

LUIS AUGUSTO GOMES ROCHA

**DESENVOLVIMENTO DE UM SISTEMA DE COLETA DE DADOS AMBIENTAIS
EM AMBIENTE PROTEGIDO**

Botucatu

2022

LUIS AUGUSTO GOMES ROCHA

**DESENVOLVIMENTO DE UM SISTEMA DE COLETA DE DADOS AMBIENTAIS
EM AMBIENTE PROTEGIDO**

Tese apresentada à Faculdade de Ciências Agronômicas da Unesp – Campus de Botucatu, para obtenção do título de Doutor em Ciência Florestal – Programa de Pós-Graduação em Ciência Florestal.

Orientador: Iraê Amaral Guerrini

Coorientador: João Eduardo Machado
Perea Martins

Botucatu

2022

R672d

Rocha, Luis Augusto Gomes

Desenvolvimento de um sistema de coleta de dados ambientais em ambiente protegido / Luis Augusto Gomes Rocha. -- Botucatu, 2022

90 p. : il., tabs., fotos

Tese (doutorado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrônômicas, Botucatu

Orientador: Iraê Amaral Guerrini

Coorientador: João Eduardo Machado Perea Martins

1. Cultivo protegido. 2. Sensores de baixo custo. 3. Estufas. 4. Redes neurais. 5. LoRa. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrônômicas, Botucatu. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: DESENVOLVIMENTO DE UM SISTEMA DE COLETA DE DADOS EM AMBIENTE PROTEGIDO**AUTOR: LUÍS AUGUSTO GOMES ROCHA****ORIENTADOR: IRAÉ AMARAL GUERRINI****COORDENADOR: JOAO EDUARDO MACHADO PEREA MARTINS**

Aprovado como parte das exigências para obtenção do Título de Doutor em CIÊNCIA FLORESTAL,
pela Comissão Examinadora:

Prof. Dr. JOAO EDUARDO MACHADO PEREA MARTINS (Participação Virtual)
Departamento de Computação / Faculdade de Ciências de Bauru



Prof. Dr. ROBERTO LYRA VILLAS BÓAS (Participação Virtual)
Ciência Florestal Solos e Ambiente / Faculdade de Ciências Agronômicas de Botucatu UNESP



Prof. Dr. FERNANDO BROETTO (Participação Virtual)
Química e Bioquímica / Instituto de Biociências de Botucatu UNESP



Prof. Dr. RAPHAEL MOREIRA BEIRIGO (Participação Virtual)
/ CCA/UFPB Câmpus II/Areia (PB)



Profa. Dra. SIMONE DAS GRAÇAS DOMINGUES PRADO (Participação Virtual)
Departamento de Computação / Faculdade de Ciências de Bauru



Botucatu, 03 de fevereiro de 2022

A Deus, pela graça de poder viver nesta época, neste planeta e com estas pessoas que fazem parte do meu caminho. Obrigado por sempre me dar o conforto de poder crer que existe um lado bom na natureza humana, podendo hoje sentir que, mesmo em anos tão atípicos e difíceis, dias melhores virão.

AGRADECIMENTOS

Obrigado, minha mãe.... Sinto muita saudade e espero que tenha orgulho de mim.

Mariana e Jorge, obrigado pelo exemplo e pelos filhos maravilhosos...

Minha segunda mãe, Ana... a senhora me possibilitou ter tudo que alcancei até hoje, não seria ninguém sem seu amor e apoio! Te amo.

Meu tio, José Ricardo, por ser um segundo pai, sendo um grande exemplo na minha vida!

Agradeço aos meus amigos Ivo, Renata, Cris, Lucas, Rodrigo, Isa, Thiago e Marcelo, por sempre me ajudarem, independente da hora e lugar.

Ao meu pai, Francisco, por me ensinar como ser uma pessoa amorosa! À minha madrastra, Ana, e às minhas irmãs Juliana e Iris, por me acolherem como parte dessa nova família.

Aos professores Iraê e Pereira, por confiarem em mim e me fornecerem sua visão a respeito de como desenvolver uma pesquisa. Tenho os senhores como um grande exemplo!

A Pamela, por toda parceria e apoio.... Após tantos anos é impossível conseguir destacar todas as coisas que sou grato! Você é uma pessoa muito especial e nesse momento, por mim, preciso agradecer o tanto que mudei a forma de entender a sociedade e a importância do feminismo em todas as questões, mas principalmente preciso agradecer por ter me ensinado como me relacionar com meus sentimentos, me deixando pronto para realmente buscar pela felicidade.

Agradeço ao Vô Careca, Vô Didi, Vô Antônio, Salete, Antônio e Arthur.... Me acolheram, mostrando que existem várias formas de se relacionarem e cuidar. Sou grato por terem me mostrado que a religião exerce um papel fundamental no processo de buscar a felicidade.

A Fernanda, por ressignificar o amar! Você é uma mulher incrível e merece ser muito feliz! Pretendo fazer parte dessa felicidade conseguindo tirar aqueles ataques de risos que amo tanto! Sou grato a Deus por ter colocado você na minha vida!

Agradeço a Mônica, Geraldo e Rute, por me acolherem mostrando como é gostoso ter uma refeição cheia de risadas e frases bobas!

A Jony e Lolla.... Tentei aprender que certas coisas não podemos mudar, porém é importante perceber que poder cuidar e amar é algo maravilhoso independentemente da situação.

Agradeço a FAPESP, Verdaz, ZUP e Capgemini, por me darem oportunidade de trabalhar e desenvolver pesquisa!

E Cá, te amo muito! Tenho muita sorte de ser seu irmão.... Me desculpa se não consegui estar ao seu lado em todos os momentos em que você precisou! Me sinto muito culpado por isso e pretendo um dia conseguir lidar com tudo isso.... Queria dizer que mesmo não conseguindo expressão todo meu amor e pela minha ausência física em todos esses anos, sempre tentei proteger você da forma que conseguia desejando sempre que você fosse muito feliz! Tenho muito orgulho pela supermãe que você é! Pegar a Nina no colo foi algo muito especial.... Me deu esperança que podemos ser felizes criando nossas famílias da forma que nunca tivemos.... Tenho certeza que nossa mãe sente muito orgulho de você! Eu sinto muito orgulho de você! Te amo!

RESUMO

As mudanças climáticas estão afetando a produtividade agrícola em nível global, o que faz necessário novas pesquisas em meios produtivos mais sustentáveis. Desta forma, é pertinente destacar que a produção de alimentos em estufas é um dos possíveis caminhos para uma intensificação da produção de forma sustentável, podendo obter uma eficiência até 10 vezes maior por área quando em comparação com a produção em campo aberto. A possibilidade de migrar o sistema de produção de campo para estufas ainda é uma barreira para pequenos produtores, pois seu custo de implementação estrutural e de monitoramento nem sempre é viável. Um dos grandes pontos positivos do cultivo protegido é o controle das variáveis microclimáticas, sendo o monitoramento dessas variáveis efetuado por dispositivos produzidos por empresas como WIDITEC, Vaisala ou Campbell, necessitando de um custo inicial de investimento muito superior ao que um produtor de pequeno porte pode custear. Neste sentido, é pertinente salientar que inovações tecnológicas favorecem o desenvolvimento de novas soluções, podendo estas serem implementadas com sensores de baixo custo, ampliando assim a acessibilidade para pequenos produtores. Dentro deste contexto, o presente estudo apresenta o desenvolvimento de um sistema de coleta de dados ambientais de baixo custo comparando dois modelos de calibração efetuados por regressões polinomiais e redes neurais artificiais, utilizando um sensor meteorológico de referência (Vaisala modelo HMP45C) para coleta das variáveis temperatura do ar e umidade relativa do ar. O experimento foi instalado em casa de vegetação no campus da UNESP de Botucatu-SP, os sensores foram instalados no abrigo meteorológico construído por meio de impressão 3D, as aferições deram-se no período de 13 de setembro de 2018 e estenderam-se até o dia 11 de fevereiro de 2019 em intervalos de cinco segundos, resultando em médias por minuto. Dentro desse período, buscou-se levantar os dias em que ocorressem as maiores variações, obtendo-se, então, o período de início às 12:00:00 do dia 11/11/2018 até 10:20:00 do dia 15/11/2018. Conclui-se que o sensor BME280 apresenta o melhor desempenho, com erro médio absoluto (MAE) de 0,64 °C, erro quadrático médio (MSE) de 1,38 °C, coeficiente de determinação de R^2 : 0,925 para temperatura e erro médio absoluto (MAE) de 4,14% UR, erro quadrático médio (MSE) de 29,39% UR, coeficiente de determinação de R^2 : 0,871 para umidade

relativa do ar. Quando comparado às metodologias de ajustes dos sensores utilizando regressões polinomiais e redes neurais, foi possível verificar que a aplicação de redes neurais apresentou os melhores ajustes em todos os casos.

Palavras-chave: Estufas; cultivo protegido; sensores de baixo custo; regressão polinomial; redes neurais.

ABSTRACT

Climate change is globally affecting agricultural productivity, which makes new research into more sustainable means of production necessary. Thus, it is pertinent to highlight that the production of food in greenhouses is one of the possible ways to intensify production sustainably, being able to obtain an efficiency up to 10 times higher per area when compared to production in the open field. The possibility of migrating the production system from open field to greenhouses is still an obstacle for small producers, because its structural implementation and monitoring costs are not always feasible. One of the great positive points of protected cultivation is the control of microclimate variables, which is done by devices, produced by companies such as WIDITEC, Vaisala, or Campbell, that require an initial investment cost much higher than what a small producer can afford. In this sense, it is pertinent to note that technological innovations favor the development of new solutions, which can be implemented with low-cost sensors, thus increasing the accessibility for small producers. Within this context, the present study presents the development of a low-cost environmental data collection system comparing two calibration models performed by polynomial regression and artificial neural networks, using a meteorological reference sensor (Vaisala model HMP45C) to collect the air temperature and relative humidity variables. The experiment was installed in a greenhouse on the campus of UNESP in Botucatu-SP, the sensors were installed in the meteorological shelter built through 3D printing, and the measurements were given in the period from September 13, 2018 and extended until February 11, 2019, in intervals of five seconds, resulting in averages per minute. Within this period, we collected the data about the days in which the greatest variations occurred, obtaining, then, the period starting at 12:00:00 on 11/11/2018 until 10:20:00 on 11/15/2018. It was concluded that the BME280 sensor presents the best performance, with mean absolute error (MAE) of 0.64 °C, mean square error (MSE) of 1.38 °C, coefficient of determination of R^2 : 0.925 for temperature and mean absolute error (MAE) of 4.14% RH, mean square error (MSE) of 29.39% RH, coefficient of determination of R^2 : 0.871 for relative humidity. When compared to the sensor adjustment methodologies using polynomial regressions and neural networks, it was possible to verify that the application of neural networks presented the best settings in all the cases.

Keywords: Greenhouses; protected cultivation; low cost sensors; polynomial regression; neural networks.

SUMÁRIO

INTRODUÇÃO GERAL.....	15
CAPÍTULO 1 – DESENVOLVIMENTO DE UM SISTEMA DE COLETA DE DADOS AMBIENTAIS DE BAIXO CUSTO PARA ESTUFAS COM CALIBRAÇÃO UTILIZANDO AJUSTE POLINOMIAL.....	18
1.1 INTRODUÇÃO.....	18
1.2 MATERIAL E MÉTODOS.....	20
1.3 RESULTADOS E DISCUSSÃO.....	25
1.4 CONSIDERAÇÕES GERAIS.....	36
1.5 CONCLUSÃO.....	43
REFERÊNCIAS.....	45
 CAPÍTULO 2 – CALIBRAÇÃO DE SENSORES DE BAIXO CUSTO POR REGRESSÕES POLINOMIAIS E REDES NEURAIS ARTIFICIAIS PARA APLICAÇÃO EM ESTUFAS.....	 49
2.1 INTRODUÇÃO.....	49
2.2 MATERIAL E MÉTODOS.....	51
2.3 RESULTADOS E DISCUSSÃO.....	59
2.4 CONCLUSÕES.....	74
REFERÊNCIAS.....	76
CONSIDERAÇÕES FINAIS.....	82
REFERÊNCIAS.....	83

INTRODUÇÃO GERAL

Um dos patamares da economia brasileira é o agronegócio, sendo de crucial importância para o crescimento do país. Este sistema produtivo é altamente dependente de fatores climáticos, cujas condições severas podem afetar a produtividade e o manejo das culturas, impactando fatores sociais, econômicos e políticos.

Segundo Sigillo (2020), muitos produtores contabilizam prejuízos devido a variações climáticas em suas plantações, gerando queda em suas rendas, baixa na qualidade do produto e consequente aumento nos preços dos hortifrutigranjeiros, prejudicando, além dos agricultores, a população que consome esses produtos. Ainda segundo o autor, o impacto adverso das mudanças climáticas sobre a agricultura é uma questão sobre a qual pesquisadores e produtores têm dado especial atenção, sendo uma alternativa para contornar esses desafios a utilização de estufas para os sistemas produtivos.

O cultivo em ambientes protegidos é uma atividade que se encontra em franca expansão no Brasil (SOUSA, 2020), e as principais vantagens dessa técnica são a possibilidade de produção nos períodos de entressafra, regularização da oferta, melhor qualidade dos produtos e controle microclimático.

Os fatores ambientais significativos no interior de estufas para qualidade e melhor produtividade são temperatura do ar, umidade relativa do ar, iluminação, radiação e umidade do solo, sendo que o monitoramento contínuo desses fatores fornece informações para tomada de decisões nos tratamentos culturais (HANGGORO, 2013). De forma geral, pequenos agricultores não possuem recursos necessários para automatização da coleta de dados ambientais em estufas, não conseguindo detectar com precisão as informações de variáveis cruciais, como umidade e temperatura (INÁCIO, 2020).

Dentro desse contexto, é pertinente desenvolver pesquisas focadas em plataformas livres e sensores de baixo custo que apresentem correlações próximas a soluções comerciais. Tais pesquisas podem fornecer a esses agricultores uma possibilidade de automatizar seus sistemas produtivos com baixo custo e

confiabilidade nas leituras, auxiliando na competitividade, rentabilidade e tomada de decisões no trato cultural.

Em conjunto, é pertinente salientar que o uso de novas tecnologias e plataformas de prototipação colaboram para redução dos custos de implantação de sistemas de monitoramento, ampliando o acesso a pequenos produtores e instituições de pesquisa, levando ao campo novas possibilidades. Desta forma, destaca-se o desenvolvimento da Internet das Coisas (IoT) e Redes Neurais, que nos últimos anos tiveram grande impacto no processo de monitoramento e na tomada de decisões em cultivos protegidos (SAGHEER, 2021; JUNG, 2020; ZHANG, 2020; RAJ, 2019; HABARAGAMUWA, 2018; MA, 2018; MOON, 2018, PALLAVI, 2017).

O desenvolvimento da Internet das Coisas (IoT) refere-se a uma rede global de objetos inteligentes, ou "coisas", com base em sensores, munidos com microcontroladores e recursos de rede. Nesse quadro, as tecnologias de comunicação podem melhorar os métodos atuais de monitoramento de estufas, apoiando a resposta apropriada em tempo real para uma ampla gama de aplicações (SAAB, 2018; RAJAB, 2018).

Na maioria dos casos, a utilização de sensores de baixo custo utiliza métodos estatísticos clássicos para ajustar as leituras (SILVA, 2006; FERNANDES, 2015; TEIXEIRA, 2017), sendo um desses métodos a aplicação de regressões polinomiais, que possibilita uma análise utilizando regressão na qual a relação entre as variáveis independentes e as variáveis dependentes são modeladas no polinômio de enésimo grau.

Outra opção para ajustes de sensores é a aplicação de redes neurais (LI, 2004; DUFOUR, 2005; TIANLONG, 2010; LINO, 2017; NICOLSI, 2017; ALI, 2019; JINDONG, 2019; KOCHHAR, 2019; ROLIM, 2021), porém esse método de calibração não é amplamente difundido para sensores utilizados em estufas, sendo esta uma possibilidade para a democratização e distribuição dessa tecnologia, favorecendo pequenos produtores a sistemas de monitoramento com valores comerciais mais acessíveis.

Com as informações acima descritas, é apresentado no presente projeto de pesquisa o desenvolvimento de um sistema de coleta de dados ambientais utilizando um sistema de comunicação sem fio, comparando sensores comerciais de baixo custo em relação Estação Meteorológica Automática – Campbell Scientific Inc.

(Modelo CR23X) munida do sensor comercial Vaisala modelo HMP45C para coleta de dados de temperatura e umidade relativa do ar. Em conjunto, foi implementado a comparação da calibração de sensores de baixo custo por regressões polinomiais e redes neurais artificiais, buscando recomendar a melhor metodologia, bem como o sensor que apresentar as melhores generalizações de erro nas aferições.

CAPÍTULO 1

DESENVOLVIMENTO DE UM SISTEMA DE COLETA DE DADOS AMBIENTAIS DE BAIXO CUSTO PARA ESTUFAS COM CALIBRAÇÃO UTILIZANDO AJUSTE POLINOMIAL

1.1 INTRODUÇÃO

Um dos maiores desafios da agricultura moderna é atender a demanda crescente por alimentos, produzindo os mesmos de forma sustentável, havendo um agravante por estarmos enfrentando grandes mudanças ambientais oriundas da atual crise climática (UNITED NATIONS, 2019). A relação entre a demanda humana por alimentos e o esgotamento de recursos (que gera impactos ambientais indesejados) está aumentando rapidamente devido ao crescimento da população global e ao aumento do consumo per capita (TILMAN, 2011). Portanto, as transformações necessárias para vencer esses desafios demandam escolha consciente por sistemas produtivos mais sustentáveis, bem como aprimoramento de tecnologias a fim de incrementar a eficiência produtiva (WILLETT, 2019).

Dessa forma, é pertinente destacar que a produção de alimentos em estufas é uma das possíveis soluções para uma intensificação da produção de forma sustentável. A alta produtividade das estufas desempenha um papel importante nesse novo cenário de alterações climáticas, pois o cultivo em ambiente protegido é 10 vezes mais eficaz quando comparado à produção convencional (MARCELIS, 2020).

Existe uma crescente migração de determinadas culturas da produção em campo para a produção em estufas, visando melhores rendimentos das safras, pois o conceito central do cultivo protegido é fornecer a cultura com condições favoráveis de crescimento por ter a possibilidade de controlar o microclima do ambiente interno da mesma (CHIOMENTO, 2021). Além do controle microclimático do ambiente produtivo, a utilização de estufas possui o benefício de possibilitar a instalação das mesmas em terrenos inadequados para produção de campo aberto e estrategicamente colocadas próximas a centros de transporte e centros populacionais, otimizando, assim, a logística.

A utilização de ambientes protegidos, ou casas de vegetação, possibilita cultivos fora de época e protege as culturas de condições climáticas adversas do meio

externo, mas essa mesma estrutura provoca alterações microclimáticas em seu interior. Essas alterações internas, tais como variação da umidade do ar, temperatura do ar, umidade do solo, índice de insolação entre outros fatores (SONSTEBY; HEIDE, 2017), influenciam diretamente o desenvolvimento da planta a partir de estágios vegetativos a reprodutivos, sendo necessários a aferição e o controle dessas variáveis.

A possibilidade de migrar o sistema de produção de campo para estufas ainda apresenta uma barreira para pequenos produtores, pois seu custo de implementação nem sempre é acessível. Em um estudo apresentado por Osmarin (2020), foi relatado a conversão de um sistema produtivo de morango (*Fragaria x ananassa* DUCH) com 600 m² de área produtiva convencional para produção semi-hidropônica em uma unidade de produção agrícola familiar, resultando em um custo de R\$ 45.585,00 (9.540,20 – USD).

Em conjunto, a implementação de estações comerciais de monitoramento de variáveis ambientais produzidas por empresas como WIDITEC, Vaisala ou Campbell podem custar de R\$ 9.500,00 (1.988,19 – USD) a R\$ 36.000,00 (7.534,21– USD) apresentando um custo proporcional de até 79 % do custo aferido por Osmarin (2020). Desta forma, é pertinente salientar que Pallavi (2017) descreve que inovações tecnológicas, como Internet das coisas (IoT) e plataformas de baixo custo e código aberto, favorecem o desenvolvimento de novas soluções tecnológicas, podendo estas serem implementadas com sensores de baixo custo ampliando, portanto, a acessibilidade para pequenos produtores.

Com a expansão de uso de plataformas de prototipação eletrônica como Arduino e Raspberry Pi, uma gama de sensores de baixo custo foram introduzidos no mercado com sua implementação facilitada pela liberdade de acesso a suas bibliotecas. Dentro desse grupo, os de menores custos e mais utilizados para coleta de dados referente a temperatura do ar e umidade do ar são LM35 (temperatura do ar), BMP180 (temperatura do ar), BME280 (temperatura e umidade do ar), DHT11 (temperatura e umidade do ar), e DHT22 (temperatura e umidade do ar).

Por fim, é também pertinente mencionar que essas novas plataformas de prototipação democratizaram tecnologias como *router laser* e impressão 3D, possibilitando a produção de placas de circuito impresso, bem como abrigos para os

sensores, o que facilita o desenvolvimento de sistemas para coleta de dados ambientais. Assim, cabe ressaltar que esses sistemas devem seguir as recomendações de aplicação e implementação descritas pela Organização Meteorológica Mundial (WMO, 2008), certificando um lastro metodológico para esses dispositivos.

Com todas essas informações supracitadas, o presente estudo apresenta o desenvolvimento de um sistema de coleta de dados ambientais de baixo custo comparando sensores comerciais de baixo custo anteriormente citados, por meio de ajuste polinomial (NOVAIS, 2020) e de um sensor meteorológico de referência (Vaisala modelo HMP45C), focando nas variáveis temperatura do ar e umidade relativa do ar.

1.2 MATERIAIS E MÉTODOS

1.2.1 LOCALIZAÇÃO

O experimento foi realizado no Departamento de Engenharia Rural da Faculdade de Ciências Agrônômicas de Universidade Estadual Paulista – UNESP, campus de Botucatu, que se caracteriza pelo clima Cfa – clima subtropical úmido (CUNHA, 2009), com precipitação pluviométrica média anual de 1516,8 mm e evapotranspiração média anual de 692 mm.

1.2.2 CARACTERÍSTICAS DA CASA DE VEGETAÇÃO E CULTURA

O local do experimento foi uma casa de vegetação que possui estrutura metálica em arco, com cobertura de polietileno de baixa densidade transparente difusor (PEBD 100 µm de espessura), com pé direito 2,5, comprimento de 24 e largura 7 m, sendo que as laterais possuíam proteção com tela antiafídica.

A cultura avaliada foi o lúpulo, variedade *Cascade*, utilizando-se mudas que foram transplantadas em vasos, podadas aos 40 dias após transplântio, com 20 cm de altura para uniformização das plantas. Por necessidades climáticas da cultura, o experimento iniciou-se dia 13 de setembro de 2018 e estendeu-se até o dia 11 de

fevereiro de 2019, tendo os dados das variáveis microclimáticas no interior da estufa coletados durante todo o período.


As distribuições dos vasos foram no espaçamento de 1 metro entre plantas e 1,5 m entre linhas, com quatro fileiras de dez vasos cada, com total de 40 plantas, a capacidade dos vasos era de 25 litros. A condução das plantas foi feita por meio de bambu e fio de sisal até a altura de 2,5m.

1.2.3 CONFECÇÃO DO ABRIGO

Segundo as instruções da Organização Meteorológica Mundial, é necessário a proteção dos sensores da incidência de radiação solar direta para aferição de temperatura e umidade do ar (WMO, 2008). Para tanto, fez-se necessário a produção de um abrigo onde fosse possível instalar tanto o senso de referência quanto as placas com os sensores comerciais de baixo custo.

Assim, seguindo a concepção apresentada pela literatura (SILVA, 2015; MARQUES, 2016; FERNANDES; COSTA, 2016; FREITAS, 2018), foi produzida uma cópia em 3D do abrigo de referência da Campbell com criação do modelo CAD 3D, e posteriormente convertidos no formato STL e importados para impressora GTMAX3D CORE A2, realizando a impressão por meio do fatiamento do arquivo em finas camadas transversais para a construção física do modelo. Todas as medidas e padrões físicos do abrigo prototipado seguiram os valores do abrigo de referência da Campbell, apresentando um preenchimento de 40% para a peça e visando equalizar parâmetros do tempo de impressão, quantidade de material gasto e resistência mecânica.

Figura 1 - A: Impressão do abrigo dos sensores, B: Visão da peça de cobertura, C: Proporção de preenchimento de uma peça em 3D- Fonte GTMax 3D / Elaborado pelos autores (2018) | Boaimpressao3d



Fonte: Elaborado pelos autores (2018).

1.2.4 PROTOTIPAÇÃO ELETRÔNICA

Foi utilizado a linguagem C++ através da IDE Arduino (MCROBERTS, 2018) para programar os microcontroladores ATME1 328 (ATMEL Corporation) e Esp32 (Espressif Systems). As bibliotecas e códigos foram reescritos a fim de reduzir seu tamanho em *bytes* e para ajustar-se às necessidades de tempo de leitura do projeto.

Para a confecção das placas eletrônicas, inicialmente o projeto foi implementado utilizando módulos e *protoboard*, em que, uma vez testado os códigos, o circuito eletrônico foi desenhado utilizando Software Eagle Versão 9.2.0 para Windows. Em seguida, esse desenho foi convertido em formato SVG para produção de um protótipo na Máquina Router Laser VS4040 com a aplicação de *dryfilm* sobre uma placa de fenolite. Após os testes dos protótipos, um modelo final foi selecionado para ser enviado para fabricação (empresa PCBWay), sendo essas placas montadas e testadas, a fim de serem instaladas no local para coleta de dados.

As seleções dos sensores foram inicialmente pautadas no levantamento bibliográfico que indicasse o uso para coleta de dados ambientais, sejam eles em estufas ou projetos relacionados, tendo sempre em vista sua relação de custo

benefício, chegando aos modelos BMP180, BME280, DHT11, DHT22 e LM35 (BACON, 2020; ROMANINI, 2010; LITJENS, 2009; BERNARDI, 2017; LOPES, 2018; PROBST, 2018; GUTKOSKI, 2018; TEIXEIRA, 2017; CAMARGO, 2015; RICO, 2018). As leituras dos sensores foram coletadas associadas a um RTC adicionado ao circuito (*real-time clock*), sendo este relógio utilizado para marcar o momento exato das leituras.

Tabela 1 – Informações sobre os sensores comerciais selecionados para o experimento

Nome	Umidade do Ar	Temperatura do Ar	Fabricante	Preço (R\$)	Tempo de resposta	Precisão	Histerese	consumo	Range de Operação
BMP180	Não	Sim	Bosch Sensortec Co., Ltd	12	1 s	$\pm 1,0\text{ }^{\circ}\text{C}$	$1,0\text{ }^{\circ}\text{C}$	$32\text{ }\mu\text{A}$	-40 até $65\text{ }^{\circ}\text{C}$
BME280	Sim	Sim	Bosch Sensortec Co., Ltd	35	1 s	$\pm 3\% \text{ UR}$ $ \pm 0,5\text{ }^{\circ}\text{C}$	$\pm 0,5\% \text{ UR}$	$3,6\text{ }\mu\text{A}$	0 até 100 % UR -40 até $85\text{ }^{\circ}\text{C}$
DHT11	Sim	Sim	Aosong (Guangzhou) Electronics Co., Ltd	17,9	10 s	$\pm 5\% \text{ UR}$ $ \pm 2,0\text{ }^{\circ}\text{C}$	$\pm 1\% \text{ UR}$	$2,5\text{ mA}$	20 até 95 % UR 0 até $50\text{ }^{\circ}\text{C}$
DHT22	Sim	Sim	Aosong (Guangzhou) Electronics Co., Ltd	39,7	2 s	$\pm 4\% \text{ UR}$ $ \pm 0,5\text{ }^{\circ}\text{C}$	$\pm 0,5\% \text{ UR}$	$2,5\text{ mA}$	0 até 100 % UR -40 até $80\text{ }^{\circ}\text{C}$
LM35	Não	Sim	Texas Instruments Incorporated	11	1 s	$\pm 0,5\text{ }^{\circ}\text{C}$	$1,0\text{ }^{\circ}\text{C}$	$60\text{ }\mu\text{A}$	-40 até $110\text{ }^{\circ}\text{C}$

Fonte: Bosch Sensortec | Aosong Eletronics | Texas Instruments

1.2.5 COLETA DE DADOS E ANÁLISE

A análise das aferições de temperatura e umidade relativa do ar efetuada com os sensores comerciais de baixo custo foi correlacionada com as leituras aferidas pela Estação Meteorológica Automática – Campbell (Modelo CR23X), munida do termo-higrômetro Vaisala modelo HMP45C. As aferições deram-se no período de 13 de setembro de 2018 e estenderam-se até o dia 11 de fevereiro de 2019 em intervalos de cinco segundos, resultando em médias por minuto. Dentro desse período, buscou-se levantar os dias em que ocorressem as maiores variações, obtendo-se, então, o período de início às 12:00:00 do dia 11/11/2018 até 10:20:00 do dia 15/11/2018.

Utilizou-se para análise dos dados a linguagem Python, com as bibliotecas Numpy e Scikit Learn para os processos estatísticos, e a biblioteca Matplotlib (HUNTER, 2007) para exibição dos gráficos e figuras.

As relações entre as medidas dos sensores comerciais de baixo custo e o sensor de referência foram exibidas por meio de gráficos de linhas para as séries temporais utilizando regressões polinomiais. A avaliação dos modelos projetados foi realizada por meio da análise do índice R-quadrado (r^2), erro médio absoluto e erro quadrático médio.

O coeficiente de determinação r^2 é usado para avaliar o desempenho de um modelo, exibindo a quantidade de variação no atributo dependente de saída, que é previsível a partir das variáveis independentes de entrada. Seus valores variam de 0 (zero) a 1 (um), sendo esse valor (a porcentagem 0 ~ 100 %) a cobertura em que as amostras podem explicadas pelo modelo proposto.

Fórmula 1 – Coeficiente de Determinação - SQ_{res} é a soma dos quadrados dos erros residuais, SQ_{tot} é a soma total dos erros

$$R^2 = \frac{SQ_{exp}}{SQ_{tot}} = 1 - \frac{SQ_{res}}{SQ_{tot}},$$

Fonte: Elaborado pelos autores

Erro médio absoluto (MAE) indica o afastamento (desvio) médio absoluto dos valores obtidos pelos sensores comerciais em relação aos valores obtidos pelo sensor de referência Vaisala - HMP45C.

Fórmula 2 – Erro Médio Absoluto

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} = \frac{\sum_{i=1}^n |e_i|}{n}$$

Fonte: Elaborado pelos autores

O erro quadrático médio (EQM ou MSE em inglês), ou o desvio quadrático médio (MSD), de um estimador mede a média dos quadrados de erro, ou seja, a diferença quadrática média entre os valores estimados e o valor verdadeiro.

Fórmula 3 – Erro Quadrático Médio

$$EQM(\hat{\theta}) = \frac{1}{N} \sum_{i=1}^N (\hat{\theta}_i - \theta_i)^2$$

Fonte: Elaborado pelos autores

1.3 RESULTADOS E DISCUSSÃO

1.3.1 BME280


O primeiro sensor a ser analisado é o BME280 produzido pela empresa Bosch Sensortec Co., Ltd. Este sensor é capaz de mensurar pressão, umidade e temperatura do ar, estando alojado em um pacote LGA de tampa de metal compacto com $2,5 \times 2,5$ mm², com uma altura de 0,93 mm.

BME280 fornece interfaces SPI e I²C, operando com tensões de 1,71 a 3,6 v (volts) e consome 3,6 microampères (µA) para aferir nas faixas de -40 até 85 graus celsius (C°), 0 até 100 % de umidade relativa do ar (% UR) e uma histerese $\pm 0,5\%$ UR. O sensor possui um tempo de resposta entre as leituras de 1 segundo, apresentando uma acurácia de $\pm 0,5$ C°, $\pm 3\%$ UR.

Com essas informações, apresenta-se nas Figuras 2 e 3 as regressões polinomiais referentes às variáveis de temperatura e umidade do ar. Ressalta-se que foram testadas em todos os graus a significância dos coeficientes das regressões, resultando em valores inferiores a 5% (p-valor<0,05), assim, rejeita-se a hipótese nula, sendo apresentada uma forte aderência entre as medidas efetuadas pelo sensor de referência e o BME280 para as leituras aferidas.

A regressão polinomial em seu quarto grau apresentou uma estabilização do erro médio absoluto (MAE) de 0,96 °C, erro quadrático médio (MSE) de 1,84 °C e coeficiente de determinação R²: 0,90, indicando um ótimo ajuste das medições ao modelo.


Figura 2 – Regressões polinomiais buscando o melhor ajuste para a determinação da calibração entre o sensor BME280 em relação ao Vaisala - HMP45C para variável temperatura



Fonte: Dados da pesquisa.

Para a variável umidade, a Figura 3 demonstra que em seu quarto grau é apresentada uma estabilização do erro médio absoluto (MAE) de 4% UR e erro quadrático médio (MSE) de 29 % UR, exibindo que esse é o melhor modelo em termos de generalização de erro, obtendo para umidade relativa do ar o coeficiente de determinação R^2 : 0,87 indicando um bom ajuste das medições ao modelo.

Figura 3 – Regressões polinomiais buscando o melhor ajuste para a determinação da calibração entre o sensor BME280 em relação ao Vaisala - HMP45C para variável umidade



Fonte: Dados da pesquisa.

Os valores de erro médio absoluto constatados no experimento são semelhantes ao descrito em Chaves (2021), que aponta o BME280 como um equipamento confiável para aferições de temperatura e umidade do ar, desde que seu range de trabalho seja respeitado.

Quando o BME280 é aplicado em sistemas de baixo custo para estufas, Vovna (2020) relatou que, com o ajuste correto respeitando as recomendações Organização Meteorológica Mundial (WMO, 2008), é possível aferir a temperatura do ar com um desvio de 0,5 a 1 °C.

Os valores próximos a 4% UR ajustados para o sensor também foram encontrados no estudo de Rezvani (2020), que descreve que esses valores poderiam melhorar no caso de medições com ventilação mecânica ativa, o que no caso teria um consumo superior, demandando um local com instalações elétricas convencionais ou um sistema solar com baterias capazes de sustentar esse consumo.

1.3.2 DHT11


O DHT11 é um sensor largamente utilizado, composto de um material NTC (Negative Temperature Coefficient) que apresenta queda da sua resistência com um aumento na temperatura. O sensor é produzido pela empresa Aosong Electronics Ltd, sendo capaz de mensurar umidade e temperatura do ar, estando encapsulado em uma caixa vazada de plástico com dimensões de $12 \times 5 \text{ mm}^2$ e com uma altura de 23,5 mm.

O sensor possui uma interface serial de comunicação, opera com tensões de 3,5v a 5,5 volts (v) e consome 2,5 miliampères (mA) para operar nas faixas de 0 até 50 graus celsius ($^{\circ}\text{C}$) e 0 até 95% de umidade relativa do ar (% UR). Ainda segundo o fabricante, o sensor possui uma histerese $\pm 1\%$ UR com um tempo de resposta entre as leituras de 10 segundos, apresentando uma acurácia de $\pm 2,0^{\circ}\text{C}$, $\pm 5\%$ UR.

Com essas informações, são apresentadas nas Figuras 4 e 5 as regressões polinomiais referentes às variáveis de temperatura e umidade do ar respectivamente. Ressalta-se que foram testadas em todos os graus a significância dos coeficientes das regressões, resultando em valores inferiores a 5% ($p\text{-valor} < 0,05$), assim, rejeita-se a hipótese nula, sendo apresentada uma forte aderência entre as medidas efetuadas pelo sensor de referência e o DHT11 para as leituras aferidas.

A regressão polinomial em seu terceiro grau apresentou uma estabilização do erro médio absoluto (MAE) de $1,02^{\circ}\text{C}$ e erro quadrático médio (MSE) de $2,10^{\circ}\text{C}$, comprovando que esse é o melhor modelo em termos de generalização de erro, obtendo coeficiente de determinação de R^2 : 0,89, o que indica um bom ajuste das medições ao modelo.


Figura 4 - Regressões polinomiais buscando o melhor ajuste para a determinação da calibração entre o sensor DHT11 em relação ao Vaisala - HMP45C para variável temperatura



Fonte: Dados da pesquisa.

Em relação aos dados de umidade relativa do ar para o sensor DHT11, apresentou-se em seu terceiro grau o melhor ajuste da regressão polinomial, estabilizando o erro médio absoluto (MAE) de 4,31% UR e erro quadrático médio (MSE) de 33,91% UR exibindo que esse é o melhor modelo em termos de generalização de erro, obtendo coeficiente de determinação de $R^2: 0,85$, indicando um bom ajuste das medições ao modelo.

Figura 5 - Regressões polinomiais buscando o melhor ajuste para a determinação da calibração entre o sensor DHT11 em relação ao Vaisala - HMP45C para variável umidade



Fonte: Dados da pesquisa.

Acerca do DHT11, apesar de possuir uma correlação próxima a 1 °C na calibração, foi possível perceber no experimento que sua precisão é reduzida quando o aparelho é submetido a valores próximos de 45 ~ 50 °C, apresentando valores discrepantes em até 4°C nesses casos, situação essa também apresentada em Ferrari (2019). Essa limitação também foi descrita em estudos de Santos (2013), Oliveira Júnior (2014) e Cunha (2009), sendo recomendado que esse sensor fosse utilizado para coleta de dados abaixo dos 40 °C.

Referente aos valores de umidade relativa do ar, foi possível encontrar aproximadamente os mesmos valores apresentados em Azevedo (2021), que encontrou um erro médio absoluto para o DHT11 de 3,8% UR, colaborando para respaldar o processo de coleta e processamento dos dados.

Ainda segundo Danita (2018), é esperado que o sensor DHT11 apresente variações de até 5% UR, uma vez que sua concepção inicial apresentada pelo fabricante descreve esse range, não sendo recomendado para projetos que exijam uma grande sensibilidade e exatidão para aferir umidade relativa do ar.

1.3.3 DHT22


O DHT22 é um sensor digital que ainda pode ser considerado de baixo custo munido de um sistema capacitivo para medição da umidade do ar junto com termistor (semicondutor sensível à temperatura – NTC) para medição da temperatura. O sensor é produzido pela empresa Aosong Electronics Ltd e é comumente vendido com encapsulamento em uma caixa vazada de plástico com dimensões de $22 \times 5 \text{ mm}^2$ com uma altura de 28 mm.

O sensor possui uma interface serial de comunicação, opera com tensões de 3,3v a 6 v (volts) e consome 2,5 miliampères (mA) para operar nas faixas de -40 até 50 graus célsius (C°) e 0 até 100 % de umidade relativa do ar (% UR). Ainda segundo o fabricante, o sensor possui uma histerese $\pm 0,5\%$ UR com um tempo de resposta entre as leituras de 2 segundos, apresentando uma acurácia de $\pm 0,5 \text{ C}^\circ$, $\pm 4\%$ UR.

Desta forma, após a coleta dos dados, podemos apresentar nas Figuras 6 e 7 as regressões polinomiais referentes às variáveis de temperatura e umidade do ar. Destaca-se que foi testada em todos os graus a significância dos coeficientes das regressões, resultando em valores inferiores a 5% ($p\text{-valor} < 0,05$). Assim, rejeita-se a hipótese nula, sendo apresentada uma forte aderência entre as medidas efetuadas pelo sensor de referência e o DHT22 para as leituras aferidas.

A regressão polinomial em seu terceiro grau apresentou uma estabilização do erro médio absoluto (MAE) de $1,0 \text{ }^\circ\text{C}$ e erro quadrático médio (MSE) de $2,10 \text{ }^\circ\text{C}$, exibindo que esse é o melhor modelo em termos de generalização de erro obtendo coeficiente de determinação de R^2 : 0,90, indicando um ótimo ajuste das medições ao modelo.


Figura 6 - Regressões polinomiais buscando o melhor ajuste para a determinação da calibração entre o sensor DHT22 em relação ao Vaisala - HMP45C para variável temperatura



Fonte: Dados da pesquisa.

No mesmo sentido, é possível apresentar os dados de umidade relativa do ar para o sensor DHT22, que apresenta em seu quarto grau o melhor ajuste da regressão polinomial, estabilizando o erro médio absoluto (MAE) de 4,17% UR e erro quadrático médio (MSE) de 30,39% UR, demonstrando que esse é o melhor modelo, em termos de generalização de erro para o sensor obtendo coeficiente de determinação R^2 : 0,86, indicando um bom ajuste das medições ao modelo.

Figura 7 – Regressões polinomiais buscando o melhor ajuste para a determinação da calibração entre o sensor DHT22 em relação ao Vaisala - HMP45C para variável umidade



Fonte: Dados da pesquisa.

O sensor DHT22 foi testado e recomendado por Marques Filho (2019) para uso em “ambiente real de cultivo, apresentando funcionamento adequado durante todo o período experimental”, expondo uma estabilidade entre as leituras. Os valores de umidade relativa encontrados no presente estudo se assemelham ao estudo descrito por Martín-Garín (2018), que relata o DHT22 como sensor estável que apresentou uma das melhores precisões para aferir umidade relativa do ar.

1.3.4 BMP180


O BMP180 é produzido pela empresa Bosch Sensortec Ltd, sendo capaz de mensurar pressão e temperatura do ar e alojado em um pacote LGA de tampa de metal compacto com $3,6 \times 3,8 \text{ mm}^2$ com uma altura de 1,23 mm. O sensor possui interfaces SPI e I²C para coleta de dados operando com tensões de 1,62 a 3,6 volts (v), consumindo 32 microampères (μA).

Este sensor opera nas faixas de -40 até 65 graus célsius (C°) e 950 até 1050 Hectopascal (hPa), com tempo de resposta entre as leituras de 1 segundo e apresentando uma acurácia de $\pm 1,0$ C° e ± 2.0 hPa.

Após essas informações sobre o sensor, podemos apresentar na Figura 8 a regressão polinomial referente à variável temperatura. Evidencia-se que foi testada em todos os graus a significância dos coeficientes das regressões, resultando em valores inferiores a 5% ($p\text{-valor} < 0,05$), rejeitando-se a hipótese nula e sendo apresentada uma forte aderência entre as medidas efetuadas pelo sensor de referência e o BMP180 para as leituras aferidas.

A regressão polinomial em seu terceiro grau apresentou uma estabilização do erro médio absoluto (MAE) de $1,0$ °C e erro quadrático médio (MSE) de $2,08$ °C, exibindo que esse é o melhor modelo em termos de generalização de erro, obtendo coeficiente de determinação R^2 : $0,89$ indicando um bom ajuste das medições ao modelo.

Figura 8 – Regressão polinomial buscando o melhor ajuste para a determinação da calibração entre o sensor BMP180 em relação ao Vaisala - HMP45C para variável temperatura



Fonte: Dados da pesquisa.

O sensor BMP180 apresentou leituras próximas ao BME280, sendo algo esperado como já descrito em Azevedo (2021), por se tratar de sensores da mesma

empresa sendo apenas de gerações diferentes. É possível visualizar na Figura 8 que existe uma dispersão maior da relação entre as leituras do BMP180 em relação aos valores do sensor de referência acima de 35 C°, fato também descrito em Azevedo (2021).

1.3.5 LM35


A série LM35 é produzido pela empresa Texas Instruments sendo capaz de mensurar temperatura, sendo o sensor encapsulado no formato TO-92 (estilo amplamente usado de pacote de semicondutor) em uma caixa de epóxi ou plástico e com as características físicas de tamanho compacto de 4,30 mm ×2,88mm com uma altura de 4,30 mm. O sensor possui interfaces analógica de leitura em que a uma variação de 10 mV (0.010 Volts) representa uma variação de um grau célsius.

O sensor LM35 opera com tensões de 4 a 30 volts (v) e consome 60 microampères (μ A) para operar nas faixas de -40 até 110 graus célsius (C°), apresentando uma acurácia de $\pm 0,5$ C°.

Com as informações supracitadas, é apresentado na Figura 9 a regressão polinomial referente a variável de temperatura. Ressalta-se que foi testada em todos os graus a significância dos coeficientes das regressões, resultando em valores inferiores a 5% (p-valor<0,05). Portanto, rejeita-se a hipótese nula, sendo apresentada uma forte aderência entre as medidas efetuadas pelo sensor de referência e o LM35 para as leituras aferidas.

Para as aferições feitas pelo sensor, a regressão polinomial em seu terceiro grau apresentou a melhor estabilização do erro médio absoluto (MAE) de 1,01 °C e erro quadrático médio (MSE) de 2,02 °C, exibindo que esse é o melhor modelo em termos de generalização de erro, obtendo coeficiente de determinação R^2 : 0,89 indicando um bom ajuste das medições ao modelo.

Figura 9 – Regressões polinomiais buscando o melhor ajuste para a determinação da calibração entre o sensor LM35 em relação ao Vaisala - HMP45C para variável temperatura



Fonte: Dados da pesquisa.

O sensor LM35 obteve um dos melhores resultados quando testado em seus limites de leitura, o que é possível visualizar na Figura 9; mesmo em temperaturas superiores a 45°C, o sensor apresentou um bom ajuste, diferentemente dos demais sensores como o DHT11. O valor de erro médio absoluto (MAE) de 1,01 °C foi semelhante ao apresentado em Monteiro et al. (2014), que utilizou o sensor para monitorar o controle térmico em estufas ajustadas pelo usuário, demonstrando a ampla aplicabilidade do sensor em questão.

1.4 CONSIDERAÇÕES GERAIS

Quando comparados os valores de erro médio absoluto (MAE) e erro quadrático médio (MSE), é possível observar na Tabela 2 que os valores de MAE são muito próximos, destacando-se por uma pequena vantagem o sensor BME280 com valor de 0,96 °C MAE.

Ainda avaliando o erro médio é possível notar que os sensores BME280, DHT22 e LM35 apresentaram 0,5 °C acima de seu erro médio apresentado por seus fabricantes, enquanto o sensor DHT11 demonstrou uma precisão melhor com o ajuste polinomial em 1°C e o sensor BMP180 apresentou a precisão exata descrita pelo seu fabricante.


Tabela 2 – Tabela MAE e MSE da variável temperatura

Sensores	MAE (°C)	MSE (°C)
BME280	0,96	1,84
BMP180	1,00	2,08
LM35	1,00	2,02
DHT22	1,00	1,94
DHT11	1,02	2,10

Fonte: Elaborado pelos autores.

É pertinente destacar que todos os sensores aplicados nesse estudo apresentaram um erro médio absoluto próximo de 1°C, demonstrando, assim, que para aplicações onde esse erro é tolerável os mesmos poderiam ser aplicados. Porém, foi possível visualizar em todos os sensores que a sensibilidade dos mesmos estava bem distante do sensor de referência, não conseguindo acompanhar as leituras em momentos de drásticas mudanças de temperatura, trabalhando melhor em faixas de temperaturas de 15 a 30°C, como exibido no exemplo da Figura 10.

Figura 10 – Ajuste polinomial para temperatura Sensor BME280 x Vaisala HMP45C



Fonte: Elaborado pelos autores.

Ao avaliarmos os valores de erro médio absoluto (MAE) e erro quadrático médio (MSE) referente a variável de umidade relativa do ar, é possível observar, como exemplificado na Tabela 3, que os valores de MAE são todos próximos de 4% UR, porém o sensor DHT11 apresenta o maior valor de MSE de 33,91% UR, indicando que o sensor apresenta leituras que estão mais distantes da média do sensor de referência. Entre todos os sensores avaliados, o BME280 mais uma vez apresentou os melhores resultados com valor de 4,14% UR MAE.


Tabela 3 – Tabela MAE e MSE da variável umidade

Sensores	MAE (%UR)	MSE (%UR)
BME280	4,00	29,00
DHT22	4,17	30,39
DHT11	4,31	33,91

Fonte: Elaborado pelos autores.

Verificando as leituras de umidade do ar, os sensores utilizados apresentaram leituras próximas aos informados pelos seus fabricantes, mas com uma histerese muito maior do que a descrita pelos mesmos, influenciando diretamente na sensibilidade das leituras, como é possível visualizar na Figura 11.

Figura 11 – Ajuste polinomial para umidade relativa do ar Sensor BME280 x Vaisala HMP45C




Fonte: Elaborado pelos autores.

Após verificar o ajuste de todos os sensores selecionados para o estudo, foi possível indicar que o BME280 apresentou os melhores valores. Desta forma, implementou-se uma separação dos dados coletados do sensor em dois grandes grupos: dados coletados durante o dia (engloba período de dados que estão entre os valores de 6h00 até às 18h00), e período noturno (dados que estão entre os valores de 18h00 até às 6h00), com o objetivo de constatar se o abrigo prototipado foi totalmente eficiente em evitar a insolação, não apresentando influência nos valores aferidos.

Dentro deste contexto, é exibido na Figura 12 que a regressão polinomial referente aos dados coletados durante o *dia* para temperatura apresentou em seu terceiro grau uma estabilização do erro médio absoluto (MAE) de 1,28 °C, erro quadrático médio (MSE) de 2,85 °C, coeficiente de determinação de R²: 0,90 e p-valor < 0,05.


Figura 12 – Regressão polinomial referente aos dados coletados durante o “dia” – BME280 Temperatura



Fonte: Elaborado pelos autores.

Na Figura 13, a regressão polinomial referente aos dados coletados durante o período da *noite* para a variável temperatura apresentou em seu terceiro grau uma estabilização do erro médio absoluto (MAE) de 0,42 °C, erro quadrático médio (MSE) de 0,47 °C, coeficiente de determinação de $R^2: 0,933$ e p-valor < 0,05.


Figura 13 – Regressão polinomial referente aos dados coletados durante o período da “noite” – BME280 Temperatura



Fonte: Elaborado pelos autores.

Em sequência é exibido na Figura 14 a regressão polinomial referente aos dados coletados durante o *dia* para umidade relativa do ar, apresentando em seu terceiro grau uma estabilização do erro médio absoluto (MAE) de 4,22% UR, erro quadrático médio (MSE) de 29,31% UR, coeficiente de determinação de R^2 : 0,90 e p-valor < 0,05.


Figura 14 – Regressão polinomial referente aos dados coletados durante o “dia” – BME280 Umidade



Fonte: Elaborado pelos autores.

Completando a análise é exibido na Figura 15 a regressão polinomial referente aos dados coletados durante o período da *noite*, apresentando em seu terceiro grau uma estabilização do erro médio absoluto (MAE) de 3,27% UR, erro quadrático médio (MSE) de 21,14% UR, coeficiente de determinação de R^2 : 0,83 e p-valor < 0,05.

Figura 14 – Regressão polinomial referente aos dados coletados durante o período da “noite” – BME280 Umidade



Fonte: Elaborado pelos autores.

Com todas essas informações apresentadas podemos descrever que o abrigo (estrutura física do sistema) impresso em 3D apresentou-se como uma solução viável, pois se o mesmo tivesse afetado de forma significativa a coleta dos dados a probabilidade de significância teria sido superior a 5% ($p\text{-valor} > 0,05$), indicando a hipótese nula como a indicação factível, apresentando baixa correlação entre as medidas aferidas pelos sensores comerciais em relação ao sensor de referência.

Porém, foi constatado através das Figuras 12, 13, 14 e 15 que ocorreu uma influência da radiação solar que pode ser explicada pelo fator de preenchimento em que as peças do abrigo foram produzidas. Esta se coloca como a possibilidade mais plausível, uma vez que as peças do abrigo foram espelhadas no modelo comercial do abrigo da Campbell largamente utilizado, apresentando a única diferença de densidade entre as mesmas.

Importa salientar que em todos os trabalhos avaliados que fornecem metodologias para prototipação de abrigos o fator de preenchimento não é descrito ou analisado (SILVA, 2015; MARQUES, 2016; FERNANDES; COSTA, 2016; FREITAS, 2018; OLIVEIRA, 2019; FOSSA, 2020; JÚNIOR, 2020; BARATTO, 2021). Desta forma, recomenda-se buscar em futuros estudos a influência do preenchimento da impressão na proteção dos sensores bem como a viabilidade econômica do tempo da impressão (tempo gasto para impressão do abrigo foi de 32 horas no total).

1.5 CONCLUSÃO

Através dessa pesquisa foi possível demonstrar a viabilidade do desenvolvimento de um sistema de coleta de dados ambientais de baixo custo para estufas com calibração utilizando ajuste polinomial.

Com relação à seleção dos sensores, foi possível identificar que o BME280 fabricado pela Bosch Sensortec Ltd apresentou os melhores valores quando correlacionado com o sensor de referência Vaisala HMP45C. Outro fator que colabora para a escolha desse sensor é seu baixo consumo de energia, viabilizando a implementação com um sistema de energia solar e facilitando a liberdade de instalação em locais sem fornecimento de energia padrão.

Foi possível concluir que os sensores podem ser utilizados para coleta de dados ambientais em estufas, mantendo um valor de investimento baixo colaborando

com a expansão dessa tecnologia para pequenos produtores. Porém, é perceptível que a sensibilidades dos sensores não se aproximam quando comparadas com o sensor de referência, não sendo impeditivo na visão dos autores sua possibilidade de utilização.

A respeito da prototipação de abrigos, recomenda-se avaliar o fator de preenchimento da impressão 3D, pois foi comprovado que o mesmo tem influência sobre a coleta de dados quando expostos a influência da radiação solar.

Por fim, agradecemos o auxílio da FAPESP PIPE - Fase 1 / 2º Ciclo/2017 (Processo nº 2017/08693-6) que possibilitou a implementação e desenvolvimento dessa pesquisa.

REFERÊNCIAS

- AZEVEDO, Angelo Tiago. **Desenvolvimento de dispositivos eletrônicos alternativos para auxílio no manejo da irrigação via IoT**. 2021. Tese de Doutorado. Universidade de São Paulo.
- BACON, Emily et al. DISTRIBUIÇÃO DE TEMPERATURA NA VERTICAL E NA HORIZONTAL NO INTERIOR DE UMA ESTUFA AGRÍCOLA. **Anais do Salão Internacional de Ensino, Pesquisa e Extensão**, v. 12, n. 3, 2020.
- BARATTO, Jakeline; GALVANI, Emerson; WOLLMANN, Cássio Arthur. Calibração e desempenho do abrigo meteorológico de baixo custo em condições de campo. **Revista Brasileira de Climatologia**, v. 26, 2020.
- BERNARDI, André Luiz; QUITAISKI, Kleison Paulo; SANTOS, Paulo Ricardo dos. **Sistema de irrigação automatizado de hortaliças**. 2017. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.
- BOSCH SENSORTec. **Data sheet BMP180 Digital pressure sensor**. [S.l.], 2013. Disponível em: Acesso em: 11 jan. 2017.
- CAMARGO, Tiago Francisoni Borges. **Determinação de distribuição de temperatura em aviário utilizando fluidodinâmica computacional e sistema de medição com Arduino**. 2015. Dissertação de Mestrado. Universidade Estadual de Maringá.
- CHAVES, Jô Vinícius Barrozo et al. **Desenvolvimento de nó-sensor de baixo custo para avaliação de variáveis meteorológicas em áreas verdes urbanas**. 2021.
- CHIOMENTO, José Luís Trevizan et al. Horticultural potential of nine strawberry cultivars by greenhouse production in Brazil: A view through multivariate analysis. **Scientia Horticulturae**, v. 279, p. 109738, 2021.
- CUNHA, Antonio Ribeiro; MARTINS, Dinival. Classificação climática para os municípios de Botucatu e São Manuel, SP. **Irriga**, v. 14, n. 1, p. 1-11, 2009.
- DANITA, M. et al. IoT based automated greenhouse monitoring system. In: **2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS)**. IEEE, 2018. p. 1933-1937.
- FERNANDES, C. A.; COSTA, J. R. Complex permittivity and anisotropy measurement of 3Dprinted PLA at microwaves and millimeter-waves. In: **INTERNATIONAL CONFERENCE ON APPLIED ELECTROMAGNETICS AND COMMUNICATIONS (ICECOM)**, v. 22. Proceedings [...]. IEEE, 2016. p. 1-6.
- FERRARI, R. M. **Análise do cultivo de alface crespa em ambiente protegido baseada em grandezas físicas e processamento digital de imagens**. 2019. Dissertação (Mestrado em Computação Aplicada) - Universidade Estadual de Ponta Grossa, Ponta Grossa, 2019.
- FREITAS, Marina Pinto Pizarro de. **Caracterização de sensores e abrigos meteorológicos de baixo custo**. 2018.

FOSSA, Solange Maria; DE CARLI, Eloir. Potencialidades e desafios na construção de uma estação meteorológica de baixo custo. In: **4º Salão de Pesquisa, Extensão e Ensino do IFRS**. 2020.

GUTKOSKI, Eduardo Pedó. **Dosador eletrônico de fertilizantes para morangos**. 2018.

HOJAJI, Hannaneh et al. Temperature and humidity calibration of a low-cost wireless dust sensor for real-time monitoring. In: **2017 IEEE sensors applications symposium (SAS)**. IEEE, 2017. p. 1-6.

HUNTER, John D. Matplotlib: A 2D graphics environment. **Computing in science & engineering**, v. 9, n. 03, p. 90-95, 2007.

JÚNIOR, Marcos de Oliveira Valin; DE MOURA SANTOS, Flávia Maria. Análise da utilização de abrigos termo-higrométricos alternativos para transectos móveis. **Engineering Sciences**, v. 8, n. 3, p. 53-64, 2020.

LITJENS, Otto Jacob et al. **Automação de estufas agrícolas utilizando sensoramento remoto e o protocolo Zigbee**. 2009. Tese de Doutorado. Universidade de São Paulo..

LOPES, Kayon VL; PIRES, Danúbia S.; GINALBER, L. de O. Sistema Hidropônico Inteligente Baseado em um Sistema MIMO Nebuloso. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 6, n. 2, 2018.

MARCELIS, L.; COSTA, J.M.; HEUVELINK, E. Achieving sustainable greenhouse production: Present status, recent advances and future developments. Achieving Sustainable Greenhouse Cultivation. **Burleigh Dodds Science Publishing Limited**, p. 1–14, 2019. Disponível em: <<https://doi.org/10.19103/AS.2019.0052.01>>. Acesso em:15/06/2019

MARQUES FILHO, Aldir Carpes et al. **Desenvolvimento e avaliação de um sistema de monitoramento micro-ambiental com o uso de torres de aquisição em casas de vegetação**. 2019, p. 1-388–416.

MARQUES, João Basso et al. **Desenvolvimento de sistema para monitoramento e aquisição de dados microclimáticos utilizando o Programa EPICS**. 2016.

MCROBERTS, Michael. **Arduino básico**. Novatec Editora, 2018.

MONTEIRO, Nathália Arthur Brunet; DA SILVA, Jaidilson Jó; DA ROCHA NETO, José Sérgio. **Uso do Conceito de Sensor Virtual Aplicado ao Monitoramento e Controle de Temperatura de uma Estufa Térmica**. 2014.

NOVAIS, Jonathan Willian Zangeski et al. Técnica de Calibração de Sensores Meteorológicos de Temperatura e Umidade Relativa do ar Utilizando um Sensor de Referência. **UNICIÊNCIAS**, v. 24, n. 1, p. 30-33, 2020.

OLIVEIRA, Lúcio Gonçalves Barbosa et al. Desenvolvimento e validação de abrigos termo-higrométricos. **Nativa**, v. 7, n. 2, p. 169-173, 2019.

OLIVEIRA JÚNIOR, A. J.; VICENTIN, T. A.; CUNHA, A. R. **Avaliação do sensor DHT11 - medidas de temperatura e umidade relativa do ar**. 3ª Jornada Científica e Tecnológica da FATEC de Botucatu, p. 1–6, 2014.

OSMARIN, Rafael. **Renda agrícola do morango (Fragaria x ananassa DUCH) convencional e viabilidade da produção semi-hidropônica em uma unidade de produção agrícola familiar, no município de Gramado dos Loureiros-RS.** 2020.

PALLAVI, S.; MALLAPUR, Jayashree D.; BENDIGERI, Kirankumar Y. Remote sensing and controlling of greenhouse agriculture parameters based on IoT. In: **2017 International Conference on Big Data, IoT and Data Science (BID)**. IEEE, p. 44-48, 2017.

PROBST, Éliton. **Desenvolvimento e avaliação de um sensor de ponto de orvalho, com pastilhas peltier, para medição de umidade relativa do ar.** 2018.

ROMANINI, Carlos EB et al. Desenvolvimento e simulação de um sistema avançado de controle ambiental em cultivo protegido. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, p. 1194-1201, 2010.

REZVANI, Sayed Moin-eddin et al. IoT-Based Sensor Data Fusion for Determining Optimality Degrees of Microclimate Parameters in Commercial Greenhouse Production of Tomato. **Sensors**, v. 20, n. 22, p. 6474, 2020.

RICO, Soto; KENIA, Guadalupe. Sensores de bajo costo para el monitoreo de la calidad del aire en la ciudad de Hermosillo, **Sonora**. 2018.

SANTOS, A. S., SATIRO, M. J. V., SANTOS, F. A., PRUDENTE, F. L. S., LISBOA, E. B. **Uma plataforma de hardware e software para medição de temperatura utilizando diferentes tecnologias de sensores.** III Simpósio Brasileiro de Engenharia de Sistemas Computacionais, 2013.

SILVA, Renan Bohrer da et al. Estações meteorológicas de código aberto: Um projeto de pesquisa e desenvolvimento tecnológico. **Revista Brasileira de Ensino de Física**, v. 37, 2015.

SONSTEBY, A.; HEIDE, O.M., 2017. Flowering performance and yield of established and recent strawberry cultivars (Fragaria x ananassa) as affected by raising temperature and photoperiod. **J. Hortic. Sci. Biotech.** v. 92, p. 367–375, 2017. Disponível em: <<https://doi.org/10.1080/14620316.2017.1283970>>. Acesso em:

TEIXEIRA, Grazielle Bonaldi; ALMEIDA, João Víctor Peroni de. **Rede LoRa® e protocolo LoRaWAN® aplicados na agricultura de precisão no Brasil.** 2017. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.

TILMAN, D.; BALZER, C.; HILL, J.; BEFORT, B.L. **Global food demand and the sustainable intensification of agriculture.** Proc. Natl. Acad. Sci. U. S. A. n. 108, 2011, p. 20260–20264. Disponível em: <<https://doi.org/10.1073/pnas.1116437108>>. Acesso em: 15/06/2019

UNITED NATIONS. **UN Climate Action Summit 2019.** Disponível em: <<https://www.un.org/en/climatechange/un-climate-summit-2019.shtml>>. Acesso em: 12 de junho de 2020.

VOVNA, Oleksandr V. et al. Study of metrological characteristics of low-cost digital temperature sensors for greenhouse conditions. **Serbian Journal of Electrical Engineering**, v. 17, n. 1, p. 1-20, 2020.

WILLETT, W. et al. Food in the Anthropocene: the EAT–lancet commission on healthy diets from sustainable food systems. **Lancet** **393**, p. 447–492, 2019. Disponível em: <[https://doi.org/10.1016/S0140-6736\(18\)31788-4](https://doi.org/10.1016/S0140-6736(18)31788-4)>. Acesso em: 15/06/2019

WMO - World Meteorological Organization. **Guide to Meteorological Instruments and Methods of Observation**: preliminary seventh edition, 2008.

CAPÍTULO 2

CALIBRAÇÃO DE SENSORES DE BAIXO CUSTO POR REGRESSÕES POLINOMIAIS E REDES NEURAIS ARTIFICIAIS PARA APLICAÇÃO EM ESTUFAS

2.1 INTRODUÇÃO

A ocorrência do aquecimento global provocará, com cada vez mais frequência, cenários de climas extremos, tais com secas, inundações, ondas de calor em maior frequência, geadas fora de época, granizo, entre outros fatores (LING, 2004). Com esse novo panorama, a produção agrícola poderá diminuir drasticamente, sendo uma alternativa viável a implantação do cultivo protegido aos produtores rurais que desejam assegurar sua produção em qualquer época do ano.

Sob este contexto, o cultivo em ambiente protegido (sistema de produção agrícola especializado) possibilita certo controle das condições edafoclimáticas, como temperatura, umidade do ar, radiação, solo, vento e composição atmosférica, possibilitando vantagens quanto ao planejamento da produção e de custos (ARAÚJO, 2019). Ainda segundo Araújo (2019), nos últimos dez anos houve uma expansão na adoção do cultivo protegido, porém o desenvolvimento tecnológico do setor não acompanhou o incremento, sendo necessárias mais pesquisas para que a atividade possa crescer de forma equilibrada e sustentável.

O cultivo protegido necessita de desenvolvimento de novas tecnologias para auxiliar no controle dos meios produtivos, particularmente por plataformas microcontroladas que têm um papel estratégico no desenvolvimento, uma vez que há possibilidades de automação agrícola, resultando na agilização e otimização do processo produtivo (LIMA, 2012; LATTUADA, 2019).

O monitoramento das variáveis climáticas em estufas evidencia que cada cultura possui uma faixa ideal em seu cultivo, sendo esses limites máximos e mínimos adequados a cada tipo de planta e, quando atendidos, é possível chegar próximo ao ponto de melhor eficiência e produção. Estes aspectos garantiriam plantas mais saudáveis, com melhor aparência e resistência a pragas, utilizando a correta quantidade de recursos naturais e evitando desperdícios (BOREL, 2019).

Neste sentido, estudos destacaram que os fatores ambientais significativos no

interior de estufas para melhor qualidade e produtividade são temperatura do ar, umidade relativa do ar, iluminação, radiação e umidade do solo, sendo que o monitoramento contínuo desses fatores fornece informações para tomada de decisões nos tratos culturais (HANGGORO, 2013; INÁCIO, 2020). De forma em geral, pequenos agricultores não possuem recursos necessários para automatização da coleta de dados ambientais em estufas, não conseguindo detectar com precisão as informações de variáveis cruciais como umidade e temperatura (INÁCIO, 2020).

Assim, é pertinente salientar que o uso de novas tecnologias e plataformas de prototipação colaboram para redução dos custos de implantação de sistemas de monitoramento, ampliando o acesso a pequenos produtores e instituições de pesquisa e levando ao campo novas possibilidades. Dentro deste contexto, destaca-se o desenvolvimento da Internet das Coisas (IoT) e Redes Neurais, que nos últimos anos tiveram grande impacto no processo de monitoramento e tomada de decisões em cultivos protegidos (SAGHEER, 2021; JUNG, 2020; ZHANG, 2020; RAJ, 2019; HABARAGAMUWA, 2018; MA, 2018; MOON, 2018; PALLAVI, 2017).

O desenvolvimento da Internet das Coisas (IoT) refere-se a uma rede global de objetos inteligentes, ou "coisas", com base em sensores, munidos com microcontroladores e recursos de rede. Nesse quadro, as tecnologias de comunicação podem melhorar os métodos atuais de monitoramento de estufas, apoiando a resposta apropriada em tempo real para uma ampla gama de aplicações (SAAB, 2018; RAJAB, 2018).

Na maioria dos casos a utilização de sensores de baixo custo utiliza métodos estatísticos clássicos para ajustar as leituras (SILVA, 2006; FERNANDES, 2015; TEIXEIRA, 2017), sendo um desses métodos a aplicação de regressões polinomiais, que possibilita uma análise utilizando regressão na qual a relação entre as variáveis independentes e as variáveis dependentes são modeladas no polinômio de enésimo grau.

Outra opção para ajustes de sensores é a aplicação de redes neurais (LI, 2004; DUFOUR, 2005; TIANLONG, 2010; LINO, 2017; NICOLSI, 2017; ALI, 2019; JINDONG, 2019; KOCHHAR, 2019; ROLIM, 2021), porém a aplicação de calibração de sensores de baixo custo em estufas não é amplamente difundida, sendo esta uma possibilidade para democratização e distribuição dessa tecnologia, possibilitando aos pequenos produtores o acesso a sistemas de monitoramento com valores comerciais mais acessíveis. Dentro deste contexto, o presente estudo tem como objetivo realizar

a calibração de sensores de baixo custo por regressões polinomiais e redes neurais artificiais, comparando os resultados a fim de recomendar a melhor metodologia, bem como o sensor, que apresentar as melhores generalizações de erro nas aferições.

2.2 MATERIAIS E MÉTODOS

2.2.1 LOCALIZAÇÃO

O experimento foi realizado no Departamento de Engenharia Rural da Faculdade de Ciências Agronômicas de Universidade Estadual Paulista – UNESP, campus de Botucatu, que se caracteriza pelo clima Cfa – clima subtropical úmido (CUNHA, 2009), com precipitação pluviométrica média anual de 1516,8 mm e evapotranspiração média anual de 692 mm.

2.2.2 CASA DE VEGETAÇÃO E CULTURA

A estufa onde o experimento foi instalado é composta por estrutura metálica do tipo em arco, coberta com polietileno de baixa densidade transparente difusor (PEBD 100µm de espessura), com pé direito de 2,5 metros e dimensões de 24 metros de comprimento por 7 metros de largura e laterais fechadas por tela antiofídica. Em relação à cultura existente na casa de vegetação durante o experimento, foram implantadas mudas de lúpulo da variedade *Cascade*, transplantadas em vasos e podadas com 20 cm de altura 40 dias após o transplantio para uniformização do tamanho e início do experimento.

Os vasos foram distribuídos em quatro fileiras de dez unidades, ao espaçamento de 1 metro entre plantas e 1,5 metro entre linhas, sendo cada vaso com capacidade de 25 litros, totalizando 40 plantas. O sistema de condução das plantas foi feito através de bambu e fio de sisal com altura de 2,5 metros.

Por necessidades climáticas da cultura, o experimento foi iniciado no dia 13 de setembro de 2018 e estendeu-se até o dia 11 de fevereiro de 2019, tendo os dados das variáveis microclimáticas no interior da estufa coletados durante todo o período.

2.2.3 SISTEMA DE REFERÊNCIA

Visando um sistema comercial com excelência na aquisição de temperatura e umidade relativa do ar, foi utilizado o sensor Vaisala modelo HMP45 como padrão de referência, em função de apresentar alta qualidade metrológica e ser usado na maioria das estações automáticas (BOULARD, 2004). Os dados coletados pelo sensor foram armazenados em um “registrador de dados” (Micrologger) da marca Campbell, modelo CR23X.

O sensor HMP45 incorpora um termístor-resistivo capaz de operar na faixa de -40° a 60° °C, com erro variando entre $\pm 0,5^{\circ}$ °C, e um higrômetro capacitivo operando na faixa de 0.8 até 100 % UR com acuracidade de ± 1 % UR. Assim como os sensores comerciais, sua instalação seguiu as normas padrões, sendo posicionado a uma altura de 2 metros acima do terreno (WMO, 2008).

As aquisições das leituras foram feitas a cada 10 segundos com armazenamento dos dados médios a cada 1 minuto de temperatura e umidade relativa do ar pelo sensor Vaisala.

2.2.4 SISTEMA DE COMUNICAÇÃO


A escolha do sistema de transferência de dados dos sensores comerciais (coleta de dados ambientais na estufa para o envio ao banco de dados) deu-se aplicando a metodologia criada em Rocha (2018), implementando a tecnologia LoRa, que é distribuída pela empresa Semtech, projetada especificamente para comunicações de longo alcance e baixa potência direcionada a aplicações IoT. De acordo com o mesmo autor, quando é feito o emprego das tecnologias GSM, Wi-fi, Xbee e Lora para coleta de dados em estufas, o ponto principal a ser levado em consideração é o baixo consumo de energia aliado a um maior, sendo LoRa a melhor escolha.

2.2.5 CONFECÇÃO DO ABRIGO

Como o sistema proposto prevê a coleta de variáveis microclimáticas da estufa, sendo estas temperatura e umidade relativa do ar, foi necessário a confecção de um abrigo que pudesse proteger os sensores comerciais e, de preferência, em um local protegido da incidência de radiação solar direta (WMO, 2008).

Para a criação do abrigo dos sensores, utilizou-se a impressora GTMAX3D CORE A2, seguindo concepções apresentadas pela literatura (SILVA, 2015; MARQUES, 2016; FERNANDES, 2016; FREITAS, 2018), realizando-se as etapas de criação do modelo CAD 3D, conversão dos dados no formato “STL” e importação para a impressora, efetuando-se a impressão através do fatiamento do arquivo em finas camadas transversais e a construção física do modelo. Todas as medidas e padrões físicos do abrigo prototipado seguiram os valores do abrigo de referência da Campbell, apresentando um preenchimento de 40% para a peça e visando equalizar parâmetros do tempo de impressão, quantidade de material gasto e resistência mecânica (Figura 1).

Figura 1 – A: Impressão do abrigo dos sensores, B: Visão da peça de cobertura, C: Proporção de preenchimento de uma peça em 3D- Fonte GTMax 3D / Elaborado pelos autores (2018) | Boaimpressao3d



Fonte: Elaborado pelos autores (2018).

2.2.6 PROTOTIPAÇÃO ELETRÔNICA

Para a programação dos microcontroladores ATMEL 328 (ATMEL Corporation) e Esp32 (Espressif Systems) foi utilizado a linguagem C++ através da IDE (Integrated Development Environment) do Arduino. As bibliotecas e códigos foram reescritos a fim de reduzir seu tamanho em *bytes* e para ajustar-se às necessidades de tempo de leitura do projeto.

Para a escolha dos sensores foi realizado um levantamento bibliográfico dos principais sensores de baixo custo utilizados para variáveis ambientais, chegando aos

modelos BMP180, BME280, DHT11, DHT22 e LM35 (BACON, 2020; ROMANINI, 2010; LITJENS, 2009; BERNARDI, 2017; LOPES, 2018; PROBST, 2018; GUTKOSKI, 2018; TEIXEIRA, 2017; CAMARGO, 2015; RICO, 2018).


Tabela 1 – Informações sobre os sensores comerciais selecionados para o experimento

Nome	Umidade do Ar	Temperatura do Ar	Fabricante	Preço (R\$)	Tempo de resposta	Precisão	Histerese	consumo	Range de Operação
BMP180	Não	Sim	Bosch Sensortec Co., Ltd	12	1 s	$\pm 1,0\text{ }^{\circ}\text{C}$	$1,0\text{ }^{\circ}\text{C}$	$32\text{ }\mu\text{A}$	-40 até $65\text{ }^{\circ}\text{C}$
BME280	Sim	Sim	Bosch Sensortec Co., Ltd	35	1 s	$\pm 3\% \text{ UR}$ $ \pm 0,5\text{ }^{\circ}\text{C}$	$\pm 0,5\% \text{ UR}$	$3,6\text{ }\mu\text{A}$	0 até 100 % UR -40 até $85\text{ }^{\circ}\text{C}$
DHT11	Sim	Sim	Aosong (Guangzhou) Electronics Co., Ltd	17,9	10 s	$\pm 5\% \text{ UR}$ $ \pm 2,0\text{ }^{\circ}\text{C}$	$\pm 1\% \text{ UR}$	$2,5\text{ mA}$	20 até 95 % UR 0 até $50\text{ }^{\circ}\text{C}$
DHT22	Sim	Sim	Aosong (Guangzhou) Electronics Co., Ltd	39,7	2 s	$\pm 4\% \text{ UR}$ $ \pm 0,5\text{ }^{\circ}\text{C}$	$\pm 0,5\% \text{ UR}$	$2,5\text{ mA}$	0 até 100 % UR -40 até $80\text{ }^{\circ}\text{C}$
LM35	Não	Sim	Texas Instruments Incorporated	11	1 s	$\pm 0,5\text{ }^{\circ}\text{C}$	$1,0\text{ }^{\circ}\text{C}$	$60\text{ }\mu\text{A}$	-40 até $110\text{ }^{\circ}\text{C}$

Fonte: Bosch Sensortec | Aosong Eletronics | Texas Instruments.

Na concepção das placas, foi inicialmente implementado os circuitos em *proto board* e posteriormente desenhados utilizando Software Eagle Versão 9.2.0 para Windows, convertendo o esquema eletrônico em formato SVG para produção na Máquina Router Laser VS4040. As placas de fenolite foram preparadas com a aplicação de *dryfilm*, utilizando a Router Laser para retirar a tinta no local que será corroído pelo percloroeto (ALMEIDA, 2017).

Figura 2 – Fluxo de produção de prototipação



Fonte: Elaborado pelos autores.

Após os testes dos protótipos, um modelo final foi selecionado incluindo ao circuito um RTC (*real-time clock*), sendo este relógio utilizado para marcar o momento exato das leituras. Com os ajustes finais realizados, os arquivos para as placas de circuito impresso (PCI) foram formatados e enviados para fabricação (empresa PCBWay), sendo estas montadas e validadas a fim de serem instaladas no local para coleta de dados.

2.2.7 COLETA DE DADOS

Para a coleta de dados realizou-se a aferição de temperatura e umidade relativa do ar em paralelo aos sensores comerciais de baixo custo com o sensor de referência.

Para o armazenamento dos dados coletados pelos sensores comerciais utilizou-se a tecnologia LoRa, que transmitia as informações coletadas para um *gateway* (receptor de dados) que armazenava essas informações em um banco de dados MySQL (CHANGQING, 2018). Referente ao armazenamento dos dados coletados pelo sensor de referência (Vaisala modelo HMP45), foi utilizado o *Micrologger* (um mini registrador de dados) modelo Campbell Scientific CR23X.

As aferições foram realizadas durante todo o período da condução da cultura iniciando no dia 13 de setembro de 2018 e estendeu-se até o dia 11 de fevereiro de 2019, tendo suas médias ajustadas a cada minuto selecionando o período com maiores variações de temperatura e umidade. Essa escolha deu-se devido ao fato de

que, na ocorrência de mudanças repentinas das variáveis aferidas, o fator de histerese e sensibilidade ficaria mais nítido de ser avaliado.

Dessa forma, foi selecionado o período de 12:00:00h do dia 11/11/2018 até 10:20:00h do dia 15/11/2018, para que as regressões polinomiais e as redes neurais fossem implementadas.

2.2.8 REGRESSÕES POLINOMIAIS

A regressão polinomial é uma forma de regressão linear conhecida como um caso especial de regressão linear múltipla, que estima a relação como um polinômio de enésimo grau (OSTERTAGOVÁ, 2012). O primeiro método de ajustar as leituras aferidas dos sensores comerciais de baixo custo em relação ao sensor de referência foi por meio da aplicação de regressões polinomiais.

Com aplicação das regressões foi possível identificar as melhores generalizações de erro, utilizando coeficiente de determinação (R^2), erro médio absoluto (MAE) e erro quadrático médio (EQM ou MSE em inglês), definindo o modelo em seu polinômio de enésimo grau.

O R-quadrado (R^2 ou o coeficiente de determinação) é uma medida estatística em um modelo de regressão que determina a proporção da variância na variável dependente, que pode ser explicada pela variável independente. Em outras palavras, R-quadrado mostra o quão bem os dados se ajustam ao modelo de regressão (a qualidade do ajuste).

Fórmula 1 – Coeficiente de Determinação - SQ res é a soma dos quadrados dos erros residuais, SQ tot é a soma total dos erros

$$R^2 = \frac{SQ_{exp}}{SQ_{tot}} = 1 - \frac{SQ_{res}}{SQ_{tot}}$$

Fonte: Elaborado pelos autores.

Erro Médio Absoluto (MAE) mede a magnitude média dos erros em um conjunto de previsões, sem considerar sua direção. MAE é a média sobre a amostra de verificação dos valores absolutos das diferenças entre a previsão (sensores

comerciais de baixo custo) e a observação correspondente (Vaisala - HMP45C). O MAE é uma pontuação linear, o que significa que todas as diferenças individuais são ponderadas igualmente na média.

Fórmula 2 – Erro Médio Absoluto

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} = \frac{\sum_{i=1}^n |e_i|}{n}$$

Fonte: Elaborado pelos autores.

O erro quadrático médio (EQM ou MSE em inglês) informa o quão próxima uma linha de regressão está de um conjunto de pontos. Ele faz isso através das distâncias dos pontos até a linha de regressão (essas distâncias são os “erros”) e elevando-as ao quadrado. O quadrado é necessário para remover quaisquer sinais negativos e também dá mais peso às diferenças maiores. É chamado de erro quadrático médio, pois você está encontrando a média de um conjunto de erros. Quanto menor o MSE, melhor será a previsão.

Fórmula 3 – Erro Quadrático Médio

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

Fonte: Elaborado pelos autores.


Com essas informações, utilizou-se para programar os *scripts* a linguagem Python, por meio das bibliotecas Numpy e Scikit Learn para os processos estatísticos, bem como da biblioteca Matplotlib para criação de gráficos e visualizações de dados (HUNTER, 2007). As relações entre as medidas de temperatura e umidade relativa entre os sensores comerciais e o sensor de referência foram exibidas utilizando Matplotlib por meio de gráfico de linhas em séries temporais em conjunto com histogramas de dispersão de erro.

2.2.9 REDE NEURAL

Utilizou-se para o pré-processamento as bibliotecas Numpy e Scikit Learn (Python) e para a construção da rede neural Tensorflow/Keras (GRATTAROLA, 2020). Excluiu-se valores faltantes (zeros/erro de leituras), resultando em 1122 leituras para o grupo umidade e temperatura (grupo A, criação da rede neural), para teste (grupo B) e para validação (grupo C).

A rede neural que foi proposta possui cinco camadas ocultas com respectivos 8, 16, 32, 16, 8 neurônios (Figura 3).

Figura 3 – Modelo da Rede Neural Artificial implementada no estudo



Fonte: Elaborado pelos autores.

A quantidade de camadas e neurônios da rede neural foi definida com a finalidade de testar ao máximo a capacidade desta rede de se adaptar aos dados fornecidos pelo algoritmo. Os testes usados para validação do modelo foram: o erro médio absoluto (MAE), o erro quadrático médio (MSE) e o coeficiente de determinação (R^2).

Apesar da escolha de 4000 épocas para o treinamento da rede, já com 300 épocas foi observado o menor erro de validação, corroborando com Malta (2019), que menciona não haver necessidade de grandes períodos para treinamento.

Para otimização, foi aplicado o algoritmo Adam (*adaptive momentum*), que, de acordo com Kingma (2014) e Ba (2014), é um método de gradiente descendente

estocástico baseado na estimação adaptativa dos momentos de primeira e segunda ordem.

Também foi utilizada uma função de ativação que determina a saída de cada neurônio da rede neural (BOUZON, 2021). Na presente rede neural foi utilizado ReLU (*rectified linear unit*), implementando a função matemática $f(x) = \max(0, x)$.

2.3 RESULTADOS E DISCUSSÃO

2.3.1 BME280


Aplicando a regressão polinomial, identificou-se em seu terceiro grau a melhor generalização dos erros, apresentando os valores de erro médio absoluto (MAE) de 0,96 °C, erro quadrático médio (MSE) de 1,84 °C, coeficiente de determinação de R^2 : 0,903 e probabilidade de significância inferior a 5% ($p\text{-valor} < 0,05$). Com o ajuste utilizando redes neurais, foi encontrado erro médio absoluto (MAE) de 0,64 °C, erro quadrático médio (MSE) de 1,38 °C, coeficiente de determinação de R^2 : 0,925 e probabilidade de significância inferior a 5% ($p\text{-valor} < 0,05$).

Inicialmente, é pertinente destacar que ambas metodologias foram testadas em todos os graus de significância, apresentando nível descritivo próximos de zero, o que resulta na rejeição da hipótese nula, demonstrando a existência de relação entre as medidas do sensor BME280 com o sensor de referência.

Observando a Figura 4, percebemos as leituras aferidas pelo sensor BME280 sem qualquer ajuste, que fornece valores acima dos coletados pelo sensor de referência (seja durante o período com exposição de luz ou durante o período noturno), exibindo a necessidade de corrigir as leituras do sensor através de algum método de ajuste (calibração).

Ainda na Figura 4, podemos visualizar que os valores ajustados através das regressões polinomiais e redes neurais apresentam valores muito próximos, porém ambos apresentam uma histerese semelhante quando ocorrem variações bruscas de temperatura, mostrando que essa dependência de leitura deve ser atribuída à própria constituição do sensor BME280.

Figura 4 – Análise temporal entre leituras direta, ajuste pela rede neural, ajuste por regressão polinomial e sensor de referência. BME280 temperatura do ar




Fonte: Elaborado pelos autores.

Podemos perceber através da Figura 5 que o melhor ajuste foi encontrado através do método de redes neurais, com coeficiente de determinação de R^2 : 0,925 e erro médio absoluto (MAE) de 0,64 °C, sendo este valor muito próximo ao $\pm 0,5$ °C especificado pelo próprio fabricante (BOSCH, 2015).

Ainda a respeito da Figura 5, podemos visualizar os erros residuais resultantes entre os valores ajustados dos modelos (ajuste através de regressões polinomiais e redes neurais) e sua distância até os valores de referência (aferidos pelo sensor Vaisala modelo HMP45). É possível interpretar que o ajuste através da rede neural (RNA) fornece uma deposição maior dos resíduos próximos do valor zero, enquanto pela regressão polinomial (RP) essa deposição ocorre entre as classes de -1 °C e 1°C.

Figura 5 – Histograma dos erros residuais: Rede Neural e Regressão Polinomial referente ao sensor BME280 para variável temperatura




Fonte: Elaborado pelos autores.

O fato de melhorar a generalização dos erros através do uso de uma rede neural em comparação a ajustes de métodos estatísticos clássicos é algo já descrito em outros estudos (HAN, 2021; BASHIT, 2018), mas é pertinente destacar o ineditismo para aplicações direcionadas para cultivo protegido visando atender pequenos produtores.

Analisando a variável umidade relativa do ar para o sensor BME280 na Figura 6, constatou que, assim como as leituras de temperatura sem ajuste, ocorre um deslocamento (*offset*) da leitura comparada ao sensor de referência.

Ainda na Figura 6, podemos visualizar que os valores ajustados através das regressões polinomiais e redes neurais apresentam valores que exibem uma baixa sensibilidade em momentos de redução seguida de estabilização da umidade relativa, claramente exemplificado pela queda ocorrida as 23h00 do dia 14 de novembro. Essa ocorrência já era esperada devido à histerese descrita pelo fabricante (BOSCH, 2015), bem como ao relato apresentado no estudo de Martín-Garín (2018).


Figura 6 – Análise temporal entre leituras direta, ajuste pela rede neural, ajuste por regressão polinomial e sensor de referência. BME280 para variável umidade relativa do ar



Fonte: Elaborado pelos autores.

Comparando os dois métodos de ajuste (Regressão Polinomial - RP e Redes Neurais Artificiais - RNA) para a variável umidade relativa do ar, foi obtido pela RP os valores de erro médio absoluto (MAE) de 4,14% UR, erro quadrático médio (MSE) de 29,39% UR, coeficiente de determinação de R^2 : 0,871 e probabilidade de significância inferior a 5% (p -valor<0,05). A respeito do ajuste fornecido pela RNA, foi encontrado um erro médio absoluto (MAE) de 2,56% UR, erro quadrático médio (MSE) de 19,61% UR, coeficiente de determinação de R^2 : 0,936 e probabilidade de significância inferior a 5% (p -valor<0,05).

Figura 7 – Histograma dos erros residuais: Rede Neural e Regressão Polinomial referente ao sensor BME280 para variável umidade relativa do ar



Fonte: Elaborado pelos autores.

Mais uma vez a hipótese nula foi descartada em ambas as metodologias de ajuste exibindo a RNA como a melhor opção para a generalização dos erros encontrando um valor de (MAE) de 2,56% UR, sendo esse resultado dentro do esperado para o erro padrão especificado pelo fabricante de $\pm 3\%$ UR (BOSCH, 2015). Este valor também foi descrito nos estudos de Rezvani (2020) e Martín-Garín (2018), demonstrando que o sensor em questão possui uma flexibilidade quanto à aplicação, mantendo sua qualidade de aferição.

2.3.2. DHT11


Referente às aferições de temperatura pelo sensor DHT11, foi obtido, através da regressão polinomial em seu terceiro grau, um erro médio absoluto (MAE) de 1,02 °C, erro quadrático médio (MSE) de 2,1 °C, coeficiente de determinação de R^2 : 0,89 e probabilidade de significância inferiores a 5% ($p\text{-valor} < 0,05$). Através da aplicação de RNA foi encontrado erro médio absoluto (MAE) de 1 °C, erro quadrático médio (MSE) de 1,93 °C, coeficiente de determinação de R^2 : 0,895 e probabilidade de significância inferiores a 5% ($p\text{-valor} < 0,05$).

Através dos valores apresentados para probabilidade de significância concluímos que ambos os métodos excluem a hipótese nula, demonstrando a existência de relação entre as medidas do sensor DHT11 com o sensor de referência.

Na Figura 8, é possível visualizar que as temperaturas aferidas pelo sensor comercial DHT11 apresentam um deslocamento (*offset*) superior aos valores apresentados pelo sensor de referência, exibindo a necessidade de calibração para seu uso.

Essa informação deve ser ressaltada, pois, segundo o fornecedor em seu *datasheet* (folha de dados ou folha de especificações que resume o desempenho e outras características do sensor), “cada sensor DHT11 é estritamente calibrado em laboratório sendo distribuído sem a necessidade de calibração” (AOSONG, 2015).


Figura 8 – Análise temporal entre leituras direta, ajuste pela rede neural, ajuste por regressão polinomial e sensor de referência. DHT11 temperatura do ar



Fonte: Elaborado pelos autores.

Observando a Figura 9, o melhor ajuste encontrado foi no uso do RNA com coeficiente de determinação de R^2 : 0,895 e erro médio absoluto (MAE) de 1 °C, sendo este valor apresentado pelo fabricante ($\pm 1^\circ\text{C}$), demonstrando que o modelo conseguiu utilizar o sensor em sua resolução máxima de precisão (AOSONG, 2015).

Figura 9 – Histograma dos erros residuais: Rede Neural e Regressão Polinomial referente ao sensor DHT11 para variável temperatura



Fonte: Elaborado pelos autores.


Quando analisamos os histogramas dos erros residuais exibidos na Figura 9, podemos observar que pela rede neural obtemos um histograma simétrico apresentando as maiores barras próximos do zero, o que demonstra um melhor ajuste dos valores, tendendo a apresentar um deslocamento (*offset*) inferior quando

comparado as leituras do sensor de referência. Também é possível perceber que nas duas metodologias de ajuste podemos visualizar uma deposição nas classes de $-4 \sim -5^{\circ}\text{C}$, bem como $4 \sim 5^{\circ}\text{C}$, podendo ser explicado pelo comportamento em faixa de operação em $45 \sim 50^{\circ}\text{C}$, que resulta em erros acima de 4°C como descritos em Ferrari (2019), Oliveira Júnior (2014) e Cunha (2009).

Em relação à variável umidade relativa do ar para o sensor DHT11, também forneceu um deslocamento (*offset*) inferior quando comparado com o sensor de referência, apresentando uma necessidade de calibração, mas apresentando uma histerese melhor do que foi descrito pelo seu fabricante (AOSONG, 2015).

Assim como o BME280, o sensor DHT11 apresentou uma baixa sensibilidade em momentos de redução seguida de estabilização da umidade relativa, podendo ser visualizada na data 14 de novembro às 23:00 ~ 4:30 AM.

Figura 10 – Histograma dos erros residuais: Rede Neural e Regressão Polinomial referente ao sensor DHT11 para variável umidade relativa do ar




Fonte: Elaborado pelos autores.

Analisando as duas metodologias para ajuste referente à variável de umidade relativa, foi observado na Figura 11 que a regressão polinomial forneceu um erro médio absoluto (MAE) de 4,31% UR, erro quadrático médio (MSE) de 33,91% UR, coeficiente de determinação de R^2 : 0,851 e probabilidade de significância inferior a 5% ($p\text{-valor} < 0,05$). Referente ao ajuste fornecido pela rede neural, encontrou-se um erro médio absoluto (MAE) de 4,18% UR, erro quadrático médio (MSE) de 25,61%

UR, coeficiente de determinação de R^2 : 0,866 e probabilidade de significância inferior a 5% (p -valor<0,05).

Figura 11 – Histograma dos erros residuais: Rede Neural e Regressão Polinomial referente ao sensor DHT11 para variável umidade relativa do ar



Fonte: Elaborado pelos autores.

Mais uma vez a hipótese nula foi descartada em ambas as metodologias de ajuste, esta última utilizando redes neurais e a melhor generalização dos erros encontrando um valor de (MAE) de 4,18% UR, sendo esse resultado dentro do esperado para o erro padrão especificado pelo fabricante de $\pm 4 \sim 5\%$ UR (AOSONG, 2015). Este valor foi superior ao apresentado em Hernández (2017), que conseguiu um ajuste de 5,25% UR utilizando o sensor DHT11, mostrando que mesmo com a utilização da prototipação do abrigo as leituras e os métodos de ajuste apresentam valores dentro do esperado.


2.3.3. DHT22

Para as medidas de temperatura efetuadas pelo sensor DHT22, são apresentados através do método de ajuste utilizando regressão polinomial os valores de erro médio absoluto (MAE) de 0,72 °C, erro quadrático médio (MSE) de 1,27 °C, coeficiente de determinação de R^2 : 0,916 e probabilidade de significância inferior a 5% (p -valor<0,05). Através da aplicação de RNA, foi encontrado erro médio absoluto (MAE) de 1 °C, erro quadrático médio (MSE) de 1,94 °C, coeficiente de determinação de R^2 : 0,898 e probabilidade de significância inferior a 5% (p -valor<0,05).

Assim como apresentados nos sensores BME e DHT11, ambos os métodos de ajuste resultaram em um valor de nível descritivo inferior a 5%, excluindo a hipótese nula e demonstrando a existência de relação entre as medidas do sensor DHT22 com o sensor de referência.

Na Figura 12, é possível visualizar que as temperaturas aferidas pelo sensor comercial DHT22 apresentam um deslocamento (*offset*) superior aos valores apresentados pelo sensor de referência, explicitando a necessidade de calibração para seu uso. Mais uma vez apontamos isso, pois, segundo o fornecedor em seu *datasheet* (folha de dados ou folha de especificações que resume o desempenho e outras características do sensor), “cada sensor DHT22 é estritamente calibrado em laboratório sendo distribuído sem a necessidade de calibração” (AOSONG, 2017).


Figura 12 - Análise temporal entre leituras direta, ajuste pela rede neural, ajuste por regressão polinomial e sensor de referência. DHT22 temperatura do ar



Fonte: Elaborado pelos autores.

Observando a Figura 13, podemos constatar que o melhor ajuste encontrado foi através da utilização de redes neurais, indicando para um coeficiente de determinação de R^2 : 0,916 e erro médio absoluto (MAE) de 0,72 °C, sendo este valor sendo próximo ao apresentado pelo fabricante de $\pm 0,5^\circ\text{C}$. O valor MAE obtido pela rede neural assemelhou-se ao valor obtido por Martín-Garín (2018), que recomenda o uso do sensor para “projetos com poucos pontos de medição, uma vez que requer uma entrada digital para cada sensor usado”.

Figura 13 - Histograma dos erros residuais: Rede Neural e Regressão Polinomial referente ao sensor DHT11 para variável temperatura




Fonte: Elaborado pelos autores.

Ainda referente à Figura 13, podemos visualizar os erros residuais resultantes entre os valores ajustados dos modelos (ajuste através de regressões polinomiais e redes neurais), constatando que existe uma maior deposição próxima a zero no modelo de redes neurais, exibindo assim uma excelente generalização dos erros médios.

Para avaliar a variável umidade relativa do ar aferida pelo sensor DHT22, foi possível verificar que, utilizando o ajuste pelo método de regressões polinomiais, encontrou-se um erro médio absoluto (MAE) de 4,31% UR, erro quadrático médio (MSE) de 33,91% UR, coeficiente de determinação de $R^2: 0,851$ e probabilidade de significância inferior a 5% ($p\text{-valor} < 0,05$). Quando utilizado o ajuste fornecido pela RNA, encontrou-se um erro médio absoluto (MAE) de 4,14% UR, erro quadrático médio (MSE) de 25,61% UR, coeficiente de determinação de $R^2: 0,873$ e probabilidade de significância inferior a 5% ($p\text{-valor} < 0,05$).

Figura 14 – Análise temporal entre leituras direta, ajuste pela rede neural, ajuste por regressão polinomial e sensor de referência. DHT22 para variável umidade relativa do ar




Fonte: Elaborado pelos autores.

Mais uma vez a hipótese nula foi descartada em ambas as metodologias de ajuste, apresentando com o uso de redes neurais o melhor ajuste e generalização dos erros encontrando um valor de (MAE) de 4,14% UR, sendo esse resultado dentro do esperado para o erro padrão especificado pelo fabricante de $\pm 2 \sim 5\%$ UR (AOSONG, 2017).

Os valores encontrados pela rede neural assemelham-se aos descritos em Martín-Garín (2018), que relata em seu estudo que sensor DHT22 foi um dos sensores juntamente com BME280 que apresentaram melhor precisão para aferir umidade relativa do ar. Ainda segundo o autor, sabendo das limitações desses sensores, podemos selecionar cada um deles para uma aplicação que foque no grau de precisão necessária e seu tempo de resposta.

Figura 15 – Histograma dos erros residuais: Rede Neural e Regressão Polinomial referente ao sensor DHT22 para variável umidade relativa do ar



Fonte: Elaborado pelos autores.

Quanto à Figura 15, podemos visualizar uma maior deposição próxima a zero no modelo de redes neurais, exibindo, assim, uma melhor generalização dos erros médios quando comparado ao modelo de regressões polinomiais. Podemos destacar que, quando utilizamos as duas metodologias de ajuste, em ambas ocorre uma deposição em 0,5 e 1°C positivos, demonstrando que o sensor tende a apresentar um erro de leitura de valores positivos quando comparado ao sensor de referência.

2.3.4. BMP180


Ao analisar as aferições de temperatura pelo sensor BMP180, foram obtidos utilizando a regressão polinomial em seu terceiro grau um erro médio absoluto (MAE) de 1,05 °C, erro quadrático médio (MSE) de 2,08 °C, coeficiente de determinação de $R^2: 0,891$ e probabilidade de significância inferior a 5% ($p\text{-valor} < 0,05$). Através da aplicação de RNA, foram encontrados erro médio absoluto (MAE) de 1,03 °C, erro quadrático médio (MSE) de 2,00 °C, coeficiente de determinação de $R^2: 0,896$ e probabilidade de significância inferior a 5% ($p\text{-valor} < 0,05$).

Por meio dos valores apresentados para probabilidade de significância, concluímos que ambos os métodos excluem a hipótese nula, demonstrando a existência de relação entre as medidas do sensor BMP180 com o sensor de referência.

Na Figura 16 é possível visualizar que as temperaturas aferidas pelo sensor comercial BMP180 apresentam um deslocamento (*offset*) superior aos valores

apresentados pelo sensor de referência, apontando uma necessidade de calibração para que as aferições possam ser confiáveis.


Figura 16 – Análise temporal entre leituras direta, ajuste pela rede neural, ajuste por regressão polinomial e sensor de referência. BMP180 temperatura do ar



Fonte: Elaborado pelos autores.

Podemos perceber através da Figura 17, que o melhor ajuste foi encontrado através do método de redes neurais, exibindo um coeficiente de determinação de R^2 : 0,896 e erro médio absoluto (MAE) de 1,03 °C, sendo este valor próximo ao ± 1 C° especificado pelo próprio fabricante (BOSCH, 2013). Os valores de precisão apontados pela rede neural foram semelhantes aos descritos em Martín-Garín (2018), que relata em seu estudo que “tanto o sensor BMP180 quanto o BME280 são sensores específicos para a medição da pressão atmosférica usando a temperatura como uma correção para a medição da pressão apresentando em alguns estudos uma precisão próxima de $\pm 1^\circ\text{C}$ ”.

Figura 17 – Histograma dos erros residuais: Rede Neural e Regressão Polinomial referente ao sensor BMP180 para variável temperatura



Fonte: Elaborado pelos autores.

Ainda referente à Figura 17, podemos visualizar os erros residuais resultantes entre os valores ajustados dos modelos (ajuste através de regressões polinomiais e redes neurais), constatando que existe uma maior deposição próxima a zero no modelo de redes neurais, expondo uma excelente generalização dos erros médios.

2.3.5. LM35

Para o sensor LM35, aplicou-se a regressão polinomial, identificando-se em seu terceiro grau a melhor generalização dos erros apresentando os valores de erro médio absoluto (MAE) de 1,01 °C, erro quadrático médio (MSE) de 2,02 °C, coeficiente de determinação de R^2 : 0,894 e probabilidade de significância inferior a 5% (p -valor<0,05). Com o ajuste utilizando redes neurais, foram encontrados erro médio absoluto (MAE) de 0,84 °C, erro quadrático médio (MSE) de 1,58 °C, coeficiente de determinação de R^2 : 0,907 e probabilidade de significância inferior a 5% (p -valor<0,05).


Inicialmente, é pertinente destacar que ambas metodologias foram testadas em todos os graus de significância dos coeficientes das regressões apresentando nível descritivo próximos de zero, resultando na rejeição da hipótese nula, demonstrando a existência de relação entre as medidas do sensor LM35 com o sensor de referência.

Salienta-se que, visualizando a Figura 18, percebemos as leituras aferidas pelo sensor LM35 apresentam, quando sem ajuste, valores acima dos coletados pelo

sensor de referência (seja durante o período com exposição de luz ou durante o período noturno), exibindo a necessidade de corrigir as leituras do sensor através de algum método de ajuste.

Inúmeros estudos descrevem que não é necessária uma calibração para a utilização do sensor LM35 (WAYKOLE, 2012; HUSSAIN, 2013; SHARMA, 2013; MUSTAFA, 2015; KAVITHA, 2017; DHONDGE, 2018; PHILOMINA, 2019), porém, esses estudos não apresentam um sensor comercial ou meteorológico como referência, ao passo que em estudos onde isso é feito sempre é evidenciado a necessidade de calibração para aferições confiáveis (PLESSIS, 2016; HELLÉN, 2020; CHOJER, 2020).


Figura 18 – Análise temporal entre leituras direta, ajuste pela rede neural, ajuste por regressão polinomial e sensor de referência. LM35 temperatura do ar



Fonte: Elaborado pelos autores.

Podemos perceber através da Figura 19, que o melhor ajuste foi encontrado através do método de redes neurais com coeficiente de determinação de R^2 : 0,907 e erro médio absoluto (MAE) de 0,84 °C, sendo este valor próximo ao $\pm 0,5$ °C especificado pelo próprio fabricante (TEXAS INSTRUMENTS, 1999). A precisão encontrada pela RNA assemelhou-se ao exibido em Plessis (2016), onde foi descrito que muitas vezes esse erro advém de uma histerese para a medida da temperatura pois, “o sensor é lento para reagir a mudanças acentuadas de temperatura, sendo recomendado para operar em situações em que a temperatura mudará lentamente”.

Figura 19 – Histograma dos erros residuais: Rede Neural e Regressão Polinomial referente ao sensor DHT11 para variável temperatura



Fonte: Elaborado pelos autores.

O histograma de erros residuais apresentou duas situações distintas quando comparado, no qual, pelo ajuste da rede neural, as temperaturas tendem a serem aferidas com um valor abaixo do sensor de referência, enquanto o ajuste através de regressões polinomiais apresenta erros depositados em sua maioria em temperaturas acima do que medidas pelo sensor de referência.

2.4. CONCLUSÕES

Quando comparadas as duas metodologias de ajuste das aferições dos sensores de baixo custo, foi possível concluir que a aplicação de redes neurais apresentou os melhores resultados em todos os casos.

Dentre todos os sensores comerciais de baixo custo avaliados no estudo, o sensor BME280 apresentou os melhores resultados tanto para aferições de temperatura quanto para umidade relativa do ar. O valor apresentado com o sensor resultou em um coeficiente de determinação de $R^2: 0,925$ e erro médio absoluto (MAE) de 0,64 °C para variável temperatura e coeficiente de determinação de $R^2: 0,936$ e erro médio absoluto (MAE) de 2,56% UR para variável umidade relativa do ar.

É pertinente salientar que metodologias de prototipação foram utilizadas para o projeto, exibindo em todos os sensores um nível descritivo próximo de zero, resultando na rejeição da hipótese nula, demonstrando a existência de relação entre as medidas dos sensores comerciais com o sensor de referência.

Desde o início da pesquisa, nunca foram esperadas sensibilidade e precisão dos sensores comerciais de baixo custo próximos do sensor de referência, mas podemos concluir que, para casos em que as faixas de trabalho da cultura aceitem uma precisão de $\pm 1\text{ }^{\circ}\text{C}$ e $\pm 4\%$ UR, todos os sensores estudados podem ser utilizados desde que previamente calibrados.

Por fim, agradecemos o auxílio da FAPESP PIPE - Fase 1 / 2º Ciclo/2017 (Processo nº 2017/08693-6) que possibilitou a implementação e desenvolvimento dessa pesquisa.

REFERÊNCIAS

ALI, Asmaa; HASSANEIN, Hossam S. Wireless sensor network and deep learning for prediction greenhouse environments. **2019 International Conference on Smart Applications, Communications and Networking (SmartNets)**. IEEE, 2019. p. 1-5.

_____. Time-Series Prediction for Sensing in Smart Greenhouses. **GLOBECOM 2020-2020 IEEE Global Communications Conference**. IEEE, 2020. p. 1-6.

AOSONG ELECTRONICS. **DHT 11 Humidity & Temperature Sensor**. Disponível em: <[https://www.mouser.com/ds/2/758/DHT11- Technical-Data-Sheet Translated-Version-1143054.pdf](https://www.mouser.com/ds/2/758/DHT11-Technical-Data-Sheet-Translated-Version-1143054.pdf)>. 2015. Acesso em: 14 de julho de 2017.

_____. **DHT 22 Humidity & Temperature Sensor**. Disponível em: <<https://www.sparkfun.com/datasheets/Sensors/Temperature/DHT22.pdf>>. 2017. Acesso em: 14 de julho de 2017.

AL BASHIT, Abdullah; VALLES, Damian. A Solar Powered Raspberry Pi Houston Toad Call Detection System Using Neural Network Model. **2018 International Conference on Computational Science and Computational Intelligence (CSCI)**. IEEE, 2018. p. 1024-1027.

ALMEIDA, FAUTH, Leduc Hermeto; DA SILVA, Edgar Monteiro; BATISTA, Pablo Diniz. Faça você mesmo: Placas de circuito impresso de dupla face usando método fotográfico Do-It-Yourself: Dual-Sided Printed Circuit Boards Using Photographic Method. **NOTAS TÉCNICAS**, v. 7, n. 1, 2017.

BACON, Emily et al. Distribuição de temperatura na vertical e na horizontal no interior de uma estufa agrícola. **Anais do Salão Internacional de Ensino, Pesquisa e Extensão**, v. 12, n. 3, 2020.

BERNARDI, André Luiz; QUITAISKI, Kleison Paulo; SANTOS, Paulo Ricardo dos. **Sistema de irrigação automatizado de hortaliças**. 2017. Monografia (Trabalho de Conclusão de Curso). Universidade Tecnológica Federal do Paraná.

BOREL JÚNIOR, P. R. Controle de sistema automatizado do microclima de uma estufa. 2019. Monografia (Conclusão de Curso) - Universidade Federal de Ouro Preto, João Monlevade.

BOSCH SG. **BMP180 Data sheet**. 2013. Disponível em: <<https://cdn-shop.adafruit.com/datasheets/BST-BMP180-DS000-09.pdf>>. Acesso em: 14 de julho de 2017.

BOULARD, Thierry et al. Effect of greenhouse ventilation on humidity of inside air and in leaf boundary-layer. **Agricultural and Forest Meteorology**, v. 125, n. 3-4, p. 225-239, 2004.

BOUZON, M. F. Estudo de algoritmos de otimização inspirados na natureza aplicados ao treinamento de redes neurais artificiais. 2021. Dissertação (Mestrado em Engenharia Elétrica) - Centro Universitário FEI, São Bernardo do Campo.

CAMARGO, Tiago Francisconi Borges. **Determinação de distribuição de temperatura em aviário utilizando fluidodinâmica computacional e sistema de medição com Arduino**. 2015. Dissertação de Mestrado. Universidade Estadual de Maringá.

CUNHA, Antonio Ribeiro; MARTINS, Dinival. Classificação climática para os municípios de Botucatu e São Manuel, SP. **Irriga**, v. 14, n. 1, p. 1-11, 2009.

CHANGQING, Cai; HUI, Liu; WENJUN, Hou. Internet of agriculture-based low cost smart greenhouse remote monitor system. **2018 chinese automation congress (CAC)**. IEEE, 2018. p. 3940-3945.

CHOJER, H. et al. Development of low-cost indoor air quality monitoring devices: Recent advancements. **Science of The Total Environment**, v. 727, p. 138385, 2020.

DHONDGE, Bhagyashri Nagorao; JADHAV, Suhas Sayajirao. RASPBERRY PI Based Greenhouse Management System. **International Journal on Recent and Innovation Trends in Computing and Communication**, 2018. v. 6, n. 1, p. 171-173.

DUFOUR, Pascal et al. Neural network-based software sensor: training set design and application to a continuous pulp digester. **Control Engineering Practice**, v. 13, n. 2, p. 135-143, 2005.

DU PLESSIS, R.; Kumar, A.; Hancke, G.P.; Silva, B.J. A wireless system for indoor air quality monitoring. In.: IECON. **Proceedings of the IECON2016-42nd Annual Conference of the IEEE Industrial Electronics Society**. IEEE, Piscataway, NJ, pp. 5409–5414. Disponível em: <<https://doi.org/10.1109/iecon.2016.7794087>>.

FAO. **The State of Food Security and Nutrition in the World – Building Climate Resilience for Food Security And Nutrition**; Food and Agriculture Organization of the United Nations (FAO): Rome, Italy, 2018.

FERNANDES, Rafael Dreux Miranda. **Resposta do almeirão (Cichorium intybus L.) cultivar “folha larga” cultivado em estufa agrícola sob diferentes lâminas de irrigação**. 2015. Tese (Doutorado). Escola Superior de Agricultura Luiz de Queiroz, Piracicaba.

FREITAS, Marina Pinto Pizarro de. **Caracterização de sensores e abrigos meteorológicos de baixo custo**. 2018.

GUTKOSKI, Eduardo Pedó. **Dosador eletrônico de fertilizantes para morangos**. 2018.

GRATTAROLA, D.; ALIPPI, C. Graph neural networks in tensorflow and keras with spektral. 2020. Disponível em: <<https://arxiv.org/abs/2006.12138>>. Acesso em: 22 de agosto de 2018.

HABARAGAMUWA, Harshana et al. Detecting greenhouse strawberries (mature and immature), using deep convolutional neural network. **Engineering in Agriculture, Environment and Food**, v. 11, n. 3, p. 127-138, 2018.

HAN, Pengfei et al. Calibrations of Low-Cost Air Pollution Monitoring Sensors for CO, NO₂, O₃, and SO₂. **Sensors**, v. 21, n. 1, p. 256, 2021.

HANGGORO, A. et al. Green house monitoring and controlling using Android mobile application. In: **2013 INTERNATIONAL CONFERENCE ON QIR**. Proceedings [...]. Yogyakarta: IEEE, 2013. p. 79-85.

HELLÉN, Heidi et al. Sesquiterpenes dominate monoterpenes in northern wetland emissions. **Atmospheric Chemistry and Physics**, v. 20, n. 11, p. 7021-7034, 2020.

HERNÁNDEZ-RIVERA, Daniel et al. A capacitive humidity sensor based on an electrospun PVDF/graphene membrane. **Sensors**, v. 17, n. 5, p. 1009, 2017.

HSIEH, Hsing-Chuan et al. Local Precipitation Forecast with LSTM for Greenhouse Environmental Control. In: **2020 International Conference on Pervasive Artificial Intelligence (ICPAI)**. IEEE, 2020. p. 175-182.

HUNTER, John D. Matplotlib: A 2D graphics environment. **Computing in science & engineering**, v. 9, n. 03, p. 90-95, 2007.

HUSSAIN, Rana H.; MARHOON, Ali F.; RASHID, Mofeed T. Wireless monitor and control system for greenhouse. **International journal of computer science and mobile computing**, v. 2, n. 12, p. 69-87, 2013.

INÁCIO, R. A.; MIGLIANO, A. C. C. Estufas automatizadas proporcionam menos impactos ambientais do que as lavouras convencionais. *Diálogos Interdisciplinares*, Mogi das Cruzes, v. 9, n. 5, p. 123-136, 2020.

JUNG, Dae-Hyun et al. Time-serial analysis of deep neural network models for prediction of climatic conditions inside a greenhouse. **Computers and Electronics in Agriculture**, v. 173, p. 105402, 2020.

KAVITHA, A.; RAMESH, M. Solar based greenhouse automation system for concrete roof. **International Journal of Mathematical Sciences and Engineering (IJMSE)**, v. 5, n. 2, p. 1-5, 2017.

KOCHHAR, Aarti; KUMAR, Naresh. Wireless sensor networks for greenhouses: An end-to-end review. **Computers and Electronics in Agriculture**, v. 163, p. 104877, 2019.

JINDONG, W. et al. Deep learning for sensorbased activity recognition: a survey. *Pattern Recognition Letters*, **Amsterdam**, v. 119, p. 3-11, 2019.

JUAN, R.; Joossen, G.; SANZ, D.; DEL CERRO, J.; BARRIENTOS, A. Mini-UAV Based Sensory System for Measuring Environmental Variables in Greenhouses. **Sensors**. 2015, n. 15, p. 3334–3350.

LI, Hanyi. **Comprehensive evaluation and optimization of empirical and semi-analytical bio-optical algorithms and application of a neural network model for**

estimating chlorophyll a concentrations in Lake Superior. Michigan: Michigan Technological University, 2004.

LINO, André Manuel Marques Ferreira. **Previsão de valores de humidade do solo com dados de rede de sensores sem fios (wireless) em área aberta e previsão meteorológica da internet para aplicação na agricultura.** 2017.

LIMA, G. H. E. L.; SILVA, L. C.; RIBEIRO NETO, P. F. WSN as a tool for supporting agriculture in the precision irrigation. In: **INTERNACIONAL CONFERENCE ON NETWORKING AND SERVICES, 6, 2012**, Cancun. Rolla: Institute of Electrical and Electronics Engineers, 2010. p. 137-142.

LIU, Yuwen et al. A long short-term memory-based model for greenhouse climate prediction. **International Journal of Intelligent Systems**, 2021.

LING, K.-S. et al. First report of tomato brown rugose fruit virus infecting greenhouse tomato in the United States. *Plant Disease*, St. Paul, v. 103, no. 6, p. 1439, 2019.

LI, Z. et al. Practical deployment of an in-field soil property wireless sensor network. *Computer Standards & Interfaces*, **New York**, v. 36, no. 1, p. 278-287, 2004.

LITJENS, Otto Jacob et al. **Automação de estufas agrícolas utilizando sensoriamento remoto e o protocolo Zigbee.** 2009. Tese de Doutorado. Universidade de São Paulo.

LOPES, Kayon VL; PIRES, Danúbia S.; GINALBER, L. de O. Sistema Hidropônico Inteligente Baseado em um Sistema MIMO Nebuloso. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 6, n. 2, 2018.

LATTUADA, D. S. et al. **Cultivo protegido de videiras: um panorama em municípios da Serra Gaúcha.** Porto Alegre: SEAPDR/ DDPA, 2020. (Embrapa Uva e Vinho-Fôlder/Folheto/Cartilha (INFOTECA-E).

MA, JunCheng et al. Disease recognition system for greenhouse cucumbers based on deep convolutional neural network. **Transactions of the Chinese Society of Agricultural Engineering**, v. 34, n. 12, p. 186-192, 2018.

MALTA, E. M.; AVILA, S.; BORIN, E. Exploring the cost-benefit of AWS EC2 GPU instances for deep learning applications. In: **IEEE/ACM INTERNATIONAL CONFERENCE ON UTILITY AND CLOUD COMPUTING**, 12, 2019, p. 21-29.

MARQUES, João Basso et al. **Desenvolvimento de sistema para monitoramento e aquisição de dados microclimáticos utilizando o Programa EPICS.** 2016.

MARTÍN-GARÍN, A. et al. Environmental monitoring system based on an Open Source Platform and the Internet of Things for a building energy retrofit. **Automation in Construction**, v. 87, p. 201-214, 2018.

MOON, Tae Won et al. Estimation of greenhouse CO₂ concentration via an artificial neural network that uses environmental factors. **Horticulture, Environment, and Biotechnology**, v. 59, n. 1, p. 45-50, 2018.

MUSTAFA, Ahmed Adil Musa et al. **MONITORING AND CONTROLLING OF GREENHOUSE**. 2015. Tese de Doutorado. Sudan University of Sciences and Technology.

NICOLOSI, Giuseppina; VOLPE, Roberto; MESSINEO, Antonio. An innovative adaptive control system to regulate microclimatic conditions in a greenhouse. **Energies**, v. 10, n. 5, p. 722, 2017.

OSTERTAGOVÁ, Eva. Modelling using polynomial regression. **Procedia Engineering**, v. 48, p. 500-506, 2012.

PALLAVI, S.; MALLAPUR, Jayashree D.; BENDIGERI, Kirankumar Y. Remote sensing and controlling of greenhouse agriculture parameters based on IoT. In: **2017 International Conference on Big Data, IoT and Data Science (BIG)**. IEEE, 2017. p. 44-48.

PHILOMINA, S.; SUNDARARAJAN, M.; SUSILA, M. Design of Greenhouse Monitoring Using Sensor Network based on Arduinio. **Eurasian Journal of Analytical Chemistry**, v. 12, n. 3, p. 159-166, 2019.

PROBST, Éliton. Desenvolvimento e avaliação de um sensor de ponto de orvalho, com pastilhas peltier, para medição de umidade relativa do ar. 2018.

RAJ, Jennifer S.; ANANTHI, J. Vijitha. Automation using IoT in greenhouse environment. **Journal of Information Technology**, v. 1, n. 01, p. 38-47, 2019.

RICO, Soto, KENIA, Guadalupe. Sensores de bajo costo para el monitoreo de la calidad del aire en la ciudad de Hermosillo, Sonora. 2018.

ROCHA, Luis Augusto Gomes. Análise da qualidade do ar em tempo real usando rede de sensores, **PIPE – FAPESP** - São Paulo, 01 de fev. 2018. Disponível em: <<https://bv.fapesp.br/pt/auxilios/99132/analise-da-qualidade-do-ar-em-tempo-real-usando-rede-de-sensores/>>. Acesso em: 20 de jun. de 2018.

ROLIM, Talyson Weber Rodrigues. Unidade autônoma de manejo da irrigação de baixo custo controlado via aplicativo para cultivos em ambiente protegido. 2021.

ROMANINI, Carlos EB et al. Desenvolvimento e simulação de um sistema avançado de controle ambiental em cultivo protegido. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, p. 1194-1201, 2010.

RAJAB, H.; CINKELR, T. IoT based smart cities. In: INTERNATIONAL SYMPOSIUM ON NETWORKS, COMPUTERS AND COMMUNICATIONS (ISNCC), 2018, Proceedings [...]. IEEE, 2018. p. 1-4.

SAAB, S. et al. Positive impact of interference on RF energy harvesting for IoT devices. In: IEEE INTERNATIONAL SYMPOSIUM ON PERSONAL, INDOOR AND MOBILE RADIO COMMUNICATIONS (PIMRC), 29. IEEE, 2018. p. 312-317.

SAGHEER, Alaa et al. A cloud-based IoT platform for precision control of soilless greenhouse cultivation. **Sensors**, v. 21, n. 1, p. 223, 2021.

SHARMA, Jay S.; MAKWANA, Gautam D. Intelligent crop management system for greenhouse environment. **International Journal of Science and Research**, v. 2, n. 4, p. 205-208, 2013.

SILVA, Ilda de Oliveira. Desenvolvimento de um sensor capacitivo para o monitoramento de umidade do solo. 2006.

TEIXEIRA, Grazielle Bonaldi; ALMEIDA, João Víctor Peroni de. **Rede LoRa® e protocolo LoRaWAN® aplicados na agricultura de precisão no Brasil**. 2017. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.

TEXAS INSTRUMENTS, "LM35 Precision Centigrade Temperature Sensors", LM35 datasheet, Aug. 1999.

TIANLONG, Ni. Application of single bus sensor dht11 in temperature humidity measure and control system [J]. **Microcontrollers & Embedded Systems**, v. 6, n. 2010, p. 026, 2010.

WAYKOLE, Uday A.; AGRAWAL, Dhiraj G. Greenhouse automation system. In: **1st International Conference on Recent Trends in Engineering & Technology**. 2012. p. 161-166.

WMO - World Meteorological Organization. **Guide to Meteorological Instruments and Methods of Observation**: preliminary seventh edition, 2008.

ZHANG, Lingxian et al. Growth monitoring of greenhouse lettuce based on a convolutional neural network. **Horticulture Research**, v. 7, n. 1, p. 1-12, 2020.

CONSIDERAÇÕES FINAIS

Através dessa pesquisa foi possível demonstrar a viabilidade do desenvolvimento de um sistema de coleta de dados ambientais utilizando sensores de baixo custo.

Quando comparadas as duas metodologias de ajuste das aferições dos sensores de baixo custo, foi possível concluir que a aplicação de redes neurais apresentou os melhores resultados em todos os casos.

A respeito da prototipação de abrigos, recomenda-se avaliar o fator de preenchimento da impressão 3D, pois foi comprovado que o mesmo tem influência sobre a coleta de dados quando expostos a influência da radiação solar.

Dentre todos os sensores comerciais de baixo custo avaliados no estudo, o sensor BME280 apresentou os melhores resultados tanto para aferições de temperatura quanto para umidade relativa do ar. O valor apresentado com o sensor resultou em um coeficiente de determinação de R^2 : 0,925 e erro médio absoluto (MAE) de 0,64 °C para variável temperatura e coeficiente de determinação de R^2 : 0,936 e erro médio absoluto (MAE) de 2,56% UR para variável umidade relativa do ar.

Desde o início da pesquisa, nunca foram esperadas sensibilidade e precisão dos sensores comerciais de baixo custo próximos do sensor de referência, mas podemos concluir que, para casos em que as faixas de trabalho da cultura aceitem uma precisão de ± 1 C° e $\pm 4\%$ UR, todos os sensores estudados podem ser utilizados desde que previamente calibrados.

Por fim, agradecemos o auxílio da FAPESP PIPE - Fase 1 / 2º Ciclo/2017 (Processo nº 2017/08693-6) que possibilitou a implementação e desenvolvimento dessa pesquisa.

REFERÊNCIAS

ALI, Asmaa; HASSANEIN, Hossam S. Wireless sensor network and deep learning for prediction greenhouse environments. **2019 International Conference on Smart Applications, Communications and Networking (SmartNets)**. IEEE, 2019. p. 1-5.

_____. Time-Series Prediction for Sensing in Smart Greenhouses. **GLOBECOM 2020-2020 IEEE Global Communications Conference**. IEEE, 2020. p. 1-6.

AOSONG ELECTRONICS. **DHT 11 Humidity & Temperature Sensor**. Disponível em: <[https://www.mouser.com/ds/2/758/DHT11- Technical-Data-Sheet Translated-Version-1143054.pdf](https://www.mouser.com/ds/2/758/DHT11-Technical-Data-Sheet-Translated-Version-1143054.pdf)>. 2015. Acesso em: 14 de julho de 2017.

_____. **DHT 22 Humidity & Temperature Sensor**. Disponível em: <<https://www.sparkfun.com/datasheets/Sensors/Temperature/DHT22.pdf>>. 2017. Acesso em: 14 de julho de 2017.

AL BASHIT, Abdullah; VALLES, Damian. A Solar Powered Raspberry Pi Houston Toad Call Detection System Using Neural Network Model. **2018 International Conference on Computational Science and Computational Intelligence (CSCI)**. IEEE, 2018. p. 1024-1027.

ALMEIDA, FAUTH, Leduc Hermeto; DA SILVA, Edgar Monteiro; BATISTA, Pablo Diniz. Faça você mesmo: Placas de circuito impresso de dupla face usando método fotográfico Do-It-Yourself: Dual-Sided Printed Circuit Boards Using Photographic Method. **NOTAS TÉCNICAS**, v. 7, n. 1, 2017.

AZEVEDO, Angelo Tiago. **Desenvolvimento de dispositivos eletrônicos alternativos para auxílio no manejo da irrigação via IoT**. 2021. Tese de Doutorado. Universidade de São Paulo.

BACON, Emily et al. Distribuição de temperatura na vertical e na horizontal no interior de uma estufa agrícola. **Anais do Salão Internacional de Ensino, Pesquisa e Extensão**, v. 12, n. 3, 2020.

BARATTO, Jakeline; GALVANI, Emerson; WOLLMANN, Cássio Arthur. Calibração e desempenho do abrigo meteorológico de baixo custo em condições de campo. **Revista Brasileira de Climatologia**, v. 26, 2020.

BERNARDI, André Luiz; QUITAISKI, Kleison Paulo; SANTOS, Paulo Ricardo dos. **Sistema de irrigação automatizado de hortaliças**. 2017. Monografia (Trabalho de Conclusão de Curso). Universidade Tecnológica Federal do Paraná.

BOREL JÚNIOR, P. R. Controle de sistema automatizado do microclima de uma estufa. 2019. Monografia (Conclusão de Curso) - Universidade Federal de Ouro Preto, João Monlevade.

BOSCH SG. **BMP180 Data sheet**. 2013. Disponível em: <<https://cdn-shop.adafruit.com/datasheets/BST-BMP180-DS000-09.pdf>>. Acesso em: 14 de julho de 2017.

BOSCH SENSORTEC. **Data sheet BMP180 Digital pressure sensor**. [S.l.], 2013. Disponível em: Acesso em: 11 jan. 2017.

BOULARD, Thierry et al. Effect of greenhouse ventilation on humidity of inside air and in leaf boundary-layer. **Agricultural and Forest Meteorology**, v. 125, n. 3-4, p. 225-239, 2004.

BOUZON, M. F. Estudo de algoritmos de otimização inspirados na natureza aplicados ao treinamento de redes neurais artificiais. 2021. Dissertação (Mestrado em Engenharia Elétrica) - Centro Universitário FEI, São Bernardo do Campo.

CAMARGO, Tiago Francisconi Borges. **Determinação de distribuição de temperatura em aviário utilizando fluidodinâmica computacional e sistema de medição com Arduino**. 2015. Dissertação de Mestrado. Universidade Estadual de Maringá.

CHANGQING, Cai; HUI, Liu; WENJUN, Hou. Internet of agriculture-based low cost smart greenhouse remote monitor system. **2018 chinese automation congress (CAC)**. IEEE, 2018. p. 3940-3945.

CHAVES, Jô Vinícius Barrozo et al. **Desenvolvimento de nó-sensor de baixo custo para avaliação de variáveis meteorológicas em áreas verdes urbanas**. 2021.

CHIOMENTO, José Luís Trevizan et al. Horticultural potential of nine strawberry cultivars by greenhouse production in Brazil: A view through multivariate analysis. **Scientia Horticulturae**, v. 279, p. 109738, 2021.

CHOJER, H. et al. Development of low-cost indoor air quality monitoring devices: Recent advancements. **Science of The Total Environment**, v. 727, p. 138385, 2020.

CUNHA, Antonio Ribeiro; MARTINS, Dinival. Classificação climática para os municípios de Botucatu e São Manuel, SP. **Irriga**, v. 14, n. 1, p. 1-11, 2009.

DANITA, M. et al. IoT based automated greenhouse monitoring system. In: **2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS)**. IEEE, 2018. p. 1933-1937.

DHONDGE, Bhagyashri Nagorao; JADHAV, Suhas Sayajirao. RASPBERRY PI Based Greenhouse Management System. **International Journal on Recent and Innovation Trends in Computing and Communication**, 2018. v. 6, n. 1, p. 171-173.

DUFOUR, Pascal et al. Neural network-based software sensor: training set design and application to a continuous pulp digester. **Control Engineering Practice**, v. 13, n. 2, p. 135-143, 2005.

DU PLESSIS, R.; Kumar, A.; Hancke, G.P.; Silva, B.J. A wireless system for indoor air quality monitoring. In.: IECON. **Proceedings of the IECON2016-42nd Annual Conference of the IEEE Industrial Electronics Society**. IEEE, Piscataway, NJ, pp. 5409–5414. Disponível em: <<https://doi.org/10.1109/iecon.2016.7794087>>.

FAO. **The State of Food Security and Nutrition in the World – Building Climate Resilience for Food Security And Nutrition**; Food and Agriculture Organization of the United Nations (FAO): Rome, Italy, 2018.

FERNANDES, C. A.; COSTA, J. R. Complex permittivity and anisotropy measurement of 3Dprinted PLA at microwaves and millimeter-waves. In: **INTERNATIONAL CONFERENCE ON APPLIED ELECTROMAGNETICS AND COMMUNICATIONS (ICECOM)**, v. 22. Proceedings [...]. IEEE, 2016. p. 1-6.

FERNANDES, Rafael Dreux Miranda. **Resposta do almeirão (*Cichorium intybus* L.) cultivar “folha larga” cultivado em estufa agrícola sob diferentes lâminas de irrigação**. 2015. Tese (Doutorado). Escola Superior de Agricultura Luiz de Queiroz, Piracicaba.

FERRARI, R. M. **Análise do cultivo de alface crespa em ambiente protegido baseada em grandezas físicas e processamento digital de imagens**. 2019. Dissertação (Mestrado em Computação Aplicada) - Universidade Estadual de Ponta Grossa, Ponta Grossa, 2019.

FREITAS, Marina Pinto Pizarro de. **Caracterização de sensores e abrigos meteorológicos de baixo custo**. 2018.

FOSSA, Solange Maria; DE CARLI, Eloir. Potencialidades e desafios na construção de uma estação meteorológica de baixo custo. In: **4º Salão de Pesquisa, Extensão e Ensino do IFRS**. 2020.

GRATTAROLA, D.; ALIPPI, C. Graph neural networks in tensorflow and keras with spektral. 2020. Disponível em: <<https://arxiv.org/abs/2006.12138>>. Acesso em: 22 de agosto de 2018.

GUTKOSKI, Eduardo Pedó. **Dosador eletrônico de fertilizantes para morangos**. 2018.

HABARAGAMUWA, Harshana et al. Detecting greenhouse strawberries (mature and immature), using deep convolutional neural network. **Engineering in Agriculture, Environment and Food**, v. 11, n. 3, p. 127-138, 2018.

HAN, Pengfei et al. Calibrations of Low-Cost Air Pollution Monitoring Sensors for CO, NO₂, O₃, and SO₂. **Sensors**, v. 21, n. 1, p. 256, 2021.

HANGGORO, A. et al. Green house monitoring and controlling using Android mobile application. In: **2013 INTERNATIONAL CONFERENCE ON QIR**. Proceedings [...]. Yogyakarta: IEEE, 2013. p. 79-85.

HELLÉN, Heidi et al. Sesquiterpenes dominate monoterpenes in northern wetland emissions. **Atmospheric Chemistry and Physics**, v. 20, n. 11, p. 7021-7034, 2020.

HERNÁNDEZ-RIVERA, Daniel et al. A capacitive humidity sensor based on an electrospun PVDF/graphene membrane. **Sensors**, v. 17, n. 5, p. 1009, 2017.

HOJAIJI, Hannaneh et al. Temperature and humidity calibration of a low-cost wireless dust sensor for real-time monitoring. In: **2017 IEEE sensors applications symposium (SAS)**. IEEE, 2017. p. 1-6.

HSIEH, Hsing-Chuan et al. Local Precipitation Forecast with LSTM for Greenhouse Environmental Control. In: **2020 International Conference on Pervasive Artificial Intelligence (ICPAI)**. IEEE, 2020. p. 175-182.

HUNTER, John D. Matplotlib: A 2D graphics environment. **Computing in science & engineering**, v. 9, n. 03, p. 90-95, 2007.

HUSSAIN, Rana H.; MARHOON, Ali F.; RASHID, Mofeed T. Wireless monitor and control system for greenhouse. **International journal of computer science and mobile computing**, v. 2, n. 12, p. 69-87, 2013.

INÁCIO, R. A.; MIGLIANO, A. C. C. Estufas automatizadas proporcionam menos impactos ambientais do que as lavouras convencionais. *Diálogos Interdisciplinares, Mogi das Cruzes*, v. 9, n. 5, p. 123-136, 2020.

JINDONG, W. et al. Deep learning for sensorbased activity recognition: a survey. *Pattern Recognition Letters, Amsterdam*, v. 119, p. 3-11, 2019.

JUAN, R.; Joossen, G.; SANZ, D.; DEL CERRO, J.; BARRIENTOS, A. Mini-UAV Based Sensory System for Measuring Environmental Variables in Greenhouses. **Sensors**. 2015, n. 15, p. 3334–3350.

JUNG, Dae-Hyun et al. Time-serial analysis of deep neural network models for prediction of climatic conditions inside a greenhouse. **Computers and Electronics in Agriculture**, v. 173, p. 105402, 2020.

JÚNIOR, Marcos de Oliveira Valin; DE MOURA SANTOS, Flávia Maria. Análise da utilização de abrigos termo-higrométricos alternativos para transectos móveis. **Engineering Sciences**, v. 8, n. 3, p. 53-64, 2020.

KAVITHA, A.; RAMESH, M. Solar based greenhouse automation system for concrete roof. **International Journal of Mathematical Sciences and Engineering (IJMSE)**, v. 5, n. 2, p. 1-5, 2017.

KOCHHAR, Aarti; KUMAR, Naresh. Wireless sensor networks for greenhouses: An end-to-end review. **Computers and Electronics in Agriculture**, v. 163, p. 104877, 2019.

LI, Hanyi. **Comprehensive evaluation and optimization of empirical and semi-analytical bio-optical algorithms and application of a neural network model for estimating chlorophyll a concentrations in Lake Superior**. Michigan: Michigan Technological University, 2004.

LINO, André Manuel Marques Ferreira. **Previsão de valores de humidade do solo com dados de rede de sensores sem fios (wireless) em área aberta e previsão meteorológica da internet para aplicação na agricultura**. 2017.

LIMA, G. H. E. L.; SILVA, L. C.; RIBEIRO NETO, P. F. WSN as a tool for supporting agriculture in the precision irrigation. In: **INTERNACIONAL CONFERENCE ON NETWORKING AND SERVICES, 6, 2012**, Cancun. Rolla: Institute of Electrical and Electronics Engineers, 2010. p. 137-142.

LIU, Yuwen et al. A long short-term memory-based model for greenhouse climate prediction. **International Journal of Intelligent Systems**, 2021.

LING, K.-S. et al. First report of tomato brown rugose fruit virus infecting greenhouse tomato in the United States. *Plant Disease, St. Paul*, v. 103, no. 6, p. 1439, 2019.

LI, Z. et al. Practical deployment of an in-field soil property wireless sensor network. *Computer Standards & Interfaces*, **New York**, v. 36, no. 1, p. 278-287, 2004.

LITJENS, Otto Jacob et al. **Automação de estufas agrícolas utilizando sensoramento remoto e o protocolo Zigbee**. 2009. Tese de Doutorado. Universidade de São Paulo.

LOPES, Kayon VL; PIRES, Danúbia S.; GINALBER, L. de O. Sistema Hidropônico Inteligente Baseado em um Sistema MIMO Nebuloso. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 6, n. 2, 2018.

LATTUADA, D. S. et al. **Cultivo protegido de videiras: um panorama em municípios da Serra Gaúcha**. Porto Alegre: SEAPDR/ DDPA, 2020. (Embrapa Uva e Vinho-Fôlder/Folheto/Cartilha (INFOTECA-E).

LOPES, Kayon VL; PIRES, Danúbia S.; GINALBER, L. de O. Sistema Hidropônico Inteligente Baseado em um Sistema MIMO Nebuloso. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 6, n. 2, 2018.

MA, JunCheng et al. Disease recognition system for greenhouse cucumbers based on deep convolutional neural network. **Transactions of the Chinese Society of Agricultural Engineering**, v. 34, n. 12, p. 186-192, 2018.

MALTA, E. M.; AVILA, S.; BORIN, E. Exploring the cost-benefit of AWS EC2 GPU instances for deep learning applications. In: **IEEE/ACM INTERNATIONAL CONFERENCE ON UTILITY AND CLOUD COMPUTING**, 12, 2019, p. 21-29.

MARCELIS, L.; COSTA, J.M.; HEUVELINK, E. Achieving sustainable greenhouse production: Present status, recent advances and future developments. *Achieving Sustainable Greenhouse Cultivation*. **Burleigh Dodds Science Publishing Limited**, p. 1–14, 2019. Disponível em: <<https://doi.org/10.19103/AS.2019.0052.01>>. Acesso em:15/06/2019

MARQUES FILHO, Aldir Carpes et al. **Desenvolvimento e avaliação de um sistema de monitoramento micro-ambiental com o uso de torres de aquisição em casas de vegetação**. 2019, p. 1-388–416.

MARQUES, João Basso et al. **Desenvolvimento de sistema para monitoramento e aquisição de dados microclimáticos utilizando o Programa EPICS**. 2016.

MARTÍN-GARÍN, A. et al. Environmental monitoring system based on an Open Source Platform and the Internet of Things for a building energy retrofit. **Automation in Construction**, v. 87, p. 201-214, 2018.

MCROBERTS, Michael. **Arduino básico**. Novatec Editora, 2018.

MONTEIRO, Nathália Arthur Brunet; DA SILVA, Jaidilson Jó; DA ROCHA NETO, José Sérgio. **Uso do Conceito de Sensor Virtual Aplicado ao Monitoramento e Controle de Temperatura de uma Estufa Térmica**. 2014.

MOON, Tae Won et al. Estimation of greenhouse CO₂ concentration via an artificial neural network that uses environmental factors. **Horticulture, Environment, and Biotechnology**, v. 59, n. 1, p. 45-50, 2018.

MUSTAFA, Ahmed Adil Musa et al. **MONITORING AND CONTROLLING OF GREENHOUSE**. 2015. Tese de Doutorado. Sudan University of Sciences and Technology.

NICOLOSI, Giuseppina; VOLPE, Roberto; MESSINEO, Antonio. An innovative adaptive control system to regulate microclimatic conditions in a greenhouse. **Energies**, v. 10, n. 5, p. 722, 2017.

NOVAIS, Jonathan Willian Zangeski et al. Técnica de Calibração de Sensores Meteorológicos de Temperatura e Umidade Relativa do ar Utilizando um Sensor de Referência. **UNICIÊNCIAS**, v. 24, n. 1, p. 30-33, 2020.

OLIVEIRA, Lúcio Gonçalves Barbosa et al. Desenvolvimento e validação de abrigos termo-higrométricos. **Nativa**, v. 7, n. 2, p. 169-173, 2019.

OLIVEIRA JÚNIOR, A. J.; VICENTIN, T. A.; CUNHA, A. R. **Avaliação do sensor DHT11 - medidas de temperatura e umidade relativa do ar**. 3ª Jornada Científica e Tecnológica da FATEC de Botucatu, p. 1–6, 2014.

OSMARIN, Rafael. **Renda agrícola do morango (Fragaria x ananassa DUCH) convencional e viabilidade da produção semi-hidropônica em uma unidade de produção agrícola familiar, no município de Gramado dos Loureiros-RS**. 2020.

OSTERTAGOVÁ, Eva. Modelling using polynomial regression. **Procedia Engineering**, v. 48, p. 500-506, 2012.

PALLAVI, S.; MALLAPUR, Jayashree D.; BENDIGERI, Kirankumar Y. Remote sensing and controlling of greenhouse agriculture parameters based on IoT. In: **2017 International Conference on Big Data, IoT and Data Science (BIG DATA)**. IEEE, p. 44-48, 2017.

PHILOMINA, S.; SUNDARARAJAN, M.; SUSILA, M. Design of Greenhouse Monitoring Using Sensor Network based on Arduinio. **Eurasian Journal of Analytical Chemistry**, v. 12, n. 3, p. 159-166, 2019.

PROBST, Éliton. **Desenvolvimento e avaliação de um sensor de ponto de orvalho, com pastilhas peltier, para medição de umidade relativa do ar**. 2018.

RAJ, Jennifer S.; ANANTHI, J. Vijitha. Automation using IoT in greenhouse environment. **Journal of Information Technology**, v. 1, n. 01, p. 38-47, 2019.

RAJAB, H.; CINKELR, T. IoT based smart cities. In: **INTERNATIONAL SYMPOSIUM ON NETWORKS, COMPUTERS AND COMMUNICATIONS (ISNCC)**, 2018, Proceedings [...]. IEEE, 2018. p. 1-4.

REZVANI, Sayed Moin-eddin et al. IoT-Based Sensor Data Fusion for Determining Optimality Degrees of Microclimate Parameters in Commercial Greenhouse Production of Tomato. **Sensors**, v. 20, n. 22, p. 6474, 2020.

RICO, Soto; KENIA, Guadalupe. Sensores de bajo costo para el monitoreo de la calidad del aire en la ciudad de Hermosillo, **Sonora**. 2018.

ROCHA, Luis Augusto Gomes. Análise da qualidade do ar em tempo real usando rede de sensores, **PIPE – FAPESP** - São Paulo, 01 de fev. 2018. Disponível em:

<<https://bv.fapesp.br/pt/auxilios/99132/analise-da-qualidade-do-ar-em-tempo-real-usando-rede-de-sensores/>>. Acesso em: 20 de jun. de 2018.

ROLIM, Talyson Weber Rodrigues. **Unidade autônoma de manejo da irrigação de baixo custo controlado via aplicativo para cultivos em ambiente protegido**. 2021.

ROMANINI, Carlos EB et al. Desenvolvimento e simulação de um sistema avançado de controle ambiental em cultivo protegido. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, p. 1194-1201, 2010.

SAAB, S. et al. Positive impact of interference on RF energy harvesting for IoT devices. In: IEEE INTERNATIONAL SYMPOSIUM ON PERSONAL, INDOOR AND MOBILE RADIO COMMUNICATIONS (PIMRC), 29. **IEEE**, 2018. p. 312-317.

SAGHEER, Alaa et al. A cloud-based IoT platform for precision control of soilless greenhouse cultivation. **Sensors**, v. 21, n. 1, p. 223, 2021.

SANTOS, A. S., SATIRO, M. J. V., SANTOS, F. A., PRUDENTE, F. L. S., LISBOA, E. B. **Uma plataforma de hardware e software para medição de temperatura utilizando diferentes tecnologias de sensores**. III Simpósio Brasileiro de Engenharia de Sistemas Computacionais, 2013.

SHARMA, Jay S.; MAKWANA, Gautam D. Intelligent crop management system for greenhouse environment. **International Journal of Science and Research**, v. 2, n. 4, p. 205-208, 2013.

SILVA, Ilda de Oliveira. **Desenvolvimento de um sensor capacitivo para o monitoramento de umidade do solo**. 2006.

SILVA, Renan Bohrer da et al. Estações meteorológicas de código aberto: Um projeto de pesquisa e desenvolvimento tecnológico. **Revista Brasileira de Ensino de Física**, v. 37, 2015.

SONSTEBY, A.; HEIDE, O.M., 2017. Flowering performance and yield of established and recent strawberry cultivars (*Fragaria x ananassa*) as affected by raising temperature and photoperiod. **J. Hortic. Sci. Biotech.** v. 92, p. 367–375, 2017. Disponível em: <<https://doi.org/10.1080/14620316.2017.1283970>>. Acesso em: 15/06/2019.

TEIXEIRA, Grazielle Bonaldi; ALMEIDA, João Víctor Peroni de. **Rede LoRa® e protocolo LoRaWAN® aplicados na agricultura de precisão no Brasil**. 2017. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.

TEXAS INSTRUMENTS, “LM35 Precision Centigrade Temperature Sensors”, LM35 datasheet, Aug. 1999.

TIANLONG, Ni. Application of single bus sensor dht11 in temperature humidity measure and control system [J]. **Microcontrollers & Embedded Systems**, v. 6, n. 2010, p. 026, 2010.

TILMAN, D.; BALZER, C.; HILL, J.; BEFORT, B.L. **Global food demand and the sustainable intensification of agriculture**. Proc. Natl. Acad. Sci. U. S. A. n. 108, 2011, p. 20260–20264. Disponível em: <<https://doi.org/10.1073/pnas.1116437108>>. Acesso em: 15/06/2019

UNITED NATIONS. **UN Climate Action Summit 2019**. Disponível em: <<https://www.un.org/en/climatechange/un-climate-summit-2019.shtml>>. Acesso em: 12 de junho de 2020.

VOVNA, Oleksandr V. et al. Study of metrological characteristics of low-cost digital temperature sensors for greenhouse conditions. **Serbian Journal of Electrical Engineering**, v. 17, n. 1, p. 1-20, 2020.

WILLETT, W. et al. Food in the Anthropocene: the EAT–lancet commission on healthy diets from sustainable food systems. **Lancet** **393**, p. 447–492, 2019. Disponível em: <[https://doi.org/10.1016/S0140-6736\(18\)31788-4](https://doi.org/10.1016/S0140-6736(18)31788-4)>. Acesso em: 15/06/2019

WAYKOLE, Uday A.; AGRAWAL, Dhiraj G. Greenhouse automation system. In: **1st International Conference on Recent Trends in Engineering & Technology**. 2012. p. 161-166.

WMO - World Meteorological Organization. **Guide to Meteorological Instruments and Methods of Observation**: preliminary seventh edition, 2008.

ZHANG, Lingxian et al. Growth monitoring of greenhouse lettuce based on a convolutional neural network. **Horticulture Research**, v. 7, n. 1, p. 1-12, 2020.