



**UNIVERSIDADE FEDERAL DE MINAS GERAIS**  
**ENGENHARIA MECÂNICA**

**DESENVOLVIMENTO DE UM MODELO DE PREDIÇÃO DE  
TEMPERATURA E UMIDADE DE UMA ESTUFA BASEADO  
EM APRENDIZADO DE MÁQUINA**

**LUÍSA CASTELLO BRANCO DE SÁ**

**Belo Horizonte, 10 de julho de 2020**

Luísa Castello Branco de Sá

**DESENVOLVIMENTO DE UM MODELO DE PREDIÇÃO DE  
TEMPERATURA E UMIDADE DE UMA ESTUFA BASEADO  
EM APRENDIZADO DE MÁQUINA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Mestre em Engenharia Mecânica.

Orientador: Prof. Antônio Augusto Torres Maia

Belo Horizonte  
Escola de Engenharia da UFMG  
2020

S111d

Sá, Luísa Castello Branco de.

Desenvolvimento de um modelo de predição de temperatura e umidade de uma estufa baseado em aprendizado de máquina [recurso eletrônico] / Luísa Castello Branco de Sá. - 2020.

1 recurso online (103 f.: il.,color.) : pdf.

Orientador: Antônio Augusto Torres Maia.

Dissertação (mestrado) - Universidade Federal de Minas Gerais, Escola de Engenharia.

Apêndices: f. 99-103.

Bibliografia: f. 94-98.

Exigências do sistema: Adobe Acrobat Reader.

1. Engenharia mecânica - Teses. 2. Estufa (Plantas) – Teses.  
3. Redes Neurais (Computação) – Teses. I. Maia, Antônio Augusto Torres.  
II. Universidade Federal de Minas Gerais. Escola de Engenharia.  
III. Título.

CDU: 621(043)



18/08/2020 SEI/UFMG - 0178092 - Ata

UNIVERSIDADE FEDERAL DE MINAS GERAIS

ESCOLA DE ENGENHARIA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

**"DESENVOLVIMENTO DE UM MODELO DE PREDIÇÃO DE TEMPERATURA E UMIDADE DE UMA ESTUFA BASEADO EM APRENDIZADO DE MÁQUINA"**

**LUÍSA CASTELLO BRANCO DE SÁ**

Dissertação submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Minas Gerais, constituída pelos Professores: Dr. Antônio Augusto Torres Maia (Orientador-Departamento de Engenharia Mecânica-UFMG), Dr. Antônio de Pádua Braga (Departamento de Engenharia Eletrônica - UFMG) e Dr. Hugo Tanzarella Teixeira (Votoranm), como parte dos requisitos necessários à obtenção do título de "**Mestre em Engenharia Mecânica**", na área de concentração de "**Projeto e Sistemas**".

Dissertação aprovada no dia 10 de julho de 2020.

Por:



Documento assinado eletronicamente por **Antonio Augusto Torres Maia, Membro**, em 13/07/2020, às 11:38, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Antonio de Padua Braga, Membro**, em 29/07/2020, às 10:34, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Hugo Tanzarella Teixeira, Usuário Externo**, em 03/08/2020, às 16:40, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site

[https://sei.ufmg.br/sei/controlador\\_externo.php?](https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0)

[acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0178092** e o código CRC **E6F10534**.

Referência: Processo nº 23072.218351/2020-89 SEI nº 0178092

*Aos meus pais, irmãos e João Vitor.*

## AGRADECIMENTOS

*Agradeço aos meus pais, pelo carinho e apoio incondicionais, indispensáveis à conclusão deste trabalho.*

*Aos meus irmãos e familiares, por todo incentivo e apoio que sempre me deram.*

*Ao meu namorado, João Vitor, pelo amor e compreensão nos vários momentos em que estive ausente por estar focada nos estudos.*

*Ao Ricardo da BeGreen e à Carolina e ao Thiago da Hekima, por abraçarem esse projeto comigo.*

*Aos professores e colegas da UFMG, pelos ensinamentos e pelo convívio desde 2011.*

*Aos colegas do LAC, pelas experiências trocadas e colaborações.*

*Ao professor Antônio Maia, grande orientador, que não hesitou em explorar comigo uma nova área de conhecimento quando manifestei que era meu sonho.*

## RESUMO

A produção de alimentos dentro de estufas depende do controle do seu clima interno, de modo que as condições ambientais sejam propícias para o crescimento de vegetais. Nesse contexto, têm sido desenvolvidos modelos preditivos de temperatura e umidade para apoiar o desenvolvimento de estratégias mais robustas de controle climático, baseadas em controladores antecipatórios. Portanto, o objetivo deste trabalho foi o desenvolvimento de um modelo de predição climática para uma estufa localizada em Belo Horizonte que produz alfaces hidropônicas. Foi feita a aquisição de dados históricos de temperatura, umidade e luminosidade com três estações meteorológicas dentro da estufa e uma estação localizada no seu ambiente externo. Em seguida, foram avaliadas três técnicas de aprendizado de máquina para o desenvolvimento do modelo, uma delas baseada em uma máquina de vetores de regressão (SVR) e duas baseadas em redes neurais artificiais (MLP e LSTM). Foram realizadas buscas randômicas para determinar as melhores configurações de cada modelo, e o desempenho médio de cada um deles foi determinado com a realização de um *backtesting*. A rede neural MLP foi escolhida para o modelo final, apresentando maior estabilidade na fase de treinamento e erros RMSE (raiz do erro quadrático médio) e MAPE (erro absoluto médio percentual) inferiores aos obtidos com as outras técnicas. O modelo final passou novamente pelas etapas de busca randômica e *backtesting*, porém desta vez utilizando dados da estação meteorológica externa, que são adequados para o controle antecipatório. A rede MLP foi capaz de prever os padrões de temperatura e umidade internos da estufa satisfatoriamente, capturando com antecedência perturbações climáticas externas que posteriormente afetariam o seu estado interno. A continuação do registro climático da estufa com a estação meteorológica externa tende a aumentar o desempenho do modelo, contribuindo para o desenvolvimento da estratégia de controle antecipatório almejada.

**Palavras-Chave:** Estufa, Máquina de Vetores de Regressão, Perceptron Multicamadas, LSTM

## ABSTRACT

Greenhouses production depends on controlling its environmental conditions so that they are suitable for vegetable growth. In this context, greenhouses temperature and humidity forecast models have been developed to support the development of robust climate control strategies based on feed-forward control. Therefore, the present study aimed to develop a climate forecast model for a greenhouse located in Belo Horizonte, which produces hydroponic lettuce. The historical temperature, humidity and luminosity data were acquired with three meteorological stations inside the greenhouse and one located in its external environment. Then, three machine learning techniques were evaluated for the climate forecast model, one of them based on support vector regression (SVR) and two based on artificial neural networks (MLP and LSTM). Random searches were performed to determine the best configurations for each model, and their average performance was assessed through a backtesting approach. The MLP architecture was chosen for the final model, due to its higher stability during the training stage and to lower RMSE and MAPE scores compared to the other techniques. The final model went through a new random search and backtesting evaluation, but now being trained with data from the external meteorological station, which is suitable for feed-forward control. The MLP model was able to predict temperature and humidity patterns inside the greenhouse satisfactorily, capturing in advance climate disturbance that would later affect its internal state. Further tuning of the model with temperature and humidity data from subsequent periods may increase its prediction ability, contributing to the development of the aimed feed-forward control strategy.

**Keywords:** *Greenhouse, Support Vector Regressor, Multilayer Perceptron, LSTM*



## LISTA DE FIGURAS

Figura 2.1 - Esquema de um controlador em malha fechada clássico.....	22
Figura 2.2 - Esquema de um controlador em malha fechada combinado a um controlador antecipatório.....	22
Figura 2.3 - Transformação do plano de representação de uma função utilizando um modelo SVR.....	25
Figura 2.4 - Função de custo $\epsilon$ -insensível.....	25
Figura 2.5 - Modelo de um neurônio artificial.....	27
Figura 2.6 - Diferença entre as topologias de ANNs diretas e recorrentes.....	29
Figura 2.7 - Arquitetura de uma rede MLP.....	31
Figura 2.8 - Arquitetura das células de memória de uma rede LSTM.....	32
Figura 3.1 - Modelo 3D da estufa experimental.....	36
Figura 3.2 - Fotografia da estufa experimental.....	36
Figura 3.3 - Diagrama de blocos do sistema de controle da estufa.....	37
Figura 3.4 – Estação meteorológica da estufa experimental.....	39
Figura 3.5 - Série temporal de dados climáticos de uma estação meteorológica interna.....	40
Figura 3.6 - Série temporal de dados climáticos da estação meteorológica externa.....	41
Figura 3.7 - Série temporal de dados climáticos de uma estação meteorológica interna após extrapolação linear.....	42
Figura 3.8 - Exemplo de divisão dos dados em amostras de treinamento, validação e teste....	45
Figura 3.9 - Funções de ativação avaliadas na busca randômica.....	51
Figura 3.10 - Exemplo de divisão de dados na validação cruzada.....	53
Figura 3.11 - Exemplo de divisão dos dados no <i>backtesting</i> .....	54
Figura 3.12 - Exemplos de janelas de tempo do <i>backtesting</i> com 30 iterações.....	56
Figura 4.1 - Erros das amostras geradas na busca randômica do SVR.....	59
Figura 4.2 - Influência da variação isolada de cada hiperparâmetro do SVR nos erros de predição de temperatura.....	60

Figura 4.3 - Influência da variação isolada de cada hiperparâmetro do SVR nos erros de predição de umidade.....	60
Figura 4.4 - Erros das amostras geradas na busca randômica da rede MLP.....	61
Figura 4.5 - Erros das amostras geradas na busca randômica da rede LSTM.....	62
Figura 4.6 - Curva de aprendizado da rede MLP.....	63
Figura 4.7 - Curva de aprendizado da rede LSTM.....	63
Figura 4.8 - Influência da variação isolada de cada hiperparâmetro da rede MLP nos erros de predição de temperatura.....	65
Figura 4.9 - Influência da variação isolada de cada hiperparâmetro da rede MLP nos erros de predição de umidade.....	65
Figura 4.10 - Influência da variação isolada de cada hiperparâmetro da rede LSTM nos erros de predição de temperatura.....	67
Figura 4.11 - Influência da variação isolada de cada hiperparâmetro da rede LSTM nos erros de predição de umidade.....	67
Figura 4.12 - Erros de predição de temperatura nos dados de treinamento no horizonte de 5 minutos.....	68
Figura 4.13 - Erros de predição de temperatura nos dados de teste no horizonte de 5 minutos.....	69
Figura 4.14 - - Erros de predição de temperatura nos dados de teste no horizonte de 15 minutos.....	70
Figura 4.15 - Erros de predição de temperatura nos dados de teste no horizonte de 30 minutos.....	70
Figura 4.16 - Intervalos de confiança dos erros de predição no horizonte de 5 minutos.....	74
Figura 4.17 - Intervalos de confiança dos erros de predição no horizonte de 15 minutos.....	74
Figura 4.18 - Intervalos de confiança dos erros de predição no horizonte de 30 minutos.....	75
Figura 4.19 - Comparação entre os dados reais de temperatura e as predições da rede MLP..	76
Figura 4.20 - Comparação entre os dados reais de umidade e as predições da rede MLP.....	77
Figura 4.21 - Erros das amostras geradas na busca randômica da rede MLP treinada com dados externos.....	79
Figura 4.22 - Curva de aprendizado da rede MLP treinada com dados externos.....	80
Figura 4.23 - Influência da variação isolada de cada hiperparâmetro da rede MLP treinada com dados externos da estufa nos erros de predição de temperatura.....	81

Figura 4.24 - Influência da variação isolada de cada hiperparâmetro da rede MLP treinada com dados externos da estufa nos erros de predição de umidade.....	82
Figura 4.25 - Erros de predição de temperatura nos dados de teste no horizonte de 5 minutos.....	83
Figura 4.26 - Erros de predição de temperatura nos dados de teste no horizonte de 15 minutos.....	83
Figura 4.27 - Erros de predição de temperatura nos dados de teste no horizonte de 30 minutos.....	84
Figura 4.28 - Comparação entre os dados reais de temperatura e as predições da rede MLP treinada com dados externos da estufa.....	87
Figura 4.29 - Comparação entre os dados reais de umidade e as predições da rede MLP treinada com dados externos da estufa.....	88

## LISTA DE TABELAS

Tabela 3.1 - Bibliotecas <i>Python</i> utilizadas no desenvolvimento dos códigos.....	46
Tabela 3.2 - Avaliação de hiperparâmetros do modelo SVR.....	48
Tabela 3.3 - Avaliação de hiperparâmetros dos modelos baseados em redes neurais.....	52
Tabela 4.1 - Combinação de hiperparâmetros escolhida para o modelo SVR.....	59
Tabela 4.2 - Combinações de hiperparâmetros escolhidas para os modelos baseados em redes neurais.....	62
Tabela 4.3 - Erro médio de predição de temperatura nos dados de teste ao longo das janelas de tempo do <i>backtesting</i> .....	72
Tabela 4.4 - Erro médio de predição de umidade nos dados de teste ao longo das janelas de tempo do <i>backtesting</i> .....	72
Tabela 4.5 - Combinação de hiperparâmetros escolhida para o modelo MLP treinado com dados externos da estufa.....	80
Tabela 4.6 - Erro médio de predição de temperatura e umidade nos dados de teste ao longo das janelas de tempo do <i>backtesting</i> .....	85
Tabela 4.7 - Aumento percentual dos RMSEs médios com o crescimento do horizonte de predição.....	86

## LISTA DE ABREVIATURAS E SIGLAS

ANN. *Artificial Neural Networks*

CEA. *Controlled-Environment Agriculture*

CV. *Cross Validation*

GRU. *Gated Recurrent Unit*

H. Horizonte de predição

IC. Intervalo de Confiança

L. Luminosidade

LS-SVM. *Least-Squares Support Vector Machine*

LSTM. *Long Short-Term Memory*

MAPE. *Mean Absolute Percentage Error*

MIMO. *Multiple Input Multiple Output*

MLP. *Multilayer Perceptron*

MLR. *Multiple Linear Regression*

RBF. *Radial Basis Function*

ReLU. *Rectified Linear Unit*

RMSE. *Root Mean Squared Error*

RNN. *Recurrent Neural Networks*

T. Temperatura

U. Umidade

SVM. *Support Vector Machine*

SVR. *Support Vector Regression*

## NOMENCLATURAS

$\varepsilon$	Largura da função de custo $\varepsilon$ -insensível
$\xi$	Distância em relação à função de custo $\varepsilon$ -insensível
$L_{\varepsilon_n}$	Função de custo $\varepsilon$ -insensível
$d_n$	Valor real de uma amostra
$y_n$	Valor de saída do modelo
$w$	Vetor de pesos
$b$	Limiar da função
$C$	Fator de penalização do SVR
$\alpha_n$	Multiplicador de Lagrange
$K$	Função Kernel
$x_j$	Sinal de entrada de um neurônio
$y_i$	Sinal de saída de um neurônio
$w_{ij}$	Peso de um neurônio
$\varphi$	Função de ativação
$\sigma$	Função logística sigmoide
$i_t$	<i>Input gate</i>
$f_t$	<i>Forget gate</i>
$o_t$	<i>Output gate</i>
$c_t$	Estado da célula LSTM
$h_t$	Saída da célula LSTM
$\Delta w_{ij}$	Correção de pesos
$\eta$	Taxa de aprendizagem

$\delta_i$	Gradiente de correção
$x_n$	Amostra normalizada
$x_{max}$	Valor máximo presente na amostra de dados
$x_{min}$	Valor mínimo presente na amostra de dados
$r_{max}$	Limite superior da escala normalizada
$r_{min}$	Limite inferior da escala normalizada
$T_{int}$	Temperatura interna da estufa
$U_{int}$	Umidade interna da estufa
$\alpha$	Penalização da função L2
$\epsilon$	Amostra de erros
$\bar{\epsilon}$	Erro médio da amostra
$\tilde{\epsilon}$	Erro médio da população
$\alpha$	Grau de significância
$z$	Quantil associado ao coeficiente de confiança
$n$	Tamanho da amostra

# SUMÁRIO

RESUMO .....	7
LISTA DE FIGURAS .....	9
LISTA DE TABELAS .....	12
LISTA DE ABREVIATURAS E SIGLAS .....	13
SUMÁRIO .....	16
1 INTRODUÇÃO .....	19
2 REVISÃO BIBLIOGRÁFICA .....	21
2.1 Introdução .....	21
2.2 Estufas e Hidroponia .....	21
2.2.1 Influência de fatores ambientais na produção de estufas .....	22
2.2.2 Controle e automação de estufas baseados em modelos climáticos.....	23
2.3 Máquinas de Vetor de Suporte para Regressão .....	26
2.4 Redes Neurais Artificiais .....	28
2.4.1 Neurônio Artificial .....	28
2.4.2 Topologias de Redes Neurais .....	30
2.4.3 Perceptron Multicamadas (MLP) .....	31
2.4.4 LSTM .....	32
2.4.5 Aprendizagem de Redes Neurais .....	34
2.5 Conclusões Parciais .....	33
3 MATERIAIS E MÉTODOS .....	36
3.1 Introdução .....	36
3.2 Dados Experimentais .....	36
3.2.1 Estufa Experimental .....	36
3.2.2 Aquisição de Dados Meteorológicos da Estufa.....	39
3.2.3 Pré-Processamento dos Dados .....	42
3.2.4 Construção das amostras de dados para os modelos de predição .....	43
3.3 Estratégia de desenvolvimento e métricas avaliação de modelos .....	46



3.4	Tecnologias utilizadas no desenvolvimento dos modelos.....	47
3.5	Desenvolvimento dos modelos baseados em máquinas de vetores por regressão.....	48
3.5.1	Otimização de Hiperparâmetros.....	48
3.6	Desenvolvimento dos modelos baseados em redes neurais artificiais.....	50
3.6.1	Diferenças entre as arquiteturas LSTM e MLP.....	50
3.6.2	Otimização de Hiperparâmetros.....	51
3.7	Escolha do modelo a ser utilizado no desenvolvimento da estratégia de controle antecipatória.....	54
3.7.1	<i>Backtesting</i> .....	54
3.7.2	Construção de intervalos de confiança para comparação entre os modelos.....	57
3.8	Aplicação do modelo final aos dados de temperatura e umidade da estação meteorológica externa.....	58
4	RESULTADOS E DISCUSSÃO .....	60
4.1	Introdução.....	60
4.2	Otimização de hiperparâmetros .....	60
4.2.1	Modelo baseado em máquinas de vetores por regressão.....	60
4.2.2	Modelos baseados em redes neurais.....	63
4.3	Escolha do modelo a ser utilizado no desenvolvimento da estratégia de controle antecipatória.....	70
4.4	Aplicação do modelo final aos dados de temperatura e umidade da estação meteorológica externa.....	80
5	CONCLUSÕES .....	91
6	REFERÊNCIAS.....	94
7	APÊNDICE.....	99
A.	Dados de Temperatura, Luminosidade e Umidade dos Sensores.....	99
A.1	– Estação Meteorológica 2 .....	99
A.2	– Estação Meteorológica 3 .....	99
B.	Erro médio de predição ao longo das janelas de tempo do backtesting .....	101
B.1	– Erros de predição de temperatura dos modelos treinados com dados internos da estufa .....	101

B.2 – Erros de predição de umidade dos modelos treinados com dados internos da estufa  
..... 102

# 1 INTRODUÇÃO

A Fazenda Urbana BeGreen foi fundada em 2014 com o objetivo de ser parte da construção de uma sociedade mais sustentável, em que a maior parte da população tenha acesso a uma alimentação fresca e saudável. Localizada em Belo Horizonte, BeGreen é a primeira fazenda urbana da América Latina e produz alfaces hidropônicas em uma estufa de 1440 m<sup>2</sup>.

O crescimento das plantas é fortemente influenciado por fatores como temperatura, umidade e luminosidade dentro da estufa. Assim, variações nesses fatores para além dos valores ótimos para uma determinada espécie, no caso as alfaces, pode comprometer os processos internos de fotossíntese, respiração, transpiração e absorção.

A estufa da BeGreen apresenta um sistema de controle *on-off* para manutenção de condições climáticas adequadas ao plantio e que atua sobre seus sistemas de ventilação, painel evaporativo e cortina. A entrada desse sistema consiste em dados de temperatura, umidade e luminosidade coletados com estações meteorológicas instaladas na estufa. Nesse cenário, a combinação do controlador em malha fechada a uma estratégia de controle antecipatório seria uma estratégia efetiva para mitigação dos distúrbios ambientais a que o microclima complexo e dinâmico das estufas está sujeito. Isso porque controladores antecipatórios se baseiam em modelos precisos do ambiente a ser controlado e, medindo distúrbios climáticos previamente, conseguem antever seu efeito no sistema e direcionar a ação dos atuadores (Wang et al, 2009).

Diversas técnicas de modelagem vêm sendo aplicadas ao desafio de predição das condições climáticas de estufas como forma de apoiar o desenvolvimento de controladores antecipatórios. Esses modelos podem se basear em fatores como condições meteorológicas externas à estufa, balanço de energia ou capacidade térmica de componentes do seu ambiente como cobertura, ar, plantas e solo (Abdel-Ghani et al, 2011; Bot, 1991). Nesse contexto, técnicas de aprendizado de máquina, em especial máquinas de vetores de suporte (SVM) e redes neurais artificiais, vêm se destacando no desenvolvimento de modelos a partir de dados climáticos históricos. Máquinas de vetores de suporte são baseadas na teoria do aprendizado estatístico (Vapnik, 1998) e frequentemente utilizadas na resolução de problemas de classificação. Contudo, uma generalização do seu método, denominada máquinas de vetores de regressão (SVR), é adequada para a solução de questões como a modelagem climática de estufas. Já redes neurais artificiais são inspiradas no sistema nervoso e realizam o

processamento de informações em paralelo, apresentando alta capacidade de aprender relações lineares e não lineares de séries temporais (Dreyfus et al, 2004).

Assim, o objetivo deste trabalho foi o desenvolvimento de um modelo de predição de temperatura e umidade para a estufa da BeGreen que possa apoiar o posterior desenvolvimento de um controlador antecipatório para seus atuadores, de forma a garantir a manutenção de condições climáticas favoráveis ao crescimento das alfaces hidropônicas. Foram avaliadas três técnicas de aprendizado de máquina na construção desse modelo, uma baseada em máquinas de vetores de regressão e outras duas baseadas em redes neurais artificiais. As redes neurais utilizadas foram o perceptron multicamadas (MLP), que apresenta mais de uma camada de neurônios, e a rede LSTM, um tipo de arquitetura recorrente que promete uma maior capacidade de aprendizado de padrões históricos em um conjunto dos dados.

Além da introdução, este trabalho contém outros quatro capítulos. No segundo capítulo, que é a revisão bibliográfica, são apresentados detalhes sobre a influência climática no cultivo de plantas em estufas e conceitos relativos às técnicas de aprendizado de máquina aplicadas no desenvolvimento do modelo de predição. O terceiro capítulo é dedicado à descrição da estufa experimental, das técnicas de pré-processamentos de dados utilizadas e das estratégias de desenvolvimento do modelo. No quarto capítulo são apresentados os modelos criados a partir das três técnicas de aprendizado de máquina, a escolha do modelo final e os resultados obtidos nos testes realizados. Por fim, o quinto capítulo resume as principais conclusões obtidas ao longo do trabalho.

## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 Introdução

Neste capítulo será apresentada uma visão geral sobre a utilização de estufas e hidroponia no cultivo de plantas, bem como a influência de fatores ambientais desse microclima artificial no crescimento de vegetais. Serão abordados modelos climáticos de estufas presentes na literatura, e que foram desenvolvidos como base para controladores antecipatórios (controladores *feedforward*) que objetivam garantir a manutenção de condições ambientais favoráveis ao plantio. Por fim, serão apresentados conceitos relativos aos tipos de modelos de previsão temperatura e umidade desenvolvidos neste trabalho, que são baseados em máquinas de vetor de suporte para regressão e redes neurais diretas e recorrentes.

### 2.2 Estufas e Hidroponia

Estufas são ambientes fechados e envoltos por uma cobertura fina e transparente que têm o objetivo de oferecer condições apropriadas para o crescimento de plantas, protegendo-as contra o frio ou calor extremo (He et al, 2010; Wang et al, 2009). A estrutura das estufas é sustentada por vigas de aço ou alumínio e o revestimento mais tradicional é o vidro, mas fibra de vidro e filmes plásticos, como o polietileno e o polivinil, também são utilizados.

A hidroponia é frequentemente associada ao cultivo em estufas, e consiste em uma tecnologia para crescimento de plantas em uma solução com fertilizantes. Sistemas hidropônicos podem ser classificados como:


- agregados ou líquidos, em função da presença ou não de uma estrutura de suporte às raízes da planta;
- fechados ou abertos, em função de a solução nutritiva ser reciclada e reutilizada ou não.

Sistemas hidropônicos em estufas têm alto potencial produtivo, além de demandar menos água para o crescimento das plantas e menor capacitação dos agricultores do que o plantio

tradicional. Entretanto, para que sejam economicamente viáveis, dependem de tecnologias que regulem as condições climáticas internas da estufa e a composição da solução hidropônica de modo que o ambiente seja propício ao crescimento das plantas. Essa combinação de fatores produtivos é denominada Agricultura de Ambiente Controlado - *Controlled-Environment Agriculture* (CEA) (Jensen, 1997).

### 2.2.1 Influência de fatores ambientais na produção de estufas

O crescimento das plantas consiste na formação de tecidos e órgãos como folhas, caule, flores e raízes. Esse desenvolvimento se inicia com o processo de fotossíntese, em que a planta utiliza energia solar, CO<sub>2</sub> presente na atmosfera e água para sintetizar compostos orgânicos e oxigênio (Eq. 2.1). Os compostos orgânicos, como os carboidratos, são transportados pelos tecidos vegetais e servem de nutriente para o crescimento e manutenção da planta (Nelson, 2011).



Cada espécie de planta apresenta uma faixa de temperatura ótima para o seu crescimento, que influencia os processos internos de fotossíntese, respiração, transpiração e absorção (Mastalers, 1977). Quando a temperatura é menor que essa faixa, pode haver formação de gelo nos tecidos vegetais, comprometendo a circulação de água necessária aos processos biológicos da planta. Por outro lado, o aumento da temperatura para além da faixa ótima leva à inativação de enzimas responsáveis por esses processos (Nelson, 2011).

Quando a umidade do ambiente é baixa, a taxa de transpiração das plantas aumenta e sua umidade interna cai, prejudicando seus processos internos (Hodgson & Williams, 2002). Já ambientes com a umidade acima do ideal favorecem a proliferação de fungos e dificultam a transpiração. A consequência dessa baixa taxa de transpiração é diminuir a circulação de água com nutrientes das raízes para as extremidades da planta (Vu, 2011).

A presença de luz influencia a taxa de fotossíntese e o desenvolvimento dos órgãos internos das plantas. Quando o ambiente é muito sombreado, a taxa de fotossíntese é reduzida, prejudicando o crescimento do caule e das folhas. Além disso, a concentração de clorofila fica baixa e a planta apresenta uma coloração amarelada (Vu, 2011). Por outro lado, altos níveis de luminosidade podem colocar a planta em uma condição de estresse que diminui a capacidade fotossintética, em um fenômeno denominado fotoinibição (Barber & Bertil, 1992). Em casos de exposição prolongada, ocorre a destruição de pigmentos fotossintéticos (fotooxidação) que pode levar à morte celular e da planta (Araújo & Deminicis, 2009).

## 2.2.2 Controle e automação de estufas baseados em modelos climáticos

O microclima complexo e dinâmico das estufas é não linear e possui múltiplas entradas e múltiplas saídas (*Multiple Input Multiple Output* – MIMO). Como visto nos tópicos anteriores, sua dinâmica ao longo do tempo é fortemente influenciada pelas condições atmosféricas, como radiação global, temperatura e umidade relativa do ar externo e velocidade e direção do vento (He et al, 2010; Wang et al, 2009).

Sistemas de controle em malha fechada clássicos apresentam baixa capacidade de rejeição aos distúrbios ambientais a que as estufas estão sujeitas, e sua combinação com um controlador antecipatório representa uma alternativa mais robusta para esse cenário (Wang et al, 2009). As Figuras 2.1 e 2.2 ilustram a diferença fundamental entre as duas estratégias de controle mencionadas. Em um sistema de controle de malha fechada tradicional, o estado do sistema após sofrer a ação dos distúrbios externos é constantemente retroalimentado para que o controlador calcule a ação dos atuadores presentes. Já ao combinar o controlador de malha fechada ao controlador antecipatório, o efeito dos distúrbios é medido antes que o sistema tenha sido afetado. Assim, é possível direcionar a ação dos atuadores de forma a mitigar esse efeito previamente (Brosilow & Joseph, 2002).

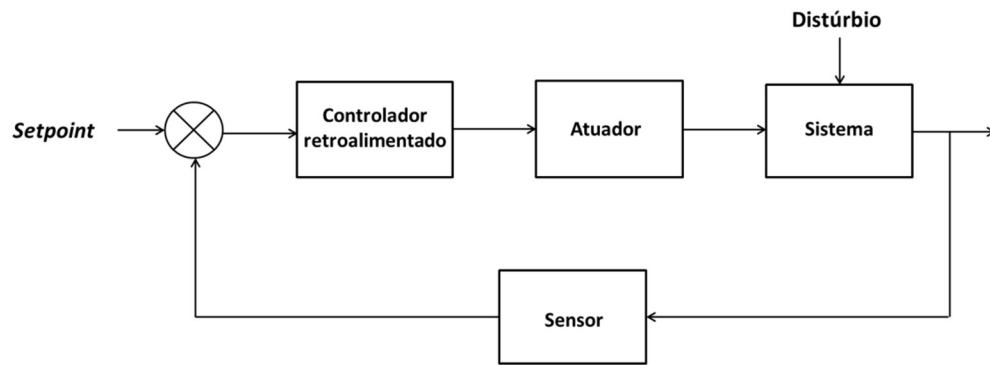


Figura 2.1: Esquema de um controlador em malha fechada clássico

Fonte: elaborado pela autora, 2019

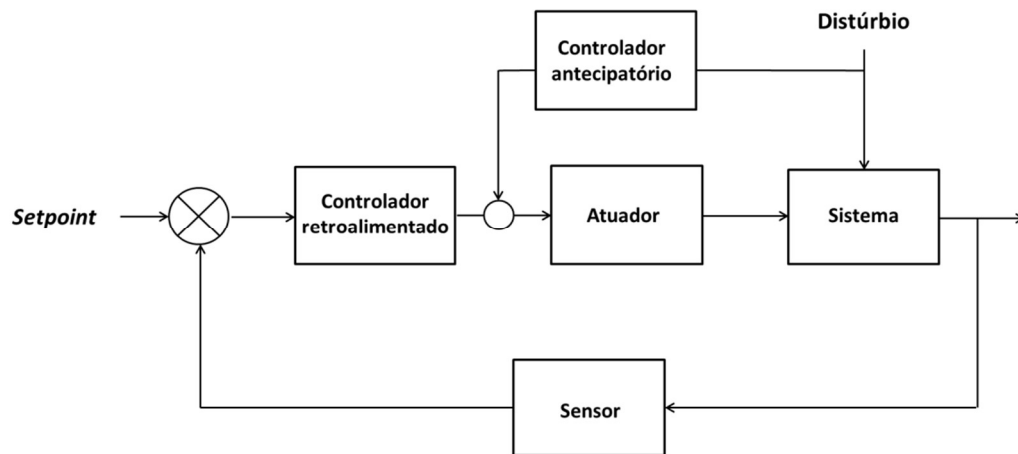


Figura 2.2: Esquema de um controlador em malha fechada combinado a um controlador antecipatório

Fonte: elaborado pela autora, 2019

Controladores antecipatórios são baseados em modelos precisos do ambiente a ser controlado, e diversas técnicas de modelagem têm sido aplicadas a esse desafio. Modelos térmicos estáticos e dinâmicos oferecem uma compreensão física do microclima das estufas. Eles são função de condições meteorológicas, do balanço de energia e da capacidade térmica de componentes do ambiente da estufa como sua cobertura, ar, plantas e solo (Abdel-Ghani et al, 2011; Bot, 1991). Modelos por função de transferência têm uma estrutura simples e já foram utilizados para descrever o comportamento de estufas, apesar de serem aplicáveis apenas a sistemas lineares (Nielsen & Madsen, 1995). Já modelos de caixa preta são baseados em dados



de entrada e de saída do sistema, e são apropriados para ambos os problemas lineares e não lineares (Dariouchy et al, 2009).

Máquinas de vetores de suporte (*Support Vector Machines* – SVMs) são baseadas na Teoria do Aprendizado Estatístico e no Princípio da Minimização do Risco Estrutural (Haykin, 2008). Modelos de predição de temperatura baseados em uma máquina de vetores de suporte por mínimos quadrados (*Least-Squares Support Vector Machine* - LS-SVM) e em uma máquina de vetores de regressão (*Support Vector Regression* – SVR) foram desenvolvidos em trabalhos anteriores (Wang et al, 2009; Yu et al, 2016).

Redes neurais artificiais (*Artificial Neural Networks* – ANNs) apresentaram um bom desempenho na predição dos parâmetros climáticos de estufas, uma vez que têm a habilidade de capturar relações lineares e não lineares de séries temporais (Dreyfus et al, 2004). Em um trabalho recente (Taki et al, 2016), foi feita uma comparação entre modelos de temperatura do ar e do teto de uma estufa baseados em um perceptron multicamadas (*Multilayer Perceptron* – MLP) e em uma regressão linear múltipla (*Multiple Linear Regression* – MLR). O modelo em MLP apresentou predições mais precisas, com valores menores de Raiz do Erro Quadrático Médio (*Root Mean Squared Error* - RMSE) e erro Absoluto Médio Percentual (*Mean Absolute Percentage Error* - MAPE). Outra pesquisa (He & Ma, 2010) concluiu que uma rede neural baseada no algoritmo *Back-Propagation* (Retropropagação) era capaz de prever a umidade relativa de uma estufa com maior acurácia do que um modelo de regressão. MLPs e outras arquiteturas de redes neurais diretas, como Redes Neurais de Base Radial (*Radial Basis Function Neural Networks* - RBFs), foram utilizadas em outros trabalhos de modelagem de estufas (Dariouchy et al, 2009; Ferreira et. al., 2002; Taki et al, 2018).

Poucos modelos climáticos de estufas foram baseados em Redes Neurais Recorrentes (*Recurrent Neural Networks* – RNNs). Um deles foi feito com uma rede neural *Elman*, um tipo de rede que armazena a saída da camada escondida da rede em uma camada adicional de contexto. Experimentos com essa rede neural *Elman* obtiveram resultados superiores do que com uma rede neural direta (Hongkang et al, 2018). Em uma outra aplicação, um modelo de temperatura e umidade utilizando uma rede neural *Elman* serviu de base para o desenvolvimento de um controlador neural para a manutenção do microclima interno de uma estufa (Fourati, 2014).

### 2.3 Máquinas de Vetor de Suporte para Regressão

Máquinas de vetores de suporte são um tipo de modelo de aprendizado de máquina baseado nos princípios da minimização do risco estrutural descritos na teoria do aprendizado estatístico. Segundo a teoria, o erro de generalização de um algoritmo de aprendizagem é função do seu erro de treinamento (risco empírico) e de uma medida da complexidade do seu espaço de funções denominada dimensão Vapnik e Chervonenkis (Semolini, 2002; Vapnik, 1998).

SVMs são frequentemente utilizadas na resolução de problemas de classificação, mas casos de regressão também podem ser abordados com uma generalização do método de SVM denominada máquina de vetores de regressão (*Support Vector Regression – SVR*). Nessa abordagem, o vetor de entrada  $\mathbf{X}$  é mapeado em um plano multidimensional utilizando um conjunto de equações não lineares  $\varphi(\mathbf{X})$  (Haykin, 2008), como ilustrado na Figura 2.3. Em ambos os gráficos, a linha contínua corresponde à curva de regressão e as linhas pontilhadas representam os vetores de suporte. O intervalo  $[-\varepsilon, \varepsilon]$ , para  $\varepsilon$  estipulado a priori, é denominado zona insensível e define a margem em que não há penalização de erros pela função de custo do SVR. Ou seja, qualquer amostra que se encontre fora da zona insensível será penalizada (Teixeira, 2016), como ocorre com as amostras em vermelho que se encontram a distâncias  $\xi$  e  $\xi'$  do intervalo.

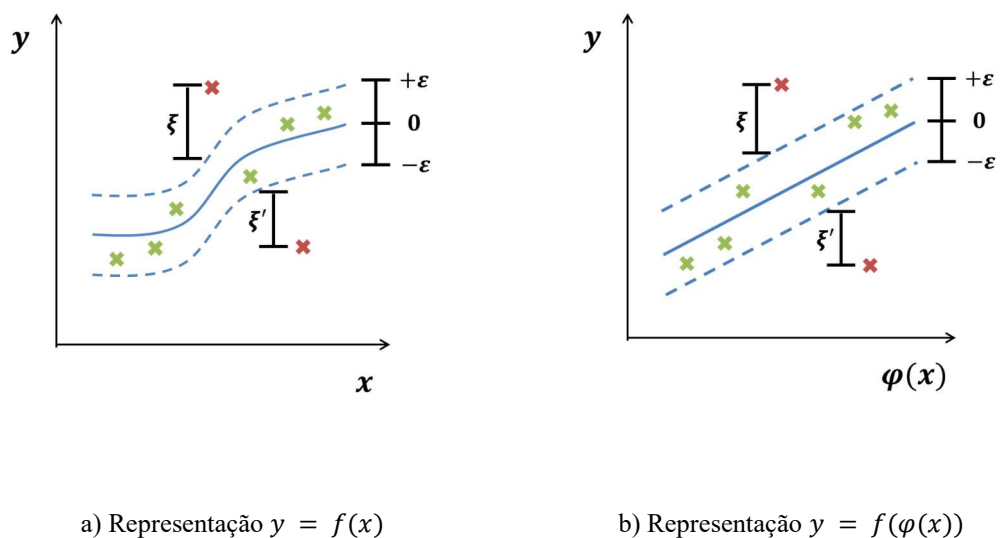


Figura 2.3: Transformação do plano de representação de uma função utilizando um modelo SVR

A função de custo do SVR, denominada função  $\varepsilon$ -insensível é descrita pela Eq 2.2, em que  $d_n$  é o valor esperado para a saída  $y_n$  da  $n$ -ésima amostra. A Figura 2.4 exemplifica a penalização sofrida pelas amostras que não se encontram dentro da zona  $\varepsilon$ -insensível.

$$L_{\varepsilon_n} = \max(0, |d_n - y_n| - \varepsilon) \quad (2.2)$$




Figura 2.4: Função de custo  $\varepsilon$ -insensível

Fonte: Elaborado pela autora, 2019

A regressão linear (Eq. 2.3) solução de um problema de SVR pode ser estimada a partir do problema de otimização apresentado por Vapnik (1998) na Eq. 2.4:

$$\mathbf{y} = \mathbf{w}^t \mathbf{x} + b \quad (2.3)$$

$$\text{Minimizar: } \frac{1}{2} \mathbf{w}^t \mathbf{w} + C \sum_{n=1}^N (\xi_n + \xi'_n) \quad (2.4)$$

$$\text{Sujeito a: } \bullet y_n - \mathbf{w}^t \mathbf{x}_n - b \leq \varepsilon + \xi_n$$

$$\bullet \mathbf{w}^t \mathbf{x}_n + b - y_n \leq \varepsilon + \xi'_n$$

$$\bullet \xi_n \xi'_n \geq 0$$

Em que  $\mathbf{w}$  representa o vetor de pesos, e  $b$  é o valor limiar da função e  $C$  é uma constante positiva que determina o compromisso entre o erro de treinamento e o termo de penalização  $\mathbf{w}^t \mathbf{w}$ .

O problema de otimização pode ser solucionado utilizando o método dos multiplicadores de Lagrange, que permite determinar o máximo e o mínimo local de uma função sujeita a uma restrição no formato de inequação. O passo-a-passo dessa solução se encontra em Haykin (2008), e resulta na formulação de  $\mathbf{w}$  exibida na Eq. 2.5:

$$\mathbf{w} = \sum_{n=1}^N (\alpha_n - \alpha'_n) \varphi(\mathbf{x}_n) \quad (2.5)$$

Em que  $\alpha_n$  e  $\alpha'_n$  são multiplicadores de Lagrange. Portanto,  $\mathbf{y}$  é dado pela Eq. 2.6:

$$\mathbf{y} = \sum_{n=1}^N (\alpha_n - \alpha'_n) (\varphi(\mathbf{x}_n), \varphi(\mathbf{x})) + b = \sum_{n=1}^N (\alpha_n - \alpha'_n) K(\mathbf{x}_n, \mathbf{x}) + b \quad (2.6)$$

Em que  $K$  é um *kernel* que pode assumir configurações diversas, como a de uma função polinomial, função base radial ou função sigmoideal.

## 2.4 Redes Neurais Artificiais

### 2.4.1 Neurônio Artificial

Redes neurais artificiais são inspiradas no sistema nervoso biológico e consistem em um algoritmo computacional que descreve diversos neurônios simples e conectados entre si. Esses neurônios realizam o processamento de informações em paralelo, em uma resposta dinâmica à sua conexão com entradas externas de dados (Dreyfus et al, 2004; Hsieh & Lu, 2008). Cada neurônio é uma unidade de processamento fundamental e composta pelos elementos apresentados na Figura 2.5:




Figura 2.5: Modelo de um neurônio artificial

Fonte: Elaborado pela autora, 2019

Esses elementos são:

- $x_j$  - Sinais de entrada do neurônio;
- $y_i$  - Sinal de saída do neurônio;
- $w_{ij}$  - Peso que multiplica o sinal de entrada da  $j^{\text{a}}$  sinapse do neurônio  $i$ . Esse peso sináptico pode assumir valores positivos ou negativos;
- $\sum w_{ij}x_j$  - Somador que combina linearmente os sinais de entrada, ponderando-os pelos seus respectivos pesos sinápticos;
- $b_i$  - Viés, que é um termo aplicado externamente para aumentar ou diminuir a entrada da função de ativação;
- $\varphi$  - Função de ativação que delimita a amplitude de saída do neurônio a um intervalo finito e normalizado, tipicamente  $[0,1]$  ou  $[-1,1]$ .

A função composta descrita pelas Eq. 2.7 e 2.9 resume em termos matemáticos o funcionamento do neurônio artificial descrito acima:

$$u_i = \sum_{j=1}^m x_j w_{ij} \quad (2.7)$$

$$y_i = \varphi(u_i + b_i) \quad (2.8)$$

## 2.4.2 Topologias de Redes Neurais

A topologia de uma rede neural diz respeito à forma como os neurônios e suas entradas e saídas se estruturam. As duas classes de arquitetura que se diferem fundamentalmente são a direta e a recorrente, como evidencia a Figura 2.6.

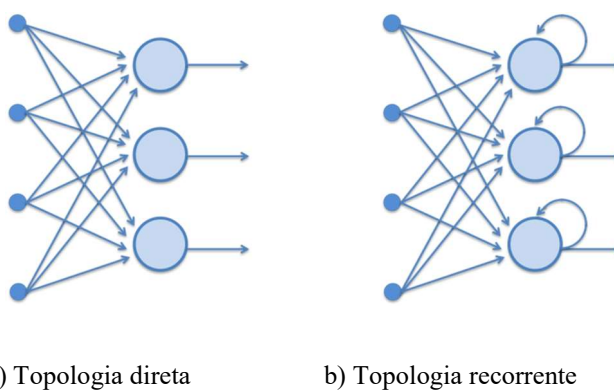


Figura 2.6: Diferença entre as topologias de ANNs diretas e recorrentes

Fonte: Elaborado pela autora, 2019

Em uma arquitetura direta, o sinal de entrada flui até a camada de saída de forma não cíclica. Já em uma arquitetura recorrente, ocorre ao menos um laço de realimentação (Haykin, 2008). Ou seja, a saída em um dado instante faz parte do conjunto de dados de entrada utilizados para calcular a saída do instante seguinte (Graves, 2014).

O perceptron multicamadas, as redes neurais de base radial, as redes neurais convolucionais e as redes neurais adversariais generativas estão dentre os tipos de arquitetura direta existentes. O perceptron multicamadas, como o próprio nome define, apresenta múltiplas camadas de neurônios interconectados e aplicação em problemas diversos de regressão e classificação. As redes neurais de base radial são caracterizadas pela utilização de uma função de base radial como ativação do neurônio da camada de saída, e também podem ser aplicadas amplamente (Taki et al, 2018). Já as redes neurais convolucionais são tipicamente utilizadas em problemas que envolvem imagens com seus neurônios que se conectam parcial e localmente aos pixels dos dados de entrada. Essa forma de conexão reduz o esforço computacional necessário e permite a extração de características locais dos dados, como a detecção das bordas existentes nas imagens (Lecun et al, 1998). Por fim, as redes adversariais generativas são

compostas por duas redes neurais com objetivos concorrentes. A rede generativa cria amostras de dados artificiais a partir dos dados de entrada, e a rede adversarial é responsável por avaliar se as amostras criadas provêm da distribuição dos dados originais ou da distribuição criada pelo modelo generativo. A competição entre as duas redes aumenta o desempenho de ambas, criando amostras artificiais indistinguíveis da realidade (Goodfellow et al, 2014).

As arquiteturas recorrentes são utilizadas principalmente em problemas envolvendo séries temporais e sequências de extensão variável, como texto e áudio, uma vez que sua componente de retroalimentação permite incorporar a dimensão temporal presente nesses tipos de dados (Medsker & Jain, 2000). Certas redes recorrentes, como a GRU (*Gated Recurrent Unit*) e a LSTM (*Long Short-Term Memory*), apresentam em seus neurônios pontos de decisão sobre o fluxo da informação denominados *gates*. Esses *gates*, organizados de maneira distinta na GRU e na LSTM, possibilitam melhor armazenamento e acesso à informação e auxiliam o aprendizado de dependências de longo prazo presentes nos dados (Dey & Salem, 2017; Greff et al, 2017).

Nenhum dos trabalhos avaliados na sessão 2.2.2. apresentou aplicações de redes neurais convolucionais ou redes neurais adversariais generativas à predição de séries temporais em estufas, devido à natureza e utilização preferencial dessas arquiteturas a outras classes de problemas. Dentre o perceptron multicamadas e as redes neurais de base radial, o perceptron multicamadas se mostrou promissor à predição do comportamento climático de estufas em uma maior quantidade de estudos (He & Ma, 2010; Taki et al, 2016; Taki et al, 2018), e sua arquitetura será apresentada em maiores detalhes na sessão 2.4.3. Sob uma ótica distinta, os trabalhos avaliados não abordaram a aplicação de redes LSTM a modelos preditivos em estufas, apesar de esse tipo de rede ter se tornado o estado da arte para uma variedade de problemas de aprendizado de máquinas. Assim, a arquitetura e implementação de redes LSTM será apresentada na sessão 2.4.4.

### 2.4.3 Perceptron Multicamadas (MLP)

O perceptron multicamadas consiste em uma rede neural direta com uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída, como pode ser observado na Figura 2.7. Os nós da camada de entrada transferem os sinais recebidos aos neurônios da segunda camada, que corresponde à primeira camada escondida. Os sinais de saída dessa segunda

camada servem de entrada para a camada subsequente, o que se repete até a camada de saída da rede.

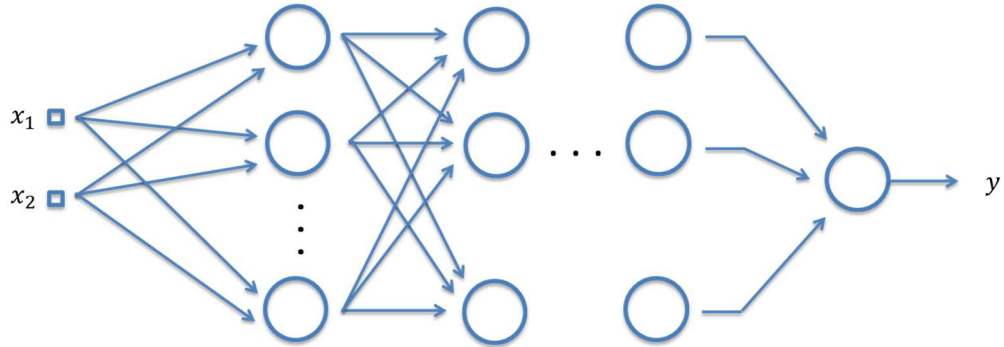


Figura 2.7: Arquitetura de uma rede MLP

Fonte: Elaborado pela autora, 2019

Os neurônios das camadas escondidas possibilitam a extração de padrões não lineares dos dados apresentados à rede, o que pode ser especialmente relevante no caso de a primeira camada apresentar um número expressivo de entradas (Haykin, 2008).

#### 2.4.4 Redes neurais LSTM

A Figura 2.8 ilustra a arquitetura das redes neurais LSTM. Seus neurônios são denominados células de memória, e apresentam um estado interno (*cell state*) que é transmitido ao longo dos intervalos de tempo. As células de memória também possuem três pontos de decisão sobre o fluxo da informação (*gates*). O *gate* de esquecimento (*forget gate*) determina quanto da informação proveniente da retroalimentação será eliminada, e o *gate* de entrada (*input gate*) calcula quanto da nova informação será incorporada. A atualização do *cell state* é dada em função do *forget gate* e do *input gate*. Por fim, o *gate* de saída (*output gate*) determina quanto da informação do estado atual da célula será transmitido à próxima iteração pela retroalimentação (Graves, 2014; Greff et al, 2017).






Figura 2.8: Arquitetura das células de memória de uma rede LSTM

Fonte: Elaborado pela autora, 2019

Pelo diagrama de arquitetura da figura 2.8, a relação entre a entrada e a saída de uma célula LSTM é dada pela seguinte função composta:

$$\sigma(\phi) = \frac{1}{1+e^{-\phi}} \quad (2.9)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2.10)$$

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (2.11)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (2.12)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (2.13)$$

$$h_t = o_t \tanh(c_t) \quad (2.14)$$

Em que  $\sigma$  é a função logística sigmoide,  $i_t$ ,  $f_t$ ,  $c_t$  e  $o_t$  são, respectivamente, o *input gate*, o *forget gate*, o estado da célula e o *output gate*,  $h_t$  é a saída da célula e  $W$  e  $b$  são, respectivamente, as matrizes de pesos e os vieses. Na Eq. 2.9,  $\phi$  representa os termos transformados pela função logística sigmoide nas Eq. 2.10, 2.11 e 2.13.

### 2.4.5 Aprendizagem de Redes Neurais

O algoritmo *Back-Propagation* é amplamente utilizado na determinação de modelos de sistemas não lineares complexos. O processo de treinamento e aprendizado de modelos acontece em duas etapas. A primeira é chamada *forward-propagation* (propagação para a frente), e é o fluxo dos dados pela camada de entrada, camada escondida e então camada de saída da rede neural. A segunda etapa é o *back-propagation* (retropropagação), em que é calculado o erro entre as saídas esperadas e obtidas pelo modelo (He & Ma, 2010). Esse erro é propagado da camada de saída em direção à camada de entrada da rede neural, atualizando os pesos entre os neurônios de acordo com a Equação 2.15:

$$\Delta w_{ij} = \eta \times \delta_i \times x_j \quad (2.15)$$

Em que  $\Delta w_{ij}$  é a correção de pesos aplicada,  $\eta$  é a taxa de aprendizagem do algoritmo,  $\delta_i$  é o gradiente que indica as modificações necessárias nos pesos sinápticos e  $x_j$  é o sinal de entrada do  $i$ -ésimo neurônio (Haykin, 2008). O processo de *forward* e *back-propagation* é repetido até que o erro seja reduzido a um valor inferior ao limite pré-estabelecido para o treinamento, ou até que o número máximo de épocas estabelecido seja atingido (He & Ma, 2010).

## 2.5 Conclusões Parciais

Este capítulo apresentou uma visão geral sobre a influência de fatores ambientais no crescimento de vegetais dentro de estufas, bem como a possibilidade da utilização de controladores antecipatórios na manutenção de condições climáticas propícias a esse crescimento. Uma vez que estratégias de controle antecipatório se baseiam em modelagens precisas das variáveis a ser controladas, foram apresentados tipos de modelos baseados em máquinas de vetor de suporte e redes neurais diretas e recorrentes aplicáveis ao problema em questão. As arquiteturas que se mostraram mais promissoras em função de sua utilização prévia na modelagem de estufas e da sua adequação à modelagem de séries temporais (máquina de vetores de suporte para regressão, perceptron multicamadas e redes LSTM) foram detalhadas.

Sua aplicação à predição de temperatura e umidade da estufa em estudo será apresentada neste trabalho.

## **3 MATERIAIS E MÉTODOS**

### **3.1 Introdução**

A fim de apoiar a criação de uma estratégia de controle antecipatório para manter as condições climáticas da estufa em estudo adequadas ao plantio, foram desenvolvidos modelos de predição temperatura e umidade do seu ambiente interno. Dessa forma, neste capítulo serão apresentadas a descrição da estufa experimental, a metodologia de pré-processamento da base de dados climáticos históricos da estufa e as estratégias de desenvolvimento e avaliação de modelos baseados em SVR, MLP e LSTM.

### **3.2 Dados Experimentais**

#### **3.2.1 Estufa Experimental**

As Figuras 3.1 e 3.2 apresentam a estufa experimental utilizada neste trabalho, que fica localizada na BeGreen Fazendas Urbanas, em Belo Horizonte – Brasil. A estufa produz alfaces hidropônicas e tem uma área construída de 1440 m<sup>2</sup>. Sua temperatura, umidade relativa e luminosidade são reguladas pelos seguintes atuadores:

- 12 exaustores de 1CV fixados em uma das paredes da estufa;
- painel evaporativo de celulose, localizado na parede oposta à em que estão os exaustores;
- cortinas rentes ao teto da estufa.




Figura 3.1 – Modelo 3D da estufa experimental

Fonte: Elaborado pela autora, 2019



Figura 3.2 – Fotografia da estufa experimental

Fonte: Elaborado pela autora, 2018

Esses atuadores são acionados por leis de controle *on-off*, cujas entradas são dados de temperatura, umidade relativa e luminosidade coletados em tempo real por estações meteorológicas dentro da estufa e que serão detalhados na seção 3.2.2. A Figura 3.3 mostra o diagrama de blocos desse sistema de controle e automação, e os algoritmos de controle são

apresentados na sequência. O procedimento de ventilação é função da medição de temperatura (em °C), e o procedimento de umidificação leva em conta também a umidade relativa do ambiente (em %). O procedimento de iluminação leva em conta a temperatura e também a intensidade luminosa (em bits) registrada por um foto-resistor em uma faixa entre 0 e 1023 bits.

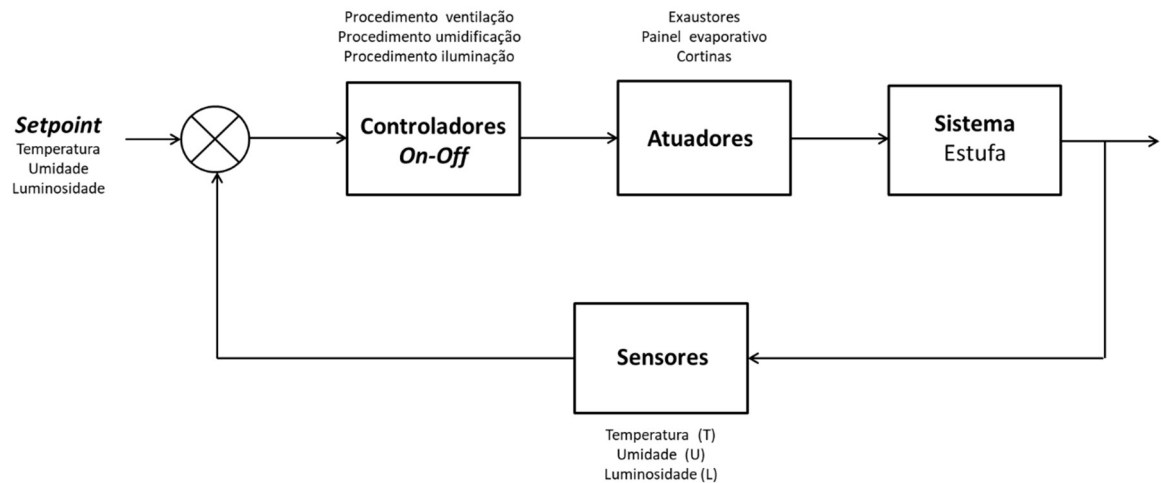


Figura 3.3 – Diagrama de blocos do sistema de controle da estufa

Fonte: Elaborado pela autora, 2019

---

### Algoritmo 1 Ventilação

---

- 1: **procedimento** Ventilação ( $T$ )
- 2:     leitura de dados dos sensores
- 3:     **se** ( $T$  entre  $26^{\circ}\text{C}$  e  $27,5^{\circ}\text{C}$  ou  $T$  maior que  $29^{\circ}\text{C}$ )
- 4:         ligar 4 exaustores superiores
- 5:     **senão**
- 6:         desligar 4 exaustores superiores
- 7:     **se** ( $T$  maior que  $27,5^{\circ}\text{C}$ )
- 8:         ligar 8 exaustores inferiores
- 9:     **senão**
- 10:        desligar 8 exaustores inferiores

---

**Algoritmo 2** Umidificação

---

- 1: **procedimento** Umidificação ( $T, U$ )
- 2:     leitura de dados dos sensores
- 3:     **se** ( $U$  menor que 20% ou  $T$  maior que 27,5°C)
- 4:         ligar painel evaporativo
- 5:     **se** ( $U$  maior que 75%)
- 6:     desligar painel evaporativo

---


**Algoritmo 3** Iluminação

---

- 1: **procedimento** Iluminação ( $T, L$ )
- 2:     leitura de dados dos sensores
- 3:     **se** ( $T$  entre 18°C e 27,5°C e  $L$  menor que 750 bits)
- 4:         abrir cortina
- 5:     **se** ( $T$  maior que 29°C ou  $L$  maior que 880 bits)
- 6:     fechar cortina

### 3.2.2 Aquisição de Dados Meteorológicos da Estufa

Foram coletados dados climáticos de três estações meteorológicas que ficam dentro da estufa, e que atualmente servem de base para o acionamento dos atuadores, e de uma estação meteorológica adicional localizada na sua área externa. Cada estação meteorológica é composta por um sensor BME280, que realiza medições de temperatura e umidade, um foto-resistor para detecção da intensidade luminosa e um microcontrolador ESP8266 para envio dos dados meteorológicos para o computador central da estufa utilizando o formato JSON (JavaScript Object Notation). A Figura 3.4 apresenta os componentes de uma estação.



a) Suporte da estação      b) sensor BME280 e fotorresistor      c) Microcontrolador ESP8266

Figura 3.4 – Estação meteorológica da estufa experimental

Fonte: Elaborado pela autora, 2018


Os sensores BME280 operam em uma faixa de temperatura de  $-40^{\circ}\text{C}$  a  $85^{\circ}\text{C}$  e em uma faixa de umidade relativa de 0% a 100%. Sua precisão de temperatura na faixa entre  $0^{\circ}\text{C}$  e  $65^{\circ}\text{C}$  é de  $\pm 1,0^{\circ}\text{C}$ , e a precisão de umidade na faixa entre 20% e 80% a  $25^{\circ}\text{C}$  é de  $\pm 3\%$ . As resoluções das leituras de temperatura e umidade dos sensores são respectivamente  $0,01^{\circ}\text{C}$  e  $0,008\%$ . Como mencionado anteriormente, a resistência do foto-resistor é convertida para uma faixa entre 0 e 1023 bits, e a intensidade luminosa é registrada com uma resolução de 10 bits.

A base de dados das estações meteorológicas dentro da estufa consiste em 158 dias de leituras, entre novembro de 2018 e abril de 2019, e a da estação externa consiste em 56 dias, de março a abril de 2019. A diferença entre os tamanhos das bases se deve à instalação posterior da estação meteorológica externa.


Os dados foram adquiridos a uma taxa de aproximadamente 1 minuto e reamostrados a uma taxa de 5 minutos. Foram consideradas apenas as medições entre 8:00 e 18:00, uma vez que o microclima da estufa sofre pouca alteração durante a noite e não é necessária uma melhoria na sua estratégia de controle nesse período. Devido a problemas de conexão de internet na estufa, houve períodos de interrupção na aquisição de dados. Isso pode ser observado




na Figura 3.5, que apresenta como exemplo as leituras de temperatura, umidade e luminosidade de uma das estações meteorológicas internas, e na Figura 3.6, com as leituras da estação externa. Outro comportamento dos dados coletados foi a frequente saturação das leituras de intensidade luminosa em 1023 bits, como mostram os gráficos de luminosidade de ambas as Figuras 3.5 e 3.6. Os dados provenientes das outras estações meteorológicas se encontram no Apêndice A.



a) Dados de temperatura




b) Dados de umidade




c) Dados de luminosidade

Figura 3.5: Série temporal de dados climáticos de uma estação meteorológica interna


Fonte: Elaborado pela autora, 2019



a) Dados de temperatura



b) Dados de umidade




c) Dados de luminosidade

Figura 3.6: Série temporal de dados climáticos da estação meteorológica externa


Fonte: Elaborado pela autora, 2019

### 3.2.3 Pré-Processamento dos Dados


Pontos de dados faltantes foram estimados por extrapolação linear. Essa abordagem considera apenas medições passadas na estimativa dos dados faltantes, uma vez que a interpolação com medições futuras não seria apropriada para um modelo de previsão. A título de exemplificação, a série resultante da estação meteorológica interna da Figura 3.5 é apresentada na Figura 3.7



a) Dados de temperatura



b) Dados de umidade



c) Dados de luminosidade

Figura 3.7: Série temporal de dados climáticos de uma estação meteorológica interna após extrapolação linear

Fonte: Elaborado pela autora, 2019

Os dados foram normalizados em escalas de valores reduzidas, uma vez que variáveis com dimensões em proporções distintas reduziriam a habilidade dos modelos de fazer previsões coerentes de temperatura e umidade relativa. Essa transformação foi realizada utilizando a Eq. 3.1:

$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} \times (r_{max} - r_{min}) + r_{min} \quad (3.1)$$

Em que  $x_n$  corresponde às amostras normalizadas,  $x$  corresponde às amostras originais,  $x_{max}$  e  $x_{min}$  são os valores máximo e mínimo da variável em questão e  $r_{max}$  e  $r_{min}$  são os limites máximo e mínimo da nova escala. A escala adotada foi [0,1], exceto para o caso das redes neurais com a função de ativação tangente hiperbólica, que, como será apresentado na sessão 3.7.2, apresenta uma faixa de atuação entre [-1,1].

### 3.2.4 Construção das amostras de dados para os modelos de predição

Os valores de temperatura e umidade dentro da estufa que foram utilizados como entrada do controlador *on-off* em um dado instante  $t$  são médias aritméticas entre as leituras dos sensores de cada estação meteorológica, como mostram as Eq. 3.2 e 3.3:

$$T_{int} = \frac{T_{int_1} + T_{int_2} + T_{int_3}}{3} \quad (3.2)$$

$$U_{int} = \frac{U_{int_1} + U_{int_2} + U_{int_3}}{3} \quad (3.3)$$

Em que  $T_{int}$  e  $U_{int}$  são as médias aritméticas de temperatura e umidade em um dado instante, respectivamente, e  $T_{int_1}$  e  $U_{int_1}$ ,  $T_{int_2}$  e  $U_{int_2}$  e  $T_{int_3}$  e  $U_{int_3}$  são as respectivas leituras de temperatura e umidade das estações meteorológicas internas 1, 2 e 3.

Foram utilizados 120 minutos de observações dos parâmetros temperatura, umidade e luminosidade como *input* para os modelos de temperatura e umidade interna da estufa. Foram avaliadas as capacidades de previsão 5, 15 e 30 minutos à frente do instante definido como  $t = 0$ , uma vez que é necessário determinar as constantes de tempo de temperatura e umidade da estufa para definir o horizonte mais apropriado para o modelo do controlador antecipatório. Segundo (Janius & Jenkins, 2004), a constante de tempo das estufas é bastante sensível ao coeficiente de transferência de calor entre as massas de ar externas e o ar interno. A título de exemplificação, o experimento de (Nielsen & Madsen, 1995) encontrou uma constante de tempo de temperatura entre 30 a 40 minutos considerando a influência da radiação solar no microclima interno.

As Eq. 3.4, 3.5 e 3.6 apresentam o formato de uma amostra de cada um dos horizontes de previsão avaliados:

$$[T_{int_{t+5}}, U_{int_{t+5}}] = f \begin{pmatrix} T_t, U_t, L_t, \\ T_{t-5}, U_{t-5}, L_{t-5}, \\ \vdots \\ T_{t-115}, U_{t-115}, L_{t-115}, \\ T_{t-120}, U_{t-120}, L_{t-120} \end{pmatrix} \quad (3.4)$$

$$\begin{bmatrix} T_{int_{t+5}}, U_{int_{t+5}} \\ T_{int_{t+10}}, U_{int_{t+10}} \\ T_{int_{t+15}}, U_{int_{t+15}} \end{bmatrix} = f \begin{pmatrix} T_t, U_t, L_t, \\ T_{t-5}, U_{t-5}, L_{t-5}, \\ \vdots \\ T_{t-115}, U_{t-115}, L_{t-115}, \\ T_{t-120}, U_{t-120}, L_{t-120} \end{pmatrix} \quad (3.5)$$

$$\begin{bmatrix} T_{int_{t+5}}, U_{int_{t+5}} \\ T_{int_{t+10}}, U_{int_{t+10}} \\ T_{int_{t+15}}, U_{int_{t+15}} \\ T_{int_{t+20}}, U_{int_{t+20}} \\ T_{int_{t+25}}, U_{int_{t+25}} \\ T_{int_{t+30}}, U_{int_{t+30}} \end{bmatrix} = f \begin{pmatrix} T_t, U_t, L_t, \\ T_{t-5}, U_{t-5}, L_{t-5}, \\ \vdots \\ T_{t-11}, U_{t-11}, L_{t-11}, \\ T_{t-120}, U_{t-120}, L_{t-120} \end{pmatrix} \quad (3.6)$$

Em que  $T = [T_{int_1}, T_{int_2}, T_{int_3}]$ ,  $U = [U_{int_1}, U_{int_2}, U_{int_3}]$  e  $L = [L_{int_1}, L_{int_2}, L_{int_3}]$  são as leituras de temperatura, umidade e luminosidade das três estações meteorológicas internas. De forma análoga, fazendo  $T = T_{ext}$ ,  $U = U_{ext}$  e  $L = L_{ext}$ , tem-se as leituras de temperatura, umidade e luminosidade da estação meteorológica externa. Como mostram as equações anteriores, os vetores de dados de entrada e de saída dos modelos apresentam as dimensões  $[amostras, observações]$  e  $[amostras, predições]$ , respectivamente.

As amostras de dados meteorológicos foram divididas em conjuntos de treinamento, validação e teste. A Figura 3.8 exemplifica como pode ser feita essa divisão, em que 60% dos dados são direcionados para treinamento, 20% para validação e 20% para teste. Os modelos se ajustam aos dados de treinamento. O conjunto de validação oferece uma avaliação não enviesada do desempenho do modelo enquanto seus hiperparâmetros ainda estão sendo sintonizados, e são denominados hiperparâmetros os parâmetros pré-configurados pelo usuário e que controlam o processo de treinamento. Por fim, o conjunto de teste é utilizado para a avaliação do modelo final.




Figura 3.8: Exemplo de divisão dos dados em amostras de treinamento, validação e teste

Fonte: Elaborado pela autora, 2019

### 3.3 Estratégia de desenvolvimento e métricas avaliação de modelos

Foi avaliado o potencial de modelos baseados em SVR, MLP e LSTM para o desenvolvimento de uma estratégia de controle antecipatória para o microclima da estufa em um futuro trabalho. Os dados de temperatura, umidade e luminosidade provenientes da estação meteorológica externa à estufa podem efetivamente ser utilizados na construção desse modelo, uma vez que consistem em distúrbios atuando sobre o sistema interno.

Em função do tamanho reduzido da base de dados da estação meteorológica externa, a escolha do modelo mais adequado aos padrões diários de temperatura e umidade na localidade da estufa foi baseada nos dados das estações internas. Na sequência, o modelo que apresentou uma maior assertividade foi aplicado aos dados externos.

As métricas de erro definidas na literatura e utilizadas nesse trabalho foram a Raiz do Erro Quadrático Médio (RMSE), que tem a unidade de medida da variável sendo estimada, e o Erro Percentual Médio Absoluto (MAPE). RMSE e MAPE são expressos, respectivamente, pelas Eq. 3.7 e 3.8:

$$RMSE = \sqrt{\frac{\sum_{n=1}^N (d_n - y_n)^2}{N}} \quad (3.7)$$

$$MAPE = \frac{1}{N} \sum_{n=1}^N \frac{|d_n - y_n|}{d_n} \quad (3.8)$$

Em que  $n$  é o número de amostras de dados,  $d_n$  é o valor real de uma amostra e  $y_n$  é a previsão de  $d_n$  feita pelo modelo.

### 3.4 Tecnologias utilizadas no desenvolvimento dos modelos

Os modelos de predição de temperatura e umidade foram escritos em linguagem *Python*, uma linguagem de código aberto, de alto nível e orientada a objeto. Essa linguagem apresenta uma sintaxe simples e dispensa a etapa de compilação, aumentando a produtividade do desenvolvimento. A linguagem também aceita módulos e pacotes externos, o que vem incentivando o desenvolvimento de bibliotecas de funções especializadas pela comunidade de programadores *Python* (Python, 201-).

A Tabela 3.1 apresenta as bibliotecas *Python* utilizadas no pré-processamento dos dados, na construção dos modelos baseados em SVR, MLP e LSTM e na avaliação de desempenho de predição de temperatura e umidade dentro da estufa. O modelo SVR foi construído com a biblioteca *Scikit-Learn*, e as redes neurais MLP e LSTM, com a API *Keras*.

Tabela 3.1: Bibliotecas *Python* utilizadas no desenvolvimento dos códigos  
Fontes: Keras, 201-; Matplotlib, 201-; Numpy, 201-; Pandas, 201-; Scikit-Learn, 201-

Biblioteca	Funcionalidade
<i>Numpy</i>	Apresenta funções para manipulação de matrizes multidimensionais ( <i>arrays</i> ) e cálculo matricial.
<i>Pandas</i>	Apresenta estrutura de dado com eixos indexados denominada <i>DataFrame</i> , além de funções para manipulação e análise de dados.
<i>Matplotlib</i>	É uma biblioteca de visualização de dados que permite gerar gráficos diversos, como histogramas, gráficos de dispersão e gráficos 3D, a partir de dados em <i>arrays</i> .
<i>Scikit-Learn</i>	É uma biblioteca de aprendizado de máquina com ferramentas de mineração e análise de dados. Apresenta algoritmos de pré-processamento de dados, classificação, regressão e <i>clusterização</i> , além de métricas de avaliação de desempenho de modelos.
<i>Keras</i>	É uma API de redes neurais que permite que o usuário personalize o modelo variando o número de camadas de neurônios e o tipo dessas camadas (como diretas, recorrentes ou convolucionais).

### 3.5 Desenvolvimento dos modelos baseados em máquinas de vetores por regressão

#### 3.5.1 Otimização de Hiperparâmetros

O desempenho dos modelos de SVR depende fortemente da escolha dos hiperparâmetros, e assim como em Smets et al. (2007), foi feita uma avaliação para determinar a combinação ótima para a predição de temperatura e umidade da estufa em estudo. Os seguintes hiperparâmetros foram avaliados na construção dos modelos:

- Largura  $\epsilon$  da zona insensível

A largura  $\epsilon$  influencia o número de vetores de suporte utilizados na construção da função de regressão. Quanto menor  $\epsilon$ , maior o número de vetores de suporte e maior a complexidade do modelo final (Smets et al, 2007).

- Fator  $C$  de penalização

O fator  $C$  também atua na complexidade do SVR. Quando  $C$  assume valores altos, o risco empírico passa a ser o objetivo principal da otimização do modelo, levando a uma maior capacidade de generalização em detrimento de uma menor complexidade (Lahiri & Ghanta, 2008).

- Tipo de função *kernel*

A função *kernel* é responsável pelo mapeamento dos dados de entrada do SVR em um plano com um maior número de dimensões, e neste trabalho foram avaliados um *kernel* polinomial e um *kernel* de base radial. O *kernel* polinomial (Eq. 3.9) é do tipo global, ou seja, é eficiente na extração de características globais das amostras de treinamento. O *kernel* RBF (Eq. 3.10) é do tipo local, e apesar de uma menor capacidade de generalização que um *kernel* global, é superior no aprendizado de especificidades do conjunto de dados, sendo o mais utilizado atualmente (Wang & Xu, 2017).



$$k(x_n, x) = (x_n \cdot x + 1)^3 \quad (3.9)$$

$$k(x_n, x) = \exp\left(-\frac{1}{p \cdot s} \|x_n - x\|^2\right) \quad (3.10)$$

$p$  e  $s$  correspondem, respectivamente, ao número de parâmetros e ao desvio padrão da amostra de dados.

Foi feita uma busca randômica (*randomized search*) para encontrar a combinação ótima entre os hiperparâmetros apresentados. Nessa busca, resumida na Tabela 3.2, os hiperparâmetros numéricos foram variados em uma faixa de valores pré-determinada, assim como sua associação com os diferentes tipos de *kernel* foi testada. O modelo de SVR foi treinado com 100 combinações aleatórias dos hiperparâmetros, e foi escolhida a configuração que obteve os menores erros de treinamento e validação no horizonte de predição de temperatura e umidade de 5 minutos (Eq. 3.4). Para que o tempo de busca não fosse demasiadamente extenso, foram utilizadas aproximadamente 60% das amostras de dados disponíveis.

Tabela 3.2: Avaliação de hiperparâmetros do modelo SVR

Hiperparâmetro	Valores
Largura $\epsilon$ da zona insensível	$10^{-5}, 10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 1, 2, 4, 8$
Fator $C$ de penalização	$2^{-5}, 2^{-4}, 2^{-3}, 2^{-2}, 2^{-1}, 2^0, 2, 2^2, 2^3, 2^4, 2^5$
Tipo de função <i>kernel</i>	RBF, polinomial

### 3.6 Desenvolvimento dos modelos baseados em redes neurais artificiais

#### 3.6.1 Diferenças entre as arquiteturas LSTM e MLP

A camada de entrada da rede MLP consiste em um vetor bidimensional de dados meteorológicos históricos da estufa com as dimensões [*amostras, observações*]. Cada amostra é composta pelos 120 minutos anteriores de observações dos parâmetros temperatura, umidade e luminosidade, como mostram as Eq. 3.4, 3.5 e 3.6.

O vetor de entrada da rede LSTM apresenta uma dimensão adicional que separa os intervalos de tempo em que os parâmetros foram observados (*[amostras, intervalos de tempo, parâmetros]*), e cada intervalo de tempo corresponde à taxa de amostragem de 5 minutos. Portanto, as amostras correspondem às Eq. 3.11, 3.12 e 3.13:

$$[(T_{int}, U_{int})_{t+5}] = f \begin{pmatrix} (T, U, L)_t, \\ (T, U, L)_{t-5}, \\ \vdots \\ (T, U, L)_{t-115}, \\ (T, U, L)_{t-120} \end{pmatrix} \quad (3.11)$$

$$\begin{bmatrix} (T_{int}, U_{int})_{t+5}, \\ (T_{int}, U_{int})_{t+10}, \\ (T_{int}, U_{int})_{t+15} \end{bmatrix} = f \begin{pmatrix} (T, U, L)_t, \\ (T, U, L)_{t-5}, \\ \vdots \\ (T, U, L)_{t-115}, \\ (T, U, L)_{t-120} \end{pmatrix} \quad (3.12)$$

$$\begin{bmatrix} (T_{int}, U_{int})_{t+5}, \\ (T_{int}, U_{int})_{t+10}, \\ (T_{int}, U_{int})_{t+15}, \\ (T_{int}, U_{int})_{t+20}, \\ (T_{int}, U_{int})_{t+25}, \\ (T_{int}, U_{int})_{t+30} \end{bmatrix} = f \begin{pmatrix} (T, U, L)_t, \\ (T, U, L)_{t-5}, \\ \vdots \\ (T, U, L)_{t-1}, \\ (T, U, L)_{t-120} \end{pmatrix} \quad (3.13)$$

O número de camadas escondidas e outros hiperparâmetros das redes neurais foram definidos via busca randômica, o que é detalhado na sessão 3.6.2. Essas camadas se diferem entre as redes MLP e LSTM, conferindo os caracteres direto e recorrente dessas respectivas arquiteturas. Por fim, a camada de saída é uma camada direta com uma função de ativação linear para ambas as redes neurais, e entrega em um vetor bidimensional [*amostras, previsões*] os valores previstos de temperatura e umidade.

### 3.6.2 Otimização de Hiperparâmetros

Assim como ocorre com os SVRs, diversos hiperparâmetros influenciam o desempenho de um modelo de redes neurais. Isso torna necessário encontrar a combinação entre eles que apresenta o melhor compromisso entre erros de treinamento e capacidade de generalização nos conjuntos de validação e teste, como postulado no Dilema de Viés-Variância (Geman, 1992). Os seguintes hiperparâmetros foram avaliados na construção dos modelos:

- Número de neurônios e de camadas escondidas

O número de neurônios e o número de camadas escondidas estão relacionados à complexidade do modelo. Quando em baixa quantidade, podem levar a um sub-aprendizado (*underfitting*), em que o modelo não é capaz de capturar padrões e relações no conjunto de dados. Já uma grande quantidade de neurônios e camadas escondidas pode levar ao fenômeno de *overfitting*, além de tornar o aprendizado demasiadamente lento (Panchal, 2011).

- Tipo de função de ativação na(s) camada(s) escondida(s)

Foram testadas as funções de ativação Tangente Hiperbólica e Unidade Linear Retificada (*Rectified Linear Unit* – ReLU), apresentadas na Figura 3.9.

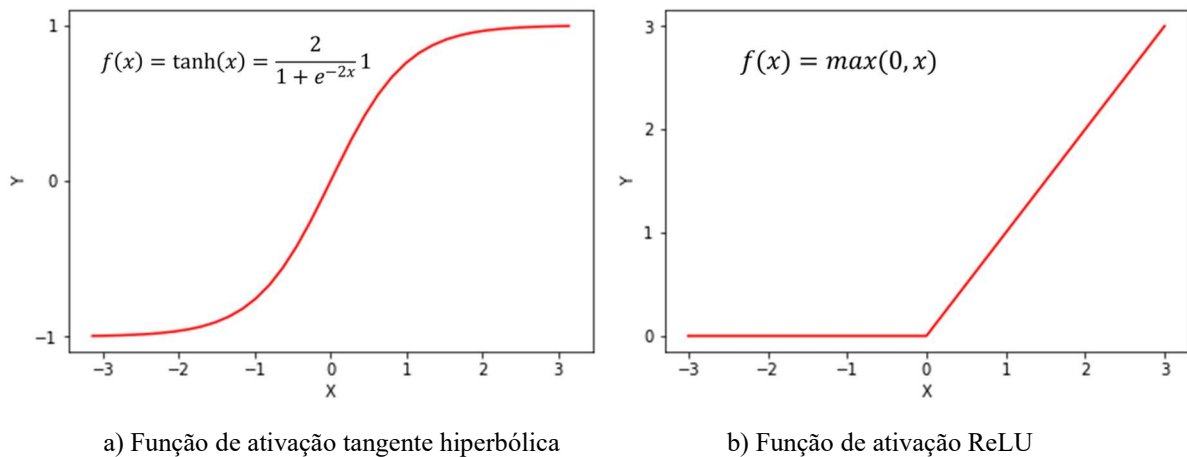


Figura 3.9. Funções de ativação avaliadas na busca randômica

Fonte: Elaborado pela autora, 2019

A função de ativação tangente hiperbólica costuma apresentar um desempenho superior ao da tradicionalmente utilizada função sigmoide. Entretanto, assim como a sigmoide, a tangente hiperbólica frequentemente incorre em saturação, em que as saídas de altos valores de  $x$  tendem a 1 e de baixos valores tendem a -1. Isso dificulta que o algoritmo de aprendizado continue a adaptar os pesos do modelo para atingir melhores resultados (Goodfellow et al, 2016). Já a função de ativação ReLU, que vem se tornando a função de ativação mais utilizada em ANNs, é computada com um baixo esforço computacional e não leva à saturação dos neurônios devido ao seu caráter aproximadamente linear (Glorot et al, 2011).

- Tamanho do batch

O tamanho do batch corresponde ao número de amostras de treinamento entregues ao modelo antes da atualização dos pesos, que pode variar entre 1 e o tamanho do conjunto de treinamento. Por um lado, batches menores resultam em uma melhor capacidade de generalização do modelo final. Por outro lado, o esforço computacional envolvido no treinamento com batches maiores é mais reduzido (Masters & Lusch, 2018).

- Taxa de aprendizado ( $\eta$ )

Uma baixa taxa de aprendizado implica em menores alterações nos pesos sinápticos a cada iteração, resultando em uma trajetória de busca de pesos mais suave e uma aprendizagem mais lenta. Já um alto valor de  $\eta$  pode levar a um aprendizado instável, que é caracterizado por erros cuja magnitude oscila consideravelmente ao longo das épocas e pela convergência do

treinamento para uma solução não ótima (Haykin, 2008). A influência da magnitude da taxa de aprendizado foi avaliada sempre em conjunto com o otimizador Adam. Esse algoritmo de otimização estocástico adapta a taxa de aprendizado ao longo do treinamento, definindo valores específicos para cada parâmetro do modelo em função das estimativas do primeiro e do segundo momento (Kingma & Ba, 2015).

- Decaimento de pesos

A técnica de decaimento de pesos adiciona um termo de regularização à função de custo do modelo. Foi avaliada a Regularização conhecida como L2, descrita pela Equação 3.14:

$$\text{Função de Custo} = RMSE + \alpha ||w||^2 \quad (3.14)$$

em que o  $RMSE$  é a métrica de função de custo original,  $\alpha$  é o parâmetro de penalização a ser variado e  $||w||^2$  é o quadrado do módulo da matriz de pesos da rede. Ou seja, a penalização se torna maior à medida que os pesos aumentam de magnitude, evitando que a complexidade da rede cresça indefinidamente.

A Tabela 3.3 resume as faixas de valores avaliadas na busca randômica dos modelos MLP e LSTM. Os modelos foram treinados com 200 combinações aleatórias dos hiperparâmetros, e foram escolhidas aquelas que alcançaram as maiores assertividades nas previsões de temperatura e umidade na estufa na janela de 5 minutos (Eq. 3.4). Novamente, foram utilizadas aproximadamente 50% das amostras disponíveis.

Tabela 3.3: Avaliação de hiperparâmetros dos modelos baseados em redes neurais

Hiperparâmetro	Valores
Nº de neurônios por camada	10, 15, 20, 25, 30, 35
Nº de camadas escondidas	1, 2
Tipo de função de ativação	Tangente hiperbólica, ReLU
Tamanho do batch	125, 250, 500
Taxa de aprendizado	$10^{-4}$ , $10^{-3}$ , $10^{-2}$
Decaimento dos pesos	$10^{-4}$ , $5 \times 10^{-4}$ , $10^{-3}$ , $5 \times 10^{-3}$ , $10^{-2}$ , $5 \times 10^{-2}$ , 0

### 3.7 Escolha do modelo a ser utilizado no desenvolvimento da estratégia de controle antecipatória

#### 3.7.1 *Backtesting*

Após a otimização de hiperparâmetros dos modelos SVR, MLP e LSTM, a técnica de *backtesting*, que é um tipo de validação cruzada (Cross Validation – CV), foi utilizada para uma estimativa mais robusta de desempenho nas previsões de temperatura e umidade. Na validação cruzada, o conjunto de dados é dividido em  $n$  subconjuntos, sendo que um deles é utilizado para validação, um para teste e  $n - 2$  são para treinamento do modelo. Esse processo é repetido sucessivamente, e a cada iteração, diferentes subconjuntos são utilizados para validação e teste. O desempenho do modelo é então calculado como uma média entre os resultados obtidos ao longo das iterações (James et al, 2013). A Figura 3.10 ilustra essa técnica:

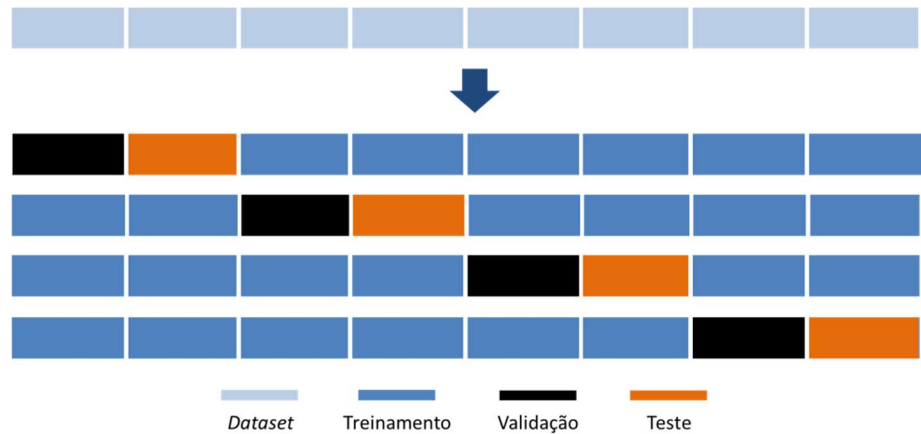


Figura 3.10: Exemplo de divisão de dados na validação cruzada

Fonte: Elaborado pela autora, 2019

A diferença fundamental entre o *backtesting* e a validação cruzada tradicional é que o *backtesting* leva em consideração a ordem cronológica das amostras de dados. Ou seja, a cada iteração, o treinamento do modelo é realizado apenas em dados anteriores aos subconjuntos de validação e teste, o que é adequado para previsões baseados em séries temporais. A Figura 3.11 apresenta um exemplo de divisão dos dados no *backtesting*:

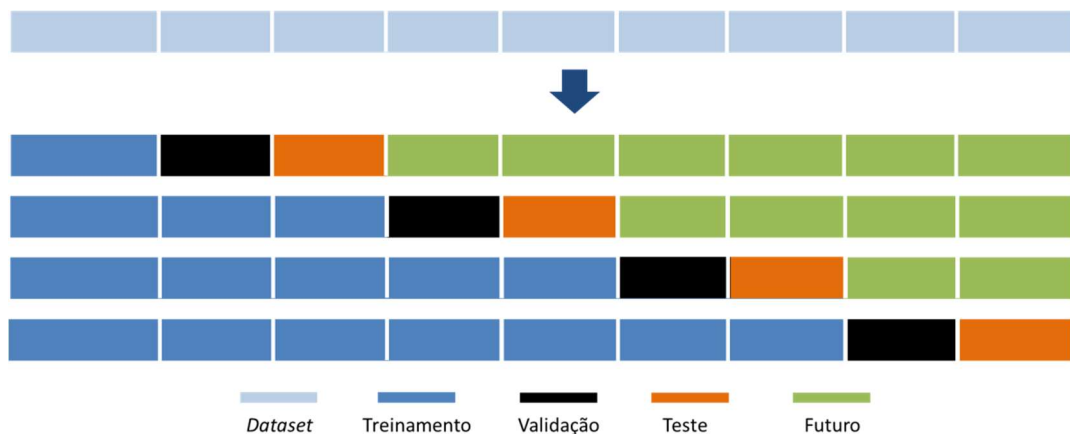



Figura 3.11: Exemplo de divisão dos dados no *backtesting*


Fonte: Elaborado pela autora, 2019

Os dados foram particionados em trinta janelas de tempo de extensão crescente. A Figura 3.12 exemplifica como o *backtesting* foi realizado nos dados de temperatura de uma das


estações meteorológicas da estufa, com os gráficos de *a* a *e* apresentando, respectivamente, a primeira, a oitava, a décima-quinta, a vigésima-segunda e a trigésima janelas de tempo. Como se observa, o número de amostras de treinamento aumenta entre uma janela de tempo e a próxima, e os conjuntos de validação e teste se deslocam para amostras futuras. Os tamanhos dos conjuntos de treinamento e de teste se mantêm constantes, de modo que as estatísticas de desempenho dos modelos treinados em cada janela de tempo sejam comparáveis.



a) Primeira janela de tempo do *backtesting*





b) Oitava janela de tempo do *backtesting*



c) Décima-quinta janela de tempo do *backtesting*



d) Vigésima-segunda janela de tempo do *backtesting*e) Trigésima janela de tempo do *backtesting*Figura 3.12: Exemplos de janelas de tempo do *backtesting* com 30 iterações

Fonte: elaborado pela autora, 2019

### 3.7.2 Construção de intervalos de confiança para comparação entre os modelos

Foram computados o RMSE e o MAPE de treinamento, validação e teste de todas as 30 janelas de tempo de *backtesting* de cada modelo desenvolvido. Esse processo foi repetido para cada horizonte de previsão de temperatura e umidade - 5 minutos (Eq. 3.4), 15 minutos (Eq. 3.5) e 30 minutos (Eq. 3.6). Como mencionado anteriormente, as estatísticas de erros de validação ( $RMSE_{validação}$  e  $MAPE_{validação}$ ) e de teste ( $RMSE_{teste}$  e  $MAPE_{teste}$ ) ao longo das janelas de expansão de tempo são comparáveis, uma vez que os tamanhos desses conjuntos de dados foram mantidos constantes.

Considerando uma amostra de erros  $\epsilon = \{\epsilon_1, \epsilon_2, \epsilon_3, \dots, \epsilon_{30}\}$ ,  $\bar{\epsilon}$  é a média amostral dos erros  $\epsilon_i$  e  $\tilde{\epsilon}$  é o erro médio da população do conjunto de dados.  $\bar{\epsilon}$  provavelmente difere de  $\tilde{\epsilon}$ , uma vez que as janelas de tempo do conjunto de dados poderiam ter sido particionadas de maneiras distintas e gerado outras amostras de erro. É possível estimar uma faixa de valores com alta probabilidade de  $\tilde{\epsilon}$  se encontrar, denominada intervalo de confiança (IC). Assim, o

desempenho médio de cada modelo nos conjuntos de validação e de teste foi reportado como um intervalo de confiança dado pela Eq. 3.15:

$$IC = \frac{\bar{\epsilon} \pm z_{1-\alpha/2} \times s}{\sqrt{n}} \quad (3.15)$$

Em que  $\alpha$  é o grau de significância, definido como 0,05;  $z$  é o quantil associado ao coeficiente de confiança ( $1 - \alpha/2$ );  $s$  é o desvio padrão da amostra e  $n$  é o tamanho da amostra, igual a 30, que é o tamanho mínimo para que a equação acima seja utilizada. Só se podem construir intervalos de confiança de amostras de tamanho inferior se as observações forem provenientes de uma população normalmente distribuída (Jain, 1991), e utilizando outro procedimento não abordado neste trabalho.

Portanto, os erros de predição nos conjuntos de validação e teste foram reportados como intervalos de confiança para que a comparação entre os modelos indique se a diferença de assertividade entre eles é estatisticamente significativa, apoiando a escolha do modelo final.

### **3.8 Aplicação do modelo final aos dados de temperatura e umidade da estação meteorológica externa**

A escolha do modelo que apresentou uma maior assertividade na predição dos padrões diários de temperatura e umidade na localidade da estufa, considerando horizontes de predição de 5, 10 e 15 minutos, é detalhada na sessão 4.3. Em seguida, esse modelo foi aplicado aos dados históricos da estação meteorológica externa.

A otimização de hiperparâmetros foi refeita a partir do treinamento e validação com o conjunto de dados da estação externa. Assim como anteriormente, foi considerado o horizonte de predição de 5 minutos na otimização.

A estimativa de desempenho do modelo adequado aos novos dados foi feita a partir do *backtesting* considerando os horizontes de predição de 5, 15 e 30 minutos. O tamanho das

janelas de tempo foi mantido o mesmo para efeito de comparação entre os modelos ajustados aos dados internos e externos. Entretanto, em função do menor tempo de monitoramento das condições ambientais com a estação externa por ela ter sido instalada na estufa posteriormente, foram avaliadas apenas seis janelas de tempo. Conseqüentemente, os resultados não foram reportados como intervalos de confiança, mas como média e desvio padrão dos erros de predição.

## 4 RESULTADOS E DISCUSSÃO

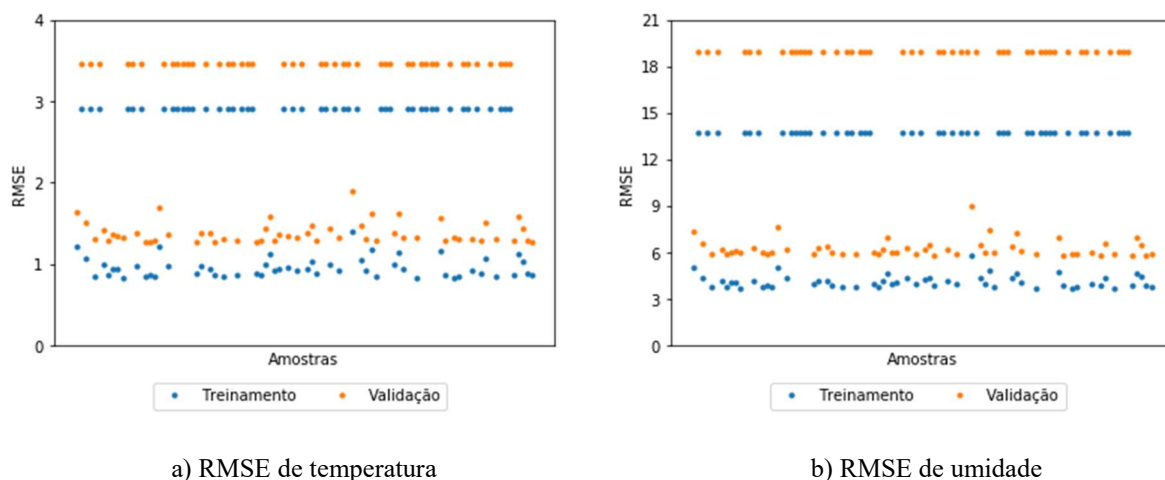
### 4.1 Introdução

Neste capítulo serão apresentados os modelos baseados em SVR, MLP e LSTM desenvolvidos a partir da estratégia de otimização de hiperparâmetros. O desempenho desses modelos nas previsões de temperatura e umidade internas da estufa experimental será comparado, apoiando a escolha do modelo final a ser utilizado na criação de uma estratégia de controle antecipatório para seu microclima.

### 4.2 Otimização de hiperparâmetros

#### 4.2.1 Modelo baseado em máquinas de vetores por regressão

A Figura 4.1 apresenta os RMSEs nas previsões de temperatura (a) e umidade (b) de cada combinação de hiperparâmetros do SVR gerada durante a busca randômica. Como apresentado nos gráficos, ocorreu a saturação dos erros máximos em um mesmo valor para diversas combinações distintas de hiperparâmetros. Esses erros máximos correspondem a 2,91°C e 3,46°C nas previsões de temperatura nos dados de treinamento e validação, respectivamente, e 13,73% e 18,95% nas previsões de treinamento e validação de umidade. Outro comportamento observável é a tendência de os erros de treinamento (em azul) serem menores que os erros de validação (em laranja), uma vez que o ajuste do modelo foi feito no conjunto de treinamento. Dentre as combinações apresentadas, a Tabela 4.1 apresenta a configuração escolhida para o modelo final.



a) RMSE de temperatura

b) RMSE de umidade

Figura 4.1. Erros das amostras geradas na busca randômica do SVR

Fonte: Elaborado pela autora, 2019

Tabela 4.1: Combinação de hiperparâmetros escolhida para o modelo SVR

Hiperparâmetro	Valor
Largura $\epsilon$ da zona insensível	$10^{-5}$
Tipo de função <i>kernel</i>	RBF
Fator $C$ de penalização	2

A saturação de erros máximos acima da média dos erros das amostras geradas na busca randômica motivou a investigação do impacto que cada parâmetro do modelo tem sobre o RMSE isoladamente. Assim, as Figuras 4.2 e 4.3 apresentam os valores de RMSE nas predições de temperatura e umidade, respectivamente, quando apenas um hiperparâmetro é variado por vez na configuração escolhida para o modelo final. Como se observa, o hiperparâmetro ao qual o modelo se mostrou mais sensível foi a largura  $\epsilon$  da zona insensível, uma vez que valores de  $\epsilon$  superiores a um resultaram nos erros máximos observados na Figura 4.1. Ou seja, a não penalização de erros em um intervalo de  $\epsilon$  maior ou igual a  $[-1, 1]$  tornou a complexidade do modelo SVR resultante insuficiente para realizar predições de temperatura e umidade coerentes com o cenário apresentado. O fator  $C$  de penalização do SVR também teve uma influência significativa no RMSE quando variado entre  $2^{-5}$  e  $2^1$ , sendo este último o valor escolhido para o modelo final. Quanto menor  $C$ , maior o RMSE, indicando a perda da capacidade de generalização do modelo em função de sua maior complexidade (Smets et al, 2007).

Comparando-se as previsões com  $C$  igual a  $2^{-5}$  e  $2^1$ , o RMSE de validação nos dados de temperatura foi reduzido de  $1,62^{\circ}\text{C}$  para  $1,29^{\circ}\text{C}$ . Nos dados de umidade, a redução foi de  $7,18\%$  para  $5,81\%$ . Já a função *kernel* utilizada exerceu uma influência praticamente nula sobre os erros. Os RMSEs de validação de temperatura fora  $1,29^{\circ}\text{C}$  e  $1,30^{\circ}\text{C}$  com o *kernel* RBF e o *kernel* polinomial, respectivamente, e os RMSEs de validação de umidade foram  $5,81\%$  e  $5,99\%$ , respectivamente. Assim, optou-se por permanecer com o *kernel* RBF, como determinado pela busca randômica e em função de sua ampla utilização e alta capacidade de aprendizado de especificidades de conjuntos de dados.




Figura 4.2. Influência da variação isolada de cada hiperparâmetro do SVR nos erros de previsão de temperatura

Fonte: Elaborado pela autora, 2019




Figura 4.3. Influência da variação isolada de cada hiperparâmetro do SVR nos erros de previsão de umidade

Fonte: Elaborado pela autora, 2019

#### 4.2.2 Modelos baseados em redes neurais

As Figuras 4.4 e 4.5 apresentam os RMSEs nas predições dos modelos MLP e LSTM, respectivamente, para cada uma das combinações de hiperparâmetros geradas durante as buscas randômicas. Para ambos os modelos, os erros de treinamento e de teste na predição de temperatura da maior parte das amostras se situa entre valores menores que 2°C. Nas predições de umidade, a maior parte dos erros se situa abaixo de 8%. Entretanto, observou-se uma maior variabilidade nos erros da busca randômica da rede LSTM. Os erros máximos de validação de temperatura e umidade da rede MLP foram 3,84°C e 21,91%, e os erros máximos da rede LSTM foram 6,12°C e 38,31%, respectivamente. Isso indica uma maior sensibilidade da rede LSTM à escolha adequada de hiperparâmetros em função da sua alta complexidade.

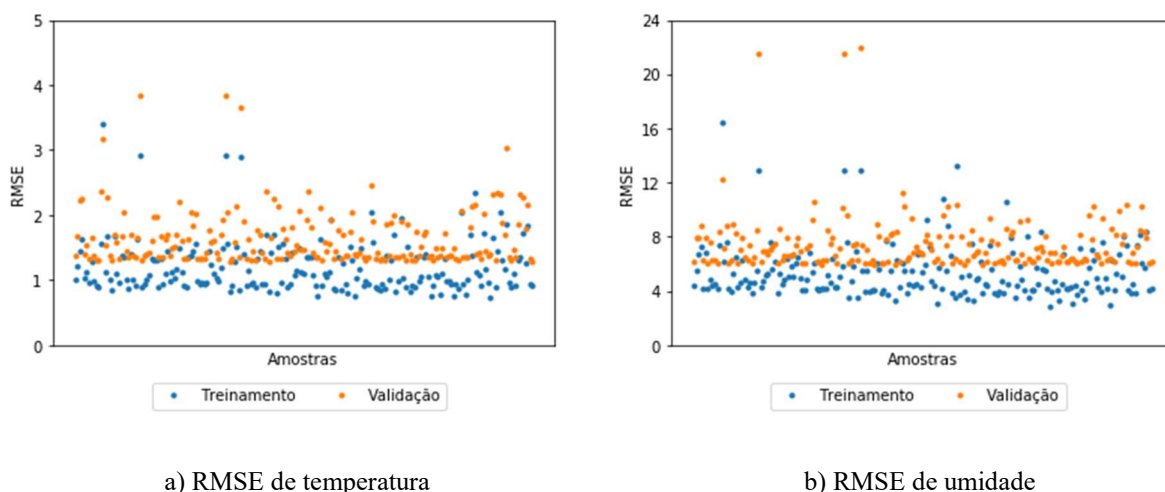


Figura 4.4. Erros das amostras geradas na busca randômica da rede MLP

Fonte: Elaborado pela autora, 2019

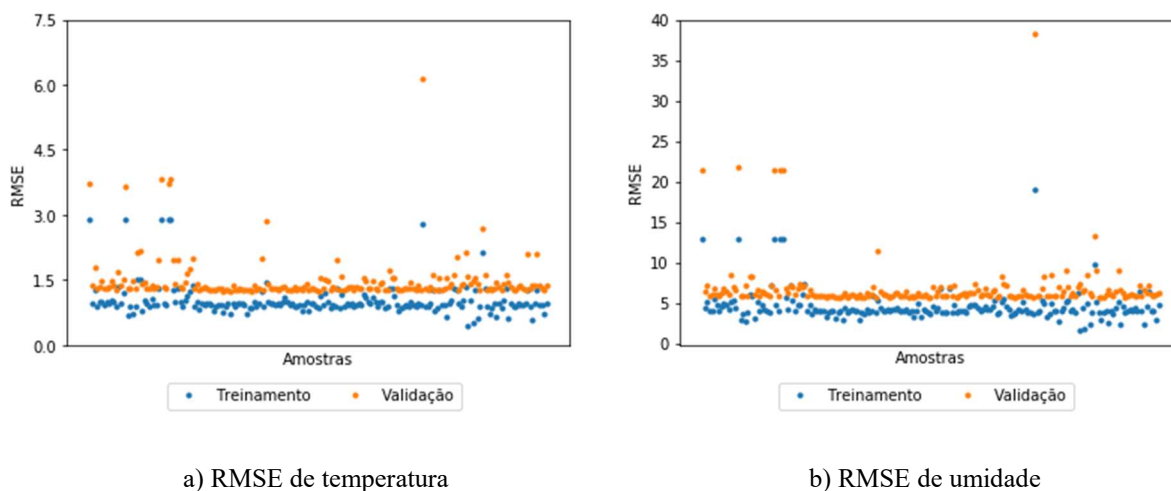


Figura 4.5. Erros das amostras geradas na busca randômica da rede LSTM

Fonte: Elaborado pela autora, 2019

A Tabela 4.2 apresenta as configurações escolhidas para as redes MLP e LSTM a partir das buscas randômicas. Apesar de coincidirem na quantidade de neurônios por camada (20) e no número de camadas escondidas (1), o desempenho de cada modelo foi superior com uma combinação distinta de valores dos outros hiperparâmetros.

Tabela 4.2: Combinações de hiperparâmetros escolhidas para os modelos baseados em redes neurais

Hiperparâmetro	Valores	
	MLP	LSTM
Nº de neurônios por camada	20	20
Nº de camadas escondidas	1	1
Tipo de função de ativação	ReLU	Tangente hiperbólica
Tamanho do batch	500	125
Taxa de aprendizado	$10^{-4}$	$10^{-3}$
Decaimento dos pesos	$5 \times 10^{-4}$	$10^{-4}$

As Figuras 4.6 e 4.7 mostram as curvas em escala logarítmica da função de custo das redes MLP e LSTM, respectivamente, ao longo de 4000 épocas de treinamento. A função de



custo foi computada para os dados de treinamento e validação normalizados. Como mencionado anteriormente, a escala de normalização da função ReLU (utilizada na rede MLP) foi  $[0,1]$  e da função tangente hiperbólica (utilizada na rede LSTM) foi  $[-1,1]$ . Os erros da rede MLP reduziram expressivamente ao longo das primeiras 1000 épocas, e as curvas da rede LSTM apresentaram um decaimento ainda mais abrupto e redução drástica de RMSE já nas primeiras 500 épocas. Todas as curvas continuaram a apresentar uma sutil redução de erro nas épocas de treinamento subsequentes, exceto a curva de validação da rede LSTM, que se estabilizou rapidamente já no início do treinamento.




Figura 4.6: Curva de aprendizado da rede MLP

Fonte: Elaborado pela autora, 2019




Figura 4.7: Curva de aprendizado da rede LSTM

Fonte: Elaborado pela autora, 2019

Assim como feito para o modelo baseado em SVR, foi avaliada a influência no RMSE da variação de apenas um hiperparâmetro por vez nas configurações escolhidas para os modelos baseados em redes neurais. As Figuras 4.8 e 4.9 apresentam o impacto de cada hiperparâmetro nas previsões de temperatura e umidade, respectivamente, da rede MLP.

A variação no número de neurônios na camada escondida não impactou significativamente o desempenho do modelo baseado em MLP, apesar de que a configuração escolhida de 20 neurônios apresentou os RMSEs mais baixos de treinamento ( $0,90^{\circ}\text{C}$  e  $3,82\%$ ) e de validação ( $1,32^{\circ}\text{C}$  e  $5,96\%$ ). O aumento de uma para duas camadas escondidas tampouco influenciou o resultado, reforçando escolha pelo modelo de uma camada por sua menor complexidade. A mudança na função de ativação e no decaimento dos pesos também não resultou em uma variação expressiva no RMSE, não se justificando optar por uma configuração desses hiperparâmetros distinta da definida a partir da busca randômica.

Já o tamanho do batch e a taxa de aprendizado quando alterados em relação a 500 e 0,0001, respectivamente, impactaram negativamente o RMSE. Por exemplo, os RMSEs das previsões de temperatura e umidade nos dados de validação aumentaram para  $1,47^{\circ}\text{C}$  e  $6,89\%$ , respectivamente, para o batch igual a 125. Para a taxa de aprendizado de 0,01, houve um aumento desses valores para  $2,19^{\circ}\text{C}$  e  $7,66\%$ .

A alteração de nenhum hiperparâmetro isolado resultou nos erros máximos apresentados na Figura 4.1, evidenciando uma maior robustez dos modelos baseados em redes neurais em relação àqueles baseados em SVR. Entretanto, ambos RMSEs máximos de temperatura ( $3,84^{\circ}\text{C}$ ) e umidade ( $21,91\%$ ) nos dados de validação ocorreram em amostras com poucos neurônios (10 e 15, respectivamente), uma alta taxa de aprendizado (0,01) e altos valores de decaimento de pesos (0,01 e 0,05, respectivamente). Isso indica que a combinação desses fatores resultou em modelos de baixa complexidade, em função do baixo número de neurônios e alta penalização da função de custo, e de treinamento instável, em função da alta taxa de aprendizado.

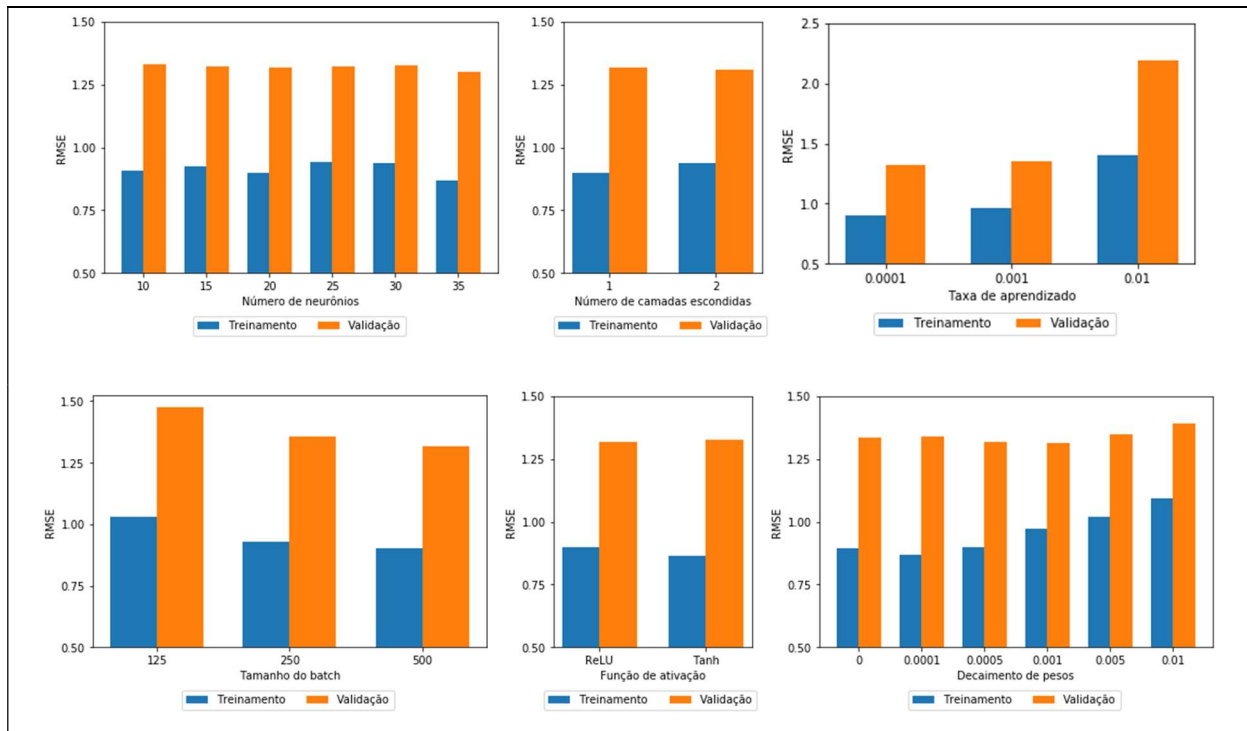


Figura 4.8. Influência da variação isolada de cada hiperparâmetro da rede MLP nos erros de predição de temperatura

Fonte: Elaborado pela autora, 2019

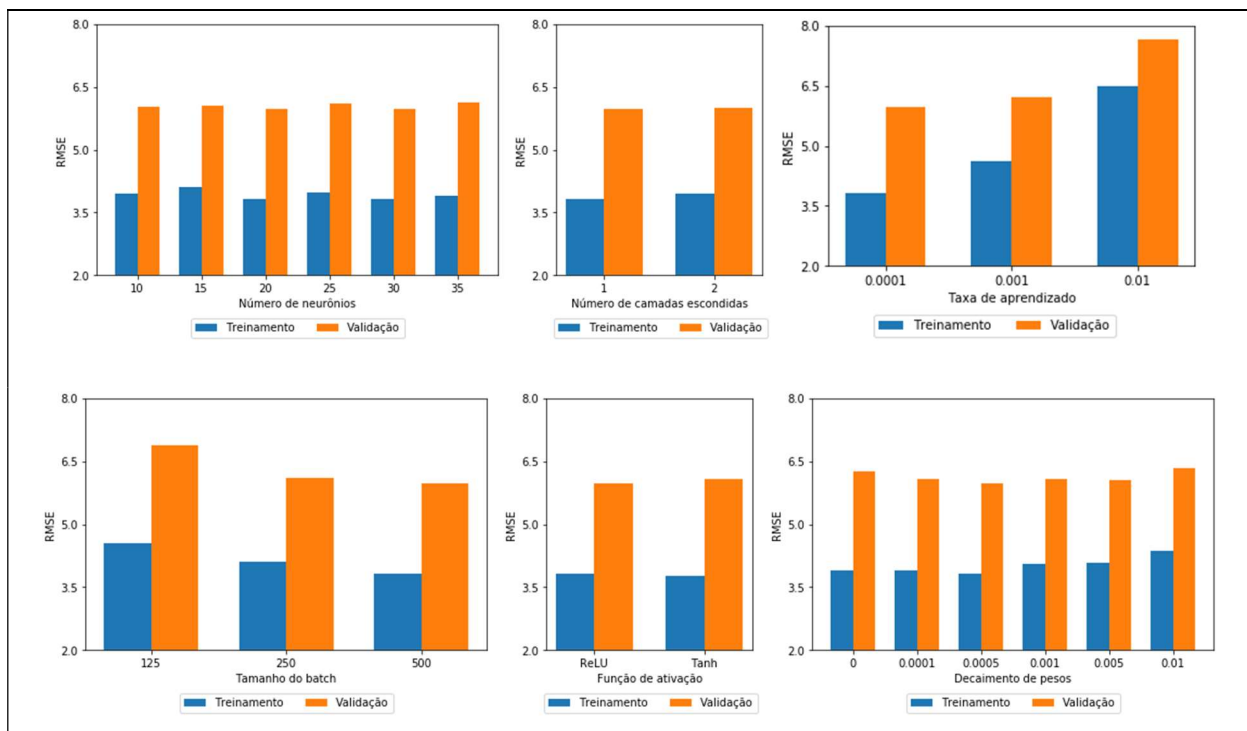


Figura 4.9. Influência da variação isolada de cada hiperparâmetro da rede MLP nos erros de predição de umidade

Fonte: Elaborado pela autora, 2019

As Figuras 4.10 e 4.11 apresentam o impacto de cada hiperparâmetro nas previsões de temperatura e umidade, respectivamente, da rede LSTM. Isoladamente, o número de neurônios, o número de camadas escondidas e a função de ativação tiveram pouca influência para alterar os RMSEs mínimos encontrados na busca, que foram  $0,76^{\circ}\text{C}$  e  $3,28\%$  nos dados de treinamento e  $1,24^{\circ}\text{C}$  e  $5,77\%$  nos dados de validação. A taxa de aprendizado, quando maior que o valor escolhido de  $0,01$ , aumentou os RMSEs de validação para  $1,36^{\circ}\text{C}$  e  $6,37\%$ . O batch size quando igual a  $500$ , elevou os RMSEs do batch definido ( $125$ ) para  $1,30^{\circ}\text{C}$  e  $5,89\%$ . Por fim, a variação da taxa de decaimento isoladamente alterou pouco o desempenho do modelo, não justificando mudar a configuração escolhida na busca randômica. A única exceção foi a amostra em que o decaimento foi nulo, em que os RMSEs aumentaram para  $1,38^{\circ}\text{C}$  e  $6,30\%$ , indicando a necessidade de regularização da rede para que os erros não cresçam indefinidamente.

Os erros máximos de validação apresentados na Figura 4.5 ( $6,12^{\circ}\text{C}$  e  $38,31\%$ ) ocorreram para uma mesma configuração. Os hiperparâmetros que mais se diferem nela em relação à configuração determinada pela busca randômica são um maior número de neurônios ( $25$ ), taxa de decaimento nula e uma maior taxa de aprendizado ( $0,01$ ). Em conjunto, esses fatores contribuem para o aumento da complexidade do modelo, resultando no fenômeno de *overfitting*, além de para uma maior instabilidade durante o treinamento.

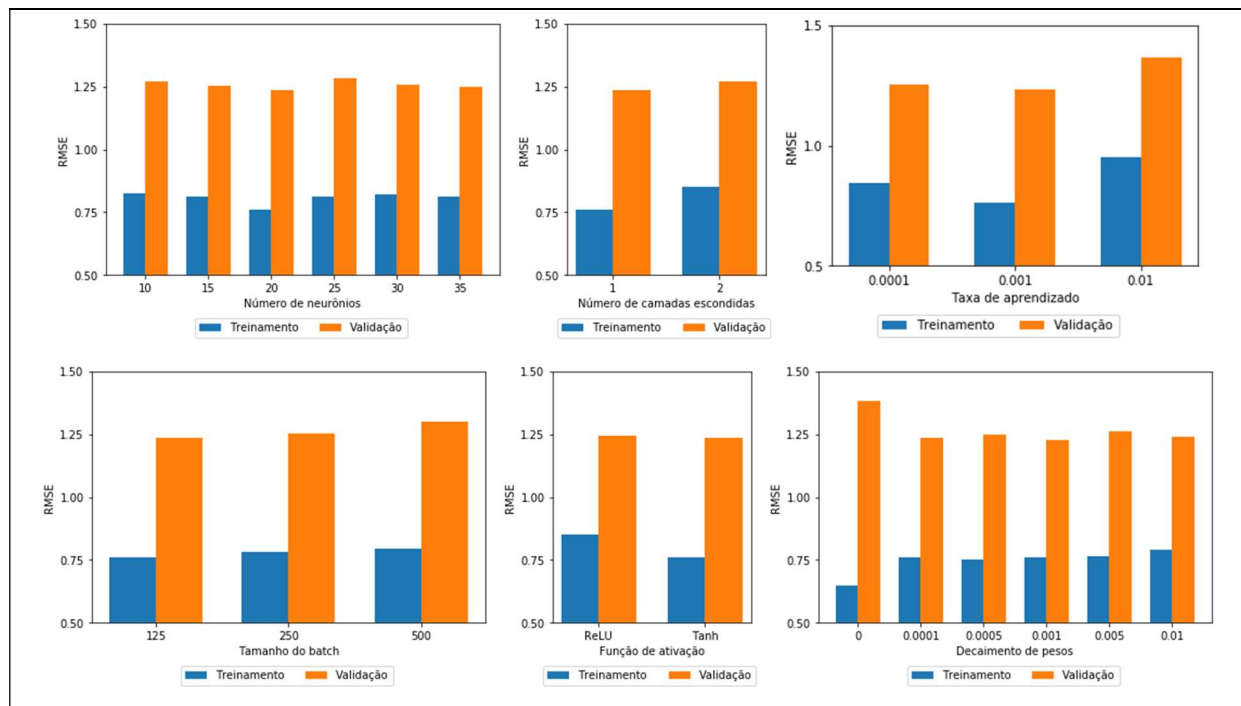


Figura 4.10. Influência da variação isolada de cada hiperparâmetro da rede LSTM nos erros de predição de temperatura

Fonte: Elaborado pela autora, 2019

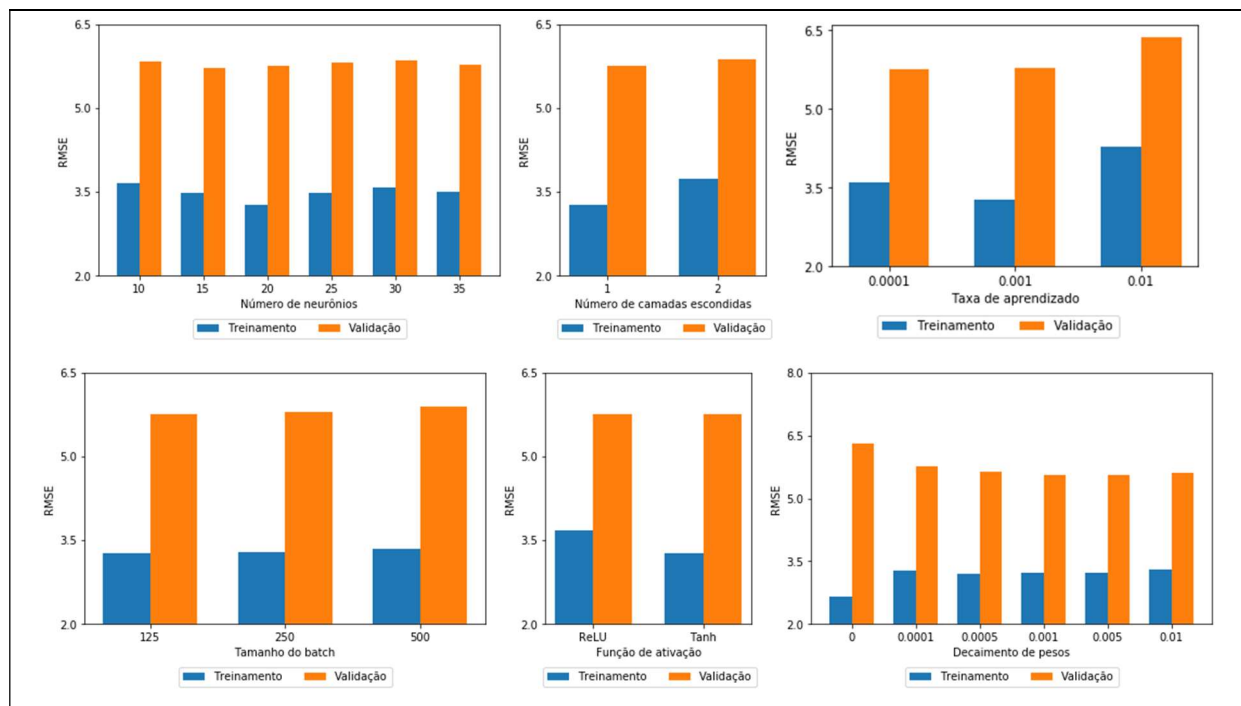


Figura 4.11. Influência da variação isolada de cada hiperparâmetro da rede LSTM nos erros de predição de umidade

Fonte: Elaborado pela autora, 2019

### 4.3 Escolha do modelo a ser utilizado no desenvolvimento da estratégia de controle antecipatória

Após a definição dos hiperparâmetros dos modelos SVR, MLP e LSTM, foi realizada a comparação entre seus desempenhos, que foram estimados utilizando a técnica de *backtesting*. Como mencionado anteriormente, cada modelo foi treinado e avaliado em trinta janelas de tempo de tamanho crescente, e foram calculados os erros médios de predição de temperatura e umidade considerando essas trinta janelas. Esse processo foi repetido para os horizontes de predição 5, 15 e 30 minutos à frente do instante  $t = 0$ .

A Figura 4.12 apresenta os RMSEs de treinamento ao longo das trinta janelas de tempo para o horizonte de predição de 5 minutos. Os gráficos com os RMSEs de treinamento dos intervalos de 15 e 30 minutos de predição não foram adicionados a esta sessão por apresentarem um padrão semelhante ao que é analisado na Figura 4.12. Como se observa, os RMSEs de treinamento das redes MLP e LSTM se mantiveram aproximadamente constantes ao longo das janelas avaliadas, o que é um indicativo da robustez dos modelos baseados em redes neurais para o contexto em estudo. Por outro lado, o desempenho do modelo baseado em SVR se mostrou mais sensível às amostras de dados utilizadas no treinamento, havendo oscilações que aumentaram o RMSE em determinadas janelas de tempo.

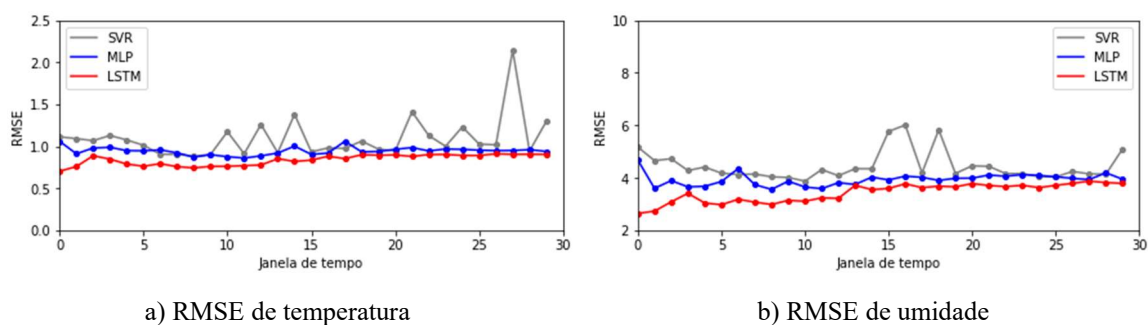


Figura 4.12. Erros de predição de temperatura nos dados de treinamento no horizonte de 5 minutos

Fonte: Elaborado pela autora, 2019

As Figuras 4.13, 4.14 e 4.15 apresentam os RMSEs de teste ao longo das trinta janelas de tempo para os horizontes de predição de 5, 15 e 30 minutos, respectivamente. Os gráficos com os RMSEs de validação não foram adicionados a esta sessão por apresentarem um padrão semelhante ao que é avaliado nas Figuras 4.13 a 4.15. Complementando os gráficos, as Tabelas

4.3 e 4.4 apresentam os RMSEs e MAPEs médios de teste das previsões de temperatura e umidade, respectivamente. Os melhores desempenhos em cada horizonte de previsão foram destacados em amarelo. As tabelas completas incluindo os RMSEs e MAPEs médios relativos a dados de treinamento e validação se encontram no Apêndice B.

Como se observa nos gráficos das três imagens, o RMSE de teste de todos os modelos avaliados depende fortemente da janela de dados em que foi feita a avaliação. Por exemplo, na Figura 4.13, o RMSE da previsão de temperatura pela rede LSTM variou de 0,63°C a 1,59°C. Na Figura 4.14, o RMSE da previsão de umidade pela rede MLP variou de 4,52% a 8,67%. Por fim, na Figura 4.15, o RMSE da previsão de temperatura do modelo baseado em SVR variou de 1,46°C a 2,83°C. Essa dependência maior do que a que ocorre com o RMSE de treinamento é esperada, uma vez que os modelos não se ajustaram aos dados de teste e fizeram as previsões com base no que aprenderam com outro conjunto de dados.

Essa oscilação de desempenho também é relacionada à qualidade dos dados adquiridos, e bases de dados com inconsistências são um desafio comum a grande parte dos modelos baseados em *machine learning*. No caso em estudo, problemas com a conexão de internet ocasionaram períodos de interrupção nas medições que afetaram o desempenho dos modelos de duas maneiras. Em primeiro lugar, os dados faltantes precisaram ser estimados por extrapolação linear, como mencionado anteriormente. Em segundo lugar, a falta desses dados em tempo real impactou momentânea e negativamente o desempenho do controlador *on-off* da estufa, perturbando parcialmente suas condições climáticas internas. Outro fator que pode ter impactado o desempenho dos modelos foi a frequente saturação dos sensores de luminosidade, que induz os procedimentos de controle a fechar as cortinas da estufa e, conseqüentemente, influencia a dinâmica do microclima interno. Nesse contexto, a busca randômica de hiperparâmetros teve o objetivo de minimizar os impactos mencionados, possibilitando a escolha dos modelos com melhor capacidade de generalização e complexidade suficiente para capturar padrões específicos dos dados.




Figura 4.13. Erros de predição de temperatura nos dados de teste no horizonte de 5 minutos

Fonte: Elaborado pela autora, 2019




Figura 4.14. Erros de predição de temperatura nos dados de teste no horizonte de 15 minutos

Fonte: Elaborado pela autora, 2019




Figura 4.15. Erros de predição de temperatura nos dados de teste no horizonte de 30 minutos

Fonte: Elaborado pela autora, 2019

Comparando-se as três figuras, observa-se a tendência de aumento dos erros de todos os modelos com o aumento do horizonte de predição. Consequentemente, os erros médios registrados nas tabelas também aumentaram. A título de exemplificação, os MAPEs médios de temperatura da rede MLP foram 2,31%, 3,78% e 4,91% para os horizontes de predição de 5, 15



e 30 minutos, respectivamente. Como um segundo exemplo, os MAPEs médios de umidade da rede LSTM foram 3,99%, 8,15% e 12,02% para os mesmos e respectivos horizontes. Esse é um comportamento esperado, uma vez que, em um horizonte de predição menor, o valor real futuro a ser estimado tem maior chance de seguir a tendência aprendida pelo modelo a partir dos dados históricos de entrada (no caso, do instante  $t = -120$  ao instante  $t = 0$ ). Por outro lado, em um intervalo mais longo, há uma maior chance de que perturbações ainda não ocorridas entre os instantes  $t = -120$  e  $t = 0$  interfiram no valor real futuro, aumentando a incerteza desse valor e sua divergência em relação à predição do modelo.

Pela Figura 4.13, observa-se que a rede LSTM apresentou erro inferior à rede MLP e ao SVR em quase todas as janelas do *backtesting* considerando o horizonte de predição de 5 minutos. Em contrapartida, os erros associados ao SVR tenderam a ser os maiores. Utilizando como exemplo a Tabela 4.3, o RMSE e o MAPE médios da predição de temperatura do SVR foram 1,1°C e 2,77%, respectivamente; para a rede MLP, o RMSE e o MAPE médios foram de 0,99°C e 2,31%, respectivamente; e para a rede LSTM, esses erros foram de 0,89°C e 2,06%.

O fenômeno não esperado foi o aumento dos RMSEs da rede LSTM em uma proporção maior do que os outros modelos nos horizontes de predição de 15 e 30 minutos. Pela Figura 4.14 e pelas tabelas de erros médios, observa-se que a rede LSTM apresentou o segundo maior erro médio de predição de temperatura (RMSE e MAPE de 1,63°C e 4,21%, respectivamente) e o maior erro médio de predição de umidade (RMSE e MAPE de 6,96% e 8,15%, respectivamente). Pela Figura 4.15 e pelas mesmas tabelas, a rede LSTM teve ambos o maior erro médio de predição de temperatura (RMSE e MAPE de 2,25°C e 6,09%, respectivamente) e o maior erro médio de predição de umidade (RMSE e MAPE de 9,93% e 12,02%, respectivamente). A queda de desempenho de redes LSTM com o aumento do horizonte de predição já foi relatada em trabalhos anteriores (Fan et al, 2019; Ismail et al, 2018). Essa queda pode ocorrer independentemente da alta capacidade da rede de capturar padrões temporais ao longo de sequências extensas de dados, uma vez que as variáveis de saída do modelo são função de ambos dados históricos e da dinâmica das variáveis monitoradas em um instante futuro e não computado dentre os dados de entrada ((Fan et al, 2019).

A rede MLP apresentou os erros mais baixos nos horizontes de predição de 15 e 30 minutos. No horizonte de 15 minutos, o RMSE e o MAPE médios de temperatura foram 1,48°C e 3,78%, respectivamente. Na predição de umidade, o RMSE e o MAPE foram 6,14% e 7,04%. Os erros médios da rede MLP foram ainda mais baixos, em comparação aos da rede LSTM, no horizonte de predição de 30 minutos. Na predição de temperatura, o RMSE e o MAPE médios foram

1,84°C e 4,91%, respectivamente. Na predição de umidade, o RMSE e o MAPE foram 7,99% e 9,36%.

Tabela 4.3: Erro médio de predição de temperatura nos dados de teste ao longo das janelas de tempo do *backtesting*

Horizonte de previsão (minutos)	SVR		MLP		LSTM	
	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
5	1,1 ± 0,31	2,77 ± 1,08	0,99 ± 0,24	2,31 ± 0,59	0,89 ± 0,21	2,06 ± 0,55
15	1,71 ± 0,35	4,45 ± 1,11	1,48 ± 0,24	3,78 ± 0,72	1,63 ± 0,37	4,21 ± 1,12
30	2,13 ± 0,36	5,72 ± 1,20	1,84 ± 0,33	4,91 ± 0,98	2,25 ± 0,41	6,09 ± 1,35

Tabela 4.4: Erro médio de predição de umidade nos dados de teste ao longo das janelas de tempo do *backtesting*

Horizonte de previsão (minutos)	SVR		MLP		LSTM	
	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
5	4,17 ± 1,02	4,69 ± 1,71	3,99 ± 1,07	4,3 ± 1,05	3,76 ± 0,91	3,99 ± 1,11
15	6,79 ± 1,26	8,06 ± 1,87	6,14 ± 1,03	7,04 ± 0,99	6,96 ± 1,79	8,15 ± 1,84
30	8,80 ± 1,56	10,4 ± 1,81	7,99 ± 1,28	9,36 ± 1,36	9,93 ± 2,03	12,02 ± 2,24

As Figuras 4.16, 4.17 e 4.18 apresentam os intervalos de confiança dos RMSEs das janelas de predição de 5, 15 e 30 minutos. Como mencionado na sessão 3.7.2, cada intervalo de confiança é função do erro médio amostral e desvio padrão da predição (descritos nas Tabelas 4.3 e 4.4), do grau de significância e do tamanho da amostra de erros. O grau de significância escolhido, 0,05, é associado a um nível de confiança de 95%. Isso significa que, se fossem desenhadas  $i$  amostras de erros a partir de  $i$  maneiras distintas de particionar o conjunto de dados em janelas de tempo, o erro médio da população do conjunto de dados ( $\tilde{\epsilon}$ ) estaria presente em 95% dos  $i$  intervalos de confiança associados a essas amostras.

Como se observa, há uma tendência de aumento da amplitude dos intervalos de confiança em função do aumento do horizonte de predição. Por exemplo, os intervalos de

confiança de umidade com o modelo SVR são [3,79%, 4,55%] (amplitude igual a 0,76%), [6,20%, 7,38%] (amplitude igual a 1,18%) e [7,90%, 9,70%] (amplitude igual a 1,80%) para os horizontes de predição de 5, 15 e 30 minutos, respectivamente. Esse comportamento é função da tendência de aumento do desvio padrão dos erros amostrais em concomitância com o aumento do horizonte de predição, como registrado nas Tabelas 4.3 e 4.4. Retomando o exemplo do modelo SVR, os desvios padrão dos RMSEs de umidade 5, 15 e 30 minutos à frente, foram 1,02%, 1,26% e 1,56%, respectivamente. Essa maior variância dos erros ocorre em paralelo ao aumento de sua magnitude, devido à menor previsibilidade de janelas de tempo mais extensas explicada anteriormente.

Outro comportamento observável nas três figuras é a não sobreposição entre os menores intervalos de confiança de temperatura com os intervalos obtidos a partir dos outros modelos. No horizonte de predição de 5 minutos, o melhor resultado foi obtido com a rede LSTM ([0,87°C, 0,91°C]), e este não se sobrepõe ao segundo melhor resultado ([0,97°C, 1,01°C]) alcançado com a rede MLP. Na janela de 15 minutos, o melhor resultado foi obtido com a rede MLP ([1,46°C, 1,50°C]), e este não se sobrepõe ao segundo melhor resultado ([1,58°C, 1,68°C]) alcançado com a rede LSTM. Por fim, na janela de 30 minutos, o melhor resultado também foi obtido com a rede MLP ([1,80°C, 1,88°C]), e este não se sobrepõe ao segundo melhor resultado ([2,08°C, 2,18°C]) obtido com o modelo SVR. Essa não sobreposição é indicativa de que a diferença de assertividade entre os modelos é estatisticamente significativa.

Houve sobreposição entre os intervalos de confiança de umidade. Entretanto, a diferença entre os erros médios dos modelos (provenientes das Tabelas 4.3 e 4.4), ainda mais substancial nos horizontes de predição de 15 e 30 minutos, também é indicativa da superioridade das predições de um modelo em relação ao outro. Como mencionado anteriormente, os RMSEs médios na predição de umidade do modelo MLP foram 6,14% e 7,99% para os horizontes de predição de 15 e 30 minutos, respectivamente. Desses resultados, os melhores obtidos foram significativamente superiores aos segundo colocados em seus respectivos horizontes de predição. No horizonte de 15 minutos, o segundo menor RMSE médio, alcançado com o modelo SVR, foi 6,79%. No horizonte de 30 minutos, o segundo menor RMSE médio, também obtido com o modelo SVR, foi 8,80%. Além disso, em ambos horizontes de predição de 15 e 30 minutos, a rede MLP apresentou os intervalos de confiança de menor amplitude dentre os modelos. No horizonte de 15 minutos, os intervalos de confiança foram [1,46°C, 1,50°C] (amplitude de 0,04°C) e [5,74%, 6,53%] (amplitude de 0,79%) para as predições de temperatura

e umidade, respectivamente. No horizonte de 30 minutos, os intervalos de confiança foram  $[1,80^{\circ}\text{C}, 1,88^{\circ}\text{C}]$  (amplitude de  $0,08^{\circ}\text{C}$ ) e  $[7,38\%, 8,59\%]$  (amplitude de  $1,21\%$ ).

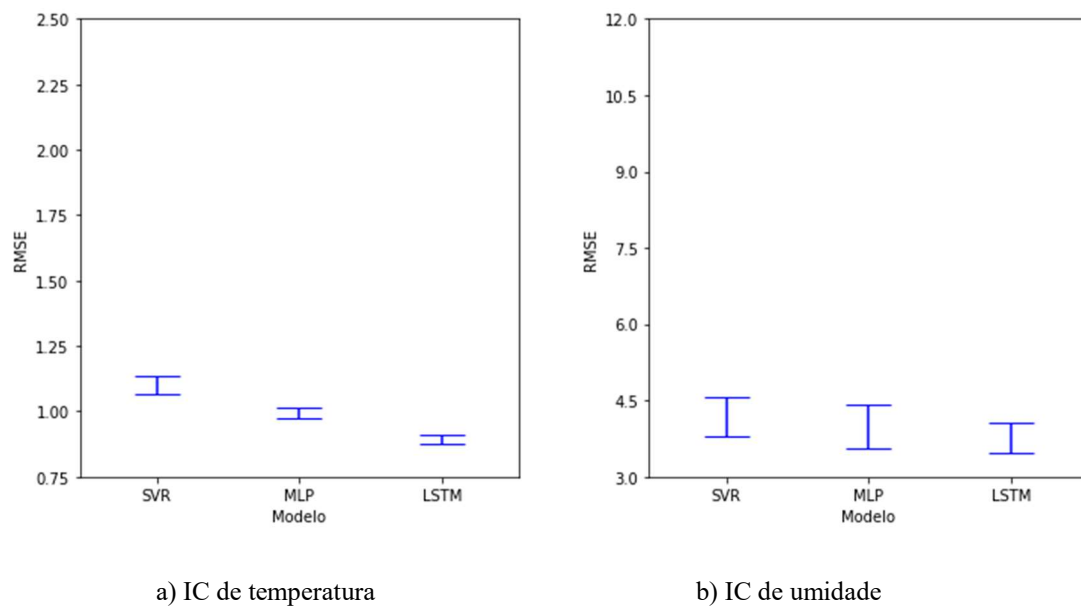


Figura 4.16. Intervalos de confiança dos erros de predição no horizonte de 5 minutos

Fonte: Elaborado pela autora, 2019




Figura 4.17. Intervalos de confiança dos erros de predição no horizonte de 15 minutos

Fonte: Elaborado pela autora, 2019





Figura 4.18. Intervalos de confiança dos erros de predição no horizonte de 30 minutos

Fonte: Elaborado pela autora, 2019

Avaliando-se os desempenhos dos três modelos nas predições de temperatura e umidade ao longo das trinta janelas de tempo, os erros médios calculados a partir do *backtesting* e os intervalos de confiança desenhados, optou-se por utilizar a rede MLP na modelagem que apoiará o desenvolvimento de uma estratégia de controle antecipatória para a estufa experimental. Em primeiro lugar, o modelo baseado em SVR se mostrou mais sensível às janelas de treinamento, apresentando oscilações no RMSE de treinamento mais proeminentes que os outros modelos. Além disso, dentre os três modelos, o SVR apresentou os erros médios de teste mais altos em dois horizontes de predição (5 e 15 minutos). Já a rede LSTM, apesar de ter se sobressaído com baixos erros no horizonte de predição de 5 minutos, exibiu um aumento no RMSE de teste em uma proporção maior que os outros dois modelos nos horizontes de 15 e 30 minutos. Assim, apresentou os erros de maior magnitude e variância no horizonte de 30 minutos. Já a rede MLP se mostrou relativamente estável na etapa de treinamento, com RMSEs de treinamento que variaram pouco em função da janela de tempo avaliada. No horizonte de predição de 5 minutos, apresentou o segundo melhor desempenho dentre os modelos. Nos horizontes de predição de 15 e 30 minutos, obteve o melhor resultado, com os RMSEs médios de temperatura e umidade mais baixos e de menor variância.


A Figura 4.19 apresenta uma janela de dados de teste de temperatura e as predições feitas pela rede MLP escolhida nos horizontes de 5, 15 e 30 minutos. Essa janela consiste em aproximadamente quatro dias de medições, evidenciados pelos quatro picos de temperatura e

umidade mais proeminentes nos gráficos. A ligeira alteração na leitura de temperatura inicial de cada gráfico é devida à variação no tamanho do vetor de saída do modelo em função da extensão do horizonte de previsão, como visto nas Eq. 3.4 a 3.6. A Figura 4.20 apresenta a mesma análise para os dados de umidade.



a) Horizonte de previsão de 5 minutos


b) Horizonte de previsão de 15 minutos



c) Horizonte de previsão de 30 minutos


Figura 4.19. Comparação entre os dados reais de temperatura e as previsões da rede MLP

Fonte: Elaborado pela autora, 2019



a) Horizonte de previsão de 5 minutos

b) Horizonte de previsão de 15 minutos



c) Horizonte de previsão de 30 minutos

Figura 4.20. Comparação entre os dados reais de umidade e as previsões da rede MLP

Fonte: Elaborado pela autora, 2019

Como se observa, as previsões no horizonte de 5 minutos acompanham as curvas de temperatura e umidade com alta fidelidade. Essa fidelidade é parcialmente e gradativamente reduzida nos horizontes de 15 e 30 minutos, em que a previsão em picos abruptos de temperatura e umidade ao longo do dia se torna o maior desafio. Como mencionado anteriormente, esse comportamento acontece quando o horizonte é maior porque perturbações climáticas ocorridas após o intervalo de tempo de entrada do modelo não são levadas em consideração no cálculo da previsão. Ainda assim, a rede MLP foi capaz de capturar os padrões diários de temperatura e umidade nos três horizontes de previsão satisfatoriamente, confirmando sua adequação para a modelagem com dados da estação meteorológica externa.

#### **4.4 Aplicação do modelo final aos dados de temperatura e umidade da estação meteorológica externa**

Após a escolha do modelo baseado na rede MLP, que apresentou maior assertividade na predição dos padrões diários de temperatura e umidade na localidade da estufa dentre os modelos avaliados, este foi aplicado aos dados históricos da estação meteorológica externa.

A otimização de hiperparâmetros a partir da busca randômica foi feita novamente com os dados de temperatura, umidade e luminosidade da estação externa. A Figura 4.21 apresenta os RMSEs nas predições nas predições de temperatura (letra a) e umidade (letra b) de cada combinação de hiperparâmetros gerada durante a busca. Em relação à busca randômica da rede MLP treinada com dados internos da estufa, cujos resultados foram exibidos na Figura 4.4, houve um ligeiro aumento no viés dos erros observados. Enquanto os erros na predição de temperatura da maior parte das amostras da busca randômica com dados internos se situam em valores menores que 2°C, a maior parte dos erros da busca com dados externos se situa em valores menores que 2,5°C. Além disso, enquanto os erros na predição de umidade da maior parte das amostras da busca randômica com dados internos se situam abaixo de 8%, a maior parte dos erros da busca com dados externos se situa entre valores menores que 10%. Entretanto, observou-se uma menor variabilidade nos erros da busca randômica com dados externos. Enquanto os erros máximos de validação de temperatura e umidade da rede MLP treinada com dados internos foram 3,84°C e 21,91%, respectivamente, os erros máximos da rede MLP treinada com dados externos foram 2,48°C e 15,42%.



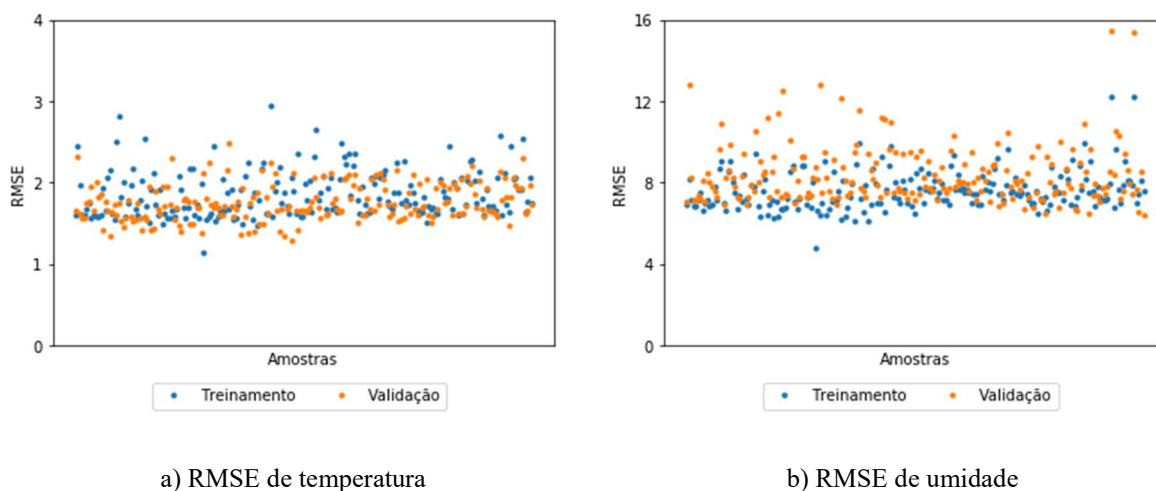


Figura 4.21. Erros das amostras geradas na busca randômica da rede MLP treinada com dados externos

Fonte: Elaborado pela autora, 2019

A Tabela 4.5 apresenta a configuração escolhida para a rede MLP a partir da busca randômica. A maior diferença observável entre essa configuração e a da rede MLP treinada com dados internos é a presença de duas camadas escondidas, apesar de que com cinco neurônios a menos em cada camada. O tamanho do batch de treinamento também foi reduzido de 500 para 250. Essas mudanças aumentam a complexidade do modelo e a sua capacidade de generalização, o que pode ter sido necessário para compensar certas diferenças entre os conjuntos de dados das estações meteorológicas internas e externa. Em primeiro lugar, o conjunto de dados externos, com aproximadamente 6600 amostras, é menor do que o conjunto utilizado na busca randômica com dados internos, que tem aproximadamente 11100 amostras. Ou seja, o modelo teve que ser capaz de aprender os padrões diários de temperatura e umidade da estufa a partir de uma quantidade menor de informação disponível. Em segundo lugar, os valores de temperatura e umidade internas a serem previstos pelo modelo são uma função direta dos dados utilizados na busca randômica com dados internos, como apresentado nas Eq. 3.2 e 3.3. Por outro lado, apesar de as condições ambientais externas influenciarem diretamente o clima interno da estufa, a correlação entre as variáveis desses dois ambientes não pode ser descrita com a simplicidade das Eq. 3.2 e 3.3. Ou seja, é necessário um modelo de maior complexidade para previsões futuras a partir dos dados externos.

Tabela 4.5: Combinação de hiperparâmetros escolhida para o modelo MLP treinado com dados externos da estufa

Hiperparâmetro	Valor
Nº de neurônios por camada	15
Nº de camadas escondidas	2
Tipo de função de ativação	ReLU
Tamanho do batch	250
Taxa de aprendizado	$10^{-4}$
Decaimento dos pesos	$5 \times 10^{-4}$

A Figura 4.22 apresenta as curvas em escala logarítmica da função de custo da rede MLP treinada com dados externos. O treinamento foi prolongado até 8000 épocas em função de ainda haver uma sutil redução nos RMSEs de treinamento e validação até esse ponto. Entretanto, assim como ocorreu com a rede MLP treinada com dados internos, a redução de erros mais expressiva ocorreu logo nas primeiras 1000 épocas de treinamento. Como mencionado anteriormente, a escala de normalização utilizada para a função de ativação ReLU foi [0,1].




Figura 4.22: Curva de aprendizado da rede MLP treinada com dados externos

Fonte: Elaborado pela autora, 2019

Foi avaliada a influência no RMSE da variação de apenas um hiperparâmetro da configuração escolhida por vez. As Figuras 4.23 e 4.24 apresentam o impacto de cada hiperparâmetro nas previsões de temperatura e umidade, respectivamente.




Figura 4.23. Influência da variação isolada de cada hiperparâmetro da rede MLP treinada com dados externos da estufa nos erros de predição de temperatura

Fonte: Elaborado pela autora, 2019

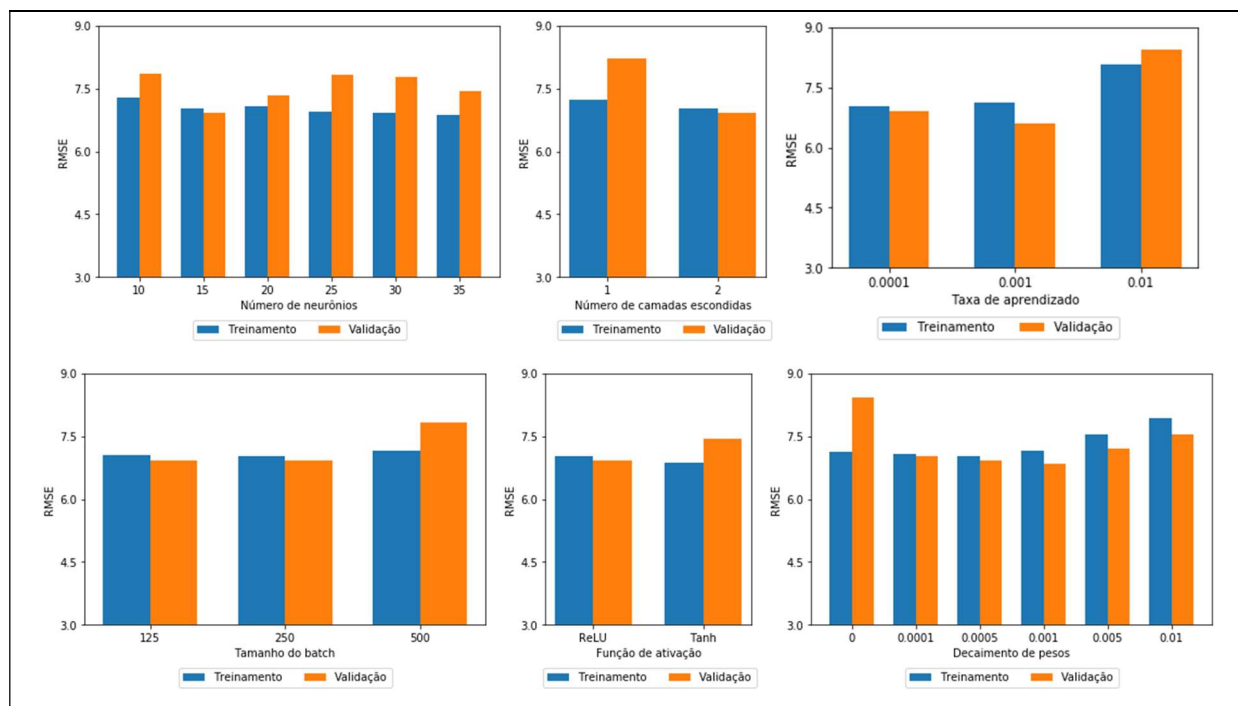


Figura 4.24. Influência da variação isolada de cada hiperparâmetro da rede MLP treinada com dados externos da estufa nos erros de predição de umidade

Fonte: Elaborado pela autora, 2019

A variação no número de neurônios impactou principalmente a predição de umidade, já que o único RMSE de validação abaixo de 7% ocorreu com 15 neurônios. Em ambas as predições de temperatura e umidade, o resultado foi mais satisfatório com o modelo com duas camadas escondidas – enquanto os erros de validação de temperatura e umidade com uma camada foram 1,88°C e 8,23%, respectivamente, os erros com duas camadas foram 1,57°C e 6,92%. Uma alta taxa de aprendizado (0,01) também teve um efeito negativo sobre o modelo, elevando os RMSEs para 1,98°C e 8,46%. As variações do tamanho do batch e da função de ativação só impactaram significativamente a predição de umidade, aumentando o erro de validação para 7,84% e 7,45%, respectivamente. Por fim, o modelo se mostrou sensível a variações no fator de penalização dos pesos. Os maiores erros de validação ocorreram para um decaimento nulo (1,85°C e 8,42%) e para um decaimento alto e igual a 0,01 (1,94°C e 7,53). O primeiro cenário favorece a ocorrência do fenômeno de *overfitting* e, o segundo, o aumento do viés do modelo.

A alteração de nenhum hiperparâmetro isolado resultou nos erros máximos apresentados na Figura 4.21. Entretanto, ambos RMSEs máximos de temperatura (2,48°C) e umidade (15,42%) nos dados de validação ocorreram em amostras com alta taxa de aprendizado (0,01)

e duas camadas escondidas. Isso indica que, apesar de que mais camadas escondidas propiciam a complexidade necessária para a rede MLP capturar os padrões de temperatura e umidade internos da estufa a partir de dados externos, também podem elevar essa complexidade a um patamar não desejável dependendo da sua interação com os outros hiperparâmetros, gerando *overfitting*.

As Figuras 4.25, 4.26 e 4.27 apresentam os RMSEs de teste ao longo das seis janelas de tempo dos dados meteorológicos externos para os horizontes de predição de 5, 15 e 30 minutos, respectivamente. A título de comparação, os RMSEs de teste da rede MLP treinada com dados internos da estufa referentes a essas mesmas janelas de tempo também foram exibidos nos gráficos.




Figura 4.25. Erros de predição de temperatura nos dados de teste no horizonte de 5 minutos

Fonte: Elaborado pela autora, 2019




Figura 4.26. Erros de predição de temperatura nos dados de teste no horizonte de 15 minutos

Fonte: Elaborado pela autora, 2019




Figura 4.27. Erros de predição de temperatura nos dados de teste no horizonte de 30 minutos

Fonte: Elaborado pela autora, 2019

Assim como na análise feita com os modelos treinados com dados internos da estufa, o desempenho da rede MLP treinada com dados externos também depende da janela de dados em que foi feita a avaliação. Por exemplo, na Figura 4.25, o RMSE da predição de umidade variou de 6,26% a 9,33%. Na Figura 4.27, o RMSE da predição de temperatura variou de 1,93°C a 2,39°C.

Os RMSEs da rede MLP treinada com dados externos da estufa foram maiores do que os da rede treinada com dados internos em todas as janelas de tempo de todos os horizontes de predição. Isso pode ser explicado pela menor quantidade de dados meteorológicos externos disponíveis, que compromete parcialmente o ajuste de pesos do modelo durante o treinamento, e pela complexidade da correlação entre os climas externo e interno da estufa. O primeiro fator pode ser solucionado pela aquisição de dados históricos por um período mais extenso, o que não foi possível nesse estudo devido a mudanças na operação da estufa experimental. O registro das medições das estações meteorológicas em banco de dados, para além da sua utilização instantânea no controle climático da estufa, se tornou uma funcionalidade paga da plataforma online utilizada na BeGreen, que optou por não seguir com essa modalidade. Entretanto, essa questão é facilmente endereçável caso os proprietários optem por seguir com o desenvolvimento do controlador antecipatório baseado em uma modelagem ainda mais precisa da estufa. O segundo fator, ainda que inerente se compararmos predições para o clima interno a partir de dados históricos internos e externos, pode ser minimizado. A repetição da busca randômica de hiperparâmetros da rede MLP com uma massa de dados de treinamento mais extensa pode levar à escolha de uma configuração distinta e que seja mais adequada à modelagem em questão.

Complementando Figuras 4.25, 4.26 e 4.27, a Tabela 4.6 apresenta os RMSEs e MAPEs médios de teste das previsões de temperatura e umidade. A tabela completa com os RMSEs e MAPEs médios relativos a dados de treinamento e validação se encontram no Apêndice B.

Tabela 4.6: Erro médio de predição de temperatura e umidade nos dados de teste ao longo das janelas de tempo do *backtesting*

Horizonte de previsão (minutos)	Temperatura		Umidade	
	RMSE	MAPE	RMSE	MAPE
5	1,78 ± 0,11	5,19 ± 0,41	7,34 ± 1,09	9,16 ± 1,62
15	1,93 ± 0,14	5,79 ± 0,55	8,36 ± 0,86	10,30 ± 1,67
30	2,11 ± 0,15	6,29 ± 0,68	9,43 ± 0,86	11,23 ± 1,23

Também foi observada a tendência de aumento dos erros ao longo das janelas de tempo com o aumento do horizonte de predição e, conseqüentemente, o crescimento da magnitude dos erros médios registrados na Tabela 4.6. A título de exemplificação, os MAPEs médios de temperatura foram 5,19%, 5,79% e 6,29% para os horizontes de predição de 5, 15 e 30 minutos, respectivamente. Os MAPEs médios de umidade foram 9,16%, 10,30% e 11,13% para os mesmos e respectivos horizontes. Entretanto, outro fenômeno observável nas Figuras 4.25 a 4.27 é que, com o aumento do horizonte de predição, os RMSEs da rede MLP treinada com dados externos cresceu a uma taxa menor do que os da rede treinada com dados internos. Por exemplo, enquanto o RMSE médio de temperatura do modelo externo cresceu de 1,78°C para 1,93°C (diferença de 0,15°C) aumentando-se o horizonte de predição de 5 para 15 minutos, o RMSE médio de temperatura do modelo interno cresceu de 0,99°C para 1,48°C (diferença de 0,49°C). Enquanto o RMSE médio de umidade do modelo externo cresceu de 7,34% para 8,36% (diferença de 1,02%), o RMSE médio de umidade do modelo interno cresceu de 3,99% para 6,14% (diferença de 2,15%). A Tabela 4.7 resume o aumento percentual dos RMSEs médios dos dois modelos, calculado com a Eq. 4.1:

$$Aumento \% = 100 \times \frac{RMSE_{H_2} - RMSE_{H_1}}{RMSE_{H_1}} \quad (4.1)$$

Em que  $H_2$  é o horizonte de predição diretamente maior do que o horizonte  $H_1$ . Ou seja, quando  $H_1$  é igual a 5 minutos,  $H_2$  é igual a 15 minutos. Quando  $H_1$  é igual a 15 minutos,  $H_2$  é igual a 30 minutos.

O aumento percentual do RMSE com o aumento do horizonte de predição foi expressivamente maior na rede MLP treinada com dados internos do que na rede treinada com dados externos. Enquanto os RMSEs de temperatura do modelo externo cresceram 8,43% e 9,33% com o aumento do horizonte de predição de 5 para 15 minutos e 15 para 30 minutos, respectivamente, os RMSEs do modelo interno cresceram 49,49% e 24,32%, respectivamente. Enquanto os RMSEs de umidade do modelo externo cresceram 13,90% e 12,80% com o aumento do horizonte de predição de 5 para 15 minutos e 15 para 30 minutos, respectivamente, os RMSEs do modelo interno cresceram 53,88% e 30,13%, respectivamente. Esse comportamento é indicativo do potencial da modelagem baseada em dados climáticos externos à estufa na predição do seu comportamento interno futuro. Ou seja, certas perturbações climáticas ocorridas em certo instante na localidade em que a estufa está instalada influenciaram as medições da estação meteorológica externa antes do que as das estações internas. Assim, o modelo baseado nos dados externos foi capaz de considerar o impacto dessas perturbações na previsão do clima da estufa em um horizonte mais extenso do que o modelo baseado nos dados internos.


Tabela 4.7: Aumento percentual dos RMSEs médios com o crescimento do horizonte de predição

Aumento do horizonte de predição	Aumento % do RMSE			
	Temperatura		Umidade	
	MLP-INT	MLP - EXT	MLP-INT	MLP - EXT
5 para 15 minutos	49,49%	8,43%	53,88%	13,90%
15 para 30 minutos	24,32%	9,33%	30,13%	12,80%

As Figuras 4.28 e 4.29 apresentam uma janela de dados de teste de temperatura e umidade e as predições feitas pela rede MLP nos horizontes de 5, 15 e 30 minutos. Essa janela é a mesma apresentada nas Figuras 4.19 e 4.20, relativas às predições da rede MLP treinada com dados das estações meteorológicas internas da estufa. Como se observa, a rede MLP foi capaz de capturar os padrões diários de temperatura e umidade nos três horizontes de predição. Entretanto, é evidente a menor aderência entre os valores reais e as predições do que no modelo

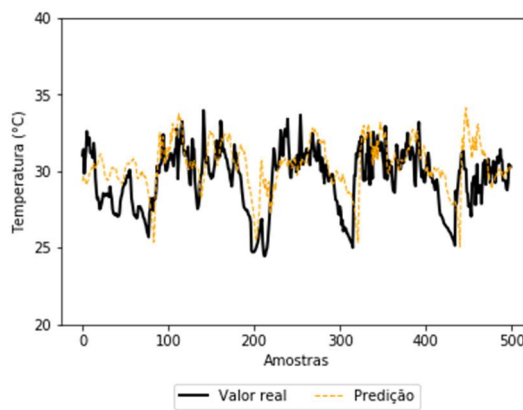


treinado com dados internos da estufa. Isso vem de encontro aos valores de RMSE mais altos do modelo treinado com dados externos, como exibido previamente nas Figuras 4.25 a 4.27.



a) Horizonte de predição de 5 minutos

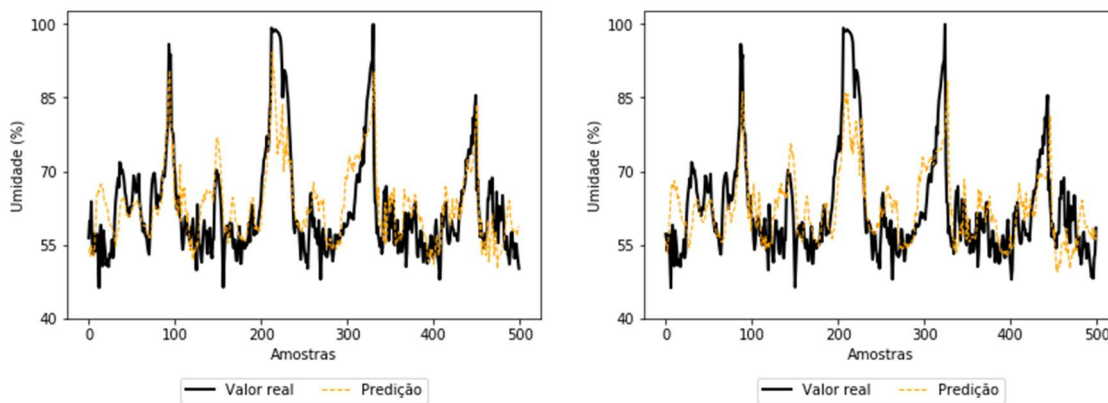
b) Horizonte de predição de 15 minutos



c) Horizonte de predição de 30 minutos


Figura 4.28. Comparação entre os dados reais de temperatura e as previsões da rede MLP treinada com dados externos da estufa

Fonte: Elaborado pela autora, 2019



a) Horizonte de predição de 5 minutos

b) Horizonte de predição de 15 minutos



c) Horizonte de predição de 30 minutos

Figura 4.29. Comparação entre os dados reais de umidade e as predições da rede MLP treinada com dados externos da estufa

Fonte: Elaborado pela autora, 2019

Com a retomada do registro de dados históricos de temperatura, umidade e luminosidade externas à estufa, é possível refazer a busca de hiperparâmetros do modelo e encontrar uma configuração que capture com maior precisão o comportamento climático da sua localidade. Além disso, uma maior massa de dados pode contribuir para um ajuste mais fino dos pesos da rede neural, já que haverá mais amostras de treinamento durante sua atualização. Esses fatores tendem a aumentar a aderência entre os valores reais e predições de temperatura e umidade, contribuindo para o desenvolvimento de uma estratégia de controle efetiva para a manutenção de condições climáticas internas da estufa favoráveis à agricultura hidropônica.

## 5 CONCLUSÕES

O presente trabalho apresentou o desenvolvimento de um modelo preditivo da temperatura e umidade internas de uma estufa localizada em Belo Horizonte, com o objetivo de apoiar o posterior desenvolvimento de uma estratégia de controle antecipatório para manutenção de condições climáticas favoráveis ao plantio hidropônico. Para o desenvolvimento desse estudo, foi feita a aquisição de dados históricos de temperatura, umidade e luminosidade com três estações meteorológicas dentro da estufa e uma estação localizada no seu ambiente externo.

Foi avaliada a adequação de três tipos de modelagem ao caso em estudo: um modelo baseado em SVR e outros dois baseados em redes neurais de arquiteturas MLP e LSTM. Essa avaliação utilizou dados históricos das estações meteorológicas internas, que por terem sido coletados por um período maior, possibilitaram uma análise mais profunda para escolha do tipo de modelagem a ser usada com os dados finais.

Primeiramente, foi feita uma busca randômica de hiperparâmetros dos modelos, que indicou a configuração mais apropriada de cada um deles para o cenário de dados históricos climáticos da estufa. O modelo baseado em SVR escolhido apresenta uma largura  $\epsilon$  da zona insensível igual a  $10^{-5}$ , função *kernel* do tipo RBF e fator  $C$  de penalização igual a 2. A rede neural de arquitetura MLP apresenta 20 neurônios por camada, 1 camada escondida, função de ativação do tipo ReLU, batch de treinamento de 500 amostras, taxa de aprendizado igual a  $10^{-4}$  e decaimento de pesos igual a  $5 \times 10^{-4}$ . A rede neural LSTM possui 20 neurônios por camada, 1 camada escondida, função de ativação do tipo tangente hiperbólica, batch de 125 amostras, taxa de aprendizado de  $10^{-3}$  e decaimento de pesos igual a  $10^{-4}$ .

Em seguida, foi realizado um *backtesting*, em que os modelos foram avaliados em diversas janelas de tempo dos dados e considerando três horizontes de predição (5, 15 e 30 minutos). Os RMSEs de treinamento dos modelos baseados em redes neurais se mantiveram aproximadamente constantes ao longo das janelas de tempo avaliadas, o que é indicativo de sua robustez. Por outro lado, o desempenho do modelo SVR se mostrou mais sensível ao conjunto de amostras utilizadas. Os RMSEs de validação e de teste de todos os modelos apresentaram uma maior variação em função das janelas de tempo do que os RMSEs de treinamento, o que foi um resultado esperado uma vez que essas predições foram baseadas no que os modelos aprenderam a partir de outro conjunto de dados. Outro comportamento observável foi a menor magnitude dos erros em horizontes de predição menores (por exemplo, os MAPEs médios de

temperatura da rede MLP foram 2,31%, 3,78% e 4,91% para os horizontes de 5, 15 e 30 minutos, respectivamente). Isso se deve ao fato de o valor real futuro a ser estimado ter maior chance de seguir a tendência aprendida pelo modelo se ele se encontrar menos distante cronologicamente do instante dos dados de entrada. Dentre os três modelos avaliados, a rede LSTM apresentou os erros mais baixos no horizonte de predição de 5 minutos, com RMSEs médios de 0,89°C e 3,76% nas predições de temperatura e umidade, respectivamente. Nos outros dois horizontes, os melhores desempenhos foram obtidos pela rede MLP, com RMSEs médios de 1,48°C e 6,14% na predição de 15 minutos e 1,84°C e 7,99%, na predição de 30 minutos. Além disso, os intervalos de confiança calculados a partir dos RMSEs médios apresentaram uma amplitude menor na rede MLP. Isso indica uma maior robustez do modelo, havendo menor variabilidade no desempenho alcançado em janelas de treinamento distintas. Portanto, a comparação entre os desempenhos médios de cada modelo obtidos a partir do *backtesting* levou à escolha da rede MLP como modelo final.

A busca randomizada e o *backtesting* foram realizados novamente com a rede MLP, porém utilizando os dados da estação meteorológica externa da estufa, que podem de fato ser aplicados ao desenvolvimento da estratégia de controle antecipatório. A nova arquitetura da rede MLP apresenta 15 neurônios por camada, 2 camadas escondidas, função de ativação do tipo ReLU, batch de treinamento com 250 amostras, taxa de aprendizado igual a  $10^{-4}$  e decaimento de pesos igual a  $5 \times 10^{-4}$ . Esses hiperparâmetros escolhidos a partir da busca randômica aumentaram a complexidade do modelo em relação à rede adaptada para os dados internos. Isso foi necessário em função da menor quantidade de dados externos disponíveis e à complexidade da correlação entre os climas externo e interno.

Os erros médios calculados após o *backtesting* foram superiores aos obtidos pela rede treinada com dados internos. Os RMSEs médios de temperatura e umidade no horizonte de 5 minutos foram 1,78°C e 7,34%, respectivamente. No horizonte de 15 minutos, esses valores subiram para 1,93°C e 8,36%, e no de 30 minutos, para 2,11°C e 9,43%. Entretanto, o aumento percentual desses erros com o aumento do horizonte de predição foi menor com o modelo treinado com dados externos. A título de exemplificação, com o aumento do horizonte de predição de 5 para 15 minutos, o RMSE de predição de temperatura do modelo interno aumentou 49,49%, enquanto o RMSE do modelo externo aumentou 8,43%. Isso indica a capacidade do modelo externo de capturar com antecedência perturbações climáticas na região da estufa que posteriormente afetarão o seu estado interno.

O modelo baseado na rede MLP desenvolvido neste trabalho pode ser utilizado na criação de um controlador antecipatório para a estufa experimental, contribuindo para a

manutenção de condições climáticas internas favoráveis ao crescimento das alfaces hidropônicas. Além disso, a continuação do registro climático da estufa com a estação meteorológica externa possibilita que a busca randômica de hiperparâmetros seja feita novamente e que a rede seja treinada com uma massa maior de dados, possivelmente aumentando o desempenho da modelagem na predição de temperatura e umidade.

## 6 REFERÊNCIAS

- Abdel-Ghani, A. M.; Al Helal, I. M.; 2011, Solar energy utilization by a greenhouse: general relations. In: *Renewable Energy*, Vol. 36, pp. 189-196.
- Araújo, S. A. C.; Deminicus, B.B.; 2009, Fotoinibição da Fotossíntese. In: *Revista Brasileira de Biociências*, Vol. 7, pp. 463-472.
- Barber, J; Bertil, A.; 1992., Too much of a good thing: light can be bad for photosynthesis. In: *Trends in Biochemical Sciences*, Vol. 17, pp. 61-66.
- Bot, G. P. A., 1991, Physical modelling of greenhouse climate. In: *Proceedings of the IFAC/ISHS Workshop*, pp. 7-12.
- Brosilow, C.; Joseph, B.; 2002, *Techniques of Model-Based Control (1ª Ed.)*. New Jersey: Prentice Hall.
- Cherkassky, V.; Mulier, F., 2007, *Learning from Data: Concepts, Theory, and Methods (2ª Ed.)*. New Jersey: Wiley-IEEE Press.
- Dariouchy, A.; Assif, E.; Lekouch, K.; Bouirden, L.; Maze, G.; 2018, Prediction of the intern parameters tomato greenhouse in a semi-arid area using a time-series model of artificial neural networks. In: *Measurement*, Vol. 42, pp. 456-463.
- Dey, R.; Salem, F. M.; 2017; Gate-variants of Gated Recurrent Unit (GRU) Neural Networks. In: *IEEE 60<sup>th</sup> International Midwest Symposium on Circuits and Systems*, pp. 1597-1600.
- Dreyfus G.; Martinez, J.M.; Samuelides, M.; Gorden, M.B.; Badran, F.; Thiria, S.; Hérault, L.; 2004, *Réseaux de neurones méthodologie et applications (2ª Ed.)*.
- Fan, C.; Zhang, Y.; Pan, Y.; Li, X.; Zhang, C.; Yuan, R.; Wu, D.; Wang, W.; Pei, J.; Huang, H.; 2019, Multi-Horizon Time Series Forecasting with Temporal Attention Learning. In: *25<sup>th</sup> ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. Anchorage, Alaska. pp. 2527-2535.
- Ferreira, P.M.; Faria, E.A.; Ruano, A.E.; 2002, Neural network models in greenhouse air temperature prediction. In: *Neurocomputing*, Vol. 43, pp. 51-75.
- Fourati, F., 2014, Multiple neural control of a greenhouse. In: *Neurocomputing*, Vol. 139, pp. 138-144.
- Geman, S.; Bienenstock, E.; Doursat, R.; 1992. Neural networks and the bias/variance dilemma. In: *Neural Computation*, Vol. 4, pp. 1-58.

- Glorot, X.; Bordes, A.; Bengio, Y.; 2011, Deep Sparse Rectifier Neural Networks. In: Proceedings of the 14<sup>th</sup> International Conference on Artificial Intelligence and Statistics, Vol. 15, pp. 315-323.
- Goodfellow, I.; Pouget-Abadie, J.; Mirza, M.; Xu, B.; Warde-Farley, D.; Ozair, S.; Courville, A.; Bengio, Y.; 2014, Generative Adversarial Nets. In: arXiv:1406.2661v1 [stat.ML].
- Goodfellow, I.; Bengio, Y.; Courville, A.; 2016, Deep Learning. Cambridge: MIT Press.
- Graves, A., 2014, Generating Sequences With Recurrent Neural Networks. In: arXiv:1308.0850v5 [cs.NE].
- Greff, K.; Srivastava, R.K.; Koutník, J.; Steunebrink, B.R.; Schmidhuber, J.; 2017, LSTM: A Search Space Odyssey. In: arXiv:1503.04069v2 [cs.NE].
- Haykin, S.; 2008; Neural networks and learning machines (3<sup>a</sup> Ed.). Hamilton: Pearson.
- He, F.; Ma, C.; 2010, Modeling greenhouse air humidity by means of artificial neural network and principal component analysis. In: Computers And Electronics In Agriculture, Vol. 71, pp. 19-23.
- Hodgson, L; Williams, T. J.; 2002, All About Greenhouses (1<sup>a</sup> Ed.) Des Moines: Wiley.
- Hongkang, W.; Li, L.; Yong, W.; Fanjia, M.; Haihua, W.; Sigrimis, N.A.; 2018, Recurrent Neural Network Model for Prediction of Microclimate in Solar Greenhouse. In: Ifac-papersonline, Vol. 51, pp. 790-795.
- Hsieh, K. L.; Lu, Y.S.; 2008, Model construction and parameter effect for TFT-LCD process based on yield analysis by using ANNs and stepwise regression. In: Expert Systems with Applications, Vol. 34, pp. 717-724.
- Isail, A. A.; Wood, T.; Bravo, H. C.; 2018, Improving Long-Horizon Forecasts with Expectation-Biased LSTM Networks. In: arXiv:1804.06776v1 [cs.LG].
- Janius, R. B.; Jenkins, B. M.; 2004, Determination of Greenhouse Time Constant Using Steady-state Assumption. In: Pertanika Journal of Science & Technology, Vol. 12, pp. 93-101.
- James, G.; Witten, D.; Hastie, T.; Tibshirani, R.; 2013, An Introduction to Statistical Learning with Applications in R (1<sup>a</sup> Ed.). Los Angeles: Springer.
- Jensen, M. H., 1997, Hydroponics. In: Hortscience, Vol. 32, pp. 1018-1021.
- Keras, 201-, Keras: The Python Deep Learning Library. Disponível em: < <https://keras.io/>>  
Acesso em: 27 de novembro de 2019.

- Kingma, D. P.; Ba, J. L.; 2015, Adam: A Method for Stochastic Optimization. In: arXiv: 1412.6980v9 [cs.LG].
- Jain, R., 1991, Art of Computer Systems Performance Analysis Techniques For Experimental Design Measurements Simulation And Modeling (1<sup>a</sup> Ed). New Jersey: John Wiley and Sons.
- Lahiri, S. K.; Ghanta, K. C.; 2008, The Support Vector Regression with the Parameter Tuning Assisted by a Differential Evolution Technique: Study of the Critical Velocity of a Slurry Flow in a Pipeline. In: Chemical Industry & Chemical Engineering Quarterly, Vol. 14, pp. 191-203.
- Lecun, Y.; Bottou, L.; Bengio, Y.; Haffner, P.; 1998, Gradient-Based Learning Applied to Document Recognition. In: Proceedings of the IEEE, Vol. 86, pp. 2278-2324.
- Mastalerz, J.W., 1977, The Greenhouse Environment: The Effect of Environmental Factors on the Growth and Development of Flower Crops (1<sup>a</sup> Ed.). New York: John Wiley and Sons.
- Masters, D.; Luschi, C.; 2018, Revisiting Small Batch Training for Deep Neural Networks. In: arXiv: 1804.07612, 2018.
- Matplotlib, 201-, Matplotlib. Disponível em: < <https://matplotlib.org/>>. Acesso em: 27 de novembro de 2019.
- Medsker, L. R; Jain, L. C.; 2000; Recurrent Neural Networks: Design and Applications (1<sup>a</sup> Ed.). CRC Press.
- Nelson, P. V., 2011, Greenhouse Operation and Management (7<sup>a</sup> Ed.). Raleigh: Pearson.
- Nielsen, B.; Madsen, H.; 1995, Identification of transfer functions for control of greenhouse air temperature. In: Journal Of Agricultural Engineering, Vol. 60, pp. 25-34.
- Numpy, 201-, Numpy. Disponível em: < <https://numpy.org/>>. Acesso em: 27 de novembro de 2019.
- Panchal, G.; Ganatra, A.; Kosta, Y. P.; Panchal, D.; 2011, Behaviour Analysis of Multilayer Perceptrons with Multiple Hidden Neurons and Hidden Layers. In: International Journal of Computer Theory and Engineering, Vol. 3, pp. 332-337.
- Pandas, 201-, Python Data Analysis Library. Disponível em: <<https://pandas.pydata.org/index.html>>. Acesso em: 27 de novembro de 2019.
- Python, 201-, What is Python? Executive Summary. Disponível em: <<https://www.python.org/doc/essays/blurb>>. Acesso em: 27 de novembro de 2019.




- Scikit-Learn, 201-, Scikit-Learn – Machine Learning in Python. Disponível em: <<https://scikit-learn.org/stable>>. Acesso em: 27 de novembro de 2019.
- Semolini, R., Support Vector Machines, Inferência Transdutiva e o Problema de Classificação. Dissertação de Mestrado. Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, Brasil, 2002.
- Smets, K.; Verdonk, B.; Jordaan, E.; 2007, Evaluation of Performance Measures for SVR Hyperparameter Selection. In: International Joint Conference on Neural Networks. Orlando, Florida. pp. 637-642.
- Srivastava, N.; Hinton, G.; Krizhevsky, A.; Sutskever, I.; Salakhutdinov, R.; 2014, Dropout: a Simple Way to Prevent Neural Networks from Overfitting. In: Journal of Machine Learning Research, Vol. 15, pp. 1929-1958.
- Taki, M.; Ajabshirchi, Y.; Ranjbar, S.F.; Rohani, A.; Matloobi, M.; 2016, Heat transfer and MLP neural network models to predict inside environment variables and energy lost in a semi-solar greenhouse. In: Energy And Buildings, Vol. 110, pp. 314-329.
- Taki, M.;Mehdizadeh, S.A.; Rohani, A.; Rahnama, M.; Joneidabad, M. R.; 2018, Applied machine learning in greenhouse simulation; new application and analysis. In: Information Processing In Agriculture, Vol. 5, pp. 253-268.
- Teixeira, H. T., Aprendizado por Reforço e Programação Dinâmica Aproximada com Máquinas Kernel para Controle de Sistemas não Lineares. Tese de Doutorado. Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, Brasil, 2016.
- Vapnik, V. N., 1998, The Nature of Statistical Learning Theory (2ª Ed.). New Jersey: Springer.
- Vu, Q. M., Automated Wireless Greenhouse Management System. Dissertação de Mestrado. School of Engineering and Advanced Techology, Massey University, Palmerston North, Nova Zelândia, 2011.
- Wang D.; Wang M.; Qiao X.; 2009, Support vector machines regression and modelling of greenhouse environment. In: Computers and Electronics in Agriculture, Vol. 66 pp. 46–52.
- Wang H.; Xu, D.; 2017, Support Vector Regression Based on Adaptive Fusion of the Mixed Kernel Function. In: Journal of Control Science and Engineering, Vol. 2017 pp. 1–12.
- Yu, H.; Chen, Y.; Gul H. S.; 2016, Prediction of the temperature in a Chinese solar greenhouse based on LS-SVM optimized by improved PSO. In: Computers and Electronics in Agriculture, Vol. 122, pp. 94-102.




## 7 APÊNDICE


### A. Dados de Temperatura, Luminosidade e Umidade dos Sensores

#### A.1 – Estação Meteorológica 2



#### A.2 – Estação Meteorológica 3





## B. Erro médio de predição ao longo das janelas de tempo do backtesting

### B.1 – Erros de predição de temperatura dos modelos treinados com dados internos da estufa

Horizonte de previsão (minutos)	SVR		MLP		LSTM	
	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
Treinamento						
5	1,09 ± 0,24	2,72 ± 0,96	0,95 ± 0,05	2,19 ± 0,17	0,84 ± 0,06	1,89 ± 0,16
15	1,69 ± 0,26	4,37 ± 0,93	1,44 ± 0,04	3,65 ± 0,12	1,29 ± 0,11	3,22 ± 0,3
30	2,05 ± 0,26	5,44 ± 0,92	1,73 ± 0,06	4,53 ± 0,18	1,38 ± 0,21	3,58 ± 0,57
Validação						
5	1,08 ± 0,34	2,74 ± 1,2	0,96 ± 0,24	2,22 ± 0,55	0,88 ± 0,21	2,01 ± 0,51
15	1,7 ± 0,35	4,45 ± 1,17	1,47 ± 0,23	3,73 ± 0,63	1,61 ± 0,35	4,1 ± 0,91
30	2,12 ± 0,4	5,74 ± 1,39	1,81 ± 0,29	4,81 ± 0,88	2,23 ± 0,39	6,03 ± 1,2
Teste						
5	1,1 ± 0,31	2,77 ± 1,08	0,99 ± 0,24	2,31 ± 0,59	0,89 ± 0,21	2,06 ± 0,55
15	1,71 ± 0,35	4,45 ± 1,11	1,48 ± 0,24	3,78 ± 0,72	1,63 ± 0,37	4,21 ± 1,12
30	2,13 ± 0,36	5,72 ± 1,20	1,84 ± 0,33	4,91 ± 0,98	2,25 ± 0,41	6,09 ± 1,35

## B.2 – Erros de predição de umidade dos modelos treinados com dados internos da estufa

Horizonte de previsão (minutos)	SVR		MLP		LSTM	
	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
<b>Treinamento</b>						
5	4,45 ± 0,55	5,1 ± 1,3	3,93 ± 0,23	4,47 ± 0,46	3,43 ± 0,35	3,71 ± 0,41
15	6,51 ± 0,78	8,16 ± 1,69	5,67 ± 0,2	6,88 ± 0,3	4,9 ± 0,61	5,95 ± 0,57
30	7,86 ± 0,77	9,98 ± 1,22	6,97 ± 0,29	8,72 ± 0,26	5,38 ± 0,9	6,78 ± 1,01
<b>Validação</b>						
5	4,12 ± 1,14	4,63 ± 1,83	3,89 ± 0,89	4,23 ± 0,93	3,65 ± 0,92	3,89 ± 1,08
15	6,65 ± 1,01	7,75 ± 1,35	6,01 ± 1	6,92 ± 0,9	6,72 ± 1,34	7,85 ± 1,37
30	8,56 ± 1,79	10,19 ± 2	7,82 ± 1,35	9,24 ± 1,35	9,47 ± 1,77	11,47 ± 1,96
<b>Teste</b>						
5	4,17 ± 1,02	4,69 ± 1,71	3,99 ± 1,07	4,3 ± 1,05	3,76 ± 0,91	3,99 ± 1,11
15	6,79 ± 1,26	8,06 ± 1,87	6,14 ± 1,03	7,04 ± 0,99	6,96 ± 1,79	8,15 ± 1,84
30	8,80 ± 1,56	10,4 ± 1,81	7,99 ± 1,28	9,36 ± 1,36	9,93 ± 2,03	12,02 ± 2,24

## B.3 – Erros de predição do modelo treinado com dados externos da estufa

Horizonte de previsão (minutos)	Temperatura		Umidade	
	RMSE	MAPE	RMSE	MAPE
<b>Treinamento</b>				
5	1,63 ± 0,02	4,26 ± 0,12	6,94 ± 0,13	8,91 ± 0,16
15	1,79 ± 0,03	4,76 ± 0,13	7,62 ± 0,14	9,79 ± 0,14
30	1,95 ± 0,02	5,29 ± 0,11	8,47 ± 0,12	10,87 ± 0,07
<b>Validação</b>				
5	1,77 ± 0,12	5,04 ± 0,36	7,72 ± 0,9	9,88 ± 1,56
15	1,92 ± 0,15	5,6 ± 0,47	8,29 ± 0,82	10,54 ± 1,58
30	2,09 ± 0,2	6,19 ± 0,69	9,39 ± 0,63	11,57 ± 1,42
<b>Teste</b>				
5	1,78 ± 0,11	5,19 ± 0,41	7,34 ± 1,09	9,16 ± 1,62
15	1,93 ± 0,14	5,79 ± 0,55	8,36 ± 0,86	10,30 ± 1,67
30	2,11 ± 0,15	6,29 ± 0,68	9,43 ± 0,86	11,23 ± 1,23