Figura 20 – Recorte arquivo de treinamento - Fonte: Elaborada pelo autor

Os dados de teste foram escolhidos aleatoriamente, contemplando 20% do total dos dados, enquanto que 80% foram utilizados no treinamento, totalizando respectivamente 21 e 84 registros.

5.2 Avaliação de Técnicas para Autoajuste Utilizando Aprendizado de Máquina

Antes de avaliar técnicas de aprendizado de máquina, buscou-se uma equação de regressão linear que representasse corretamente as saídas esperadas para os dados coletados e não obteve-se sucesso, corroborando com o que já havia sido levantado na revisão dos trabalhos relacionados.

Deste modo, uma única equação não foi capaz de apresentar um coeficiente de determinação linear considerado representativo para os três compostos utilizando apenas a leitura analógica da umidade e o valor de referência, com um coeficiente de correlação de 0.7857 e erro médio absoluto de 6.5138.

Por sua vez, considerando todos os atributos (dias, temperatura do ar, umidade do ar, temperatura do composto e umidade do composto), o coeficiente de correlação encontrado foi de 0.9075, com um erro médio absoluto de 4.9865.

Estes resultados, obtidos com todos os atributos, ainda não constituíram uma aproximação adequada o suficiente, já que estatisticamente um coeficiente de correlação possui maior relevância quanto mais próximo de 1 e o erro médio absoluto mais próximo de 0 possível.

Para pesquisar o melhor classificador para os dados considerados pelo RealSense, tendo em vista a quantidade de possibilidades existentes e os seus diferentes parâmetros (como apresentado na Seção 2.7.2), foi feita a opção de empregar o Auto-WEKA (KOTTHOFF *et al.*, 2017). Esta opção teve como critérios a reconhecida maturidade da plataforma junto a comunidade científica e os decorrentes ganhos potenciais tanto na assertividade dos resultados, como em tempo empregado em esforços de prototipação.

5.2.1 Etapas da Avaliação de Técnicas de Aprendizado de Máquina Explorando o Auto-WEKA

Inicialmente buscou-se um algoritmo de aprendizado de máquina que explicasse a relação direta entre a leitura analógica do sensor de umidade e o valor de referência apurado através da gravimetria. O Auto-WEKA apresentou como resultado o MLP (*Multilayer Perceptron*), contudo o coeficiente de correlação foi de apenas 0.7303, inviabilizando o trabalho apenas com essa grandeza de entrada.

Sendo assim, foram acrescentadas outras entradas além da umidade adquirida através do sensor capacitivo, como o número de dias decorridos desde o início da montagem da leira (entrada manual), temperatura do composto (adquirida pelo sensor Termopar), temperatura do ar e umidade do ar (adquiridos através do sensor DHT22).

Foi feita uma nova simulação, desta vez com os atributos acima mencionados, à exceção do atributo "Dias" (número de dias decorridos desde o início da montagem da leira).

O algoritmo apresentado pelo Auto-WEKA foi o *Vote*².

Na base de testes apresentou-se como resultado um coeficiente de correlação de 0.8856, com um erro médio absoluto de 3.229 pontos percentuais.

O resultado ainda não apresentava a aproximação adequada, já que estatisticamente um coeficiente de correlação possui maior relevância quanto mais próximo de

²Maiores informações em: <http://bit.ly/2ssE4pC>.

consistência perfeita com o conjunto inicial de treinamento e, embora resuma os dados, ele não tenta maximizar a precisão da classificação em novas instâncias, e isso ignora problemas do mundo real, como os ruídos. Já o IBL é um algoritmo incremental e tem como objetivo maximizar a acurácia sobre novas instâncias do problema (AHA; KIBLER; ALBERT, 1991).

A saída principal dos algoritmos IBL é uma descrição do conceito. Essa é uma função que mapeia instâncias para categorias. Uma descrição do conceito baseada em instância inclui um conjunto de instâncias armazenadas e, possivelmente, algumas informações sobre seus desempenhos anteriores durante a classificação (por exemplo, seu número de previsões de classificação corretas e incorretas). As descrições dos conceitos são determinadas pela forma como as funções de similaridade e classificação selecionadas do algoritmo IBL usam o conjunto atual de instâncias salvas.

Ainda segundo AHA; KIBLER; ALBERT (1991), a estrutura de todos algoritmos de IBL possuem 3 componentes:

- 1) Função de similaridade: calcula a similaridade entre uma instância de treinamento "i" e as instâncias na descrição do conceito. As semelhanças têm valores numéricos;
- 2) Função de classificação: recebe os resultados da função de similaridade e os registros de desempenho de classificação das instâncias na descrição de conceito. Ele produz uma classificação para "i";
- 3) Atualizador da descrição do conceito: mantém registros sobre o desempenho da classificação e decide quais instâncias incluir na descrição do conceito. As entradas incluem "i", os resultados de similaridade, os resultados da classificação e uma descrição atual do conceito. Ele produz a descrição de conceito modificado.

5.3 Considerações Finais do Capítulo

Estão representados neste capítulo os esforços de coleta de dados com o Nodo Sensor, a metodologia, os aspectos laboratoriais que constituem os valores de referência para esse trabalho e um descritivo da pesquisa para seleção da técnica de aprendizagem de máquina mais adequada para o RealSense.

Ressalta-se que a ferramenta Auto-WEKA representou ganhos de tempo e assertividade nos esforços de pesquisa que envolvem a seleção de algoritmos de aprendizado de máquina que melhor explicassem a relação entre as entradas coletadas e a saída esperada, constituindo-se um instrumento de apoio de grande valor para esta pesquisa.

Com base nos dados coletados, no valor de referência e no resultado obtido através do Auto-WEKA, no capítulo 6 é apresentada uma análise dos resultados alcançados.

6 ANÁLISE DOS RESULTADOS OBTIDOS

Neste capítulo é apresentada a técnica utilizada para implementação do algoritmo selecionado para o RealSense, um comparativo entre a predição e o valor de referência, outro comparativo entre resultados obtidos com o IBK e MLP e finalmente uma apresentação de resultado do RealSense com IBK em novo teste com amostras de compostos desconhecidos.

6.1 Implementação da Técnica de Aprendizado de Máquina Seleccionada

O Weka pode ser utilizado de três formas diferentes: interface gráfica, linha de comando e através de sua API. A interface gráfica fornece diversas ferramentas aos usuários através de janelas. A linha de comando é um meio utilizado para dar mais agilidade a processos repetitivos. O acesso via API é utilizado por desenvolvedores de *software* e fornece um meio prático de acesso às funcionalidades disponíveis.

Para utilizar a API do weka em um código Java, é preciso adicionar a biblioteca *weka.jar* e fazer os *imports* necessários.

Desta forma, foi implementado um *software* em Java utilizando Eclipse-IDE juntamente com Weka-API para certificação dos resultados.

Foi utilizada a linguagem Java por ser gratuita e pela integração com a API do Weka, que também é desenvolvido em Java com todas as classes disponibilizadas. A escolha pelo Eclipse IDE também deu-se pelo motivo de ser gratuito e oferecer suporte à linguagem Java.

6.2 Validação do RealSense e Resultados Comparativos

Uma vez concluída a programação do *software*, executou-se o treinamento com base nos parâmetros oferecidos pelo Auto-WEKA e gerou-se o modelo de regressão correspondente a partir dos mesmos dados de treinamento que foram submetidos ao modo gráfico do weka.

Após a geração do modelo, executou-se a função de teste empregando a base criada anteriormente para este fim, a qual compreende 21 registros.

A diferença entre o valor da gravimetria e da predição do modelo para os 21 registros submetidos à fase de testes é apresentada na Figura 22.

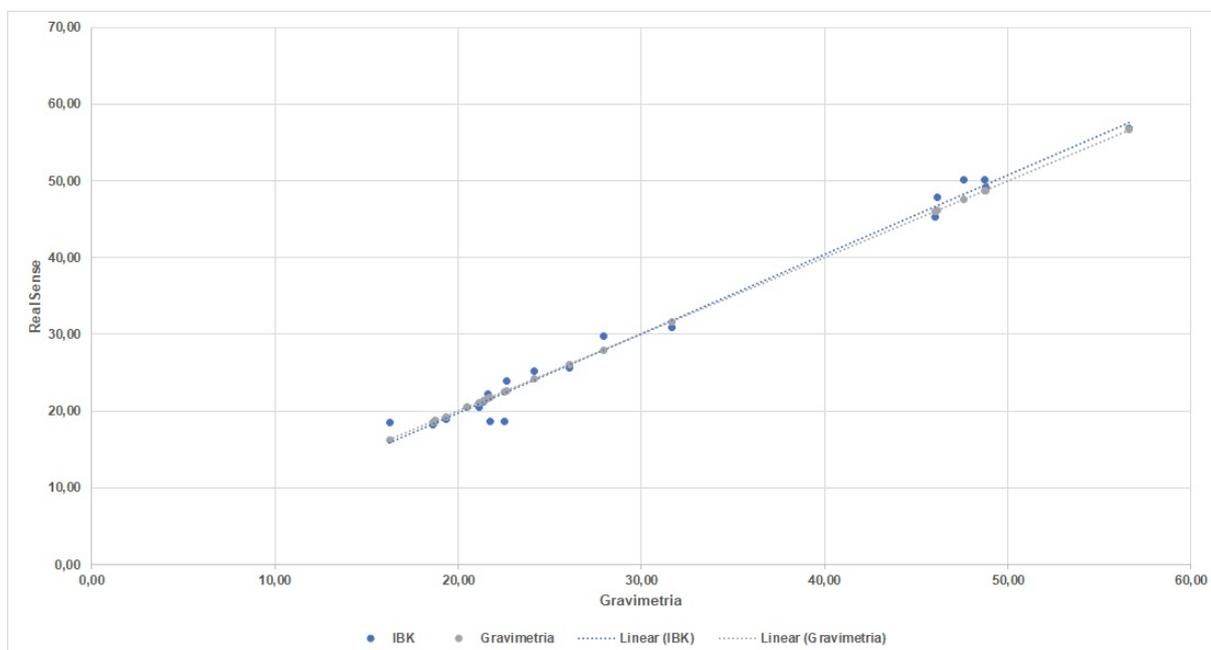


Figura 22 – Resultado do teste do modelo gerado (IBK) - Fonte: Elaborada pelo autor

Pode-se observar na Figura 22 que o modelo apresentou baixa variação entre o valor real medido e a predição, explicando 99,39% dos registros de teste, com um erro médio absoluto de apenas 1,1105.

Mesmo assim, com o propósito de confrontar o resultado do modelo obtido através do algoritmo IBK com outro algoritmo amplamente utilizado na literatura, o weka foi configurado pelo modo gráfico para apurar o resultado do MLP (*multilayer perceptron*), explicado no Capítulo 2, com a mesma base de treinamento e mesma base de teste que foi submetida ao IBK.

Foram experimentadas diversas configurações para o MLP, sendo que a que alcançou melhor resultado foi com 8 camadas ocultas. Na Figura 23 são apresentados graficamente os resultados obtidos para o modelo gerado com MLP.

Na Tabela 5 é apresentado um comparativo entre as duas abordagens (IBK e MLP), onde o algoritmo IBK foi superior ao MLP para o problema deste trabalho, apresentando um melhor resultado em todos os parâmetros de avaliação considerados.

A Figura 24 apresenta um gráfico comparativo das predições dos algoritmos IBK e MLP com relação ao valor de referência (gravimetria) para cada registro da base de testes, mostrando também uma linha de tendência linear que aponta visualmente uma maior proximidade entre o IBK e a gravimetria.

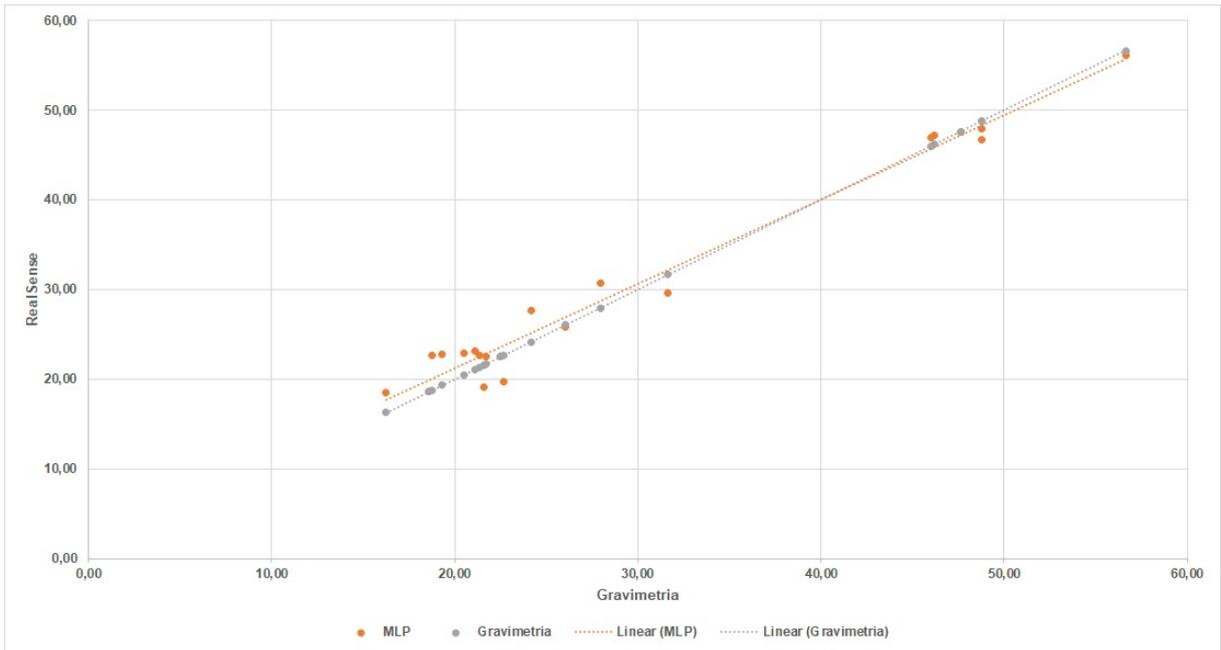


Figura 23 – Resultado do teste do modelo gerado (MLP) - Fonte: Elaborada pelo autor

Tabela 5 – Comparação de resultados entre IBK e MLP

Parâmetros de Avaliação	IBK	MLP
Coefficiente de Correlação	0.9939	0.9807
Erro médio absoluto	1.1105	2.594
Raiz do erro médio quadrático	1.5169	3.0288
Erro relativo absoluto	9.9747 %	23.3007 %
Raiz do erro relativo quadrático	12.0074 %	23.9749 %

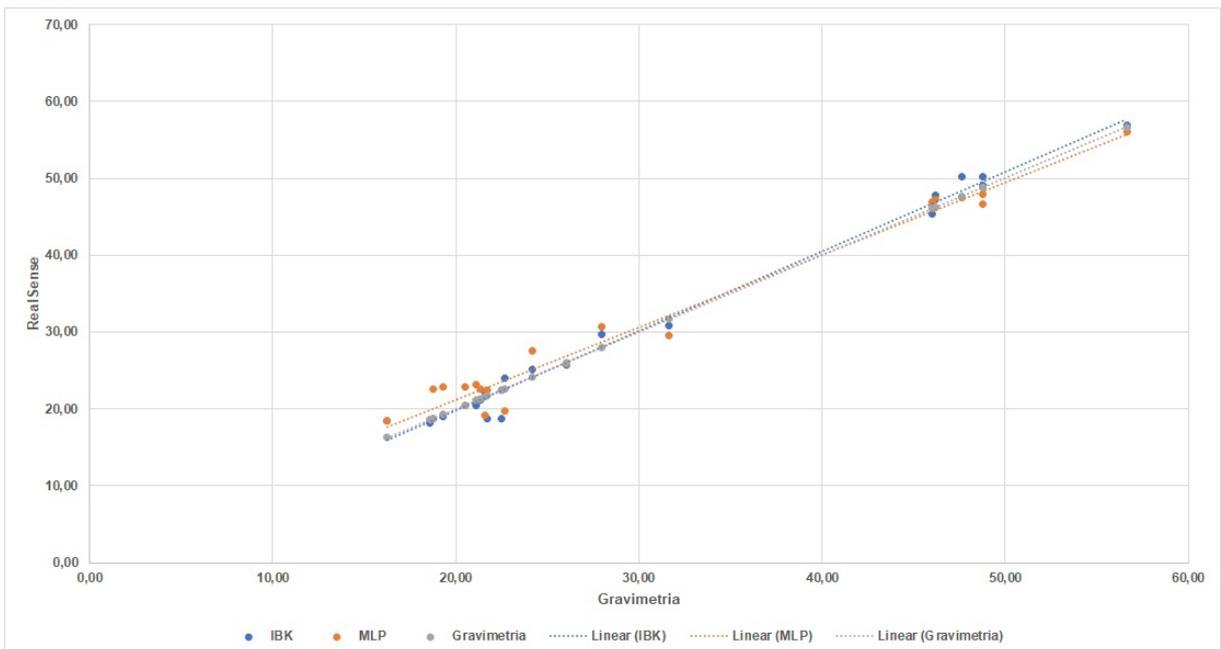


Figura 24 – Gráfico comparativo Gravimetria X IBK X MLP - Fonte: Elaborada pelo autor

Em um novo teste, desta vez com 3 (três) amostras novas, o valor de referência (gravimétrico) não foi apresentado ao módulo sensor — dados totalmente desconhecidos — e as referidas amostras foram de leiras de compostagem diferentes daquelas que foram submetidas ao treinamento inicial. Para essas amostras, para efeito comparativo, também foi coletado o percentual obtido pelo método empírico conhecido como teste de mão.

Os resultados foram comparados depois de concluídas as leituras pelos sensores, obtido o valor de predição e feita a gravimetria das amostras seguindo o mesmo protocolo dos testes anteriores. Esse comparativo pode ser verificado na Tabela 6.

As amostras em questão são constituídas apenas de Serragem e Biossólido.

Tabela 6 – Comparativo Gravimetria X Sensor X Teste de Mão

Amostra	Gravimetria (%)	Sensor com IBK (%)	Diferença Sensor X Grav. (pp)	Teste de Mão (%)	Diferença Teste de Mão X Grav. (pp)
1	31.37	28.47	-2.9	54	22.63
2	29.56	28.47	-1.09	50	20.44
3	49.68	48.15	-1.53	58	8.32

Foi possível constatar que, mesmo em amostras totalmente desconhecidas para o RealSense, a diferença da leitura ficou dentro do esperado. O método empírico do teste de mão se mostrou distante da realidade, tendo uma maior aproximação apenas na amostra 3.

6.3 Considerações Finais do Capítulo

Os diferentes testes de campo apontaram que o emprego combinado das diferentes medições oferecidas pelo Nodo Sensor trouxe uma sinergia que facultou a obtenção de níveis bastante elevados para a correlação obtida entre valores apurados pelo método Gravimétrico, empregado como referência, e os valores de saída oferecidos pelo RealSense.

Deste modo, ao longo dos diferentes testes envolvendo a concepção do Nodo Sensor, apesar da indicação da literatura quanto ao uso de sensores capacitivos, o mesmo não atingiu níveis de correlação representativos quando empregado de forma isolada.

O próximo capítulo discute as considerações finais decorrentes dos esforços de concepção do RealSense, bem como introduz possibilidades para continuidade dos trabalhos de pesquisa relativos ao mesmo.

7 CONSIDERAÇÕES FINAIS

Neste capítulo estão sumarizadas as principais conclusões obtidas durante o desenvolvimento desta dissertação. É também dado destaque à disponibilização do *dataset* produzido por consequência dos trabalhos de campo realizados, bem como são elencados os trabalhos futuros entendidos como prioritários para o avanço das pesquisas relacionadas ao RealSense.

7.1 Principais Conclusões

Durante o desenvolvimento deste trabalho, acompanhando os esforços de compostores e do próprio laboratório da UFPel onde foram feitas as análises de campo, pôde-se observar que o processo de compostagem, embora utilize técnicas tradicionais da área de Engenharia Ambiental, ainda possui desafios básicos relacionados ao seu acompanhamento científico, os quais comprometem a sua efetiva reprodutibilidade para uma produção em larga escala.

O método empírico do teste de mão, o qual é bastante utilizado enquanto um método rápido e possível de ser feito no próprio local da compostagem, apresentou resultados distantes daqueles obtidos por testes laboratoriais empregando o método gravimétrico, constatação esta que fortalece os propósitos desta dissertação. Esta situação traduz a necessidade de buscar uma alternativa que combine a agilidade do teste de mão, com uma precisão compatível com a do método gravimétrico.

A área de Inteligência Artificial é entendida como central para os principais avanços modernos em diferentes áreas do conhecimento. Entretanto, pesquisadores que não são oriundos da área de Computação enfrentam alguns dificultadores, principalmente aqueles associados à validação das diferentes técnicas existentes para aprendizagem de máquina considerando o cenário de aplicação em questão.

Desta forma, pode-se entender que o software Weka constitui efetivamente um facilitador para que profissionais de diferentes áreas do conhecimento possam se valer destas técnicas no desenvolvimento de suas pesquisas. Neste sentido, a plataforma Auto-WEKA constituiu uma importante contribuição. Dada a ampla documentação

disponibilizada pelos desenvolvedores, seu uso colaborou significativamente para realização dos trabalhos desta dissertação.

Entre os trabalhos encontrados na literatura, o que mais se aproxima deste estudo é o de LÓPEZ *et al.* (2014), o qual também se propõe a monitorar temperatura e umidade em compostagem empregando sensor capacitivo.

Sendo assim, dentre as constatações apresentadas por LÓPEZ *et al.* (2014), que são de ordem prática, buscou-se um comparativo entre este trabalho e o RealSense, podendo-se destacar que um diferencial significativo a favor do RealSense seria a sua não necessidade de calibração do sensor de umidade para cada tipo de leira.

Pode-se citar ainda a não necessidade de infraestrutura de rede, pois diferentemente do proposto por LÓPEZ *et al.* (2014), o RealSense tem a capacidade de trabalhar em modo *offline*, apresentando as informações em *display* LCD no momento da leitura e armazenando os dados localmente em cartão SD, permitindo que os mesmos possam ser transferidos para um computador central, caso seja de interesse do usuário.

Outro trabalho relacionado que buscou solução para medição do teor de umidade especificamente em compostagem foi o de SUEHARA *et al.* (1999). Os autores optaram por um equipamento de medição diferente (NIRS) do sensor selecionado para esta pesquisa, e empregaram técnicas de calibração também diferentes, fazendo uso de equações de regressão para corrigir as leituras. O trabalho é direcionado para um tipo específico de composto e apresentou como resultado um coeficiente de correlação entre leituras e predição de 0.979. O RealSense por sua vez, alcançou um coeficiente de correlação de 0.9939, demonstrando que o algoritmo de aprendizado de máquina se mostrou mais eficiente, podendo ser empregado em compostagens de diferentes naturezas.

A escolha pelo sensor capacitivo CS12 se justificou adequada para os propósitos deste trabalho, pois além de ser um sensor de baixo custo e resistente a corrosão, tendo obtido em relação ao método gravimétrico um desvio padrão entre 0.9 e 4.39, e para a diferença do valor real uma média de 1.11pp. Estes resultados são bastante satisfatórios no que diz respeito a precisão e a exatidão, as quais são medidas de qualidade para instrumentos de sensoriamento.

Por ser um equipamento portátil, o RealSense propicia maior praticidade de uso, permitindo que usuários responsáveis pelo monitoramento nas compostagens possam verificar os parâmetros de temperatura e umidade conforme suas necessidades, reposicionando o Nodo Sensor sempre que se fizerem necessários novos monitoramentos em quaisquer pontos da leira.

Para atender essa funcionalidade de operação portátil com alimentação por bateria, a escolha do microcontrolador foi fundamental, principalmente quando habilitada a função de leitura automática, com leituras de 10 em 10 minutos, pois o microcon-

trolador pode ser colocado em modo *Deep Sleep* entre as leituras. Neste modo, o consumo do microcontrolador fica em torno de 20 μA (ESPRESSIF, 2019), propiciando maior tempo de uso do RealSense na operação sem necessidade de recarga da bateria. A operação por bateria também foi entendida, durante o desenvolvimento desta dissertação, como importante para atender outros dois aspectos: a segurança dos operadores e o uso do Nodo Sensor em locais onde a disponibilidade de energia elétrica é reduzida.

A análise dos resultados obtidos indica que a abordagem proposta para o RealSense atendeu os objetivos deste trabalho, apresentando um conjunto de *hardware* e *software* que permitiu o autoajuste do sensor a ser utilizado na medição do teor de umidade em compostagens, encontrando um equilíbrio entre as leituras do sensor capacitivo e o valor de referência dado pela gravimetria.

Deste modo, um mesmo Nodo Sensor pode ser empregado não só durante os diferentes ciclos de maturação da compostagem em uma leira, mas também entre leiras de diferentes composições, sem necessidade de calibração em laboratório.

A técnica proposta se mostrou uma forma rápida e confiável para a medição de umidade em compostagens. Assim, a expectativa com a concepção do RealSense é prover condições para um controle mais eficiente das proporções do resíduo e dos materiais aeradores *in loco*, propiciando uma melhor atividade para os organismos microscópicos que ajudam na decomposição e conseqüentemente gerando um adubo mais adequado.

7.2 **Dataset Produzido no Desenvolvimento da Pesquisa**

Durante os esforços de pesquisa e revisão da literatura, não foram encontradas base de dados disponíveis que pudessem ser utilizadas neste trabalho.

Na perspectiva de contribuir com a comunidade científica para pesquisas futuras, o arquivo completo em formato *.arff* com todos os dados coletados ao longo desta pesquisa está disponível para *download* em <https://github.com/pmoncks/Dataset>.

7.3 **Trabalhos Futuros**

Durante os esforços de estudo e pesquisa decorrentes desta dissertação, diferentes possibilidades de continuidade do trabalho foram identificadas. Nesta seção estão elencados três possíveis trabalhos futuros, selecionados em função do seu potencial de contribuir com os resultados já atingidos.

Como um dos trabalhos futuros, pretende-se fazer novos estudos laboratoriais para encontrar outras propriedades físico-químicas dos compostos que apresentem relação direta com a variação do teor de umidade. A perspectiva com esta frente de estudo

é incorporar ao RealSense outros sensores, melhorando ainda mais a precisão das leituras do teor de umidade em compostagens.

Outra frente entendida como oportuna para continuidade das pesquisas relacionadas ao RealSense seria, preservando as funcionalidades do Nodo Sensor, já validadas pela comunidade que atua na área de compostagens, avaliar alternativas para o sensor empregado para medição de umidade. Esta avaliação deverá considerar os recentes avanços tecnológicos na área de sensoriamento, bem como a preservação de uma relação custo/benefício, que potencialize seu emprego por diferentes segmentos da sociedade.

Outrossim, considerando a comunidade usuária que deseje operar em rede, entende-se como promissor, para potencializar o emprego do RealSense, incorporar a abordagem para autoajuste do sensoriamento de umidade no Nodo Sensor, em uma arquitetura de *software* operando de forma autônoma em uma nuvem computacional. Esta arquitetura irá explorar mecanismo de aprendizagem de máquina que se valha de históricos de sensoriamentos para promover calibrações no Nodo Sensor que qualifiquem o procedimento de coleta de dados.

Por fim, é oportuno ressaltar a previsão de divulgar o RealSense junto à comunidade científica. Dentre os canais de publicação possíveis, destacamos entre os eventos o WCAMA — Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais, evento satélite do XL Congresso da Sociedade Brasileira de Computação - que acontece em Julho/2020 em Cuiabá/MT. Enquanto periódico da área de computação, identificou-se o Journal Computers and Electronics in Agriculture, com classificação A2 no sistema brasileiro de avaliação de periódicos.

Por sua vez, na área de ciências ambientais, identificou-se dois possíveis candidatos à publicação, o International Journal of Integrated Waste Management, Science and Technology e o Journal of Environmental Management, ambos com classificação A1 no sistema brasileiro de avaliação de periódicos.

REFERÊNCIAS

AHA, D. W.; KIBLER, D.; ALBERT, M. K. Instance-based learning algorithms. **Machine learning**, New York, NY, v.6, n.1, p.37–66, 1991.

AL-GHOBARI, H. M.; EL MARAZKY, M. S.; ABOUKARIMA, A. M.; MINYAWI, M. Calibration of Soil Water Content Data from EnviroSCAN System Using Artificial Neural Network. **American Journal of Experimental Agriculture**, Londres, v.12, n.5, 2016.

ANDA. **PRINCIPAIS INDICADORES DO SETOR DE FERTILIZANTES**. Disponível em: <<http://anda.org.br/estatisticas/>>. Acesso em: 2018-12-22.

ANNAN, A. Ground penetrating radar workshop notes. **Sensors & Software Inc.**, Ontario, Canada, 2001.

ARDUINO. **Arduino IDE**. Disponível em: <<https://www.arduino.cc/en/main/software>>. Acesso em: 2019-08-05.

BISHOP, C. M. **Pattern recognition and machine learning**. New York, NY: springer, 2006.

BOGENA, H. R. *et al.* Effective calibration of low-cost soil water content sensors. **Sensors**, Switzerland, 2017.

BOSLAUGH, S.; WATTERS, P. **Statistics in a nutshell: A desktop quick reference**. Sebastopol, CA, USA: O'Reilly Media, Inc., 2008.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro, RJ: LTC Editora, 2007.

CORRÊA, E.; CORRÊA, L.; PAZ, M. **Resíduos: análises físicas, químicas, microbiológicas, parasitológicas e toxicológicas**. Pelotas, RS, Brasil: Cópias Tanta Cruz, 2018. 125p.

CRUZ, T. M. L. *et al.* Avaliação de sensor capacitivo para o monitoramento do teor de água do solo. **Engenharia Agrícola**, Jaboticabal, SP, v.30, n.1, p.33–45, 2010.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA, E. **Sistema brasileiro de classificação de solos**. Rio de Janeiro, RJ: Embrapa, 2018.

ESALQ/USP. **Dependência na importação de fertilizantes é a principal fragilidade de agronegócio**. Disponível em: <<http://bit.ly/2Tah7Cp>>. Acesso em: 2019-01-16.

ESPRESSIF. **ESP8266EX Datasheet**. Disponível em: <<http://bit.ly/2NeHHXI>>. Acesso em: 2019-08-05.

FERNANDES, F.; SILVA, S. M. C. P. da. **Manual Prático Para a Compostagem De Biossólidos**. Rio de Janeiro: ABES, 1999. 84p.

FRANK, A. **Análise de Regressão**. Disponível em: <<http://bit.ly/306SRCG>>. Acesso em: 2019-07-03.

FREITAS, W. A. de. **Desenvolvimento e avaliação de um dispositivo capacitivo para manejo de irrigação**. 2014. 210p. Tese (Doutorado em Ciência da Computação) — Universidade Federal de Lavras.

GARDNER, C. M.; DEAN, T. J.; COOPER, J. D. Soil water content measurement with a high-frequency capacitance sensor. **Journal of Agricultural and Engineering Research**, Bedford, Reino Unido, 1998.

GEESING, D.; BACHMAIER, M.; SCHMIDHALTER, U. Field calibration of a capacitance soil water probe in heterogeneous fields. **Australian Journal of Soil Research**, Australia, 2004.

GUIMARÃES, P. L.; SANTANA, M. A.; OLIVEIRA, I. R.; JÚNIOR, J. C. T. Proposta de procedimento para calibração de sensores e medidores de umidade do solo (Soil Moisture). In: 2010, São Paulo. **Anais...** Congresso da Qualidade em Metrologia Rede Metrológica do Estado de São Paulo, 2010.

HAYKIN, S. **Neural Networks and Learning Machines**. [S.l.]: Pearson Education, 2011.

JOHNSON, P. M. S. **The Design of an Integrated Soil Moisture Sensor for Agriculture**. 2007. 181p. Tese (Doutorado em Ciência da Computação) — School of Microelectronics Engineering, Australia.

JOHNSON, P.; WATLING, K.; THIEL, D. V.; JAMES, D. A. Validation of a soil interface model to account for apparent aberrations in capacitive soil moisture sensors. In: MICROELECTRONICS: DESIGN, TECHNOLOGY, AND PACKAGING II, 2006, Austrália. **Anais...** International Society for Optics and Photonics, 2006. v.6035.

JORDÃO, M. D. *et al.* Low-cost automatic station for compost temperature monitoring. **Revista Brasileira de Engenharia Agrícola e Ambiental**, São Paulo, SP, v.21, n.11, p.809–813, 2017.

KIZITO, F. *et al.* Frequency, electrical conductivity and temperature analysis of a low-cost capacitance soil moisture sensor. **Journal of Hydrology**, Amsterdam, Holanda, v.352, n.3-4, p.367–378, 2008.

KOTTHOFF, L. *et al.* Auto-WEKA 2.0: Automatic model selection and hyperparameter optimization in WEKA. **The Journal of Machine Learning Research**, Estados Unidos, v.18, n.1, p.826–830, 2017.

LÓPEZ, M. *et al.* Intelligent composting assisted by a wireless sensing network. **Waste management**, Amsterdam, Holanda, v.34, n.4, p.738–746, 2014.

MARTÍ, P.; GASQUE, M.; GONZÁLEZ-ALTOZANO, P. An artificial neural network approach to the estimation of stem water potential from frequency domain reflectometry soil moisture measurements and meteorological data. **Computers and electronics in agriculture**, Amsterdam, Holanda, v.91, p.75–86, 2013.

MENDES, P. C. d. S. **Caracterização de um Sensor para Medição de Umidade do Solo com Termo-resistor a Temperatura Constante**. 2006. Tese (Doutorado em Ciência da Computação) — Universidade Federal da Bahia.

NUNES, M. Compostagem de Resíduos para Produção de Adubo Orgânico na Pequena Propriedade. **Circular Técnica**, Rio de Janeiro, RJ, 2009.

OLIVEIRA, M. A. de; AMARAL, J. L. do; AMARAL, J. F. do. Algoritmos para auto-ajuste de sensores utilizando redes neurais. **VIII Seminário Internacional de Metrologia Elétrica**, João Pessoa ,PB, 2009.

PHILIPPI JR, A.; ROMERO, M. d. A.; BRUNA, G. C. Curso de gestão ambiental. In: **Curso de gestão ambiental**. São Paulo, SP: Editora Manole, 2014.

PIZETTA, S. C. *et al.* Calibração de um sensor capacitivo para estimativa da umidade em três classes de solos. **IRRIGA**, São Paulo, SP, 2017.

RIVERA, J. *et al.* Self-calibration and optimal response in intelligent sensors design based on artificial neural networks. **Sensors**, Basel, Suíça, 2007.

Russell, Stuart J.; Norvig, P. **Inteligência Artificial**. Washington, Estados Unidos: Journal of Chemical Information and Modeling, 2013.

SINGH, A. Foundations of Machine Learning. **SSRN Electronic Journal**, Estados Unidos, 2019.

SUEHARA, K. I.; OHTA, Y.; NAKANO, Y.; YANO, T. Rapid measurement and control of the moisture content of compost using near-infrared spectroscopy. **Journal of Bioscience and Bioengineering**, Japão, 1999.

VRETTOS, G.; KAZAMIAS, G.; LEKKAS, D. Smart Compost Monitoring System using Open Source Technologies. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS, 2017, Rhodes, Grécia. **Anais...** 15th International Conference on Environmental Science And Technology, 2017.

WAIKATO, U. O. **Weka 3**: Machine Learning Software in Java. Disponível em: <<https://www.cs.waikato.ac.nz/ml/weka/>>. Acesso em: 2019-08-07.

WITTEN, I. H.; FRANK, E.; HALL, M. A.; PAL, C. J. **Data Mining**: Practical machine learning tools and techniques. São Francisco, Estados Unidos: Morgan Kaufmann, 2016.

WORLD BANK. **Área Agriculturável 2015**. Disponível em: <<http://bit.ly/3a21LIU>>. Acesso em: 2019-08-29.

APÊNDICE A TABULAÇÃO DOS DADOS DO COMPOSTO 1

Composto 1		Leituras do Sensor								Ar		Gravimetria
Dias	Amostras	1		2		3		Média		Temp	Umíd	Umíd
		Temp	Analog	Temp	Analog	Temp	Analog	Temp	Analog			
1	1	23	537	23	535	23	464	23,00	512	24,00	58,97	56,08
	2	23	444	24	446	24	436	23,67	442	24,00	58,90	56,64
	3	24	431	23	387	23	440	23,33	419	24,00	58,30	55,89
	4	23	400	24	394	23	397	23,33	397	24,00	58,40	56,01
	5	25	429	24	471	24	442	24,33	447	24,00	58,17	56,86
20	1	25	481	25	518	25	454	25,00	484	24,00	58,80	44,71
	2	24	465	24	461	24	449	24,00	458	24,00	58,87	43,88
	3	25	473	24	460	24	453	24,33	462	24,00	58,37	45,49
	4	24	460	25	439	24	405	24,33	435	24,00	58,23	44,58
	5	24	427	23	407	24	447	23,67	427	24,00	57,43	44,24
40	1	25	490	25	481	25	485	25,00	485	24,00	57,37	29,63
	2	25	453	25	462	24	455	24,67	457	24,00	57,67	29,74
	3	25	460	25	450	25	456	25,00	455	24,00	58,23	30,29
	4	25	498	24	514	25	504	24,67	505	24,00	57,50	29,5
	5	25	515	25	506	25	502	25,00	508	24,00	57,70	30,05
60	1	25	666	25	638	24	634	24,67	646	24,00	65,17	17,2
	2	24	633	24	623	23	621	23,67	626	24,00	65,17	18,38
	3	24	619	24	617	24	617	24,00	618	24,00	65,33	18,55
	4	23	617	24	611	24	609	23,67	612	24,00	65,07	18,72
	5	24	608	24	629	24	626	24,00	621	24,00	64,80	19,74
80	1	25	626	24	624	25	623	24,67	624	24,00	64,97	19,02
	2	24	623	26	616	25	615	25,00	618	24,00	64,80	19,31
	3	25	616	25	609	24	608	24,67	611	24,00	64,60	19,48
	4	24	608	25	632	25	631	24,67	624	24,00	63,97	19,36
	5	25	632	25	617	25	615	25,00	621	24,00	64,27	19,64
100	1	25	614	25	615	25	609	25,00	613	24,00	64,03	21,93
	2	25	611	25	601	25	600	25,00	604	24,00	63,73	21,99
	3	25	599	25	586	24	584	24,67	590	24,00	63,57	21,91
	4	24	585	25	582	25	582	24,67	583	24,00	64,17	23,18
	5	25	617	26	615	26	615	25,67	616	24,00	64,47	22,78
120	1	26	597	26	597	25	606	25,67	600	25,00	64,13	20,5
	2	25	589	26	587	25	586	25,33	587	25,00	63,30	21,13
	3	26	613	25	612	25	612	25,33	612	25,00	63,50	21,16
	4	26	601	25	597	26	597	25,67	598	25,00	64,07	20,52
	5	26	608	26	609	26	609	26,00	609	25,00	64,07	19,9

Figura 25 – Tabulação dos dados do composto 1 - Fonte: Elaborada pelo autor

APÊNDICE B TABULAÇÃO DOS DADOS DO COMPOSTO 2

Composto 2		Leituras do Sensor								Ar		Gravimetria
Dias	Amostras	1		2		3		Média		Temp	Umid	Umid
		Temp	Analog	Temp	Analog	Temp	Analog	Temp	Analog			
1	1	27	569	26	542	26	541	26,33	551	25,00	63,67	48,76
	2	26	561	26	560	26	558	26,00	560	25,00	64,23	49,61
	3	26	539	26	541	27	540	26,33	540	25,00	64,00	50,19
	4	26	552	26	549	26	547	26,00	549	26,00	63,83	47,6
	5	26	558	26	557	26	555	26,00	557	25,00	63,17	48,03
20	1	26	535	26	525	26	523	26,00	528	25,00	64,47	48,82
	2	26	523	26	519	26	517	26,00	520	25,00	64,97	48,15
	3	26	516	26	516	25	515	25,67	516	25,00	64,17	47,51
	4	26	480	26	477	26	477	26,00	478	26,00	64,17	49,13
	5	25	456	26	456	26	456	25,67	456	26,00	63,77	48,79
40	1	26	585	26	590	26	584	26,00	586	25,00	66,83	29,74
	2	26	599	26	597	26	596	26,00	597	25,00	67,10	27,94
	3	26	565	26	561	26	561	26,00	562	25,00	66,93	27,91
	4	26	584	26	581	26	579	26,00	581	25,00	66,97	26,53
	5	26	580	26	576	26	574	26,00	577	25,00	67,23	28,47
60	1	26	633	26	630	26	631	26,00	631	25,00	66,47	18,12
	2	26	622	26	620	26	620	26,00	621	25,00	66,67	19,13
	3	26	626	26	623	26	620	26,00	623	25,00	67,10	19,99
	4	26	620	27	619	26	619	26,33	619	25,00	67,50	21,19
	5	26	594	26	595	26	594	26,00	594	25,00	67,40	21,37
80	1	26	610	26	614	26	613	26,00	612	25,00	67,60	18,72
	2	27	587	26	584	27	584	26,67	585	25,00	67,47	21,14
	3	26	611	26	609	26	605	26,00	608	25,00	67,50	21,74
	4	26	606	26	605	26	604	26,00	605	25,00	67,70	22,51
	5	26	598	26	597	26	597	26,00	597	25,00	67,53	18,75
100	1	26	628	27	627	27	626	26,67	627	25,00	67,80	14,92
	2	27	610	27	609	27	609	27,00	609	25,00	67,80	15,35
	3	26	635	27	632	27	632	26,67	633	25,00	67,87	16,75
	4	27	619	26	618	26	616	26,33	618	25,00	67,80	15,93
	5	26	606	27	606	27	605	26,67	606	25,00	66,70	17,27
120	1	26	640	26	639	25	639	25,67	639	24,00	58,57	18,22
	2	26	650	26	648	25	648	25,67	649	24,00	58,30	18,6
	3	26	644	26	644	26	643	26,00	644	24,00	57,77	18,57
	4	26	641	26	640	26	640	26,00	640	24,00	57,23	16,27
	5	26	649	26	648	26	649	26,00	649	24,00	57,40	18,51

Figura 26 – Tabulação dos dados do composto 2 - Fonte: Elaborada pelo autor

APÊNDICE C TABULAÇÃO DOS DADOS DO COMPOSTO 3

Composto 3		Leituras do Sensor								Ar		Gravimetria
Dias	Amostras	1		2		3		Média		Temp	Umid	Umid
		Temp	Analog	Temp	Analog	Temp	Analog	Temp	Analog			
1	1	26	601	25	600	25	598	25,33	600	24,00	57,07	47,82
	2	25	578	26	577	25	574	25,33	576	24,00	57,30	45,35
	3	25	616	26	613	26	608	25,67	612	24,00	57,30	46,17
	4	26	584	26	582	26	582	26,00	583	24,00	57,30	47,04
	5	25	541	26	541	26	542	25,67	541	24,00	57,10	46,03
20	1	25	500	25	497	25	497	25,00	498	24,00	57,00	44,56
	2	25	516	25	510	25	508	25,00	511	24,00	57,20	48,33
	3	25	534	25	531	25	529	25,00	531	24,67	57,27	46,67
	4	25	505	25	500	26	501	25,33	502	25,00	57,20	46,34
	5	25	535	25	531	25	527	25,00	531	25,00	57,33	45,89
40	1	26	620	25	618	25	616	25,33	618	24,34	57,60	24,16
	2	26	613	26	609	25	608	25,67	610	25,00	58,20	23,62
	3	26	607	26	605	26	604	26,00	605	25,00	57,63	26,05
	4	26	621	26	619	26	619	26,00	620	24,00	57,87	25,68
	5	26	625	26	624	25	622	25,67	624	24,34	57,77	25,2
60	1	25	654	25	654	25	653	25,00	654	23,00	66,17	22,19
	2	25	654	24	654	25	654	24,67	654	24,00	65,30	23,4
	3	25	657	24	656	24	656	24,33	656	24,00	64,30	22,36
	4	25	655	25	654	25	654	25,00	654	24,00	64,60	23,97
	5	24	653	25	653	25	653	24,67	653	24,00	64,73	22,65
80	1	25	649	25	649	24	648	24,67	649	24,00	64,50	26,5
	2	24	649	24	647	23	647	23,67	648	24,00	64,17	24,98
	3	23	646	23	644	23	644	23,00	645	24,00	65,03	26,02
	4	23	643	24	645	23	644	23,33	644	24,00	65,27	26,57
	5	23	651	24	651	24	651	23,67	651	24,00	65,20	26,98
100	1	24	631	24	629	4	629	17,33	630	24,00	65,53	30,84
	2	24	633	24	631	24	632	24,00	632	24,00	66,13	30,91
	3	24	639	23	639	24	639	23,67	639	24,00	66,37	31,65
	4	24	636	24	636	24	636	24,00	636	24,00	64,87	30,28
	5	24	635	24	633	24	635	24,00	634	24,00	65,07	30,16
120	1	25	657	25	657	25	656	25,00	657	24,00	64,97	21,61
	2	25	657	25	657	25	656	25,00	657	24,00	64,53	22,19
	3	26	656	26	656	26	656	26,00	656	24,00	64,90	23,09
	4	26	654	26	654	26	654	26,00	654	24,00	65,50	22,53
	5	25	656	26	656	26	656	25,67	656	24,00	65,87	21,21

Figura 27 – Tabulação dos dados do composto 3 - Fonte: Elaborada pelo autor

RealSense: Uma Abordagem Explorando Aprendizado de Máquina no Monitoramento de Temperatura e Umidade em Sistemas de Compostagem – Paulo César Sedrez Moncks



UNIVERSIDADE FEDERAL DE PELOTAS
Centro de Desenvolvimento Tecnológico
Programa de Pós-Graduação em Computação



Dissertação

RealSense: Uma Abordagem Explorando Aprendizado de Máquina no Monitoramento de Temperatura e Umidade em Sistemas de Compostagem

PAULO CÉSAR SEDREZ MONCKS

Pelotas, 2020