

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

JOÃO BATISTA GOMES DA SILVA FILHO

**GÊMEOS DIGITAIS APLICADO NO MONITORAMENTO E CONTROLE DE
ESTUFAS**

CURITIBA

2024

JOÃO BATISTA GOMES DA SILVA FILHO

**GÊMEOS DIGITAIS APLICADO NO MONITORAMENTO E CONTROLE DE
ESTUFAS**

Digital twins applied to greenhouse monitoring and control

Trabalho de conclusão de curso de graduação apresentada
como requisito para obtenção do título de Bacharel em
Engenharia Eletrônica da Universidade Tecnológica
Federal do Paraná (UTFPR).
Orientador: André Eugênio Lazzaretti.

**CURITIBA
2024**



Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

JOÃO BATISTA GOMES DA SILVA FILHO

**GÊMEOS DIGITAIS APLICADO NO MONITORAMENTO E CONTROLE DE
ESTUFAS**

Trabalho de Conclusão de Curso de Graduação apresentado
como requisito para obtenção do título de Bacharel em
Engenharia Eletrônica da Universidade Tecnológica
Federal do Paraná (UTFPR).

Data de aprovação: 26/junho/2024

André Eugênio Lazzaretti
Doutorado
Universidade Tecnológica Federal do Paraná

Daniel Rodrigues Pipa
Doutorado
Universidade Tecnológica Federal do Paraná

Heitor Silvério Lopes
Doutorado
Universidade Tecnológica Federal do Paraná

Ronnier Frates Rohrich
Doutorado
Universidade Tecnológica Federal do Paraná

**CURITIBA
2024**

A minha mãe Celina (Em memória) e esposa Elionara pelo
apoio e companheirismo.

AGRADECIMENTOS

Agradeço ao meu orientador André Eugênio Lazzaretti, pela sabedoria com que me guiou nesta trajetória.

Aos meus colegas de sala.

A Secretaria do Curso, pela cooperação.

À minha família.

RESUMO

Este trabalho investiga a aplicação de gêmeos digitais no controle de estufas, com o objetivo de otimizar o uso de recursos na produção agrícola, abordando desafios como mudanças climáticas, a necessidade de produção sustentável de alimentos e conceitos de gêmeos digitais. Os gêmeos digitais são divididos no domínio físico e virtual. Para o domínio físico, foi desenvolvido um simulador embarcado capaz de controlar e fornecer os dados de temperatura, umidade e radiação dentro de estufas. Foram utilizados modelos matemáticos para representar a dinâmica do microclima, e o DSSATTools como ferramenta para interpretar o comportamento da cultura. A partir do simulador, foi possível gerar dados necessários para a montagem de um *dataset* de treinamento para o modelo computacional do microclima utilizando RNN-LSTM. Dessa forma, o modelo RNN-LSTM e a ferramenta DSSATTools foram utilizadas como gêmeos digitais. O sistema foi validado por meio da comparação com métodos tradicionais de controle supervisorio e controle PID com *setpoint* fixo, demonstrando maior eficiência energética. O gêmeo digital em sua fase inicial e ótima comparados ao controle supervisorio, obteve ganhos de 18% e 61%, respectivamente. Os resultados indicam que o uso de gêmeos digitais não só melhora o controle do microclima, mas também permite uma análise preditiva mais precisa e uma gestão otimizada dos recursos. Conclui-se que a tecnologia pode transformar significativamente as práticas agrícolas em ambientes controlados, oferecendo soluções inovadoras e sustentáveis.

Palavras-chave: gêmeos digitais; estufas; IoT; controle; agricultura; RNN-LSTM.

ABSTRACT

This work investigates the application of digital twins in the control of greenhouses with the aim of optimizing the use of resources in agricultural production. Challenges such as climate change, the need for sustainable food production and digital twin concepts are considered. Digital twins are divided into the physical and virtual domains. For the physical domain, an embedded simulator was developed that is able to control temperature, humidity and radiation in greenhouses and provide data. Mathematical models were used to represent the dynamics of the microclimate and DSSATTools was used as a tool to interpret the behavior of the plants. With the help of the simulator, it was possible to generate the necessary data to compile a training data set for the computational model of the microclimate using RNN-LSTM. Thus, the RNN-LSTM model and the DSSATTools tool were used as digital twins. The system was validated by comparing it with traditional monitoring methods and fixed setpoint PID control, demonstrating higher energy efficiency. The digital twin achieved a gain of 18% and 61% in the initial and optimal phases compared to the higher-level controller. The results show that the use of digital twins not only improves microclimate control, but also enables more accurate predictive analysis and optimized resource management. It is concluded that technology can significantly change agricultural practices in controlled environments, offering innovative and sustainable solutions.

Keywords: digital twin; greenhouses; IoT; control; agriculture; RNN-LSTM.

LISTA DE ILUSTRAÇÕES

Figura 1 – Formatos das estufas.....	17
Figura 2 – Arquitetura de um gêmeo digital.....	19
Figura 3 – <i>Framework</i> e ferramentas utilizadas na arquitetura aplicada em estufa	20
Figura 4 – Modelo de um neurônio de McCulloch e Pitts	21
Figura 5 – Topologia de redes neurais recorrentes	22
Figura 6 – Raspberry Pi 4 modelo B.....	24
Figura 7 – Arquitetura de gêmeos digitais para sistemas de agricultura	27
Figura 8 – Fluxo de atividades do sistema.....	27
Figura 9 – Fluxo de atualização do modelo embarcado na Raspberry Pi.....	32
Figura 10 – Estrutura de funções da camada de integração	33
Figura 11 – Fluxo de tarefas da camada de integração	33
Figura 12 – Estrutura do dataset de treinamento	34
Figura 13 – Dados brutos do <i>dataset</i> de treinamento	35
Figura 14 – Mapa de correlação com as novas <i>features</i>	35
Figura 15 – Estrutura do modelo a ser treinado	36
Figura 16 – Curva de aprendizado do modelo RNN-LSTM	38
Figura 17 – Temperatura da estufa predita para as 24 horas do dia	39
Figura 18 – Umidade da estufa predita para as 24 horas do dia	39
Figura 19 – Radiação da estufa predita para as 24 horas do dia	40
Figura 20 – Consumo de energia da estufa predita para as 24 horas do dia	40
Figura 21 – Temperatura mínima da estufa predita para o DSSAT em um mês	41
Figura 22 – Temperatura máxima da estufa predita para o DSSAT em um mês.....	41
Figura 23 – Umidade média da estufa predita para o DSSAT em um mês	42
Figura 24 – Radiação total diária da estufa predita para o DSSAT em um mês	42
Figura 25 – C01 Comportamento da temperatura interna	43
Figura 26 – C01 Capacidade requerida dos atuadores	44
Figura 27 – C02 Comportamento da temperatura interna	44
Figura 28 – C02 Capacidade requerida dos atuadores	45
Figura 29 – C03 Comportamento da temperatura interna	45
Figura 30 – C03 Capacidade requerida dos atuadores	46
Figura 31 – C04 Comportamento da temperatura interna	47

Figura 32 – C04 Capacidade requerida dos atuadores47

LISTA DE TABELAS

Tabela 1 – Configuração dos parâmetros da estufa	28
Tabela 2 – Resultados gerais dos modos de controle e consumo de energia para um dia	48
Tabela 3 – Resultados de produção	48

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Objetivo geral.....	14
1.2	Objetivos específicos.....	14
1.3	Organização do trabalho.....	14
2	REFERENCIAL TEÓRICO	16
2.1	Estufas.....	16
2.2	Gêmeo digital	17
2.2.1	Modelo digital, sombra digital, e gêmeo digital	18
2.2.2	Arquitetura do gêmeo digital	18
2.2.3	Aplicações na agricultura	19
2.3	Redes neurais recorrentes de memória longa e curta (RNN-LSTM)	20
2.4	Otimização multiobjetivo	23
3	MATERIAIS	24
3.1	<i>Hardware</i>.....	24
3.2	<i>Software</i>.....	24
3.2.1	Spyder IDE	24
3.2.2	DSSATTools	24
3.2.3	PYMOO.....	25
3.2.4	MySQL Workbench.....	25
4	METODOLOGIA.....	26
5	DESENVOLVIMENTO.....	28
5.1	Camada de dispositivos	28
5.1.1	Modelo físico	28
5.1.2	Modelo matemático	29
5.1.3	Modelo embarcado	30
5.2	Camada de integração.....	32
5.2.1	Camada de virtualização	33
<u>5.2.1.1</u>	<u>Microclima da estufa</u>	<u>33</u>
<u>5.2.1.2</u>	<u>Produção e recursos da cultura</u>	<u>36</u>
5.2.2	Camada de suporte à decisão	36
6	RESULTADOS	38
6.1	Modelo do microclima LSTM.....	38
6.2	Consumo de energia	42

6.3	Capacidade de produção.....	48
7	CONCLUSÃO.....	50
	REFERÊNCIAS.....	51

1 INTRODUÇÃO

O crescimento da população, mudanças climáticas, degradação do solo, segurança e qualidade dos alimentos são alguns desafios para a agricultura sustentável, (PURCELL; NEUBAUER; MALLINGER, 2020). A agricultura brasileira desempenha um papel crucial tanto na economia interna quanto no comércio global (VALDES, 2022). A produção de tomate no Brasil é uma atividade agrícola relevante, especialmente nas regiões Sudeste e Centro-Oeste. Essa produção inclui tanto o tomate de mesa quanto o tomate industrial, utilizado na fabricação de molhos, extratos e outros produtos processados.

A agricultura protegida, como o uso de estufas, tem ganhado destaque, melhorando a produtividade e a qualidade dos tomates, tornando-se um fator essencial para o desenvolvimento do setor agrícola (HEMMING *et al.*, 2020). Os métodos de controle aplicados em estufas são constantemente estudados com o intuito de garantir a qualidade do produto, monitoramento, e otimização do uso dos recursos, como o consumo de energia e nutrientes. Esses métodos envolvem o uso de tecnologias avançadas para regular e otimizar as condições ambientais internas. De acordo com Soussi *et al.* (2024), incluem sensores que monitoram temperatura, umidade, luz e níveis de CO₂ em tempo real; sistemas automatizados que ajustam ventilação, irrigação e aquecimento com base nos dados coletados; internet das coisas (IoT) para monitoramento e controle remoto; e análise de dados com inteligência artificial (IA) para prever necessidades futuras e otimizar recursos, melhorando a produtividade e eficiência.

Na agricultura inteligente, os gêmeos digitais (do inglês, *Digital Twin* – DT) desempenham um papel crucial ao criar réplicas virtuais detalhadas dos sistemas agrícolas físicos. Eles permitem a otimização do uso de recursos, a redução do impacto ambiental e o aumento da produtividade das colheitas, promovendo um ecossistema agrícola sustentável e eficiente, (PELADARINOS *et al.*, 2023). De acordo com Arisen-Verschuur, Verdouw e Tekinerdogan (2022), esses sistemas permitem a detecção antecipada de problemas por meio de simulações de ações corretivas e preditivas na representação virtual, o que aumenta a resiliência das operações agrícolas. Essa abordagem proativa leva a uma agricultura mais adaptável e eficiente, capaz de enfrentar desafios climáticos e de mercado.

Além disso, VanDerHorn e Mahadevan (2021) explica que o conceito de gêmeos digitais, assim como IoT, computação em nuvem, aprendizado de máquina e realidade aumentada, tem despertado crescente interesse nos últimos anos, tanto na área acadêmica quanto na indústria. Essa ideia faz parte do surgimento de novas tecnologias digitais, que

oferecem recursos para novos modelos de negócios e sistemas de suporte à decisão, ampliando as possibilidades de inovação e eficiência em diversos setores.

Um estudo conduzido por Chaux, Sanchez-Londono e Barbieri (2021) desenvolveu uma arquitetura de gêmeos digitais para otimizar a produtividade e o consumo dos recursos em estufas. Utilizando o *software EnergyPlus* como modelo do microclima da estufa e DSSAT (*Decision Support System for Agrotechnology Transfer*) para simular o desenvolvimento das culturas, os pesquisadores demonstraram que é possível ajustar automaticamente as condições ambientais para atender as necessidades das plantas. Embora o estudo tenha enfatizado a validação da comunicação bidirecional, ele propõe a implementação de um estudo de caso para certificar a capacidade da arquitetura. Além disso, sugere a migração da camada de integração para a nuvem, e a simplificação do domínio físico, eliminando a necessidade do *gateway*.

Qu (2023), criou um *framework* de gêmeos digitais para controle de clima em estufas, visando otimizar o cronograma de operação dos atuadores e minimizar o consumo de energia e os custos de produção sem comprometer a qualidade. O gêmeo digital utiliza modelos implementados com Redes Neurais Artificiais, que respondem adequadamente às solicitações de previsão e otimização. Para a seleção das soluções finais, foi implementada uma plataforma de controle climático baseada em Otimização Multiobjetivo (do inglês, *Multi-objective optimization* - MOO).

Fitz-Rodrigues *et al.* (2010), descreve a construção de um simulador interativo e dinâmico para ambientes de estufas. Este modelo, baseado em princípios de balanço de energia e massa, foi implementado como uma aplicação *web*, permitindo a seleção de diferentes *designs* de estufas, condições climáticas e estratégias operacionais.

Araújo (2020), elaborou um sistema de controle de temperatura para estufas utilizando o método de controle supervisorio. O sistema consiste em um controle liga/desliga dos atuadores de aquecimento e resfriamento para alcançar automaticamente as condições de temperatura ideais para diferentes plantas. Validado por um simulador baseado em princípios de balanço de massa e energia, foram propostas três modelagens de controle, com o objetivo de determinar a melhor relação de viabilidade e eficiência, considerando o consumo energético, a taxa de erro e o tempo dentro das condições ideais.

Dessa forma, considerando a arquitetura e os trabalhos futuros sugeridos por Chaux, Sanchez-Londono e Barbieri (2021), o presente trabalho tem como objetivo realizar um estudo de caso aplicando conceitos de gêmeos digitais a uma estufa virtualizada. Para isso, foi construído um simulador que utiliza os modelos dinâmicos de microclima propostos por Fitz-Rodrigues *et al.* (2010) e emprega a biblioteca Python DSSATTools para simular o

comportamento da cultura, tudo isso embarcado no Raspberry Pi 4 modelo B. Toda a camada de integração foi desenvolvida em nuvem, substituindo o *EnergyPlus* por um modelo digital do microclima e consumo de energia elaborado com RNN-LSTM, e a versão desktop do DSSAT foi substituída pela biblioteca Python DSSATTools para prever o comportamento da cultura. Com base nas experiências de Qu (2023), optou-se pelo uso do método de otimização multiobjetivo implementado através da biblioteca Python Pymoo. Foi utilizada uma função que minimiza os recursos e maximiza a produção da estufa, aplicando o algoritmo NSGA-II para definir o *setpoint* de cada hora do próximo dia. Com isso, os resultados obtidos a partir do controle utilizando gêmeos digitais serão comparados com o modelo de controle denominado *temperature_in_out* elaborado por Araújo (2020). Essa comparação levará em consideração a capacidade de produção a partir do consumo de recursos hídricos e energéticos.

1.1 Objetivo geral

Desenvolver, por meio de eletrônica embarcada, um sistema de controle para estufas, simulando a dinâmica de temperatura, umidade e radiação, utilizando conceitos de gêmeos digitais.

1.2 Objetivos específicos

- 1) Desenvolver a camada de dispositivos.
- 2) Desenvolver o simulador embarcado na Raspberry Pi 4.
- 3) Implementar o controle PID para os atuadores.
- 4) Coletar dados do microclima, clima externo, atuadores e consumo de energia.
- 5) Treinar a RNN-LSTM para predição do microclima e consumo de energia.
- 6) Implementar o DSSATTools para predição da produção da cultura.
- 7) Aplicar o Pymoo para otimizar o melhor conjunto de *setpoint* para o dia.
- 8) Avaliar os resultados do modelo treinado pela RNN-LSTM.
- 9) Analisar o desempenho em comparação ao método de controle supervisão, medindo o consumo energético e produção.

1.3 Organização do trabalho

O capítulo 2 começa com o referencial teórico, apresentando os conceitos-chave para entender o presente trabalho. O capítulo 3 apresenta os *softwares* e *hardware*, justificando suas escolhas. O capítulo 4 revela a organização do desenvolvimento e a delimitação do projeto. No

capítulo 5, o desenvolvimento do trabalho é demonstrado, detalhando as camadas utilizadas e justificando as decisões do projeto. O capítulo 6 apresenta uma validação final do sistema, comparação de controle e análise de eficiência. Finalmente, o capítulo 7 apresenta a conclusão do projeto, melhorias futuras e os desafios enfrentados durante o processo de desenvolvimento.

2 REFERENCIAL TEÓRICO

Neste capítulo, são apresentados alguns dos principais conceitos e um panorama geral necessário para entender o trabalho. A seção 2.1 apresenta as estufas, os impactos das variáveis controladas no cultivo das plantas e os principais formatos. A seção 2.2 introduz o gêmeo digital, explorando suas características e camadas aplicadas em estufas, com o intuito de definir os *setpoints* de temperatura utilizando dados históricos e previsões futuras do comportamento da estufa. A seção 2.3 aborda as redes neurais recorrentes de memória de longo e curto prazo, necessário para a modelagem do microclima e consumo de energia. E por fim, a seção 2.4 mostra a otimização multiobjetivo para definição de possíveis conjuntos de *setpoints* ótimos para gerenciamento da estufa para o dia seguinte.

2.1 Estufas


Uma estufa melhora a produção agrícola ao criar um ambiente controlado que otimiza o crescimento das plantas. Com controle preciso de temperatura, umidade e luz, as estufas protegem as culturas de condições climáticas adversas, pragas e doenças, que possibilitam a produção contínua ao longo do ano, o que resulta em ciclos de crescimento mais rápidos e maior densidade de plantio (BRASIL ESTUFAS, 2024).

Os modelos de estufas podem variar significativamente em *design*, materiais utilizados, tecnologia incorporada e finalidade de uso, adaptando-se às necessidades específicas dos agricultores e às condições ambientais de cada região. Os três principais formatos de estufas apresentados por Vieira Neto (2015), são mostrados na Figura 1, são eles:

- Túnel baixo ou *Quonset*: Trata-se de um modelo de estufa de construção simples e custo reduzido. Apresenta desvantagens significativas, como a menor durabilidade devido à necessidade de desmontagem para o preparo do solo, a capacidade limitada de retenção de calor, controle de ventilação insuficiente e desafios no manejo eficaz das culturas.
- Duas águas ou *A-Frame*: Este modelo é bastante utilizado, apresentando-se em versões que vão desde estruturas básicas até configurações mais elaboradas. Podem ser encontradas com coberturas de vidro e até mesmo plástico. Um diferencial significativo é a gestão da condensação interna, a água condensada tende a não escoar adequadamente pelo telhado e paredes, resultando em gotículas que podem cair diretamente sobre as plantações.

- Arco ou *Arch-Roof*: Estas estruturas são comumente fabricadas com aço, madeira ou alumínio e revestidas com material plástico. A água condensada tende a seguir o contorno dos arcos até as paredes, evitando assim o gotejamento direto sobre as culturas.

Figura 1 – Formatos das estufas



Fonte: Adaptado de Vieira Neto (2015)

O modelo de estufa utilizado nesse estudo é o *A-Frame* para o cultivo do tomate. As variáveis externas e internas adotadas são: temperatura, umidade e radiação. De acordo com Ferrante e Mariani (2018), a temperatura influencia diretamente as taxas metabólicas e de fotossíntese das plantas, enquanto a umidade está intimamente ligada à disponibilidade de água, que é essencial para o processo fotossintético. Além disso, a radiação solar regula os processos fisiológicos das plantas, podendo afetar a morfologia das raízes e a distribuição de matéria seca, o que contribui para a adaptação das plantas a diferentes condições ambientais (ONG; CAO; ZHU, 2021).

As principais estratégias para a manutenção da temperatura ideal em uma estufa incluem: ventilação natural ou forçada, que permite a troca de ar e a diminuição do calor; sistemas de resfriamento por evaporação e nebulização; e sistemas de aquecimento elétrico, a gás ou tubos de água quente. O uso de sensores e sistemas de controle garantem o funcionamento adequado desses equipamentos, proporcionando ajustes precisos e integrados.

2.2 Gêmeo digital

Um gêmeo digital pode ser descrito como uma réplica virtual de um objeto ou sistema do mundo real, utilizada para representar digitalmente o desempenho, identificar ineficiências e desenvolver soluções para melhorar seus equivalentes físicos (COURSERA, 2023).

De acordo com Grieves (2022), apenas nos últimos anos essa ideia cresceu em importância e complexidade, sendo aplicada em uma ampla gama de setores, incluindo

manufatura, saúde e agricultura. Em relação aos níveis de integração entre a representação virtual e os objetos ou sistemas físicos, estes podem ser categorizados em três subtipos e que são comumente confundidos, sendo eles: modelo digital (do inglês, *Digital Model* - DM), sombra digital (do inglês, *Digital Shadow* - DS), e gêmeo digital (do inglês, *Digital Twin* – DT) (FULLER *et al.*, 2020).

2.2.1 Modelo digital, sombra digital, e gêmeo digital

De acordo com Kritzinger *et al.* (2018), um modelo digital é uma representação computacional de um objeto ou sistema físico, que pode incluir detalhes geométricos, propriedades físicas, e comportamento dinâmico, permitindo que os usuários testem cenários, realizem análises preditivas e otimizem projetos antes da produção ou construção física. Não existe um mecanismo automático para atualizar o modelo digital com base em alterações realizadas no objeto físico.

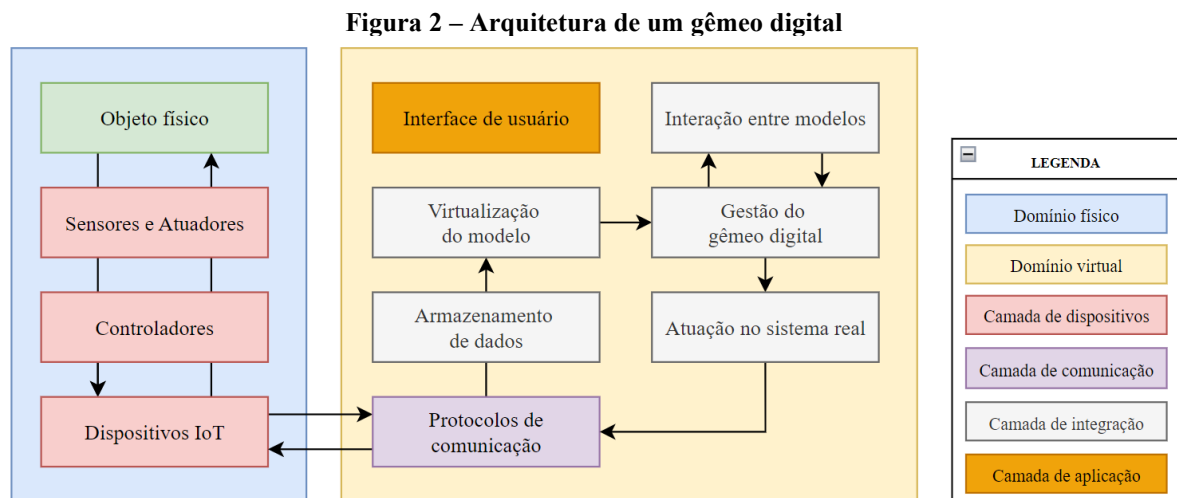
A sombra digital funciona como uma ponte vital entre o mundo físico e o digital, caracterizando-se por uma via de comunicação unidirecional. Isso significa que ela recebe dados constantemente do objeto físico para o digital, assegurando que qualquer alteração no estado do objeto físico seja refletida automaticamente em sua representação digital. Além disso, essa sincronização não ocorre no sentido inverso, modificações no objeto digital não afetam o objeto físico.

No conceito de gêmeo digital, existe uma troca de dados contínua e bidirecional entre o domínio físico e digital, permitindo total integração entre ambos. Dessa forma, qualquer alteração realizada no objeto do mundo real é imediatamente refletida no modelo digital, e o inverso também ocorre, criando um vínculo dinâmico e recíproco. Através dos dados gerados e coletados ao longo do tempo, os gêmeos digitais podem ser usados para prever comportamentos futuros e otimizar operações (IBM, 2023).

2.2.2 Arquitetura do gêmeo digital

A arquitetura de um gêmeo digital é composta por várias camadas que trabalham juntas, como mostrado na Figura 2. Essa estrutura deve permitir a simulação, monitoramento e análise, facilitando a tomada de decisão baseada em dados. Arisen-Verschuur, Verdouw e Tekinerdogan (2022) mostra que esses sistemas podem ser compactados em quatro camadas, sendo elas:

- Camada de dispositivos: Conta com os componentes de *hardware* para que seja realizada uma integração direta com o mundo físico. Sensores para fazer a coleta de dados, mensurando a dinâmica do sistema, e atuadores para que as condições dos objetos sejam alteradas.
- Camada de comunicação: Responsável pela transferência das informações dos objetos de forma eficiente e segura.
- Camada de integração: Aqui é feito o processamento e a integração dos dados dos objetos. Nessa etapa os gêmeos digitais são administrados, e fazem a integração de informações que abrange capacidades básicas de gestão de dados, incluindo armazenamento na nuvem e segurança.
- Camada de aplicação: Proporciona funcionalidades específicas para usuários variados, fundamentadas nas informações dos gêmeos digitais acessíveis na camada de integração. Além disso, a camada engloba a interface de usuário destinada à interação.



Fonte: Adaptado de Rabelo, Magalhães e Cabral (2020)

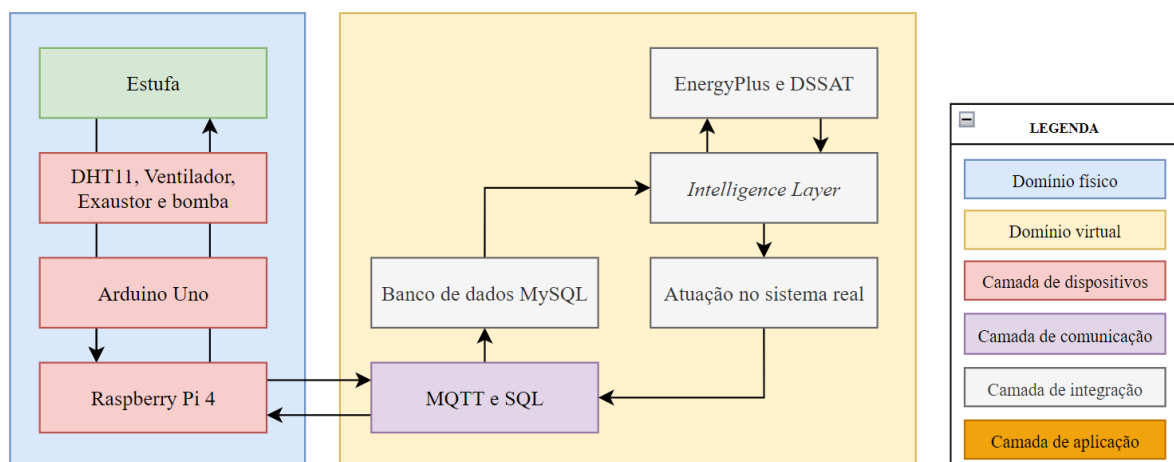
2.2.3 Aplicações na agricultura

Na Figura 3, é apresentada a arquitetura e as ferramentas empregadas por Chaux (2021) na implementação de um gêmeo digital em uma estufa. Os dados relativos à temperatura e umidade são captados por um Arduino Uno, que transfere essas informações via comunicação serial para um Raspberry Pi 4. Este último atua como um *gateway*, encarregado de armazenar os dados em um banco de dados. No ambiente virtual, um computador é utilizado para executar os simuladores do microclima da estufa, representado pelo *software EnergyPlus*, e da cultura

plantada, através do sistema de suporte à decisão para transferência de agro tecnologia (*Decision Support System for Agrotechology Transfer – DSSAT*). A camada de inteligência, denominada *Intelligence Layer*, assume a responsabilidade de estabelecer a conexão com o banco de dados e gerenciar as informações trocadas com os modelos. Esta camada também analisa as melhores configurações para os atuadores: ventilador, exaustor e sistema de irrigação, cujas instruções são enviadas ao *gateway*, e posteriormente executadas pelo Arduino Uno.

A arquitetura elaborada por Qu (2023) segue os mesmos conceitos de arquiteturas aqui apresentados, com uma diferença, além das quatro camadas apresentadas anteriormente, ele divide a camada de integração em mais três camadas: virtualização, suporte à decisão, e configuração. A camada de virtualização é responsável por estabelecer o modelo digital da estufa, que tem bastante influência sobre toda a análise e sistema de decisão. A camada de suporte à decisão tem a função de definir um problema com múltiplos objetivos através do mapeamento das lógicas e estratégias de operação, além de aprimorar os planos de ação dos atuadores utilizando os resultados obtidos na modelagem realizada pela camada de virtualização. Na camada de configuração e monitoramento é disponibilizada a interface de usuário para acompanhar tanto as condições atuais quanto os históricos do sistema climático da estufa, incluindo sugestões para melhorar a operação dos atuadores. Além disso, soluções otimizadas podem ser enviadas diretamente para os controladores, transformando as orientações de atuação dos dispositivos em sinais de controle.

Figura 3 – Framework e ferramentas utilizadas na arquitetura aplicada em estufa



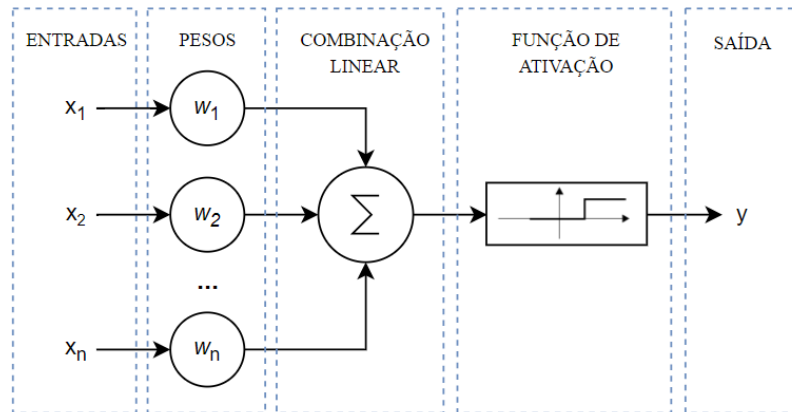
Fonte: Adaptado de Chaux, Sanchez-Londono e Barbieri (2021)

2.3 Redes neurais recorrentes de memória longa e curta (RNN-LSTM)

De acordo com Rauber (2014), as Redes Neurais Artificiais (RNA) são inspiradas na capacidade cognitiva dos neurônios biológicos, visando simular a inteligência humana em

máquinas. Elas são compostas por unidades de processamento simplificadas, denominadas neurônios artificiais, que se conectam e formam redes capazes de realizar tarefas complexas através da aprendizagem e adaptação. A estrutura de uma RNA inclui um modelo de neurônio artificial baseado em combinações lineares de entradas ponderadas por pesos, seguidas de uma função de ativação, como mostra a Figura 4.

Figura 4 – Modelo de um neurônio de McCulloch e Pitts



Fonte: Adaptado de Rauber (2014)

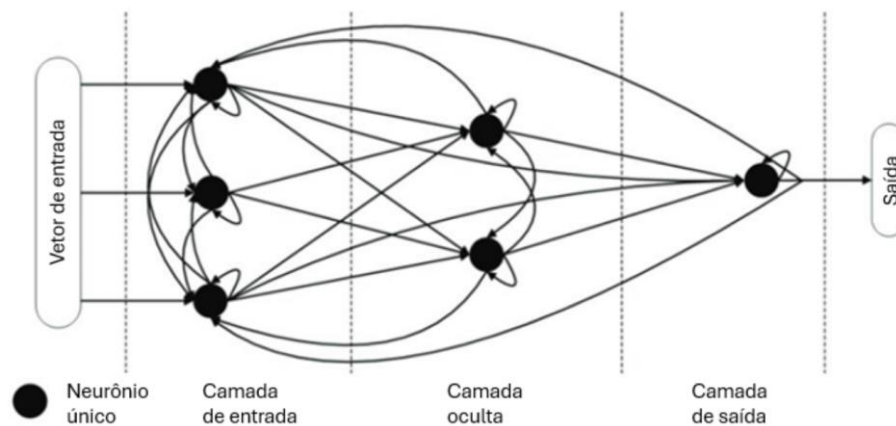
Para Rodrigues (2022) o processo de aprendizado em RNA envolve ajustes iterativos dos parâmetros do modelo, especificamente os pesos e os *bias*, de forma que a rede consiga capturar o conhecimento apresentados pelos dados de treinamento. Existem três principais métodos de aprendizado que moldam a maneira como uma rede adquire conhecimento a partir de dados (SUZUKI, 2011), que são:

- **Aprendizado supervisionado:** A rede é treinada usando um conjunto de dados que inclui tanto as entradas quanto as saídas desejadas. O objetivo é aprender uma função que mapeie as entradas para as saídas. Durante o treinamento, o algoritmo ajusta os pesos e *bias* para minimizar a diferença entre as previsões da rede e as saídas reais. Este método é amplamente utilizado para tarefas de classificação e regressão.
- **Aprendizado não supervisionado:** A rede é treinada usando um conjunto de dados que contém apenas entradas, sem saídas etiquetadas. O objetivo é descobrir padrões, agrupamentos, ou estruturas nos dados. Algoritmos de aprendizado não supervisionado são úteis para análise exploratória de dados, agrupamento, e redução de dimensionalidade.

- **Aprendizado por reforço:** Neste tipo de aprendizado, um agente aprende a tomar decisões através de tentativa e erro, interagindo com um ambiente. O agente recebe recompensas ou penalidades com base em suas ações, e o objetivo é aprender uma política de ação que maximize a recompensa total ao longo do tempo. Este método é comumente aplicado em jogos, navegação de robôs, e em sistemas autônomos.

A RNA pode ter diferentes topologias, como propagação para frente (do inglês, *Feed-Forward* - FNN), onde o fluxo de informação é unidirecional. E redes com realimentação (do inglês, *Recurrent* - RNN), que apresentam comportamento dinâmico e permitem a retroalimentação de sinais. De acordo com Cardozo (2022), a diferença crucial entre redes recorrentes e não recorrentes está em sua estrutura única, que envolve *loops* de *feedback* como mostrado na Figura 5. Esses *loops* permitem que as informações geradas em uma etapa sejam retroalimentadas como entrada em etapas anteriores ou subsequentes, criando assim uma forma de memória de curto prazo em que estados passados influenciam os futuros.

Figura 5 – Topologia de redes neurais recorrentes



Fonte: Adaptado de Suzuki (2011)

O termo memória curta e longa (do inglês, *Long-Short Term Memory* - LSTM) surge como solução de um problema proveniente da RNN, o desaparecimento do gradiente. A LSTM é conhecida por sua capacidade de reter informações por longos períodos, o que a torna altamente eficaz em tarefas de classificação, processamento e previsão envolvendo séries temporais com diferentes durações, (RODRIGUES, 2022). Ela se destaca em cenários nos quais é crucial “esquecer” dados irrelevantes do passado e manter somente os elementos essenciais para compreender a sequência completa.

2.4 Otimização multiobjetivo

A otimização multiobjetivo (do inglês, *Multi-Objective Optimization* – MOO) é crucial para resolver problemas complexos que envolvem múltiplos objetivos conflitantes. De acordo com Gunantara e Ai (2018), através do processo de otimização é possível determinar o valor ótimo, seja buscando valores máximos ou mínimos, tendo aplicações em diversas áreas, como engenharia, economia e logística. A fronteira de Pareto é um conceito fundamental, que representa o conjunto de soluções não-dominadas, ou seja, soluções para as quais não é possível melhorar um objetivo sem piorar pelo menos um dos outros.


Diversas técnicas foram desenvolvidas para encontrar a fronteira de Pareto, abrangendo tanto abordagens clássicas e metaheurísticas. Entre os métodos clássicos, destacam-se a programação linear ponderada, o método ϵ -restrito e a decomposição de Tchebycheff. Já entre as metaheurísticas, destacam-se os algoritmos evolutivos, como NSGA-II (*Non-dominated Sorting Genetic Algorithm II*) e SPEA2 (*Strength Pareto Evolutionary Algorithm 2*), devido à sua capacidade de encontrar múltiplas soluções ótimas em uma única execução, oferecendo uma diversidade de conjuntos.

De acordo com Verma, Pant e Snasel (2021), o NSGA-II é baseado em quatro princípios: classificação não-dominada, onde os membros da população são organizados em frentes de Pareto e cada frente é removida sequencialmente até que todos sejam classificados em diferentes níveis; operador de preservação de elite, que mantém as soluções não-dominadas transferindo-as para a próxima geração até que sejam substituídas por novas soluções; distância de *crowding*, que estima a distância média das soluções adjacentes em cada objetivo; e operador de seleção, que baseado no *rank* e na distância de *crowding* dos membros da população seleciona os membros para a próxima geração. Os principais parâmetros incluem o tamanho da população, número de gerações, taxas de cruzamento e mutação, e tamanho do torneio.

3 MATERIAIS

3.1 Hardware

A Figura 6 apresenta o Raspberry Pi 4 Modelo B, que é um computador de placa única, equipado com um processador Broadcom ARM Cortex-A72 quad-core de 1,5GHz e disponível em configurações de memória RAM de 2GB, 4GB e 8GB. Suas principais características incluem conectividade Gigabit Ethernet, Wi-Fi, Bluetooth e suporte para duas saídas de vídeo 4K via micro-HDMI. Dessa forma, é uma solução de baixo custo, sendo interessante para criação de sistemas portáteis e de IoT.



Fonte: Raspberry Pi, <https://www.raspberrypi.com/products/raspberry-pi-4-model-b/>.

3.2 Software

3.2.1 Spyder IDE

O Spyder IDE é um ambiente de desenvolvimento integrado para a linguagem de programação Python. É particularmente útil para análise de dados, engenharia e projetos científicos. Ele oferece um conjunto robusto de ferramentas, incluindo um editor de código, um console interativo e ferramentas de depuração.

3.2.2 DSSATTools

O DSSATTools é uma biblioteca que simplifica a criação de *scripts* para executar simulações do comportamento da planta. Com apenas três etapas, uma instância do DSSAT é

inicializada, o ambiente de simulação é configurado e a simulação é executada. Essa abordagem simplificada otimiza o processo de simulação. A escolha dessa ferramenta considerou a eliminação da necessidade de instalar a versão *desktop* do DSSAT, exigindo apenas a biblioteca Python, diminuindo assim a complexidade de embarcar o modelo das culturas. Essa ferramenta necessita de quatro classes de entrada: *Crop*, que se refere ao tipo de cultura; *SoilProfile*, que abrange as características do solo; *Weather*, que representa as condições climáticas; e *Management*, que trata do gerenciamento da colheita.

3.2.3 PYMOO

O PYMOO é uma biblioteca Python desenvolvida para otimização multiobjetivo, fornecendo algoritmos avançados para lidar com problemas complexos que envolvem múltiplos objetivos simultaneamente. Adicionalmente, o *framework* oferece uma variedade de recursos adicionais, incluindo ferramentas de visualização e suporte à tomada de decisões. Esse estudo utilizou a técnica NSGA-II apresentada na seção 2.4.

3.2.4 MySQL Workbench

O MySQL Workbench é uma ferramenta visual para desenvolvimento de banco de dados em MySQL. Ele permite a modelagem de dados, desenvolvimento de SQL, administração de bancos de dados, configuração de servidores e execução de *scripts*.

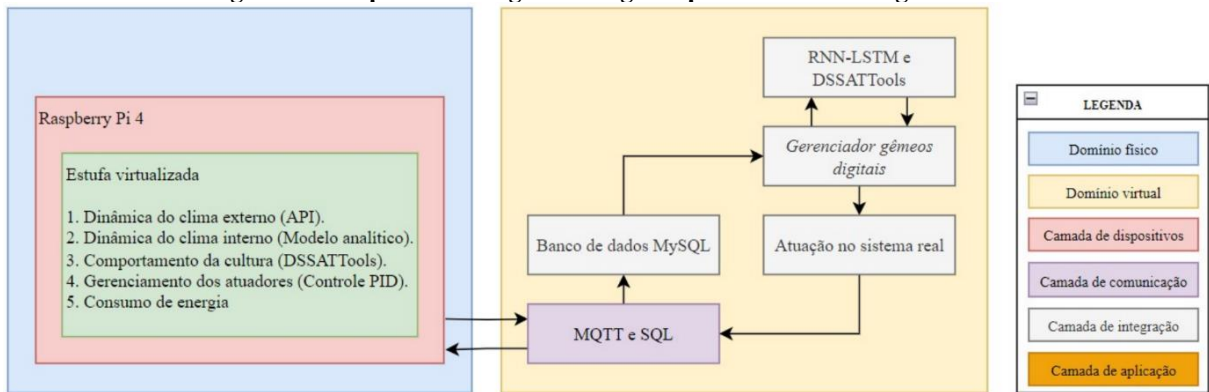
4 METODOLOGIA

As etapas realizadas no projeto foram organizadas em camadas. Na camada de dispositivos, todo o controle e instrumentação foram definidos com o objetivo de minimizar os custos. Em seguida, na camada de comunicação, foram determinados os protocolos de comunicação e a modelagem do banco de dados. A camada de integração concentrou a maior parte do tempo do projeto, focando na otimização dos algoritmos e na elaboração dos modelos digitais. Por fim, a camada de aplicação envolveu o desenvolvimento da interface de usuário e a integração com o banco de dados.

A arquitetura adotada nesse trabalho foi baseada no trabalho de Chaux (2021). A Figura 7 representa a interação do sistema, com foco nos *frameworks* e tecnologias utilizadas em dois domínios, o físico que conta com a estufa e controle principal, e o virtual onde estão implementados os modelos digitais. O gerenciador é responsável por encontrar o melhor conjunto de referência da temperatura da estufa, considerando o menor consumo e maior produção. O modelo do microclima recebe os conjuntos a serem testados, e as condições externas previstas, retornando para o gerenciador o consumo de energia para aquele dia. O modelo da cultura representado pelo DSSATTools, recebe o microclima previsto pelo modelo digital do clima da estufa, e retorna o consumo e produção para aquelas condições. Com os dados de consumo e produção para cada conjunto, o gerenciador utiliza o algoritmo NSGA-II para definição da agenda de *setpoint* a serem enviados para o simulador embarcado na Raspberry Pi 4. Os dados do clima e dos atuadores são armazenados no banco de dados (MySQL), que são utilizados pelos gêmeos digitais.

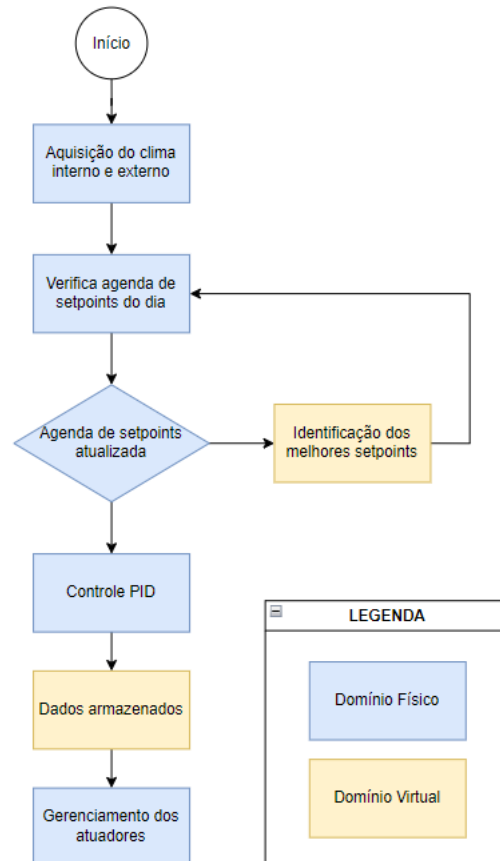
A Figura 8 mostra de maneira simplificada as atividades executadas por cada domínio. No domínio físico, é iniciado pela aquisição de dados do clima interno e externo como radiação, temperatura, umidade e pressão. Em seguida, é verificado o *setpoint* atual para controle do clima. O método de controle utilizado para o gerenciamento dos atuadores foi o PID (Proporcional, integral e derivativo). Com isso, é feito o gerenciamento dos atuadores. No domínio virtual, tem-se o algoritmo para gerenciamento do clima a ser utilizado no dia em questão.

Figura 7 – Arquitetura de gêmeos digitais para sistemas de agricultura



Fonte: Autoria própria

Figura 8 – Fluxo de atividades do sistema



Fonte: Autoria própria

5 DESENVOLVIMENTO

5.1 Camada de dispositivos

A camada de dispositivos abrange os componentes de *hardware* para integração direta com o mundo físico. Para versatilidade e possibilitar a utilização em trabalhos futuros toda a camada foi embarcada no Raspberry Pi 4, um modelo fenomenológico da estufa proposto por Fitz-Rodrigues *et al.* (2010) e o DSSATTools para emular o comportamento da cultura. Dessa forma, é possível gerar os dados de temperatura, umidade e radiação interna da estufa (Microclima), possibilitando a utilização de diferentes estruturas e escalas. Esse tipo de solução é conhecido como *Hardware in the loop* (HIL), com isso, toda a camada de dispositivos foi simulada, não sendo necessário o uso dos sensores e atuadores.

Dessa forma, nessa etapa do trabalho, o objetivo é construir e embarcar um simulador capaz de gerar o microclima da estufa, com base no clima externo e no funcionamento dos sistemas de resfriamento e aquecimento. A temperatura, umidade e radiação simuladas são aplicadas através da biblioteca python DSSATTools para medir a produção e o consumo de recursos. Além disso, o simulador servirá para gerar dados, possibilitando o treinamento de um RNN-LSTM para a predição do microclima tratada na Seção 5.2.1.1.

5.1.1 Modelo físico

A Tabela 1 apresenta a configuração da estufa, foi considerado o formato *A-frame*, utilizando polietileno como material da cobertura, um sistema de refrigeração evaporativo e aquecimento elétrico.

Tabela 1 – Configuração dos parâmetros da estufa

Parâmetros	Valor
Tamanho da plantação	Pequena
Altura da estufa	4 m
Área da cobertura	674 m ²
Área do solo	300 m ²
Potência do evaporador	128 kWh
Potência do aquecedor	75 kWh
Taxa de ventilação do exaustor	0,043 m ³ /m ² .s
Coefficiente de transmissão do calor	6,2 J/m ² .°C.s
Transmitância do polietileno	0,87
Capacidade de reflexão da luz do material	0,682
Massa específica do ar	1,2 Kg/m ³
Calor específico do ar	1010 J/Kg.K

Fonte: Adaptado de Araújo (2020) e Fitz-Rodrigues *et al.* (2010)

5.1.2 Modelo matemático

O modelo matemático aqui apresentado é proposto por Fitz-Rodrigues *et al.* (2010).

O comportamento da radiação global interna absorvida pela estufa pode ser estimada pela seguinte equação:

$$Q_{GRin} = \tau_c \cdot (1 - \rho_g) \cdot Q_{GRout} \quad (1)$$

onde τ_c é a transmitância da radiação solar do material da cobertura (adimensional), ρ_g é a reflectância da radiação solar na superfície do solo (adimensional), e Q_{GRout} é a radiação global externa ($W \cdot m^{-2}$).

A variação da umidade interna pode ser representada pela seguinte equação diferencial de primeiro grau:

$$\frac{dW_{in}}{dt} = \frac{1}{H \cdot \rho} \cdot (E - (W_{in} - W_{out}) \cdot q_v \cdot \rho) \quad (2)$$

tal que, H é a altura da estufa (m), ρ é a massa específica do ar ($Kg \cdot m^{-3}$), W_{in} e W_{out} são as umidades absolutas do ar internas e externas ($g \cdot Kg^{-1}$), q_v é a taxa de ventilação ($m^3 \cdot m^{-2} \cdot s^{-1}$), e E é a evapotranspiração do sistema que se dá pela seguinte equação:

$$E = E_C + E_T \quad (3)$$

onde E_C é a evapotranspiração proveniente do sistema de resfriamento evaporativo ($Kg \cdot m^{-2} \cdot s^{-1}$), E_T é a transpiração da planta dada pelas seguintes equações em relação ao tamanho da plantação:

$$E_T = \begin{cases} 0,0003 \cdot \tau_c \cdot Q_{GRout} + 0,002, & \text{grande} \\ 0,00006 \cdot \tau_c \cdot Q_{GRout} + 0,0004, & \text{pequena} \\ 0, & \text{nenhuma} \end{cases} \quad (4)$$

A variação da temperatura interna tem seu comportamento estimado pela seguinte equação diferencial:

$$\frac{dT_{in}}{dt} = \frac{1}{C_p \cdot \rho \cdot H} (Q_{GRin} + Q_{Heater} - L \cdot E - (T_{in} - T_{out}) \cdot (q_v \cdot C_p \cdot p + w \cdot k)) \quad (5)$$

onde C_p é o calor específico do ar ($J \cdot Kg^{-1} \cdot K^{-1}$), L é o calor latente de vaporização da água ($J \cdot Kg^{-1}$), T_{in} e T_{out} são as temperaturas internas e externas ($^{\circ}C$), w é a razão entre a área da superfície da cobertura A_{gl} e a do piso A_{fl} , k é o coeficiente de transmissão de calor do material

de cobertura ($W \cdot m^{-2} \cdot ^\circ C^{-1}$), Q_{Heater} é a radiação proveniente do sistema de aquecimento expressado da seguinte forma:

$$Q_{Heater} = N_H \frac{H_{cap}}{A_{fl}} \quad (6)$$

tal que, N_H é a quantidade de aquecedores, H_{cap} é a potência dos aquecedores (W).

5.1.3 Modelo embarcado

A equação (1) que representa a radiação global interna é simples de ser implementada. Para as equações diferenciais (2) e (5) utilizou-se a técnica de equações de estados para resolvê-las, e para implementar no Raspberry Pi foi necessário discretiza-las.

Para simplificar a visualização das equações, foram consideradas as seguintes substituições:

$$a = H \cdot \rho, \quad (7)$$

$$b = q_v \cdot \rho, \quad (8)$$

$$c = C_p \cdot p \cdot H, \quad (9)$$

$$d = (q_v \cdot C_p \cdot \rho) + (w \cdot k). \quad (10)$$

Ao analisar a equação (2) que representa a umidade interna, é possível observar dois parâmetros que variam ao longo do tempo, a evapotranspiração e a umidade externa, essas serão consideradas como entradas, representadas a seguir:

$$y = W_{in}(t), \quad (11)$$

$$u_1 = E(t), \quad (12)$$

$$u_2 = W_{out}. \quad (13)$$

Dessa forma, substituindo as equações (12) e (13), na equação (2) pode ser reescrita da seguinte forma:

$$a \cdot y' + b \cdot y - u_1 - b \cdot u_2 = 0, \quad (14)$$

sendo o vetor de estado

$$\dot{x}_1 = \left(-\frac{b}{a}\right) \cdot x_1 + [1/a \quad b/a] \cdot \begin{bmatrix} u_1 \\ u_2 \end{bmatrix}, \quad (15)$$

e o vetor de saída

$$y = 1 \cdot x_1 + [0 \quad 0] \cdot \begin{bmatrix} u_1 \\ u_2 \end{bmatrix}. \quad (16)$$

A equação diferencial da temperatura interna (5) que é a saída desejada, é possível observar quatro parâmetros que variam ao longo do tempo, a radiação proveniente do aquecedor, a evapotranspiração, a radiação interna da estufa, e a temperatura externa, essas serão consideradas como entradas, representadas a seguir:

$$y = T_{in}(t), \quad (17)$$

$$u_1 = Q_{Heater}(t), \quad (18)$$

$$u_2 = L.E(t), \quad (19)$$

$$u_3 = Q_{Rin}(t), \quad (20)$$

$$u_4 = T_{out}(t). \quad (21)$$

Substituindo as equações (18), (19), (20) e (21), a equação (5) pode ser reescrita da seguinte forma:

$$c.y' + d.y - u_1 + u_2 - u_3 - d.u_4 = 0, \quad (22)$$

sendo o vetor de estado

$$\dot{x}_1 = \left(-\frac{d}{c}\right).x_1 + [1/c \quad -1/c \quad 1/c \quad d/c]. \begin{bmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \end{bmatrix}, \quad (23)$$

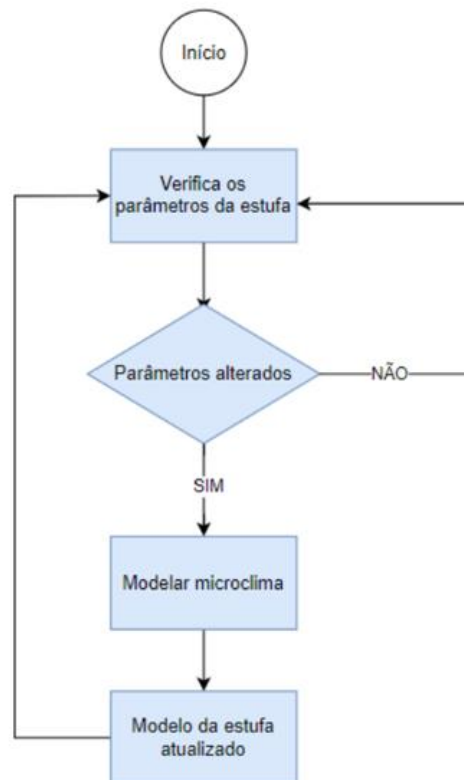
e o vetor de saída

$$y = 1.x_1 + [0 \quad 0 \quad 0 \quad 0]. \begin{bmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \end{bmatrix}. \quad (24)$$

Nesse projeto foi criada uma função em Python para atualizar o modelo toda vez que as características da estufa sejam alteradas, onde são passados os parâmetros da estufa, amostragem desejada do sistema, e o método utilizado para discretizar. A função utiliza a biblioteca *control*, utilizando os comandos *ss* para criar um espaço de estados contínuo e o *c2d* para discretizar através do método desejado, aonde retorna os valores das matrizes discretizadas.

As matrizes discretizadas são utilizadas para gerar o microclima da estufa para aquele instante de tempo. A função *microclima* recebe os parâmetros da estufa, o clima externo atual através de uma API de clima, o histórico do clima interno, as condições de controle, e as matrizes discretizadas. O fluxo de tarefas pode ser observado na Figura 9. Inicia-se com a verificação dos parâmetros, toda vez que modificados, se faz necessário a atualização do modelo.

Figura 9 – Fluxo de atualização do modelo embarcado na Raspberry Pi



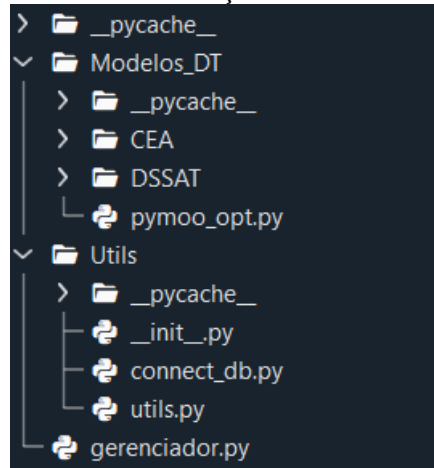
Fonte: Autoria própria

5.2 Camada de integração

Nesta fase, os dados dos objetos são processados e integrados. A Figura 10 apresenta a estrutura utilizada para esta camada. A pasta *CEA* armazena os arquivos referentes ao modelo digital do microclima e consumo de energia, enquanto o *DSSATTools* contém arquivos relacionados ao modelo da cultura. A pasta *Utils* armazena os arquivos necessários para a gestão de dados, conexão com o banco de dados, e estrutura de parâmetros. O arquivo *gerenciador.py* é o arquivo responsável pela gestão dos gêmeos digitais.

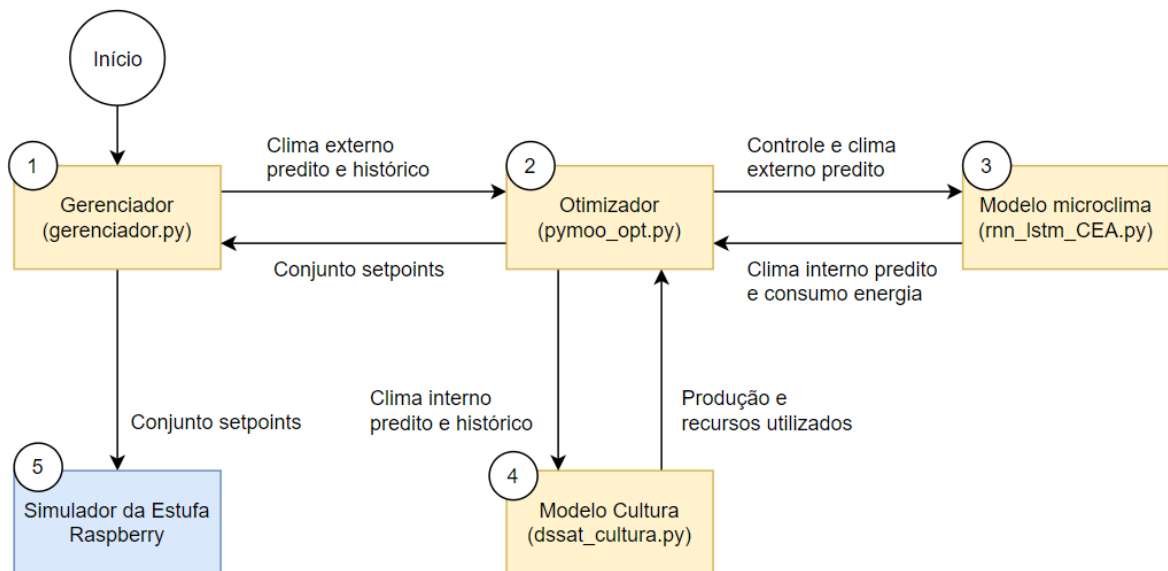
Na camada de integração, o fluxo adotado segue o esquema representado na Figura 11. O gerenciador verifica se há necessidade de atualização dos *setpoints* e fornece ao otimizador os dados requeridos para iniciar a seleção do melhor conjunto. Com os dados em mãos, o otimizador avalia diversos conjuntos, simulando-os por meio dos modelos de microclima e cultura. Após concluir os testes dos conjuntos, o otimizador sugere a melhor solução encontrada para o gerenciador. Esta solução é então enviada para o simulador embarcado no Raspberry Pi 4, onde ocorre o gerenciamento dos atuadores por meio do controle PID.

Figura 10 – Estrutura de funções da camada de integração



Fonte: Autoria própria

Figura 11 – Fluxo de tarefas da camada de integração



Fonte: Autoria própria

5.2.1 Camada de virtualização

5.2.1.1 Microclima da estufa

O gêmeo digital do microclima foi realizado através da Rede Neural Recorrente LSTM com o intuito de prever a temperatura, umidade, radiação e o consumo total dos atuadores da estufa com intervalo de uma hora. O *dataset* de treinamento foi criado através do simulador apresentado na Seção 5.1, e a configuração da estufa mostrada na Seção 5.1.1. A Figura 12 mostra a estrutura do *dataset* utilizado, os dados de temperatura interna (*temp_in*), umidade interna (*umid_in*), radiação interna (*rad_in*), temperatura externa (*temp_ext*), umidade externa (*umid_ext*), radiação externa (*rad_ext*), pressão externa (*pres_ext*), *setpoints*, capacidade de

refrigeração (*capRefrig*) e aquecimento (*capAquec*), consumo de energia do sistema de resfriamento (*KWhRefrig*), aquecimento (*KWhAquec*) e total (*KWhTotal*) foram registrados a cada 60 segundos, no intervalo de janeiro a dezembro do ano de 2023 na cidade de Curitiba.

Figura 12 – Estrutura do dataset de treinamento

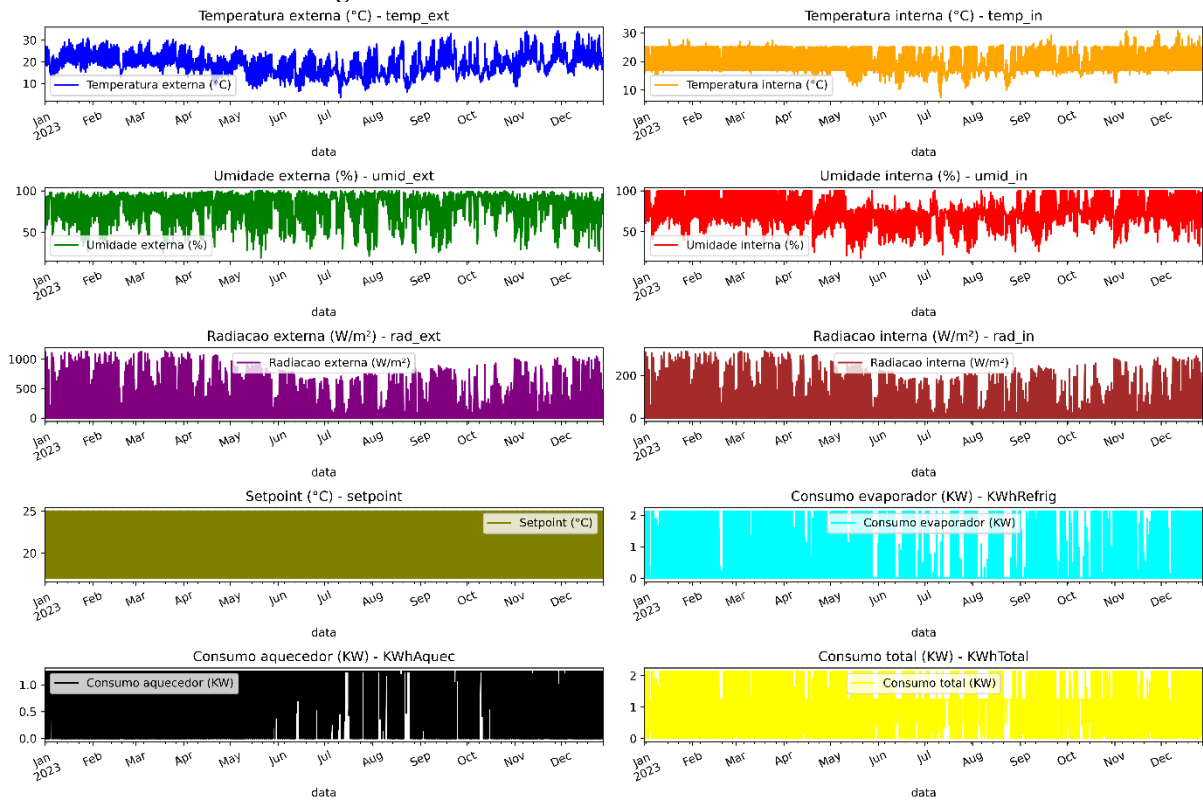
```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 519781 entries, 0 to 519780
Data columns (total 14 columns):
#   Column      Non-Null Count  Dtype
---  -
0   data        519781 non-null  datetime64[ns]
1   temp_in     519781 non-null  float64
2   umid_in     519781 non-null  float64
3   rad_in      519781 non-null  float64
4   temp_ext    519781 non-null  float64
5   umid_ext    519781 non-null  float64
6   rad_ext     519781 non-null  float64
7   pres_ext    519781 non-null  float64
8   setpoint    519781 non-null  float64
9   capRefrig   519781 non-null  float64
10  capAquec    519781 non-null  float64
11  KWhRefrig   519781 non-null  float64
12  KWhAquec    519781 non-null  float64
13  KWhTotal    519781 non-null  float64
dtypes: datetime64[ns](1), float64(13)
memory usage: 55.5 MB
```

Fonte: Autoria própria

A Figura 13 mostra o comportamento dos dados brutos no decorrer do tempo, para a primeira modelagem, o *setpoint* assumiu os valores de 16°C durante a noite e 25°C durante o dia, que reflete na temperatura e umidade interna. A radiação interna é menor do que a externa devido o material da estufa, e o consumo de energia com máxima de 3 KWh a cada minuto registrado.


Na etapa de pré-processamento, foram criadas *features* realizando operações de multiplicação e *shift* com a temperatura, umidade e radiação externas, como mostra a Figura 14. Antes de adicionar as novas *features* foi realizado o agrupamento de dados para intervalos de uma hora, utilizando a operação de soma para *setpoint*, temperatura, umidade e consumo, e para a radiação utilizou a máxima registrada no período. No final do pré-processamento os dados foram normalizados.

Figura 13 – Dados brutos do *dataset* de treinamento



Fonte: Autoria própria

Figura 14 – Mapa de correlação com as novas *features*



Fonte: Autoria própria

A estrutura do *dataset* final de treinamento, resulta em 11 *features* e 4 variáveis a serem preditas. O *time_step* refere-se ao intervalo de 24 horas que devem ser preditos para aquele mesmo intervalo do clima externo conhecido (previsão baixada da API do clima), e os *setpoints* testados pelo otimizador discutido na Seção 5.2.2.

O modelo LSTM apresentado na Figura 15 é configurado para processar sequências temporais e fazer previsões múltiplas. Ele consiste em duas camadas LSTM empilhadas com 50 unidades cada, uma camada *Dropout* com taxa de 20% responsável pela regularização, uma camada *Dense* intermediária com 50 neurônios responsáveis por transformar a saída da LSTM em uma forma que possa ser processada pela camada de saída, e em seguida uma camada *Dense* de saída com 96 neurônios que gera 24 previsões para as 4 variáveis alvo.

Figura 15 – Estrutura do modelo a ser treinado

Model: "sequential"

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 24, 50)	12,400
lstm_1 (LSTM)	(None, 50)	20,200
dropout (Dropout)	(None, 50)	0
dense (Dense)	(None, 50)	2,550
dense_1 (Dense)	(None, 96)	4,896

Total params: 40,046 (156.43 KB)
 Trainable params: 40,046 (156.43 KB)
 Non-trainable params: 0 (0.00 B)

Fonte: Autoria própria

Para o treinamento do modelo foi utilizado o otimizador *Adam* responsável por ajustar os pesos da rede durante o treinamento, e o erro quadrático médio (do inglês, *Mean Squared Error* – MSE) foi utilizada como função de perda, sendo apropriada para problemas de regressão. Além disso, foi implementado uma função chamada *Early Stopping* para interromper o treinamento antecipadamente se a perda de validação não melhorar por 10 épocas consecutivas. O modelo foi treinado em 117 épocas, com *batch size* de 32, e 20% dos dados de treinamento usados para validação.

5.2.1.2 Produção e recursos da cultura

A virtualização da cultura visa fornecer informações sobre a produção e o uso de recursos, utilizando o histórico e a previsão do clima interno e externo da estufa como entrada. Esse modelo utiliza a biblioteca DSSATTools como ferramenta de simulação, possibilitando a especificação do tipo de solo, da cultura, da data de plantio e do período de colheita.

5.2.2 Camada de suporte à decisão

Nesta fase do projeto, os requisitos são definidos para encontrar a melhor solução para o problema, considerando múltiplos objetivos com base nos modelos criados pela camada de

virtualização. O código presente no arquivo *pymoo_opt.py* é a implementação de um problema de otimização multiobjetivo usando a biblioteca PYMOO para encontrar o melhor conjunto de *setpoints* para um sistema de controle de estufa. Os passos adotados na implementação são os seguintes:

Definição do problema: A classe *GreenhouseProblem* é definida como uma subclasse de *Problem* da biblioteca pymoo. Essa classe representa o problema a ser resolvido, recebe dados sobre o clima externo, limites de temperatura mínima e máxima da estufa e define o número de variáveis de decisão, objetivos e restrições. As condições de análise para cada conjunto são: minimizar o consumo de energia, o tempo em que a temperatura fica fora dos limites, o tempo dos atuadores ficam em capacidade máxima, os recursos como fertilizantes e água, e maximizar a produção.

Avaliação das soluções: O método *_evaluate* da classe é implementado para avaliar a função objetiva para cada solução candidata. Ele executa a simulação para cada conjunto de *setpoints* fornecido, e calcula os objetivos.

Execução da Otimização: A função *optimize_setpoint* inicializa o problema, define o algoritmo de otimização escolhido nesse projeto como NSGA-II e executa a otimização. Depois, ela retorna os melhores conjuntos encontrados.

Processamento dos Resultados: Após a otimização, os melhores *setpoints* são encontrados. Nesse trabalho optou-se por escolher o grupo com menor diferença absoluta entre os valores consecutivos de cada conjunto.


6 RESULTADOS

Nesse trabalho utilizou-se os mesmos parâmetros de configuração da estufa apresentados no trabalho de Araújo (2020), para que seja possível realizar a comparação dos resultados obtidos posteriormente. A estufa simulada foi do formato A-frame e a configuração utilizada está descrita Seção 5.1.1. E como cultura foi simulado o cultivo do tomate para o período de janeiro a maio de 2024, o modelo adotado foi o CROPGRO disponível no DSSATTools.

6.1 Modelo do microclima LSTM

A curva de aprendizado do modelo pode ser consultada na Figura 16, ambas as curvas diminuem rapidamente nas primeiras épocas, sugerindo que o modelo está aprendendo, após cerca de 60 épocas o modelo não está mais aprendendo significativamente novas informações a partir dos dados. A diferença entre as curvas é pequena, e os valores de perdas baixo, que sugere que o modelo não está sofrendo de *overfitting* ou *underfitting*.

Figura 16 – Curva de aprendizado do modelo RNN-LSTM



Fonte: Autoria própria

As figuras Figura 17, Figura 18, ia própria

Figura 19 e Figura 20 apresentam os resultados do modelo para o dia 21 de janeiro de 2024. O modelo LSTM consegue capturar a tendência geral da variação das variáveis geradas pelo simulador, mas apresenta algumas limitações na precisão durante períodos críticos do dia.

As previsões são razoavelmente precisas durante a madrugada e manhã, mas tendem a superestimar durante a tarde e não capturam adequadamente rápidas mudanças.

Figura 17 – Temperatura da estufa predita para as 24 horas do dia

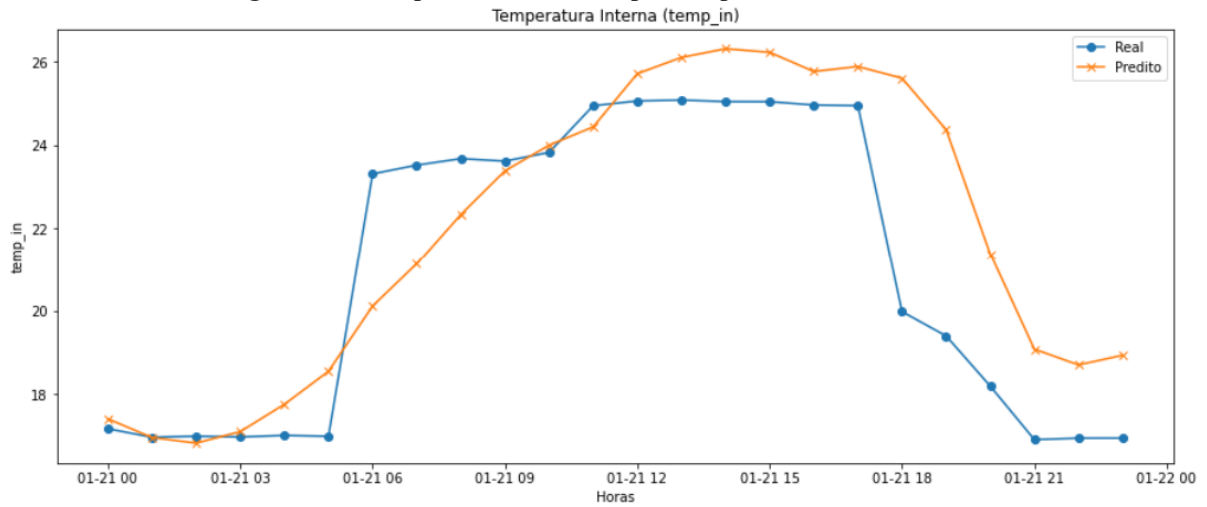


Figura 18 – Umidade da estufa predita para as 24 horas do dia

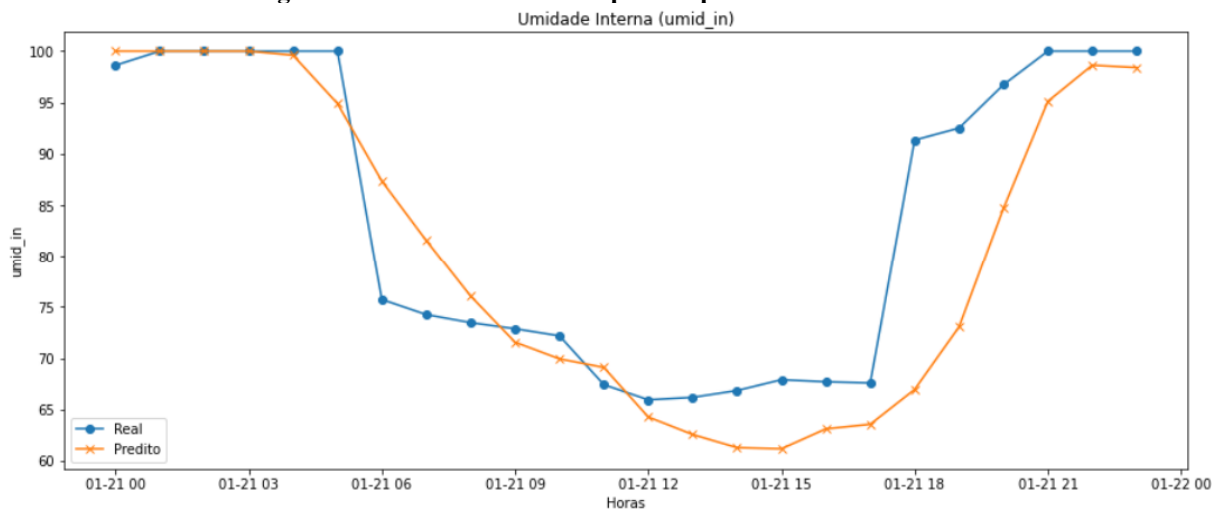
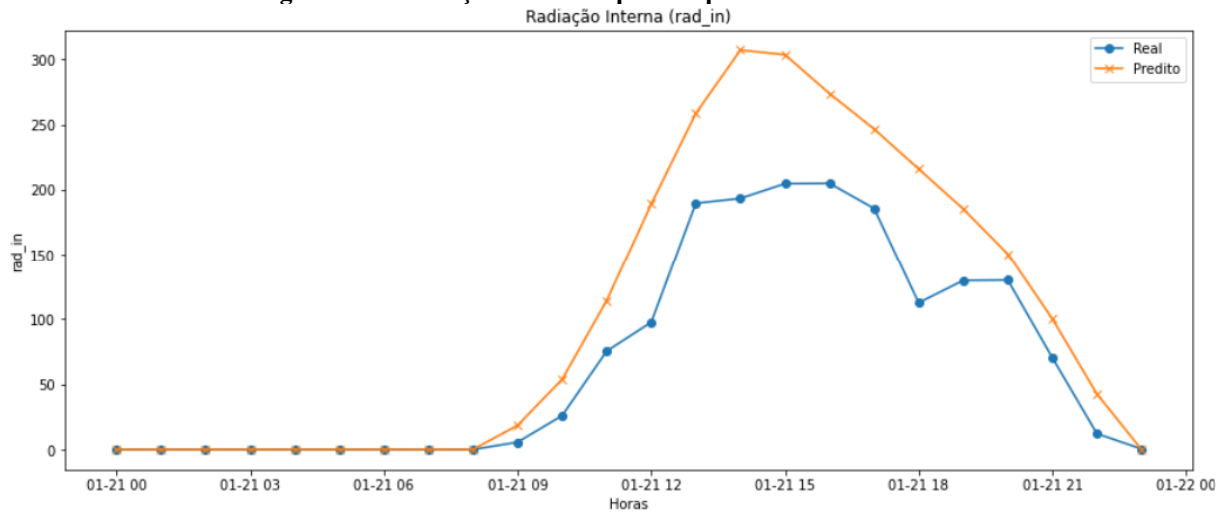
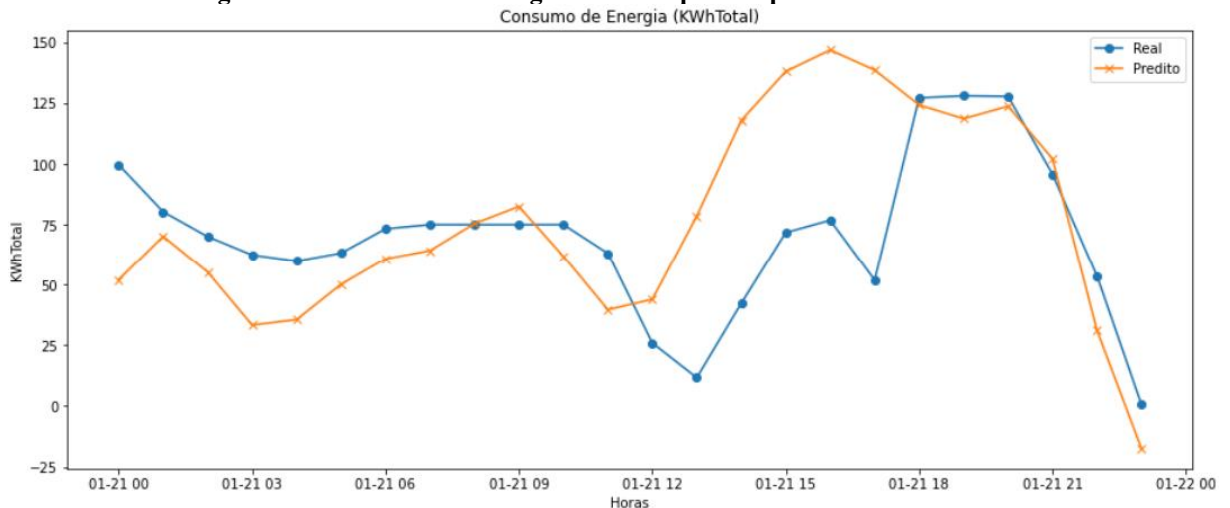


Figura 19 – Radiação da estufa predita para as 24 horas do dia



Fonte: Autoria própria


Figura 20 – Consumo de energia da estufa predita para as 24 horas do dia



Fonte: Autoria própria

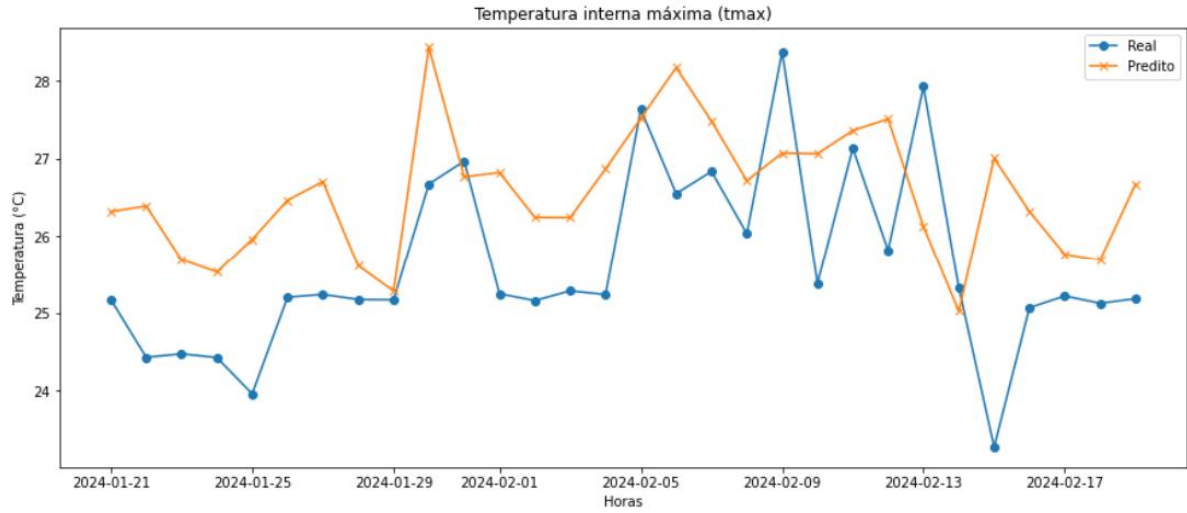
Para simulação do comportamento da cultura pelo DSSAT e a otimização junto ao MOO, são necessários os dados de mínima e máxima temperatura, umidade média, radiação total e consumo de energia da estufa diariamente. As figuras Figura 21, Figura 22, Figura 23 e Figura 24 apresentam os resultados do modelo para o intervalo de 21 de janeiro de 2024 a 19 de fevereiro de 2024. O modelo apresentou bons resultados iniciais, a ideia no decorrer da utilização dos gêmeos digitais é que o modelo seja atualizado até que demonstre o comportamento ideal da estufa.

Figura 21 – Temperatura mínima da estufa predita para o DSSAT em um mês
 Temperatura interna mínima (tmin)



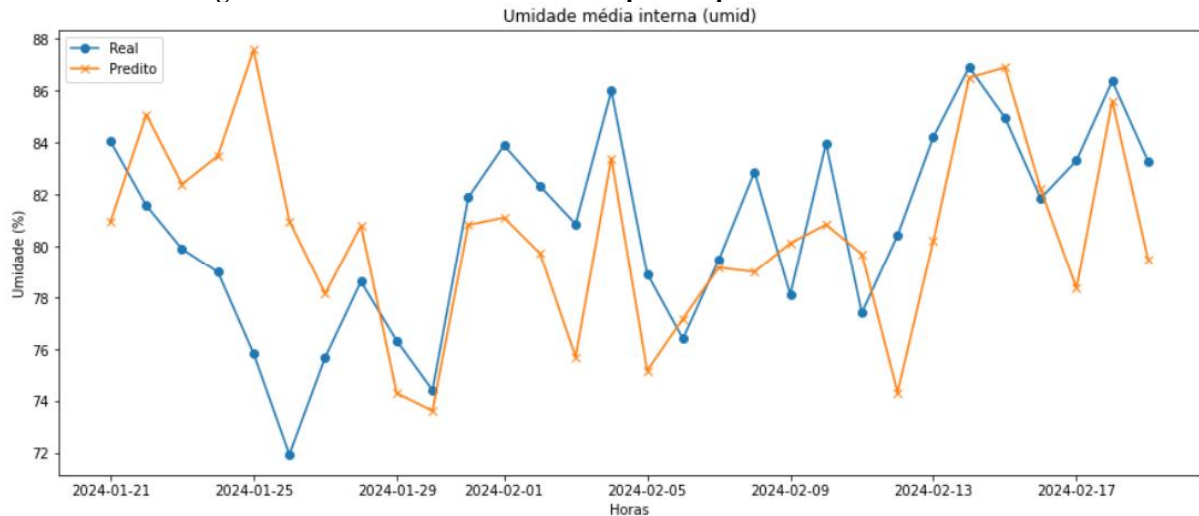
Fonte: Autoria própria

Figura 22 – Temperatura máxima da estufa predita para o DSSAT em um mês
 Temperatura interna máxima (tmax)




Fonte: Autoria própria

Figura 23 – Umidade média da estufa predita para o DSSAT em um mês



Fonte: Autoria própria

Figura 24 – Radiação total diária da estufa predita para o DSSAT em um mês



Fonte: Autoria própria

6.2 Consumo de energia

Para as primeiras análises e efeito de comparação inicial, foi considerado os dados utilizados por Araújo (2020) do dia 20 de julho de 2018, contendo um registro do clima externo a cada 1 hora, totalizando 24 amostras. O Quadro 1 mostra os tipos de controle utilizados para possibilitar a validação da arquitetura de gêmeos digitais. Os controles serão avaliados em 4 pontos: tempo em que a temperatura fica fora dos limites, tempo em que os atuadores ficam saturados, consumo de energia, e economia.

Quadro 1 – Modos de controles utilizados

Modelo do controle	Descrição
C01	Controle <i>temp_in_out</i> utilizado por Araújo (2020)
C02	PID com <i>setpoint</i> fixo

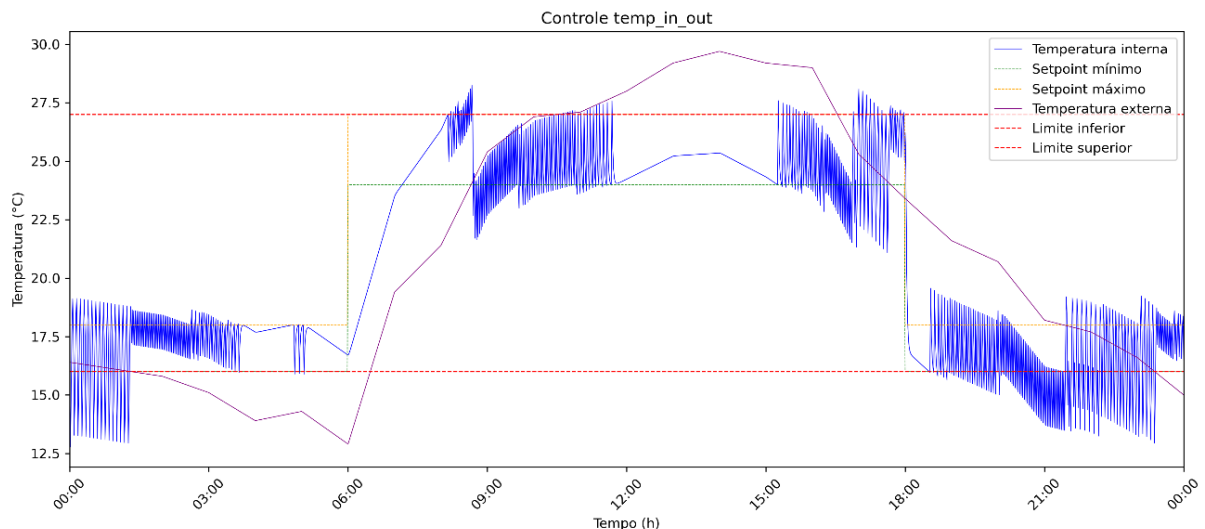
C03	PID com agenda de <i>setpoint</i> definida pelo gêmeo digital, utilizando RNN-LSTM para a previsão do clima da estufa
C04	PID com agenda de <i>setpoint</i> definida pelo gêmeo digital, utilizando modelo ótimo do clima da estufa

Fonte: Autoria própria

O tomate é uma planta de cultivo de média temperatura. Para esse projeto foi considerado a temperatura mínima em 16°C e máxima de 27°C.

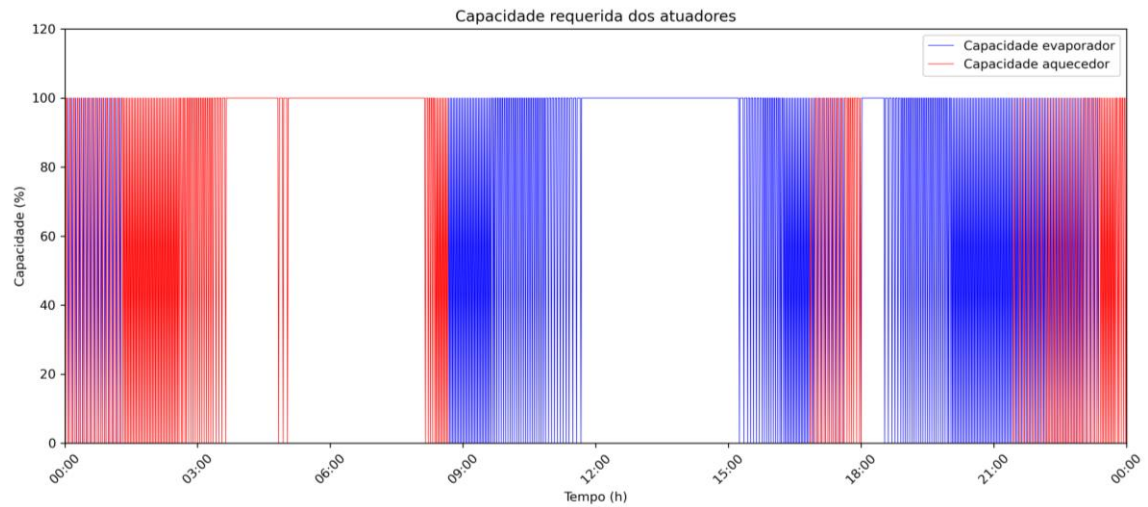
A Figura 25 ilustra o comportamento da temperatura interna da estufa com o controle *temp_in_out* desenvolvido por Araújo (2020). Nota-se uma oscilação na variável controlada, que em determinados momentos ultrapassa os limites estabelecidos. Essa variação ocorre devido às estratégias de controle implementadas, conforme é possível observar pelo funcionamento dos atuadores na Figura 26. Com base nos dados analisados, o consumo de energia desse modelo foi de 1845 kWh, apresentando uma taxa de saturação dos atuadores de 73,84% e uma taxa de operação de 15,47%.

Figura 25 – C01 Comportamento da temperatura interna



Fonte: Autoria própria

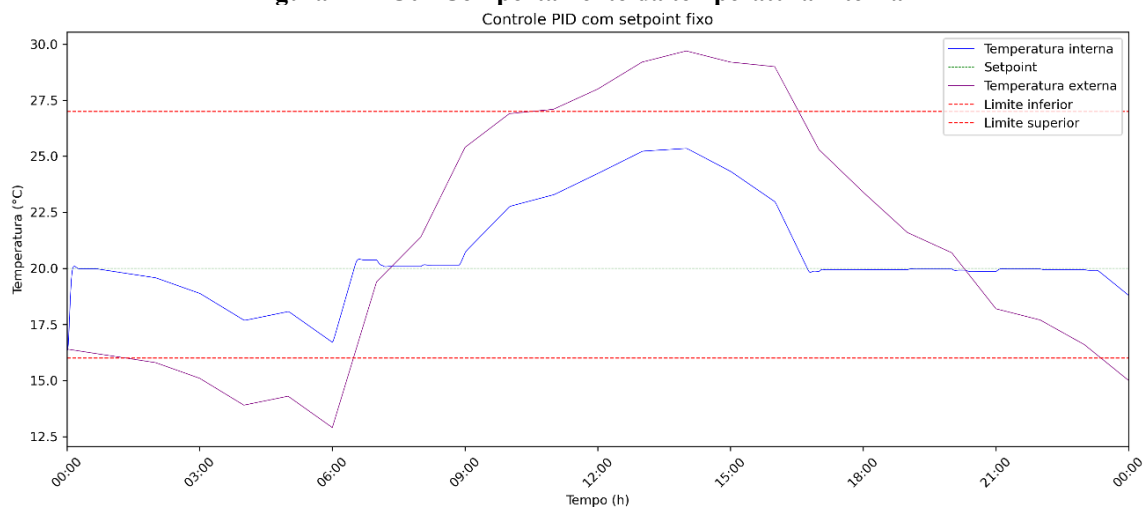
Figura 26 – C01 Capacidade requerida dos atuadores



Fonte: Autoria própria


Nas figuras Figura 27 e Figura 28 o controle C02 que utiliza um PID com *setpoint* fixo, mostra uma boa capacidade de manter a temperatura interna próxima ao *setpoint* desejado, mesmo com variações significativas na temperatura externa ao longo do dia. O gráfico evidencia que a temperatura interna se mantém estável e bem controlada, ajustando-se adequadamente durante o dia. É possível observar que a potência do aquecedor não é suficiente para manter a temperatura na referência de controle. No entanto, isso resulta em um consumo de energia relativamente alto, de 1988,27 kWh. Isso indica que, embora o controle C02 seja eficaz na manutenção da temperatura, ele não é o mais eficiente em termos de economia de energia.

Figura 27 – C02 Comportamento da temperatura interna



Fonte: Autoria própria

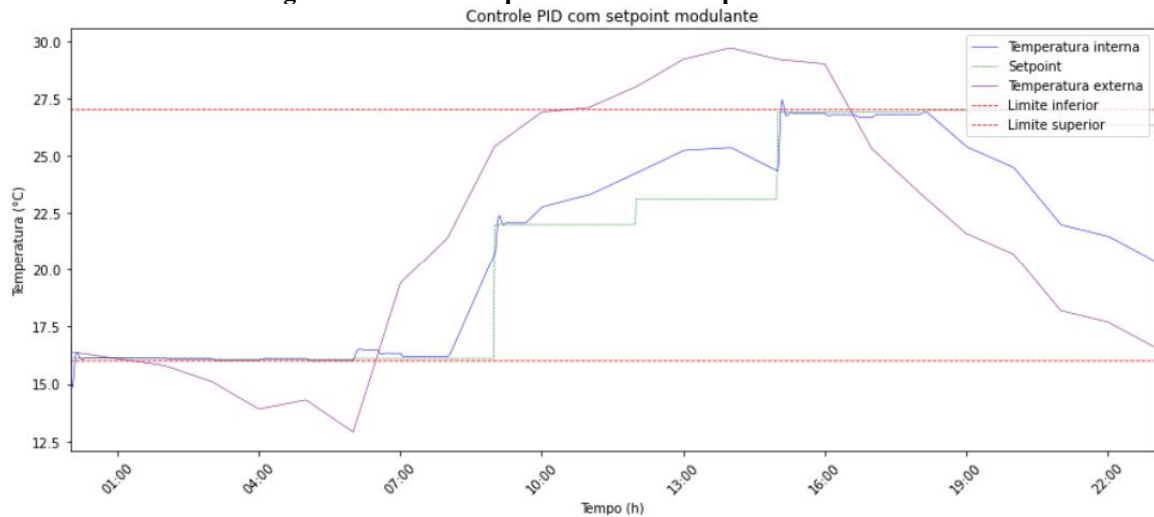
Figura 28 – C02 Capacidade requerida dos atuadores



Fonte: Autoria própria

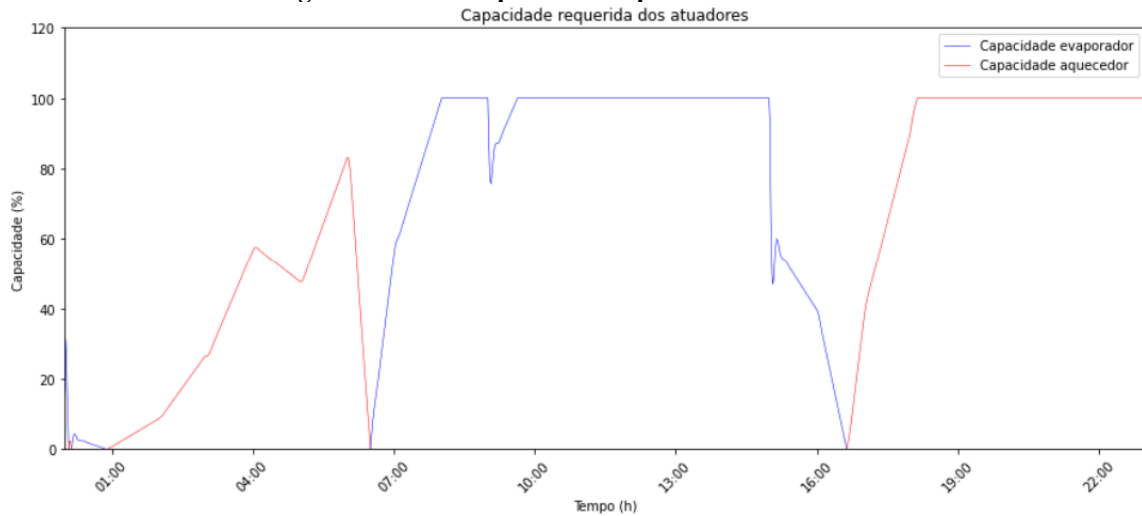
Nas figuras Figura 29 e Figura 30 o controle C03 que utiliza um PID com *setpoints* definido pelo gêmeo digital inicial, mostra uma boa adaptação às variações da temperatura externa ao longo do dia. O gráfico indica que a temperatura interna se ajusta rapidamente para atender aos diferentes *setpoints* definidos, permanecendo dentro dos limites desejados. Este controle resulta em um consumo de energia de 1670,73 kWh, com uma economia significativa de 19,48% em relação ao controle base C01. Isso demonstra que o C03 é mais eficiente em termos de economia de energia, mantendo o conforto térmico com menor consumo energético.

Figura 29 – C03 Comportamento da temperatura interna



Fonte: Autoria própria


Figura 30 – C03 Capacidade requerida dos atuadores



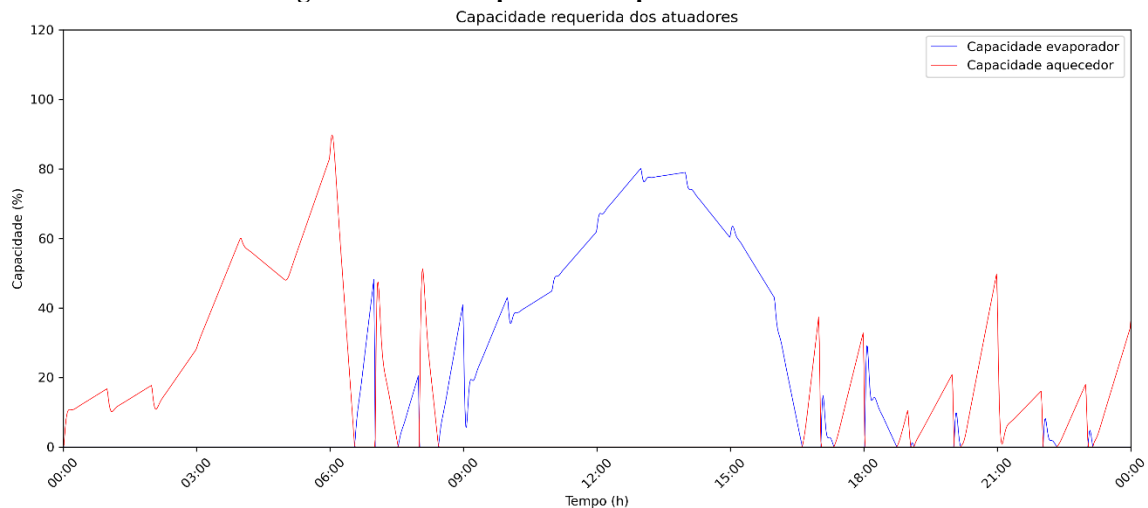
Fonte: Autoria própria

Nas figuras Figura 31 e Figura 32 o controle C04 que utiliza um PID com *setpoint* modulante definido pelo modelo digital, apresenta um ajuste dinâmico e contínuo da temperatura interna para seguir as variações do *setpoint* ao longo do dia. Quando levado em consideração principalmente o consumo de energia, o gêmeo digital entendeu que acompanhar a evolução da temperatura externa requer menos esforço dos atuadores. O gráfico indica que a temperatura interna se adapta eficientemente às mudanças no *setpoint*, mantendo-se dentro dos limites desejados apesar das variações significativas na temperatura externa.

Este controle permite uma modulação precisa e uma resposta rápida às alterações de temperatura, resultando em um consumo de energia significativamente menor, de 827,11 kWh. A economia de energia mostra uma redução de 55,17% em relação ao controle base C01. Isso destaca o C04 como o modo de controle mais eficiente em termos de economia de energia, ao mesmo tempo que mantém o conforto térmico.

Figura 31 – C04 Comportamento da temperatura interna

Fonte: Autoria própria

Figura 32 – C04 Capacidade requerida dos atuadores

Fonte: Autoria própria

A Tabela 2 resume os resultados obtidos nas diversas condições climáticas, e indicam que o controle C04, que utiliza um PID com *setpoint* modulante baseado em um gêmeo digital ótimo, é consistentemente o mais eficiente em termos de economia de energia, apresentando reduções significativas no consumo em todas as situações. Em um dia ameno/quente (A002_2018-07-20), o C04 alcançou uma economia de 55,17%, enquanto em um dia frio (D02-15_07_2023) e em um dia quente (D03-24_09_2023), as economias foram de 26,29% e 57,60%, respectivamente. Isso demonstra a capacidade do C04 de ajustar-se eficientemente às variações de temperatura externa, mantendo o conforto térmico com menor consumo energético.

Comparativamente, o controle C02, com PID e *setpoint* fixo, apresentou menor eficiência, variando entre -7,77% de economia negativa em um dia ameno/quente (A002_2018-

07-20) e 28,77% em um dia quente (D03-24_09_2023). O controle C03, teve desempenho intermediário, com economias variando de 9,45% em um dia ameno/quente (A002_2018-07-20) a 39,67% em um dia ameno/quente (D01-01_04_2023). Esses resultados destacam a importância de um controle mais adaptável e modulante, como o C03 e C04, para otimizar o consumo de energia em sistemas de controle de temperatura.

Tabela 2 – Resultados gerais dos modos de controle e consumo de energia para um dia

Dados	Controle	Temperatura fora da faixa (%)	Atuador saturado (%)	Consumo (kWh)	Economia (%)
A002_2018-07-20	C01	15,47	73,84	1845	--
	C02	0	60,58	1988,27	-7,77
	C03	0,94	48,73	1670,73	9,45
	C04	0	0	827,11	55,17
D01-01_04_2023	C01	19,91	77,77	1948,47	--
	C02	0	32,22	1517,61	22,11
	C03	0	17,74	1175,42	39,67
	C04	0	3,84	579,15	70,28
D02-15_07_2023	C01	64,52	94,28	1672,55	--
	C02	60,32	77,55	1532,32	8,39
	C03	68,93	64,30	1422,39	14,95
	C04	63,94	61,40	1232,87	26,29
D03-24_09_2023	C01	31,28	82,48	2160,45	--
	C02	15,86	36,06	1538,9	28,77
	C03	17,45	32,66	1777,67	17,72
	C04	19,98	17,45	916,07	57,60

Fonte: Autoria própria

6.3 Capacidade de produção

Para analisar a produção de cada modelo de controle, foi utilizado o cultivo de tomate simulado através do DSSATTools. Para essa simulação, foi empregado o modelo padrão do solo e o modelo TM0001 para a cultura. A irrigação foi configurada para ser automática e não houve adição de fertilizantes. O período de plantio simulado foi de 1º de janeiro de 2024 a 30 de abril de 2024, totalizando 121 dias. A Tabela 3 resume os valores observados para cada variável analisada.

Tabela 3 – Resultados de produção

Controle	Fator de produção	Consumo (KWh)	Eficiência Energética	Ganho (%)
C01	761	229192,63	3,32	--
C02	442	168379,88	2,62	-26,72
C03	697	172734,49	4,03	17,62
C04	575	67163,39	8,56	61,2

Fonte: Autoria própria

A produção de cada condição experimental foi estabelecida como adimensional, uma vez que o modelo utilizado não representa a área e as propriedades reais da estufa, dessa forma, foi considerado como um fator de produção. A maior produção foi observada na condição C01, com 761, seguida pela condição C03 com 697, C04 de 575 e finalmente pela condição C02 com 442.

O consumo de energia foi registrado em quilowatt-hora (kWh). A condição C01 apresentou o maior consumo energético com 229192,63 kWh, seguida pela condição C03 com 172734.49 kWh, C02 com 168379,88 kWh, e por último C04 com 67163,39 kWh.

A eficiência energética foi calculada através da razão entre o fator de produção e o consumo de energia, que representa a produção obtida por unidade de energia consumida. A condição C04 apresentou a maior eficiência energética com 8,56, C03 com 4,03, seguida pela condição C01 com 3,32, e a condição C02 teve a menor eficiência energética com 2,62.

7 CONCLUSÃO

Os resultados demonstraram que o controle de uma estufa utilizando conceitos de gêmeos digitais obteve a melhor eficiência de capacidade de produção. Embora a condição C01, tenha apresentado o maior fator de produção, obteve menor eficiência em comparação com a C03 e C04. Dessa forma, o estudo mostrou que a eficiência produtiva aumentou em 18% para um gêmeo digital inicial podendo chegar a 61% para gêmeos digitais que representam com mais precisão o objeto físico.

A aplicação de gêmeos digitais no controle da estufa demonstra um avanço significativo na otimização de recursos e na eficiência energética. A utilização de modelos matemáticos e ferramentas de simulação como DSSATTools e RNN-LSTM permite uma previsão mais precisa do microclima e do comportamento das culturas, resultando numa gestão mais eficaz das condições internas da estufa.

Além disso, a capacidade dos gêmeos digitais de integrar e processar grandes volumes de dados em tempo real fornece análises preditivas poderosas, permitindo que os problemas sejam antecipados e que soluções corretivas sejam implementadas proativamente. Isto aumenta a resiliência agrícola e a capacidade de resposta às alterações climáticas e de mercado, promovendo assim uma agricultura mais adaptável e eficiente. A aplicação de técnicas de otimização multiobjetivo, como o NSGA-II, também demonstra o potencial desta tecnologia para alcançar um equilíbrio ideal entre produção e consumo de recursos, maximizando a produtividade e minimizando custos.

Finalmente, os desafios encontrados durante o desenvolvimento e implementação do sistema destacam a importância de uma abordagem integrada e multidisciplinar à inovação na agricultura. Combinar conhecimentos em eletrônica, modelagem matemática, inteligência artificial e otimização de recursos resulta em soluções inovadoras que podem transformar significativamente as práticas agrícolas em ambientes controlados.

Trabalhos futuros podem focar na melhoria dos modelos de previsão utilizando diferentes arquiteturas de redes neurais e técnicas de aprendizado de máquina, exploração de algoritmos de otimização mais avançados para eficiência energética, testes de escalabilidade em estufas comerciais, e desenvolvimento da camada de aplicação. Essas direções visam aumentar a precisão, eficiência, sustentabilidade e aplicabilidade comercial das soluções de gêmeos digitais em ambientes controlados.

REFERÊNCIAS

- ARAÚJO, G. M. **Controle de temperatura de estufas utilizando método de controle supervísório**. 2020. Dissertação (Graduação em Sistemas de Informação) – Universidade Federal Rural de Pernambuco, Recife, 2020. Disponível em: https://repository.ufrpe.br/bitstream/123456789/4166/1/tcc_guilhermematheusdearaujo.pdf. Acesso em: 23 set. 2023.
- ARIESEN-VERSCHUUR, N.; VERDOUW, C.; TEKINERDOGAN, B. Digital twins in greenhouse horticulture: a review. **Computers and Electronics in Agriculture**, v. 199, 2022. Disponível em: <https://doi.org/10.1016/j.compag.2022.107183>. Acesso em: 8 mai. 2023.
- BLANK, J.; DEB, K. Pymoo: multi-objective optimization in Python. **IEEE Access**, v. 8, p. 89497-89509, 2020. Disponível em: <https://doi.org/10.1109/ACCESS.2020.2990567>. Acesso em: 12 mar. 2024.
- BRASIL ESTUFAS. **As características mais importantes na hora de adquirir uma Estufa Agrícola**. 2024. Disponível em: <https://brasilestufas.com.br/>. Acesso em: 12 jun. 2024.
- CARDOZO, F. H. P. **Aplicação de redes neurais para inferência de temperaturas históricas na usina nuclear Angra 1**. 2022. Dissertação (Mestrado em Engenharia Nuclear) – Programa de Pós-graduação em Engenharia Nuclear, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2022. Disponível em: <https://www.nuclear.ufrj.br/images/Dissertacao-Fernando-Cardozo.pdf>. Acesso em: 15 abr. 2024.
- CHAUX, J. D.; SANCHEZ-LONDONO, D.; BARBIERI, G. A digital twin architecture to optimize productivity within controlled environment agriculture. **Applied Sciences**, 2021. Disponível em: <https://doi.org/10.3390/app11198875>. Acesso em: 9 mai. 2023.
- COURSERA. **What is a digital twin? Definition, types, and uses**. 29 nov. 2023. Disponível em: <https://www.coursera.org/articles/digital-twin>. Acesso em: 7 mai. 2024.
- FERRANTE, A.; MARIANI, L. Agronomic management for enhancing plant tolerance to abiotic stresses: high and low values of temperature, light intensity, and relative humidity. **Horticulturae**, v. 4, n. 3, p. 21, 2018. Disponível em: <https://doi.org/10.3390/horticulturae4030021>. Acesso em: 23 set. 2023.
- FITZ-RODRÍGUEZ, E.; *et al.* Dynamic modeling and simulation of greenhouse environments under several scenarios: A web-based application. **Computers and Electronics in Agriculture**, p. 105-116, 2010. Disponível em: <https://doi.org/10.1016/j.compag.2009.09.010>. Acesso em: 23 set. 2023.
- FULLER, A.; *et al.* Digital twin: enabling technologies, challenges and open research. **IEEE Access**, v. 8, p. 108952-108971, 2020. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9103025>. Acesso em: 23 set. 2023.
- GRIEVES, M. Intelligent digital twins and the development and management of complex systems. **Digital Twin**, 2022. Disponível em: <https://doi.org/10.12688/digitaltwin.17574.1>. Acesso em: 23 set. 2023.

GUNANTARA, N.; AI, Q. A review of multi-objective optimization: methods and its applications. **Cogent Engineering**, v. 5, n. 1, 2018. Disponível em: <https://doi.org/10.1080/23311916.2018.1502242>. Acesso em: 5 abr. 2024.

HEMMING, S.; *et al.* Cherry tomato production in intelligent greenhouses—Sensors and AI for control of climate, irrigation, crop yield, and quality. **Sensors**, v. 20, n. 22, 2020. Disponível em: <https://doi.org/10.3390/s20226430>. Acesso em: 4 out. 2023.

HOOGENBOOM, G.; *et al.* **Decision support system for agrotechnology transfer (DSSAT) Version 4.8.2**. DSSAT Foundation, 2023. Disponível em: <www.DSSAT.net>. Acesso em: 23 set. 2023.

IBM. **How digital twins optimize the performance of your assets in a sustainable way**. 4 abr. 2023. Disponível em: <https://www.ibm.com/blog/how-digital-twins-optimize-the-performance-of-your-assets-in-a-sustainable-way/>. Acesso em: 18 abr. 2024.

KRITZINGER, W.; *et al.* Digital Twin in manufacturing: A categorical literature review and classification. **International Federation of Automatic Control**, 2018. Disponível em: <https://doi.org/10.1016/j.ifacol.2018.08.474>. Acesso em: 24 set. 2023.

ONG, R.; CAO, Y.; ZHU, Z. Solar radiation effects on leaf nitrogen and phosphorus stoichiometry of Chinese fir across subtropical China. **Forest Ecosystems**, v. 8, n. 62, 2021. Disponível em: <https://doi.org/10.1186/s40663-021-00344-6>. Acesso em: 7 mai. 2024.

ORACLE. **MySQL workbench, versão 8.0.28**. Disponível em: <https://www.mysql.com/products/workbench/>. Acesso em: 13 jan. 2024.

PELADARINOS, N.; *et al.* Enhancing smart agriculture by implementing digital twins: a comprehensive review. **Sensors**, v. 23, 2023. Disponível em: <https://doi.org/10.3390/s23167128>. Acesso em: 16 jun. 2024.

PURCELL, W.; NEUBAUER, T.; MALLINGER, K. Digital twins in agriculture: challenges and opportunities for environmental sustainability. **Current Opinion in Environmental Sustainability**, v. 61, 2023. Disponível em: <https://doi.org/10.1016/j.cosust.2022.101252>. Acesso em: 28 abr. 2024.

QU, Y. **A digital twin framework for commercial greenhouse climate control system**. 2023. Dissertação (Pós-Doutorado), Universidade do Sul da Dinamarca, Dinamarca, 2023. Disponível em: <https://doi.org/10.21996/nx33-aj13>. Acesso em: 20 fev. 2024.

QUINTERO, D. **DSSATTools package 2.1.3**. 29 jan. 2024. Disponível em: <https://pypi.org/project/DSSATTools/>. Acesso em: 2 mar. 2024.

RABELO, R. J.; MAGALHÃES, L. C.; CABRAL, F. G. Uma proposta de arquitetura de referência de gêmeo digital para sistemas ciberfísicos em um cenário de Indústria 4.0. **Congresso Brasileiro de Automática**, 2020. Disponível em: <https://www.researchgate.net/publication/347568093>. Acesso em: 12 mai. 2024.

RAUBER, T.W. **Redes neurais artificiais**. 23 mai. 2014. Disponível em: https://www.researchgate.net/profile/Thomas-Rauber-2/publication/228686464_Redex_neurais_artificiais/links/02e7e521381602f2bd000000/Redes-neurais-artificiais.pdf. Acesso em: 15 abr. 2024.

RODRIGUES, N. T. J. **Redes neurais artificiais LSTM aplicadas na previsão de padrões de um forno de reaquecimento de Tarugos**. 2022. Dissertação (Mestrado em Engenharia Química) – Programa de Pós-graduação em Engenharia Química, Universidade Federal de Campina Grande, Campina Grande, 2022. Disponível em: <http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/27646>. Acesso em: 3 abr. 2024.

SOUSSI, A.; *et al.* Smart sensors and smart data for precision agriculture: a review. **Sensors**, v. 24, 2024. Disponível em: <https://doi.org/10.3390/s24082647>. Acesso em: 7 jun. 2024.

SPYDER. **Spyder IDE, versão 5.2.2**. Disponível em: <https://www.spyder-ide.org>. Acesso em: 5 mar. 2024.

SUZUKI, K. **Artificial neural networks - Methodological advances and biomedical applications**. Rijeka: InTech, 2011. E-book. Disponível em: https://www.researchgate.net/profile/Kenji-Suzuki-2/publication/319316102_Artificial_Neural_Networks_-_Methodological_Advances_and_Biomedical_Applications/links/59a42f16aca272a6461bb35e/Artificial-Neural-Networks-Methodological-Advances-and-Biomedical-Applications.pdf. Acesso em: 15 abr. 2024.

VALDES, C. **Brazil's momentum as a global agricultural supplier faces headwinds**. 27 set. 2022. Disponível em: <https://www.ers.usda.gov/amber-waves/2022/september/brazil-s-momentum-as-a-global-agricultural-supplier-faces-headwinds/>. Acesso em: 13 jun. 2024.

VANDERHORN, E.; MAHADEVAN, S. Digital twin: generalization, characterization and implementation. **Decision Support Systems**, v. 145, 2021. Disponível em: <https://doi.org/10.1016/j.dss.2021.113524>. Acesso em: 28 set. 2023.

VERMA, S.; PANT, M.; SNASEL, V. A comprehensive review on NSGA-II for Multi-Objective combinatorial optimization problems. **IEEE Access**, v. 9, p. 57757-57791, 2021. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9393947>. Acesso em: 3 abr. 2024.

VIEIRA NETO, J. G. **Influência da forma de estufas agrícolas na performance estrutural e no conforto térmico**. 2015. Dissertação (Mestrado em Engenharia Agrícola) – Programa de Pós-graduação em Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2015. Disponível em: <https://doi.org/10.47749/T/UNICAMP.2015.952031>. Acesso em: 7 jun. 2024.