

**UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC  
CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT  
PROGRAMA DE PÓS-GRADUAÇÃO – DOUTORADO EM ENGENHARIA ELÉTRICA**

**MARCELO CAMPOS SILVA**

**DESENVOLVIMENTO DE CONTROLE PREDITIVO UTILIZANDO  
REDES-NEURAIS RECORRENTES COM APLICAÇÃO EM REFRIGERADORES  
RESIDENCIAIS**

**JOINVILLE**

**2023**

**MARCELO CAMPOS SILVA**

**DESENVOLVIMENTO DE CONTROLE PREDITIVO UTILIZANDO  
REDES-NEURAIS RECORRENTES COM APLICAÇÃO EM REFRIGERADORES  
RESIDENCIAIS**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências Tecnológicas da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do grau de Doutor em Engenharia Elétrica.

Orientador: Dr.<sup>a</sup> Mariana Santos Matos Cavalca  
Coorientador: Dr. Celso José Faria de Araújo

**JOINVILLE  
2023**

Campos Silva, Marcelo

Desenvolvimento de Controle Preditivo utilizando  
Redes-Neurais recorrentes com aplicação em  
Refrigeradores Residenciais / Marcelo Campos Silva. -  
Joinville, 2023.

114 p. : il. ; 30 cm.

Orientador: Dr.<sup>a</sup> Mariana Santos Matos Cavalca.

Coorientador: Dr. Celso José Faria de Araújo.

Tese (Doutorado) - Universidade do Estado de Santa  
Catarina, Centro de Ciências Tecnológicas, Programa de  
Pós-Graduação em Engenharia Elétrica, Joinville, 2023.

1. Controle Preditivo. 2. Rede Neural Artificial.  
3. Sistemas Térmicos. 4. Identificação de Sistemas. 5.  
Otimização Numérica. I. Santos Matos Cavalca, Dr.<sup>a</sup>  
Mariana. II. José Faria de Araújo, Dr. Celso. III.  
Universidade do Estado de Santa Catarina, Centro de  
Ciências Tecnológicas, Programa de Pós-Graduação em  
Engenharia Elétrica.

## **MARCELO CAMPOS SILVA**

### **DESENVOLVIMENTO DE CONTROLE PREDITIVO UTILIZANDO REDES-NEURAIS RECORRENTES COM APLICAÇÃO EM REFRIGERADORES RESIDENCIAIS**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências Tecnológicas da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do grau de Doutor em Engenharia Elétrica.

Orientador: Dr.<sup>a</sup> Mariana Santos Matos Cavalca  
Coorientador: Dr. Celso José Faria de Araújo

#### **BANCA EXAMINADORA:**

Dra. Mariana Santos Matos Cavalca  
CCT/UDESC

Membros:

Dr. Diego Santos Greff  
UFSC

Dr. Alexandre Garro Brito  
Nome da Instituição

Dr. Ademir Nied  
CCT/UDESC

Dr. José de Oliveira  
CCT/UDESC

Joinville, 31 de março de 2023

À minha família.

## AGRADECIMENTOS

Começo agradecendo à minha família pelo apoio nos momentos mais difíceis. Ao meu pai Mauro e mãe Anita por seu contínuo suporte e aos meus filhos Arthur e Nathália, que em tenra idade e muita energia, me ensinaram o sentido da vida e a importância de se viver intensamente cada detalhe.

À minha orientadora, Prof<sup>a</sup>. Mariana Cavalca por aceitar o desafio da orientação, seus direcionamentos e discussões valiosas, e ao meu Coorientador Prof. Celso Araújo por questionamentos precisos e pelas discussões acerca da vida.

Ao Prof. Ademir Nied pela compreensão e empréstimo dos equipamentos de laboratórios por vasto tempo.

Agradecimentos são ofertados ao Fabio R. Pimentel *Whirlpool Home Appliances* no Brasil pelo patrocínio do refrigerador bem como ao Eduardo Ortiga e Dietmar Erich Bernhard Lilie (*in memoriam*) Nidec Compressores pelo patrocínio do inversor de frequência utilizado nesta tese.

“A hora mais escura do dia é a que vem antes do sol nascer.” (Provérbio Árabe)

## RESUMO

A busca por eficiência energética e redução de complexidade nos componentes dos produtos de linha branca se intensifica a cada ano, especialmente em relação às geladeiras, que consomem a maior parte da energia elétrica destinada a esses produtos de linha branca. Neste contexto, apresenta-se uma proposta de algoritmo para melhorar o desempenho de uma geladeira de uso doméstico, através da fusão de conhecimentos contemporâneos de controle e termodinâmica, ferramentas computacionais validadas experimentalmente. É proposta uma topologia de controle preditivo não-linear, utilizando preditores bioinspirados, com otimizador numérico e horizontes de predição e controle finitos e restrições lineares do tipo rígidas, visando restringir o espaço de busca das soluções e ajustá-las aos desafios encontrados em um laboratório multidisciplinar. As premissas são fundamentadas em conhecimentos de sistemas térmicos para direcionar os trabalhos de identificação de sistemas, como seleção da topologia do regressor e auxiliar na busca e seleção das grandezas necessárias para identificar o preditor de temperatura. Uma rede neural artificial recursiva totalmente conectada em cascata (RNN+FCC) implementa este preditor de temperatura interna baseada em grandezas reais, como potências, frequências e temperatura ambiente. Este preditor de temperatura interna explica as dinâmicas do protótipo mesmo com perturbações, ou melhor, variações de cargas térmicas entre “vazio”, “pouca”, “total” utilizadas no treinamento da RNN. Via metodologia experimental adequada, encontra-se a frequência de amostragem compatível com as previsões requisitadas pelo controle. Filtros passa-baixas limpam eventuais ruídos de medições e o treinamento da rede neural compensa distorções de fase e ganho desses filtros. A validação da RNN classifica o modelo como aceitável, pois os erros entre modelo e medição de temperatura estão contidos em  $\pm 1^{\circ}\text{C}$ . A sintonia dos ganhos do controlador é realizada para minimizar os *overshoots* de temperatura durante os testes de dinâmica de controle na qual apresentam bons resultados dentro do espaço de inferência de utilização da geladeira. A jornada de testes em laboratório sempre esbarra em percalços que abrem novas perspectivas e propostas futuras que visam, além de melhorar o controle, detectar anormalidades e falhas. Esta tese discorre sobre um caminho, pavimentando a estrada entre as melhorias apresentadas hoje, solidificando a base para as oportunidades de amanhã.

**Palavras-chave:** Controle Preditivo; Rede Neural Artificial; Sistemas Térmicos; Identificação de Sistemas; Otimização Numérica.

## ABSTRACT

The search for energy efficiency and reduction of complexity in the components of white goods products intensifies every year, especially with regard to refrigerators, which consume the majority of the electrical energy used by these white goods products. In this context, a proposal is presented for an algorithm that improves the performance of a domestic refrigerator through the fusion of contemporary knowledge in control and thermodynamics, using rigorously validated computational tools. A non-linear predictive control topology is proposed, using bioinspired predictors, with numerical optimizer and finite prediction and control horizons and rigid linear constraints, aiming to restrict the search space of solutions and adjust them to the challenges encountered in a multidisciplinary laboratory. The premises are based on thermal systems knowledge to direct the system identification work, such as the selection of the regressor topology and assisting in the search and selection of the quantities necessary to identify the temperature predictor. A fully connected recursive artificial neural network in cascade (RNN+FCC) implements this internal temperature predictor based on real quantities such as power, frequency, and ambient temperature. This internal temperature predictor explains the dynamics of the prototype even with disturbances or thermal load variations between “empty”, “little”, and “full” that are used in RNN training. Via adequate experimental methodology, the sampling frequency compatible with the control’s required predictions is found. Low-pass filters clean up any measurement noise, and the neural network training compensates for phase and gain distortions of these filters. The validation of the RNN classifies the model as acceptable, as the errors between the temperature model and measurement are contained within  $\pm 1^{\circ}\text{C}$ . The controller gain tuning is performed to minimize temperature overshoots during the control dynamics tests, which show excellent results within the refrigerator’s utilization inference space. The laboratory test journey always encounters hurdles that open new perspectives and future work proposals that aim to detect abnormalities and failures in addition to improving control. This thesis paves the way between the improvements presented today, solidifying the base for tomorrow’s opportunities.

**Keywords:** Predictive Control; Artificial Neural Network; Thermal Systems; System Identification; Numerical Optimization.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Aparato de refrigeração proposto por Perkins em 1834 (PERKIN, 1834). . . . .	20
Figura 2 – Rede Neural Artificial do tipo Perceptron. Fonte: Autor (2020). . . . .	23
Figura 3 – Horizonte de iluminação de uma lanterna. Fonte: AUTOR (2021). . . . .	25
Figura 4 – Diferença entre motor e refrigerador. Fonte: AUTOR (2021). . . . .	28
Figura 5 – Ciclo de Refrigeração. Fonte: AUTOR (2021). . . . .	29
Figura 6 – Condução de calor entre duas fontes térmicas, baseada em (INCROPERA FRANK P., 2011). . . . .	31
Figura 7 – Modos de convecções forçada e natural. Fonte: (ÇENGEL, 2014). . . . .	33
Figura 8 – Gradiente de temperatura em convecção sobre um sólido, Fonte: (INCROPERA FRANK P., 2011). . . . .	33
Figura 9 – Condução de calor por radiação no vácuo, baseada em (INCROPERA FRANK P., 2011). . . . .	34
Figura 10 – Geladeira protótipo. Fonte: (BRASTEMP, 2021). . . . .	35
Figura 11 – Fluxo laminar em dutos, adaptado de (BEJAN, 2013). . . . .	36
Figura 12 – Multilayer perceptron MLP. Fonte: AUTOR (2021). . . . .	40
Figura 13 – Funções de ativação e suas derivadas. Fonte: AUTOR (2021). . . . .	41
Figura 14 – RNN totalmente conectada em cascata - FCC. Fonte: AUTOR (2021). . . . .	42
Figura 15 – RNN MLP com recorrência do tipo Jordan. Fonte: Autor (2021). . . . .	44
Figura 16 – RNN FCC com recorrência do tipo Jordan. Fonte: AUTOR (2021). . . . .	44
Figura 17 – Caminhos direto e reverso de treinamento. Fonte: AUTOR (2021). . . . .	45
Figura 18 – Algoritmo de treinamento de retropropagação do erro. Fonte: AUTOR (2021). . . . .	48
Figura 19 – Gerador de PRBS. Fonte: (AGUIRRE, 2015) . . . . .	50
Figura 20 – Referência de Frequência para o Compressor. Fonte: AUTOR (2021). . . . .	51
Figura 21 – Diagrama de Blocos de um Controle Preditivo. Fonte: AUTOR (2021). . . . .	53
Figura 22 – Ganhos com $N_y = 20$ . Fonte: AUTOR (2021). . . . .	59
Figura 23 – Função objetivo linear e convexa. Fonte: AUTOR (2021). . . . .	60
Figura 24 – Função objetivo não-linear. Fonte: AUTOR (2021). . . . .	62
Figura 25 – Função objetivo de testes de otimizador - <i>Himmelblau</i> . Fonte: AUTOR (2021). . . . .	63
Figura 26 – Função objetivo não-linear com restrições. Fonte: AUTOR (2021). . . . .	64
Figura 27 – Restrição do tipo <i>soft</i> - penalização adicional à função objetivo. Fonte: AUTOR (2021). . . . .	67
Figura 28 – Diagrama de Blocos de um Controle Preditivo implementando laço integrador externo. Fonte: AUTOR (2023). . . . .	70
Figura 29 – Ilustração de “Tubos” para avaliar a estabilidade de um controle preditivo. Fonte: (RAWLINGS DAVID Q. MAYNE, 2019). . . . .	73
Figura 30 – Diagrama de ligação. Fonte: AUTOR (2021). . . . .	74
Figura 31 – Estrutura do programa principal. Fonte: AUTOR (2021). . . . .	76

Figura 32 – Degraus <i>negativos</i> de velocidade de referência do compressor: a) 50 Hz, b) 100 Hz, c) 150 Hz. Fonte: AUTOR (2021).	77
Figura 33 – Correlações linear e não-linear com degraus de compressor: 50, 100 e 150Hz. Fonte: AUTOR (2021).	78
Figura 34 – Exemplo de uso de filtro nos sinais adquiridos. Fonte: AUTOR (2021).	79
Figura 35 – Lógica de empilhamento e preparação de arquivos. Fonte: AUTOR (2021).	80
Figura 36 – Evolução do <i>MSE</i> do “melhor” resultado de treinamento. Fonte: AUTOR(2021).	84
Figura 37 – Evolução do <i>MSE</i> do “pior” resultado de treinamento. Fonte: AUTOR(2021).	84
Figura 38 – “Melhor” caso de predição da RNN. Fonte: AUTOR (2021).	85
Figura 39 – “Pior” caso de predição da RNN. Fonte: AUTOR (2021).	85
Figura 40 – Resposta temporal restrições ao seu valor máximo. $\rho_e = 0.001$ , $\rho_{ei} = 1.0$ , $\rho_m = 0.007$ Fonte: AUTOR (2023).	89
Figura 41 – Resposta temporal restrições aplicadas. $\rho_e = 0.001$ , $\rho_{ei} = 1.0$ , $\rho_m = 0.002$ Fonte: AUTOR (2023).	90
Figura 42 – Resposta temporal restrições aplicadas. $\rho_e = 0.001$ , $\rho_{ei} = 1.0$ , $\rho_m = 0.001$ Fonte: AUTOR (2023).	91
Figura 43 – Resposta temporal com o reset de integrador do laço externo. Fonte: AUTOR (2023).	91
Figura 44 – Tempo excessivo de otimização violando os tempos de amostragem. Fonte: AUTOR (2023).	92
Figura 45 – Atuação da RNN fora do espaço de atuação. Fonte: AUTOR (2023).	93
Figura 46 – Perturbação com ar condicionado no laboratório. Fonte: AUTOR (2023).	94
Figura 47 – Experimento com evaporador bloqueado. Fonte: AUTOR (2023).	95
Figura 48 – Diagrama de ligação. Fonte: AUTOR (2021).	103
Figura 49 – Fluxograma Arduino. Fonte: AUTOR (2019).	105
Figura 50 – Sensor DS18B20. Fonte: Internet (2021).	106
Figura 51 – Medições de temperaturas dentro do congelador. À esquerda, freezer com gavetas montadas, ao centro, sem gavetas e com capa plástica e à direita, a evaporadora exposta e insuflador com medição de temperatura. Fonte: AUTOR (2021).	107
Figura 52 – Medições de temperatura no refrigerador, saída de ar frio e nos centros geométricos (suspenso) dos compartimentos. Fonte: AUTOR (2021).	107
Figura 53 – Medição de temperatura no retorno de ar "quente" no refrigerador, atrás da gaveta de legumes. Fonte: AUTOR (2021).	108
Figura 54 – Módulo Arduino para leitura de temperaturas usando termopares. Fonte: Internet (2021).	109
Figura 55 – Posicionamento dos termopares no produto indicados pelos círculos vermelhos. Fonte: AUTOR (2021).	110

Figura 56 – Módulo de relés para controle de ventilador e resistência de degelo. Fonte: AUTOR (2019). . . . .	111
Figura 57 – Módulo de relés para controle de ventilador e resistência de degelo. Fonte: AUTOR (2019). . . . .	111
Figura 58 – Wattímetro Yokogawa WT500. Fonte: Internet (2019). . . . .	111
Figura 59 – Diagrama de classes com conexões aos dispositivos. Fonte: AUTOR (2019). .	112

## **LISTA DE TABELAS**

Tabela 1 – Sensores para aquisição de dados. . . . .	37
Tabela 2 – Parâmetros da sequência PRBS, baseado em (AGUIRRE, 2015). . . . .	50
Tabela 3 – Sumário das funções de Computador, Arduino e Wattímetro WT500. Fonte: Autor (2021). . . . .	75
Tabela 4 – Sumário do Tempo de Amostragem. . . . .	76
Tabela 5 – Plano de teste para seleção de parâmetros da RNN. Fonte: AUTOR (2021). .	82
Tabela 6 – Resultados da seleção de parâmetros da RNN. Fonte: AUTOR (2021). . .	83

## LISTA DE ABREVIATURAS E SIGLAS

ASCII	Código Padrão Americano para o Intercâmbio de Informação do inglês, <i>American Standard Code for Information Interchange</i>
CARIMA	do inglês, <i>Controlled Auto-Regressive Integrated Moving Average</i>
COBYLA	do inglês, <i>Constrained Optimization BY Linear Approximation</i>
COP	<i>Coefficient of Performance</i>
DSP	Processador Digital de Sinais (do inglês <i>Digital Signal Processing</i> )
GPC	<i>Generalized Predictive Control</i>
MIMO	do inglês, <i>Multiple Inputs and Multiple Outputs</i>
MLP	do inglês, <i>Multi Layer Perceptron</i>
MPC	<i>Model Based Predictive Control</i>
MSE	erro quadrático médio, do inglês, <i>Mean Squared Error</i>
NI	<i>National Instruments</i>
PRBS	sinal binário pseudo randômico, do inglês, <i>Pseudo Random Binary Signal</i>
PWM	Modulação em largura de pulso (do inglês <i>Pulse Width Modulation</i> )
QP	do inglês, <i>Quadratic Programming</i>
RMS	raiz quadrada do erro quadrático médio, do inglês, <i>Root Mean Square</i>
RNA	Rede Neural Artificial
RNN	Rede Neural Artificial Recursiva
STD	devio padrão, do inglês, <i>Multi Layer Perceptron</i>
USB	<i>Universal Serial Bus</i>
VISA	<i>Virtual Instrument Software Architecture</i>

## LISTA DE SÍMBOLOS

$^{\circ}\text{C}$	Graus Celsius ( $^{\circ}\text{C}$ )
$Q_H$	Calor da fonte quente ( $J$ )
$Q_C$	Calor da fonte fria ( $J$ )
$S_H$	Fonte quente de calor ( $J$ )
$S_C$	Fonte fria de calor ( $J$ )
$\tau_W$	Trabalho térmico ( $J$ )
$\dot{Q}_{cond}$	Taxa de condução temporal de calor ( $W$ )
$A_s$	Área de seção normal ( $m^2$ )
$T_{s1}$	Temperatura de superfície 1 ( $^{\circ}\text{C}$ )
$T_{s2}$	Temperatura de superfície 2 ( $^{\circ}\text{C}$ )
$\delta s$	Espessura de substância entre superfícies ( $m$ )
$h_c$	Coeficiente de transferência de calor por convecção ( $W/m^2 \cdot ^{\circ}\text{C}$ )
$T_s$	Temperatura de superfície ( $^{\circ}\text{C}$ )
$T_{\infty}$	Temperatura no infinito, i.e. longe o suficiente de um dado ponto de interesse ( $^{\circ}\text{C}$ )
$f_H$	Função de ativação de camada oculta de redes neurais
$f_O$	Função de ativação de camada de saída de redes neurais
<b>O</b>	Vetor de saída de rede neural
<b>I</b>	Vetor de entrada de rede neural
<b>W</b>	Matriz de ganho entre camadas de rede neural
$\Sigma$	Potencial de ativação de rede neural
$f_H$	Função de ativação de camada oculta de rede neural
$f_O$	Função de ativação de camada de saída de rede neural
$f_x$	Função de ativação de camada oculada ou de saída de rede neural; de acordo com o seu uso
$f_s$	Frequência de amostragem ( $\text{Hz}$ )
$T_s$	Tempo de amostragem ( $s$ )
$r_{y^*}$	Operador de auto-correlação linear
$r_{y^{2*}}$	Operador de auto-correlação não-linear
$\eta$	Taxa de aprendizado de treinamento de RNA

$\delta_j$	Gradiente descendente calculado no treinamento de RNA
$\Delta u$	Incremento da variável de entrada ou incremento do sinal de controle
$u$	Variável de entrada ou sinal de controle
$N_u$	Horizonte de controle a partir de $k$
$N_y$	Horizonte final de predição a partir de $k$
$N_{y0}$	Horizonte inicial de predição a partir de $k$
$r$	Sinal de referência aplicado ao controlador
$y$	Sinal de medição da saída da planta controlada
$y_k$	Sinal de medição da saída da planta controlada no instante $k$
$J$	Função objetivo (função custo) total
$J_e$	Função objetivo com a parcela relativa ao erro de seguimento
$J_{ei}$	Função objetivo com a parcela relativa à integral do erro de seguimento
$J_u$	Função objetivo com a parcela relativa ao sinal absoluto de controle
$J_{\Delta u}$	Função objetivo com a parcela relativa ao sinal incremental de controle
$W_y$	Matriz ou vetor de ganhos ponderados para a função objetivo de rastreio
$W_u$	Matriz ou vetor de ganhos ponderados para a função objetivo de esforço absoluto de controlador
$W_{\Delta u}$	Matriz ou vetor de ganhos ponderados para a função objetivo de esforço incremental de controlador
$w_y(i)$	<i>iésimo</i> elemento da matriz ou vetor $W_y$
$w_u(i)$	<i>iésimo</i> elemento da matriz ou vetor $W_u$
$w_{\Delta u}(i)$	<i>iésimo</i> elemento da matriz ou vetor $W_{\Delta u}$
$\rho_e$	Ganho de penalização do erro de seguimento
$\rho_{ei}$	Ganho de penalização da integral do erro de seguimento
$\rho_m$	Ganho de penalização da variável (sinal) de controle
$n_{ma}$	Número de amostras utilizadas para cálculo do filtro de média móvel
$T_d$	Tempo de atraso de transporte (s)
$d$	Atraso de transporte, múltiplos de $k$ ( $k \cdot T_s$ )
$n_{opt}$	Espaço do sistema de otimização
$g_j(x)$	Restrição de inequidade para o otimizador
$h_j(x)$	Restrição de igualdade para o otimizador
$x_{barr}$	Definição de constante para penalização do tipo <i>soft</i>

$J_{soft}$	Função de restrição do tipo <i>soft</i> adiciona à função objetivo
$J_{barr}$	Restrição <i>soft</i> do tipo <i>barreira</i>
$K_{soft}$	Constante de restrição <i>soft</i>
$N_o$	Número de saídas do sistema utilizadas na função objetivo
$N_i$	Número de entradas do sistema utilizadas na função objetivo

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>20</b>
<b>2</b>	<b>SISTEMA TÉRMICO . . . . .</b>	<b>27</b>
2.1	TERMODINÂMICA E TRANSFERÊNCIA DE CALOR . . . . .	27
2.2	CICLO DE REFRIGERAÇÃO . . . . .	28
2.3	MODOS DE TRANSFERÊNCIA DE CALOR . . . . .	30
2.3.1	<b>Condução . . . . .</b>	<b>31</b>
2.3.2	<b>Convecção . . . . .</b>	<b>32</b>
2.3.3	<b>Radiação . . . . .</b>	<b>34</b>
2.4	GELADEIRA . . . . .	34
2.5	COMPRESSOR DE CAPACIDADE VARIÁVEL . . . . .	35
2.6	DUOTOS . . . . .	36
2.7	INSTRUMENTAÇÃO . . . . .	37
<b>3</b>	<b>IDENTIFICAÇÃO DE SISTEMAS . . . . .</b>	<b>38</b>
3.1	DESAFIOS DA MODELAGEM TÉRMICA . . . . .	38
3.2	REDES NEURAIS ARTIFICIAIS . . . . .	39
3.2.1	<b>Topologias . . . . .</b>	<b>39</b>
3.2.2	<b>Funções de Ativação . . . . .</b>	<b>41</b>
3.2.3	<b>Polinômio Equivalente . . . . .</b>	<b>42</b>
3.3	RECORRÊNCIA . . . . .	43
3.4	TREINAMENTO - <i>BACKPROPAGATION</i> . . . . .	45
3.5	RNA MALHAS ABERTA E FECHADA . . . . .	47
3.6	SELEÇÃO DO NÚMERO DE CAMADAS E UNIDADES . . . . .	48
3.7	FREQUÊNCIA DE AMOSTRAGEM . . . . .	49
3.8	SINAIS DE EXCITAÇÃO . . . . .	49
<b>4</b>	<b>CONTROLE PREDITIVO . . . . .</b>	<b>53</b>
4.1	HORIZONTE RETROCEDENTE . . . . .	54
4.2	OBTENÇÃO DA MALHA DE CONTROLE . . . . .	55
4.3	FUNÇÃO OBJETIVO . . . . .	57
4.4	OTIMIZADOR . . . . .	59
4.4.1	<b>Restrições . . . . .</b>	<b>63</b>
4.5	CONTROLE NÃO-LINEAR . . . . .	68
4.6	INTEGRADOR NO LAÇO EXTERNO . . . . .	69
4.7	AVALIAÇÃO DE ESTABILIDADE . . . . .	71
4.7.1	<b>Condição de Lipschitz . . . . .</b>	<b>71</b>
4.7.2	<b>Planta térmica aproximada com BIBO . . . . .</b>	<b>71</b>

4.7.3	<b>Redes Neurais</b> . . . . .	71
4.7.4	<b>Controle</b> . . . . .	72
<b>5</b>	<b>RESULTADOS EXPERIMENTAIS</b> . . . . .	74
5.1	<b>PROTÓTIPO</b> . . . . .	74
5.2	<b>IDENTIFICAÇÃO DE SISTEMAS</b> . . . . .	77
5.2.1	<b>Frequência de Amostragem</b> . . . . .	77
5.2.2	<b>Limpeza e Preparação de Dados</b> . . . . .	78
5.2.3	<b>Seleção de Entradas e Saídas da RNN</b> . . . . .	80
5.2.4	<b>Treinamento e Validação da RNN</b> . . . . .	81
5.3	<b>CONTROLE PREDITIVO</b> . . . . .	86
5.3.1	<b>Partida do controle</b> . . . . .	86
5.3.2	<b>Ajuste de Horizontes M e N</b> . . . . .	86
5.3.3	<b>Configuração das referências</b> . . . . .	87
5.3.4	<b>Restrições</b> . . . . .	87
5.3.5	<b>Ajuste do ganho do integrador externo</b> . . . . .	87
5.3.6	<b>Ajuste dos ganhos do Controle Preditivo</b> . . . . .	88
5.3.7	<b>Reset de integrador do laço externo</b> . . . . .	90
5.3.8	<b>Otimizador</b> . . . . .	90
5.3.9	<b>Tempo de otimização</b> . . . . .	92
5.3.10	<b>Condição Inicial</b> . . . . .	92
5.3.11	<b>Avaliação da Estabilidade</b> . . . . .	93
5.3.12	<b>RNN fora do seu espaço de inferência de treinamento</b> . . . . .	93
5.3.13	<b>Ventilação forçada sobre o evaporador</b> . . . . .	94
5.3.14	<b>Controle com evaporador bloqueado</b> . . . . .	95
<b>6</b>	<b>CONCLUSÕES E CONSIDERAÇÕES FINAIS</b> . . . . .	96
	<b>REFERÊNCIAS</b> . . . . .	99
	<b>APÊNDICE A – COMPONENTES DO PROTÓTIPO</b> . . . . .	103
A.0.1	<b>Seleção do produto como protótipo</b> . . . . .	103
A.0.2	<b>Arduino</b> . . . . .	104
A.0.3	<b>Instrumentação com sensores e atuadores no protótipo</b> . . . . .	104
A.0.4	<b>Temperatura das partes frias e externas</b> . . . . .	104
A.0.5	<b>Temperatura de partes externas e quentes do circuito de refrigeração</b> . . . . .	106
A.0.6	<b>Status de porta fechada ou aberta</b> . . . . .	109
A.0.7	<b>Controle de ventilador e de resistência de degelo</b> . . . . .	109
A.0.8	<b>Velocidades de referência do compressor</b> . . . . .	109
A.0.9	<b>Grandezas elétricas</b> . . . . .	109
	<b>APÊNDICE B – PROGRAMAS – ARDUINO &amp; PYTHON</b> . . . . .	112

<b>B.0.1</b>	<b>Python</b>	112
<b>B.0.2</b>	<b>Camada do controlador</b>	112
<b>B.0.3</b>	<b>Camada de comunicação serial</b>	113
<i>B.0.3.1</i>	<i>Protocolo serial</i>	113
<b>B.0.4</b>	<b>Camada de comunicação com Wattímetro WT500</b>	114

## 1 INTRODUÇÃO

Mesmo durante a pandemia da Covid19, houve aumento significativo da demanda mundial de energia elétrica - 8% em 2021 e 6% em 2022 utilizando diversas fontes renováveis e não renováveis (AGENCY, 2021). Está previsto que a demanda por energia elétrica utilizada para sistemas de refrigeração seja dobrada até 2050 (DUPONT et al., 2019). Nesse contexto, aumentar a eficiência energética de produtos como refrigeradores domésticos torna-se com elevada importância, pois, no Brasil, geladeiras são responsáveis por 31% do total de energia utilizada por todos os produtos de uso doméstico (SCHNÉ; JASKÓ; SIMON, 2018). A importância dos sistemas de refrigeração no dia a dia é inegável (MARCATO, 2019), seja no processamento, armazenamento e transporte de alimentos, na climatização de ambientes, em processos industriais e, mais recentemente, em componentes eletrônicos, a refrigeração está sempre presente. Para a Agência Internacional de Energia (IAE), as MEPs (em português, "Padrões Mínimos de Desempenho Energético") de países desenvolvidos, 70% da energia de uso doméstico é consumida por refrigeradores e ar condicionado (AGENCY, 2022);

O refrigerador residencial da atualidade utiliza os mesmos princípios propostos por Perkins em 1834, onde Perkins propôs um ciclo de refrigeração que utiliza a compressão de vapores em circuitos fechados capazes de operar continuadamente. A Figura 1 ilustra a proposição de Perkins de seu aparato.

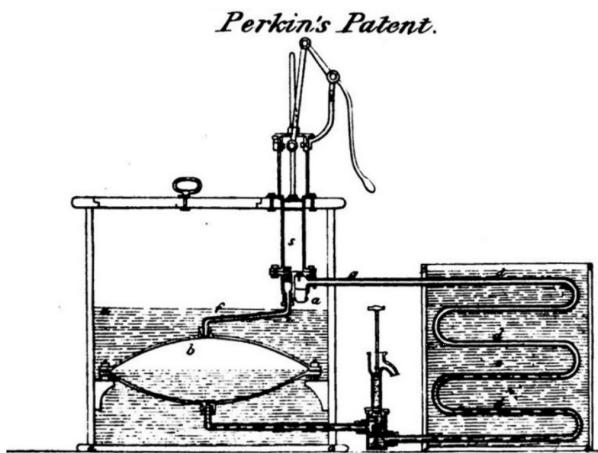


Figura 1 – Aparato de refrigeração proposto por Perkins em 1834 (PERKIN, 1834).

Fabricantes mundiais de refrigeradores produzem ao total, centenas de milhões de unidades anualmente (STATISTA, 2021), e cada fabricante possui quantidade limitada de modelos de refrigeradores. Dado o contexto industrial, estes modelos não são modificados rapidamente e, por questões estratégicas, reusam peças e componentes entre esses modelos. A metodologia proposta nesta tese, visa avaliar um modelo em particular. Com seus parâmetros levantados, pode-se simplificar aspectos construtivos, de testes e análises mais profundas, visando algumas características de interesse, como por exemplo: desempenho; eficiência; normas internacionais; características comerciais; entre outros. Sugere-se também que para novos modelos, esta

metodologia seja empregada para alcançar estes objetivos supracitados.

Revisando a literatura e discorrendo sobre soluções atuais de mercado, encontram-se históricos de substituição de termostato mecânico por implementações eletrônicas para implementar controle do tipo “*bang-bang*”, ou seja, onde controla-se o compressor aplicando uma histerese de temperatura. (JUNG; JEONG; YANG, 2014)(BEJARANO et al., 2018) e (HAMID; KAMAL; YAHAYA, 2009) avaliaram o uso de controles *PID*; estas técnicas têm vantagem de serem fáceis de implementar e utilizar poucos recursos computacionais, porém seus desempenhos tem acoplamentos com perturbações térmicas, além do fato de uma geladeira ser um sistema não-linear e controlador *PID* ser linear. Estudos recentes mostram o uso de controle preditivo para tomada de decisão de postergar o comando de compressor levando-se em conta a hora e preço da energia ao longo do dia, e das temperaturas de ambiente e interna. Com o auxílio da “Internet das Coisas”, (SABEGH; BINGHAM, 2019) adquire sinais com diversos sensores para decidir o momento de comandar o produto, enquanto (SCHNÉ; JASKÓ; SIMON, 2018) apresenta uma solução idêntica e com modelos menos sofisticados implementados em sistemas embarcados. Contextualizando o uso racional de energia verde com uso de controle preditivo, (MATTIA et al., 2022) avalia através de implementação em Matlab e validação em ambientes de “*Models-in-the-loop*” para decidir o momento armazenar energia ou refrigerar. De qualquer maneira, esses estudos mantém seu escopo na tomada de decisão de comando utilizando modelos de regressão baseados em médias móveis; esses modelos são distintos do que é implementado no controle preditivo desta tese.

Tornar o refrigerador residencial acessível, seja para adquirir ou mantê-lo funcional por sua vida útil é de importância considerável. Usar a engenharia para acelerar testes, encurtar tempos e baixar custos de testes de desempenho (LIMA, 2010) e de produto auxiliam a adquiri-los e melhorar a eficiência energética do refrigerador aumenta a sua acessibilidade. Para tal, é necessário alcançar um modelo representativo da planta, embasar a teoria termodinâmica e rigidez experimental para que todas as regras de identificação de sistemas sejam satisfeitas e assim, garantir a qualidade do modelo que será usado como preditor. Um dos objetivos desta tese é apresentar uma abordagem visando melhorias de eficiência energética de refrigeradores residenciais, identificando um modelo matemático representativo, e neste contexto, encontrar um conjunto de equações que modelem as dinâmicas de interesse de saída como função de entradas (AGUIRRE, 2015).

A identificação, como um processo específico de inferência estatística, explora dois tipos de informações: a primeira é o experimento em si e a outra, chamada de *a priori*, é o conhecimento existente antes de executar qualquer experimento (GREBLICKI, 2008). Muitos problemas em engenharia, especificamente aqueles associados a controle, podem ser divididos em quatro etapas inter-relacionadas:

1. Identificação de objetivos;
2. Determinação da posição atual em relação ao objetivo;

3. Determinação de fatores de ambiente que afetam o passado, o presente e o futuro e, consequentemente, o modelo do sistema;
4. Determinação de regras em harmonia com os objetivos definidos no Passo 1, conhecimento do estado atual no Passo 2 e modelos do sistema e ambiente do Passo 3.

Normalmente as regras definidas no Passo (4.) são determinadas no ponto ótimo (SAGE, 1971). O processo de identificar envolve testes comumente chamados de *teste da caixa*, onde a cor desta caixa é definida pelo nível de conhecimento previamente disponível. Identificação do tipo *caixa branca* é quando todo o conhecimento está definido antes de identificar o sistema, por exemplo, as equações analíticas que regem a física do sistema a ser experimentado. Identificação *caixa preta* é quando não há conhecimento prévio algum e é necessário explorar a planta o máximo possível para, de alguma forma, encontrar o modelo das dinâmicas de interesse. Identificação de *caixa cinza* e suas diferentes tonalidades é definida quando há algum conhecimento prévio da planta e, obviamente, quanto mais conhecimento prévio do sistema houver, mais clara será a tonalidade desta identificação. Esta classificação de cores é usada apenas para auxiliar na comunicação das identificações, pois, não há definição formal das cores na literatura.

A identificação de sistema utiliza um ou mesmo vários conjuntos de ferramentas matemáticas e, cabe ao engenheiro encontrar a ferramenta mais adequada ao problema que se deseja identificar. Salienta-se que, após identificar o sistema ainda é vital validar o modelo identificado para que as incertezas acerca do modelo sejam minimizadas ou mesmo mitigadas. Estas incertezas podem ocorrer devidas ao pouco conhecimento, modelos matemáticos insuficientes, ruído e contaminantes de dados adquiridos, etc.

Identificar um sistema, antes de qualquer atividade, é conhecer mentalmente os *mapas* de como as grandezas estão interligadas neste mesmo sistema; e usar a mente para inspirar algoritmos matemáticos que busquem obter a mesma capacidade de “pensamento”. Neste contexto, algoritmo matemático *bioinspirado* baseia a sua tomada de decisões, similar a comportamentos de organismos “pensantes” encontrados na natureza. O algoritmo que será utilizado para este fim, que se baseia em redes neurais biológicas, é o de redes neurais artificiais (RNA). As RNAs são altamente flexíveis e “aprendem” as relações entre as grandezas de alta complexidade (AGUIRRE, 2015).

“A Natureza é a fonte do conhecimento verdadeiro. Ela tem a sua própria lógica, suas próprias leis, ela não tem efeito sem causa ou invenção sem necessidade”, a frase foi supostamente postulada por Leonardo da Vinci e, mesmo séculos depois, tem servido como inspiração para inúmeros estudos, dentre os quais, os estudos *bioinspirados*. No presente contexto, aplica-se rede neural artificial para imitar uma rede neural do cérebro de um ser vivo para tomada de decisões.

Na década de 40 nos EUA, dois pesquisadores da Universidade de Illinois fizeram um sistema eletrônico capaz de ter comportamento análogo ao de células nervosas. Este estudo chamado de *threshold logic* foi publicado pelo Warren McCulloch e Walter Pitts, um neurofisi-

logista e um matemático respectivamente (MCCULLOCH, 1943). Este pode ser considerado o ponto de partida para o desenvolvimento das redes neurais artificiais.

Algumas décadas depois, em 1957, Frank Rosenblatt publicou o primeiro modelo de um *Perceptron* (ROSENBLATT, 1957), onde este modelo apresenta uma topologia de rede neural artificial que é utilizada até nos dias de hoje. Esta RNA é funcional mas tem algumas limitações, por exemplo, ela não pode ser expandida para problemas mais complexos, pois ela é capaz de apenas fazer classificações em sistemas lineares. Perdeu-se o interesse pela comunidade acadêmica, pois ela falhou ao classificar dados gerados a partir de funções *ou exclusiva - XOR*. Uma RNA com apenas uma camada é apresentada na Figura 2.

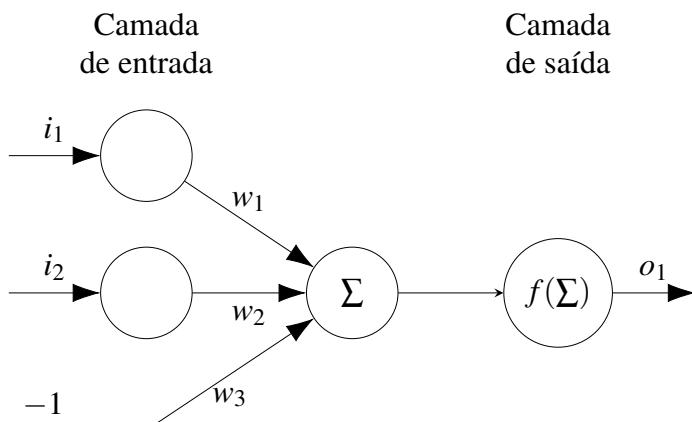


Figura 2 – Rede Neural Artificial do tipo Perceptron. Fonte: Autor (2020).

As entradas são definidas por  $i_1$ ,  $i_2$ ,  $-1$  e a saída  $O_1$ . A entrada fixa em  $-1$  é nomeada de viés (do inglês *bias*) e é utilizada para calcular o viés do neurônio ao ajustar o parâmetro  $w_3$ . O Neurônio é representado pela função de ativação  $f(\Sigma)$  aplicado ao potencial de ativação  $\Sigma$ . O potencial de ativação é simplesmente o produto escalar de vetores:  $\Sigma = I_1 \cdot w_1 + I_2 \cdot w_2 - w_3$ . Para fins de fluidez de leitura, o viés será omitido de todas as Figuras em diante, porém é utilizado no processo de treinamento e predição.

O advento do algoritmo de treinamento de RNA em 1975 (WERBOS, 1974), conhecido por *back-propagation*, colocou a RNA novamente sob os holofotes da comunidade científica, pois topologias mais complexas de RNA puderam resolver problemas mais complexos. Com a RNA em voga novamente, então, a academia desenvolveu, além de novas teorias de uso de RNA como modelo, mas também, controles mais sofisticados que empregam tais modelos para tomadas de decisões. Dentro deste novo campo que se abriu, destaca-se o controle preditivo baseado em modelos, que toma decisões no presente baseado em informações *futuras* preditas por estes modelos.

Com o modelo térmico validado, sua implementação é simples sistemas embarcados pois os neurônios selecionados necessitam de poucas instruções, e os microcontroladores da atualidade apresentam relativamente alto poder computacional com baixo custo financeiro. Esta abordagem torna-se interessante do ponto de vista industrial, pois, a eventual remoção do sensor interno de temperatura implica em altos valores a serem economizados pelo fabricante. Por

exemplo, mesmo que o custo individual de um sensor seja baixo, 2,00USD (dólares americanos) e um volume de produção de 500 mil geladeiras/ano tem-se uma economia direta do sensor; ainda há porém, custos indiretos como valores gastos e tempos com manufatura/instalação, logística de fornecimento, custos de “não-qualidade” com robustez de placa eletrônica impactada, até despesas com peças sobressalentes em estoque, e assistências técnicas espalhadas em um país com dimensões continentais como o Brasil. Estas são apenas alguns potenciais que o modelo a ser utilizado dentro do controle preditivo traz ao ser implementado.

O Controle Preditivo baseado em Modelo (do inglês *Model Predictive Control - MPC*) se desenvolveu consideravelmente, nos últimos anos, tanto na academia como na indústria. A razão para este sucesso pode ser atribuída ao fato que o MPC é, provavelmente, a maneira mais genérica de propor soluções para problemas de controle no domínio do tempo (CAMACHO, 1999). MPC é uma classe de algoritmos de controle em computador que utiliza explicitamente o modelo do processo para predizer respostas futuras da planta (QIN; BADGWELL, 2003), i.e., é um controlador que utiliza previsões e históricos, incluindo restrições, para tomada de decisões no presente momento.

O Controle Preditivo sob a implementação do Controle de Matriz Dinâmica (do inglês *Dynamic Matrix Control - DMC*) foi inicialmente apresentado pela indústria de Óleo e Gás em 1979 pela Shell (PRETT BRIAN L. RAMAKER, 1982) para então despertar o interesse da academia para desenvolver a teoria mais completa para o MPC. O termo MPC não define uma estratégia de controle em particular mas uma ampla gama de métodos de controle que fazem o uso explícito do modelo do processo para obter a lógica do sinal de controle através de minimização de uma função custo (CAMACHO, 1999).

Para ilustrar o conceito do MPC, pode-se fazer analogias com o andar de uma pessoa através de uma rua escura com e sem o advento da iluminação de uma lanterna. Ao andar, uma nova decisão é tomada a cada passo e, a iluminação da lanterna mostra ao caminho a ser percorrido bem como eventuais obstáculos. A lanterna é dotada de uma distância máxima, um horizonte, até onde o seu facho de luz alcança - na Figura 3 o horizonte é de 9 Passos à frente, i.e. do Passo 2 ao 11. Obviamente, a cada passo dado, o facho é deslocado um passo à frente: este é o conceito básico de *horizonte retrocedente*. Nesta situação, a linha pontilhada indica o caminho desejado e, com o horizonte até o Passo 11, a pedra ainda não foi iluminada, porém, ela poderá ser considerada de antemão na tomada de decisão tão logo esta for iluminada - felizmente no caso da figura, o caminho desejado desvia-se da pedra. Então, a pessoa computa as informações baseadas no caminho desejado, no caminho iluminado, no esforço da caminhada, eventuais obstáculos e até do histórico que fora andado até o momento. Uma vez de posse de todas estas informações, a pessoa toma a decisão ótima para dar o próximo Passo e então, repete-se o ciclo para a próxima tomada de decisão. Esta é o conceito de controle preditivo e, fazendo um paralelo para o controle clássico nesta rua, basta retirar a lanterna e a pessoa andar pela mesma rua. A pessoa toma decisão a cada passo também, porém, ela utiliza apenas as informações do passado e presente. Note que, eventualmente ela pode topar seus dedos do pé com obstáculos para então

tomar uma nova decisão. Em termos de comportamento normal de humanos; todas as pessoas sabem o quanto à frente deve-se prever eventos e quais as consequências de se fazer isto errado (ROSSITER, 2018).

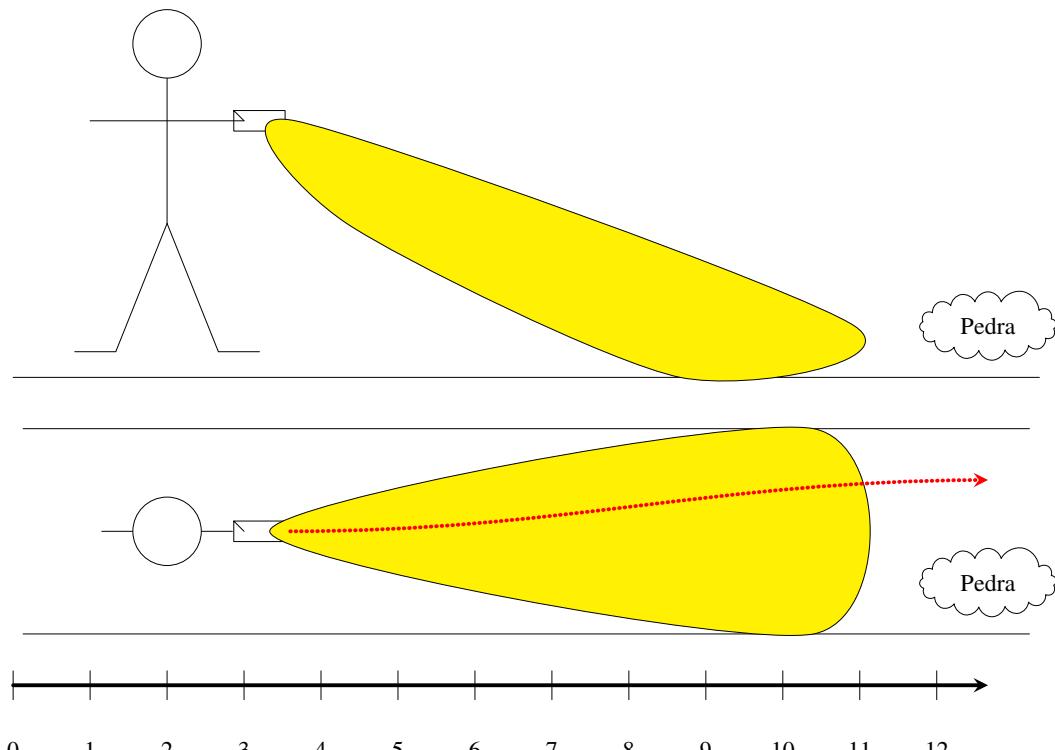


Figura 3 – Horizonte de iluminação de uma lanterna. Fonte: AUTOR (2021).

Ao comparar com outras técnicas, o MPC apresenta uma série de vantagens que se sobressaem (CAMACHO, 1999), tais como:

- atrativo para pessoas com conhecimento limitado de controle, pois, os conceitos do controlador bem como o ajuste de seus ganhos, são intuitivos;
- pode ser usado para controlar uma grande variedade de processos, desde aqueles com dinâmica simples até outros com dinâmicas mais complexas, incluindo sistemas com atrasos grandes, ou fase não-mínima ou mesmo instáveis;
- sistemas multivariáveis são relativamente simples de serem gerenciados;
- tem compensação intrínseca de pequenos tempos mortos ou tempos mortos conhecidos;
- é capaz de introduzir compensação direta (*feedforward*) para perturbações medidas;
- tratamento de restrições explícitas é conceitualmente simples e estas podem ser sistematicamente introduzidas durante o projeto dos controladores;
- especialmente útil quando referências futuras e trajetórias são previamente conhecidas;

- é uma metodologia ampla e aberta baseada em princípios simples que permitem desenvolvimento de futuras contribuições.

Ao condensar esses tópicos nessa tese, discorre-se brevemente sobre a implementação de um controle preditivo não-linear, que utiliza o modelo de rede neural artificial recursiva (*RNN*) com otimizador não-linear por aproximações lineares (*COBYLA*). As suas restrições foram ajustadas para acomodar o espaço de inferência do protótipo, pois, condições de altas e baixas velocidades implicavam em dificuldades de controle, seja por desligar o compressor inadvertidamente ou mesmo manter a variável controlada além do objetivo. O otimizador apresentou grande robustez numérica e tempo hábil de convergência, porém, mínimos locais foram identificados e contornados pela condição inicial do otimizador. Os ganhos do controlador foram testados até encontrar uma solução funcional, e durante esse processo de natureza lenta (devido ao processo térmico), percalços surgiaram no caminho abrindo desafios e novas oportunidades.

A contribuição desta tese se dá com a união dos conhecimentos multidisciplinares introduzidos acima que delimita o escopo desta tese para implementar o controle preditivo usando redes neurais artificiais recursivas como preditor de temperaturas futuras em um refrigerador residencial. O preditor de temperatura identificado é implementado como uma *RNA* recursiva (*RNN*) de séries temporais. Esta *RNA* utiliza um sensor interno e sensores externos ao produto como entrada de predição; ela ainda apresentou um resultado sólido de predição onde os erros de temperatura ficaram contidos no intervalo de  $\pm 1.0^{\circ}\text{C}$  e a característica de usar poucos neurônios torna factível a sua implementação em microcontroladores.

Salienta-se que quanto menor for o *custo computacional*, maiores serão as chances de implementar em um produto real. Considerando que se trata de uma tese multidisciplinar, pode-se implementar totalidade ou mesmo em partes. Por exemplo, o uso da *RNA* pode substituir o uso do sensor interno ao expandir os testes para aumentar o espaço de inferência dos dados de treinamento. Ainda abre possibilidade para implementar detecções de operação sob falha ou mesmo comportamentos anômalos. O controle por sua vez, via suas restrições, provê graus de liberdade extra para atender exigências de mercado, por ex., evitar determinadas frequências indesejadas de ressonância que causam desconforto acústico e assim, gastos extras de empresas com “reclamações de campo”.

Com o intuito de prover lógica à sequência de leitura desta tese, apresenta-se no Capítulo 2, os conceitos de sistemas térmicos necessários para conceituar a física regente a ser controlada; Capítulo 3 apresenta a teoria de identificação de sistemas utilizando redes neurais artificiais para então; ser incorporada ao controle preditivo proposto no Capítulo 4. O Capítulo 5 apresenta os resultados obtidos e os desafios práticos encontrados durante testes de identificação de sistemas e execução do controle preditivo. Por fim, conclui-se sobre os esforços e adiciona-se propostas futuras no Capítulo 6.

## 2 SISTEMA TÉRMICO

Um sistema térmico tem o seu estudo condensado em duas classes: 1) termodinâmica e 2) transferência de calor (CENGEL, 2014). Transferência de calor é a ciência que estuda as características de energia entre corpos materiais causadas por diferenças de temperatura. A termodinâmica ensina que esta energia é definida como *calor* e a transferência de calor é uma energia térmica em trânsito devido a uma diferença espacial de temperatura (INCROPERA FRANK P., 2011). O objetivo da transferência de calor não é meramente explicar como esta energia pode ser transferida, mas também avaliar as taxas *temporais* em que esta interação ocorre sob certas condições especificadas (HOLMAN, 1983).

### 2.1 TERMODINÂMICA E TRANSFERÊNCIA DE CALOR

Termodinâmica e transferência de calor são intimamente ligadas entre si e são áreas de conhecimento muito amplas. No contexto desta tese, é necessário que os conceitos básicos sejam sedimentados, pois, estes conceitos serão usados nos próximos capítulos. Estes dois campos são muito interessantes pois eles explicam como calor se comporta e flui em todas as substâncias. O calor é uma forma de energia que é transferida de uma fonte quente para um fonte mais fria (INCROPERA FRANK P., 2011) e, durante este processo passivo, esta energia executa trabalho; esta é a definição de um motor térmico.

O refrigerador, por sua vez, opera com fluxos de calor invertidos. Ele absorve calor da fonte fria, a transfere para a fonte quente e, assim, ele exige que trabalho seja injetado neste processo. Para ilustrar o conceito, analogias são feitas com motor e refrigerador térmicos usando uma represa de água com dois reservatórios de água em diferentes alturas. A fonte quente é o reservatório mais alto e o mais baixo é a fonte fria. Ao abrir a comporta, pela atuação da gravidade, a água escorrerá “de cima para baixo” e, durante este processo, o movimento da água (análogo ao fluxo de calor) pode ser capturado e gerar energia mecânica (trabalho) em um moinho, este é o análogo de um motor térmico. No caso de um refrigerador, bombeia-se a água do reservatório mais baixo da represa para o mais alto. O trabalho injetado pela bomba d’água faz com que o fluxo de água seja contra a gravidade e, assim, tem-se o análogo de um refrigerador pois o calor estaria sendo retirado da fonte fria e sendo transferido para a fonte quente.

A Figura 4 ilustra um motor térmico e um refrigerador térmico. Note que apenas as direções da energia são invertidas.

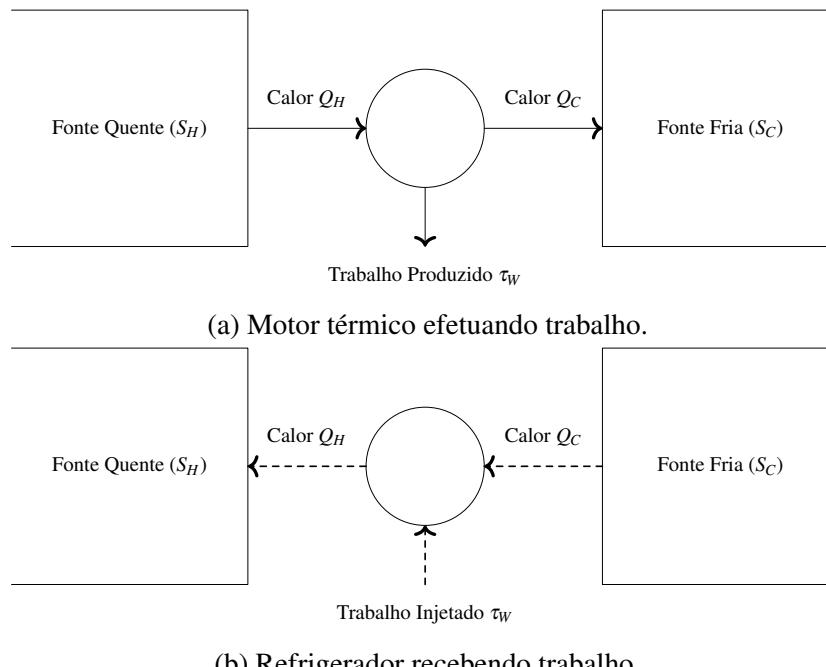


Figura 4 – Diferença entre motor e refrigerador. Fonte: AUTOR (2021).

## 2.2 CICLO DE REFRIGERAÇÃO

Define-se como um ciclo de refrigeração, o ciclo entre absorver e rejeitar calor continuamente. Para tal, emprega-se um gás refrigerante com propriedades físicas definidas de tal forma que ele absorva calor de um dado lugar quando expandir e que rejeite calor para outro lugar, quando condensar.

Um refrigerador residencial implementa um ciclo *fechado* de refrigeração, onde o ciclo com líquido pressurizado é convertido em vapor e de vapor para líquido (INCROPERA FRANK P., 2011), isto é, a massa de gás refrigerante contida em seus tubos é constante. Salienta-se também que o gás sofre mudanças de *estado físico* durante o ciclo térmico, ou seja, há apenas eventos físicos no gás refrigerante, pois não há reações químicas do gás.

Para tornar possível este ciclo, é necessário que alguns componentes sejam utilizados e o diagrama de blocos da Figura 5 ilustra estes componentes.

Nota-se que, o gás é circulado em um ciclo fechado através de componentes e estes componentes desempenham uma função específica contribuindo para o ciclo de refrigeração. As funções de cada componente podem ser summarizadas como:

1. Evaporador é um tipo de trocador de calor, pois é o local onde o gás expande em pressão constante e volume variável. Neste componente, o gás muda sua fase da mistura de líquido e vapor para apenas vapor e, durante a sua mudança de fase, o gás absorve o calor das suas adjacências forçando a temperatura diminuir drasticamente o seu valor. A evaporadora é o ponto mais frio do ciclo de refrigeração e ela está posicionada dentro do compartimento do congelador. Usualmente, o evaporador apresenta aletas com escoamentos *cruzados* de

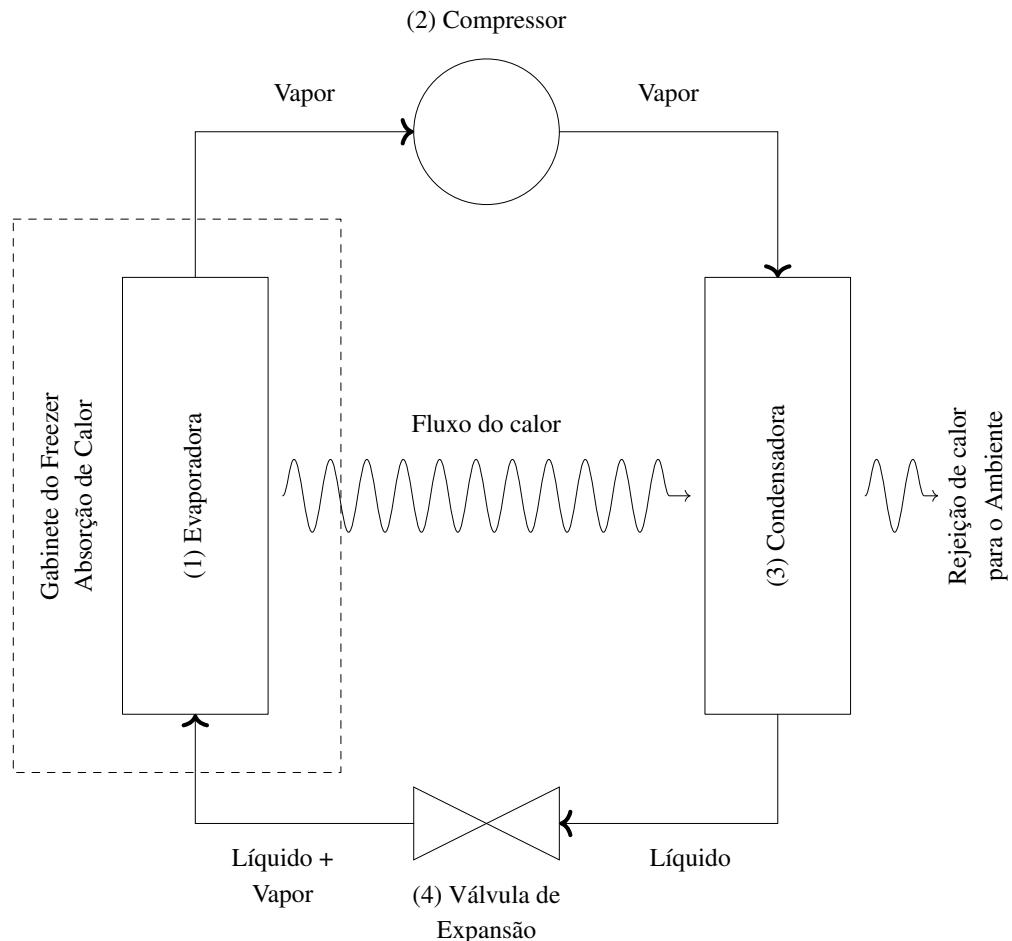


Figura 5 – Ciclo de Refrigeração. Fonte: AUTOR (2021).

ar unidirecionais (INCROPERA FRANK P., 2011).

2. Compressor é o componente que, como seu nome sugere, comprime o gás aumentando a sua pressão. Em sua entrada, nomeada de *sucção*, o vapor gás está em baixa pressão, é comprimido e então, o vapor em alta pressão é liberado pela sua saída (*descarga*). O Compressor adiciona *trabalho* ao ciclo, conforme ilustrado na Figura 4b, pois ele converte energia elétrica em pressão, e por conseguinte, calor. O gás neste estágio é chamado de *gás super aquecido* pois ele tem o calor absorvido durante a sua evaporação mais o calor injetado durante a sua compressão.
3. Condensador é outro tipo de trocador de calor e é o componente onde o gás condensa internamente, ou seja, ele muda de fase de gás para líquido. Durante a condensação do gás, o calor é então rejeitado para o ambiente. Vale salientar que para ocorrer a condensação é necessário que a temperatura do ambiente seja mais baixa que a temperatura do condensador e que, a esta diferença de temperatura determina a capacidade de rejeição de calor ou seja, quanto mais rejeitar, mais frio o gás retorna para o sistema e rápida é a queda de temperatura no evaporador.

4. Válvula de expansão é um dispositivo mecânico utilizado para reduzir a pressão do gás e iniciar o processo de expansão. Por questões de projeto, alguns evaporadores incorporam a função da válvula de expansão.

Como sumarizado, há dois trocadores de calor em um ciclo térmico nos quais foram projetados especificamente para aquela função, porém, todos os outros componentes trocam calor em maior ou menor grau mas suas funções primárias são outras. A capacidade de refrigeração é especificada pela capacidade de absorção e rejeição de calor e, o seu dimensionamento apropriado é de extrema importância pois o produto tem um valor econômico (HOLMAN, 1983). A seção a seguir discorre sobre como tais trocas podem ocorrer.

### 2.3 MODOS DE TRANSFERÊNCIA DE CALOR

Com os princípios básicos de um ciclo de refrigeração compreendidos, é importante conceituar os mecanismos de transferência de calor entre elementos. A transferência de calor é energia térmica em trânsito devido a uma diferença de temperatura no espaço (INCROPERA FRANK P., 2011). Estes conceitos ilustrarão os mecanismos que serão, de alguma forma, identificados no Capítulo 3 onde a modelagem térmica será tratada; adianta-se que, para modelar um sistema com alta confiabilidade, é importante conhecer quais parâmetros terão relação com a estrutura de modelo selecionado (AGUIRRE, 2015).

A primeira lei da termodinâmica determina que o calor pode ser apenas transferido, ou seja, ele não pode ser criado e nem destruído pois a sua energia é conservada. A segunda lei da termodinâmica postula que o calor flui da fonte mais quente para a fonte mais fria de forma *espontânea*, isto é, todos os processos térmicos são *irreversíveis* (BEJAN, 2013).

O calor é uma das várias formas que a energia pode assumir. No caso térmico, o calor está associado à energia interna e esta última pode ser entendida como a soma das energias cinética e potencial das moléculas. A parte da energia interna associada à energia cinética das moléculas é denominada *calor sensível*. A velocidade média e o grau de atividade das moléculas são proporcionais (CENGEL, 2014) e, quanto mais energia, maior a temperatura.

No Século XIX, o cientista James Prescott Joule elaborou um experimento que convertia, através de roldanas e espátulas, o trabalho gerado pela gravidade atuando em massas penduradas em energia térmica em um tonel de água. Ele definiu que a energia necessária para aumentar a temperatura em  $1^{\circ}\text{C}$  de 1 grama de água a  $14,5^{\circ}\text{C}$  como sendo 4,1868 *J ou Joules*; 1 *J* equivale a 1 *cal* e *J* é a unidade utilizada pelo Sistema Internacional *SI*. Foi definido também que  $1 \text{ J/s} = 1 \text{ W}$  ou *Watts*; *Watts* é a unidade de potência térmica.

Como o calor é definido como o grau de agitação de moléculas, então esta agitação pode ser *transferida* de uma molécula para a seguinte seguindo alguns mecanismos que são definidos a seguir.

### 2.3.1 Condução

A simples menção da palavra *condução* aponta para os conceitos de atividade molecular e atômica, pois processos neste nível mantém este modo de transferência de calor; a condução é vista como a transferência de energia das partículas mais energéticas para as menos energéticas e adjacentes de uma dada substância (INCROPERA FRANK P., 2011).

A geometria da substância é um fator importante para a transferência de calor, porém, para fins didáticos e sem perda de generalização dos conceitos necessários, os fluxos de calor serão aproximados por análise unidimensional e suas equações diferenciais simplificadas. Por conseguinte, suas soluções são obtidas mais facilmente (HOLMAN, 1983). A título de ilustração, posiciona-se uma fonte quente e uma fonte fria, e entre as duas fontes coloca-se uma substância planar conforme Figura 6.

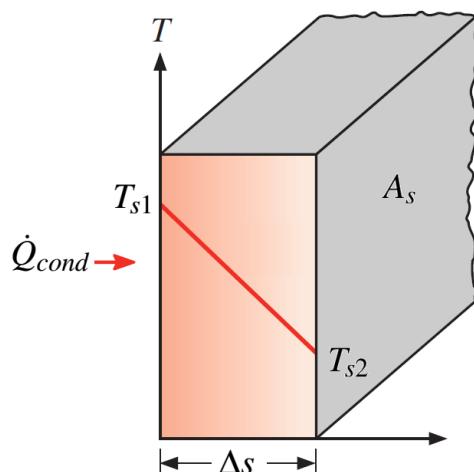


Figura 6 – Condução de calor entre duas fontes térmicas, baseada em (INCROPERA FRANK P., 2011).

Para modelar a taxa de condução<sup>1</sup> de calor, usa-se a equação:

$$\dot{Q}_{cond} = k_{cond} \cdot A_s \cdot \frac{T_{s1} - T_{s2}}{\Delta s} = -k \cdot A_s \cdot \frac{\Delta T_s}{\Delta s} \text{ W} \quad (1)$$

sendo, a área  $A_s$  ( $m^2$ ) normal ao fluxo de calor e espessura  $\Delta s$  ( $m$ ) entre as fontes de calor, a diferença de temperatura entre as duas fontes quente  $T_{s1}$  ( $^{\circ}\text{C}$  ou  $K$ ) e fria  $T_{s2}$  ( $^{\circ}\text{C}$  ou  $K$ ) e a condutividade térmica da substância  $k_{cond}$  ( $\text{W}/\text{m} \cdot \text{K}$ ); a relação indica que a condução de calor na direção de  $\Delta s$  é proporcional ao gradiente de temperatura decrescente e o *sinal negativo* assegura que a transferência de calor, na mesma direção, seja uma quantidade *positiva* (CENGEL, 2014). A condutividade térmica determina a *facilidade* com que o calor é transferido pela substância e ela é usualmente tabelada; em casos específicos, pode ser experimentada para quantificar o seu valor. Ao aplicar limite na Equação (1), chega-se à definição da *Lei de Fourier da condução térmica* conforme Equação (2).

<sup>1</sup> Para facilitar a leitura, as derivadas *temporais* são denotadas pelo operador *ponto*, ex.  $\dot{Q}_{cond}$ , e terão a variável tempo ( $t$ ) omitida.

$$\lim_{\Delta s \rightarrow 0} -k_{cond} A_s \frac{\Delta T_s}{\Delta s} = -k A_s \frac{dT_s}{ds} W \quad (2)$$

Para modelagem em equilíbrio, ou seja, quando o sistema não apresenta mais dinâmica, os valores médios são uma excelente simplificação para a modelagem, porém, um refrigerador sempre está operando em modo transitório.

Para maximizar a troca de calor entre o ambiente e componentes em um refrigerador, usa-se um sistema de aletas que envolvem os tubos do evaporador e do condensador. Neste caso, as aletas aumentam a área  $A_s$  entre evaporador e condensador com os ambientes de interesse. Apesar da Equação (2) ter solução trivial para problemas planares, a sua solução para sistemas *aletados* é complexa e demanda técnicas sofisticadas de soluções numéricas como computação de fluídos dinâmicas, em inglês *Computational Fluids Dynamics - CFD* (SHARMA, 2017).

### 2.3.2 Convecção

A convecção é o modo de transferência de energia entre uma superfície sólida e uma líquida ou um gás adjacente, que está em movimento e que envolve os efeitos combinados de *condução* e de *movimento de um fluido*; Quanto mais rápido o movimento do fluido, maior será a transferência de calor por convecção (CENGEL, 2014). O estudo da transferência de calor por convecção, requer, além de um balanço de energia, uma análise da dinâmica dos fluidos dos problemas considerados (HOLMAN, 1983), porém, salienta-se que o objetivo é desenvolver e sedimentar os princípios físicos envolvidos no processo de troca de calor por convecção.

A geração e manutenção de um fluxo exige o sacrifício de alguma força mecânica (trabalho disponível). De fato, a *destruição (sic)* de trabalho disponível utilizando o fluxo de um dado fluido é a razão termodinâmica para a existência da transferência de calor (BEJAN, 2013).

Para ilustrar a convecção, utiliza-se um sólido quente que transfere calor por condução para um gás que está em contato com este corpo aquecido; o gás na adjacência do corpo é então aquecido por condução. Como o calor aquece o gás e este expande, a sua densidade é diminuída fazendo com o que o gás aquecido “suba” e o frio “desça” e, este movimento do gás caracteriza a convecção.

A convecção é classificada como sendo: 1) natural e 2) forçada. A convecção natural é a troca de calor espontânea e apresenta uma baixa troca de calor entre as substâncias. No caso de um refrigerador e com o intuito de aumentar a troca de calor por convecção, adiciona-se o uso de ventiladores. A Figura 7 ilustra estes dois modos de convecção utilizando um ovo quente como corpo quente.

A grande diferença entre convecção normal e forçada é o fluxo de gás que atinge o sólido quente. A Figura 8 ilustra o gradiente de temperatura onde, o fluxo de ar se dá da esquerda para a direita escoando pela parte superior do bloco quente, e a temperatura do ar mais próximo  $T_s$  ao bloco quente é mais alta.

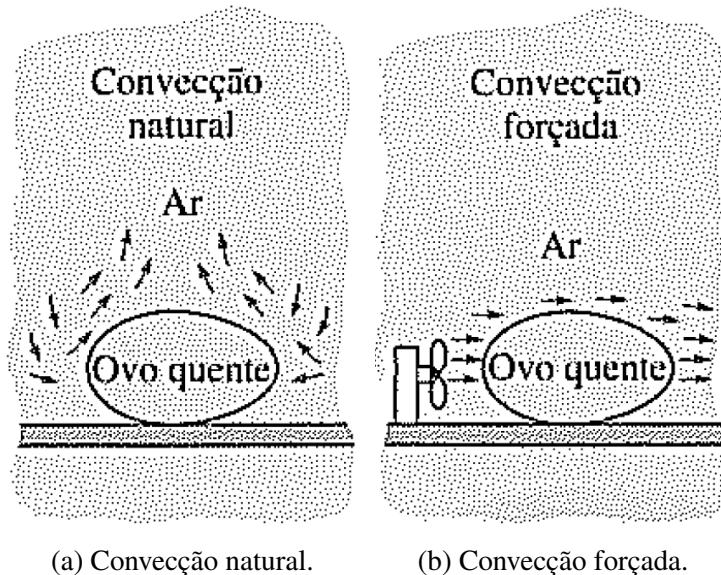


Figura 7 – Modos de convecções forçada e natural. Fonte: (CENGEL, 2014).

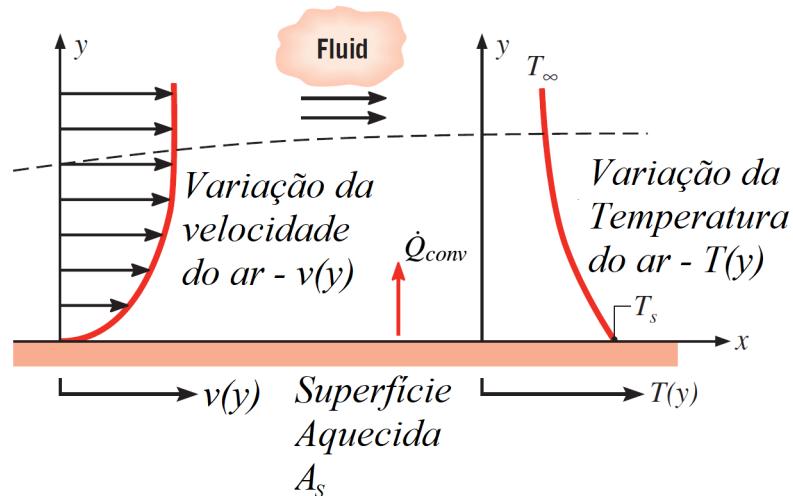


Figura 8 – Gradiente de temperatura em convecção sobre um sólido, Fonte: (INCROPERA FRANK P., 2011).

A convecção pode ser convenientemente expressa pela *lei de Newton do resfriamento*, ver Equação (3).

$$\dot{Q}_{conv} = h_c \cdot A_s \cdot (T_s - T_\infty) \quad J/s \quad (3)$$

onde  $h_c$  é o *coeficiente de transferência de calor por convecção* ( $W/m^2 \cdot ^\circ C$ ),  $A_s$  ( $m^2$ ) é a área de superfície em contato entre as substâncias,  $T_s$  ( $^\circ C$  ou  $K$ ) é a temperatura da superfície,  $T_\infty$  ( $^\circ C$  ou  $K$ ) é a temperatura do fluido suficientemente longe da superfície do sólido. A temperatura de superfície do sólido é igual a temperatura do gás em contato com ela. Vale salientar que o calor interno do sólido é transferido para a superfície por condução para então, ser transferido por convecção para o gás.

### 2.3.3 Radiação

É reconhecido que a transferência de calor ocorra por substâncias, seja por condução ou por convecção, e é natural que seus conceitos sejam absorvidos com uma certa facilidade, porém, a transferência de calor por radiação térmica não exige a presença de meio material (INCROPERA FRANK P., 2011).

Radiação é a energia emitida pela matéria sob a forma de *ondas eletromagnéticas* (ou *fótons*) como resultado das mudanças nas configurações eletrônica dos átomos ou moléculas; Ao contrário da condução e da convecção, a transferência de calor por radiação não exige a presença de um meio interveniente (CENGEL, 2014).

Ao colocar um corpo aquecido no vácuo, conforme mostrado na Figura 9, sabe-se que não haverá troca de calor por convecção ou condução, porém, a intuição aponta que a temperatura  $T_s$  atingirá o valor de  $T_\infty$  em algum momento. Esta troca de calor se dá unicamente por radiação.

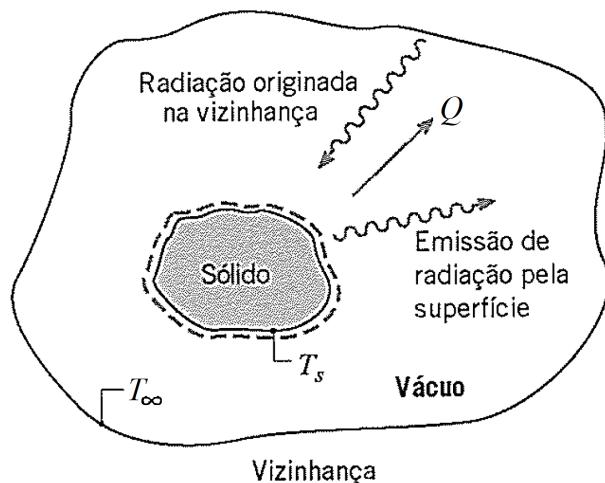


Figura 9 – Condução de calor por radiação no vácuo, baseada em (INCROPERA FRANK P., 2011).

Este mecanismo de transferência de calor não será abordado, pois o sistema utilizado é um refrigerador residencial e este, sempre proverá algum meio disponível para que o calor seja transferido, seja condução ou convecção. Isto não significa que a radiação não seja importante nas trocas de calor, como demonstram as diversas aplicações espaciais onde este é o único modo possível de transferência de energia (HOLMAN, 1983).

## 2.4 GELADEIRA

Define-se como produto no escopo desta tese, a união de todos os componentes para uma determinada finalidade; neste caso, uma geladeira. Assim, foi selecionada uma geladeira da marca Brastemp, modelo BRE50, que implementa um inversor de frequência para controlar a velocidade do compressor. Esta geladeira é classificada como *bottom mount*, ou seja, o congelador está localizado na parte inferior do produto, Figura 10.



Figura 10 – Geladeira protótipo. Fonte: (BRASTEMP, 2021).

Esta estrutura de produto é um pouco mais complexa, pois, conforme explicado na Seção 2.3.2, o ar frio tem a tendência de descer devido à densidade ser maior que o ar quente e a evaporadora está localizada dentro do congelador (compartimento inferior). O fabricante adicionou um ventilador para soprar o ar do congelador através das aletas do evaporador e canalizar este ar frio, através de um duto, para o refrigerador. Note que a convecção forçada é implementada como solução para fluir o ar frio para compartimentos superiores, aumentando a eficiência de transferência de calor do evaporador.

Através de um difusor de ar localizado na parte superior do refrigerador, este ar frio é insuflado dentro do compartimento do refrigerador. Após o ar frio entrar em contato e retirar o calor dos insumos localizados dentro do refrigerador, esta massa de ar retorna ao congelador para novo ciclo.

Para este ciclo, considera-se as portas fechadas. O abrir de ao menos uma das portas implica em uma perturbação térmica severa porque a massa de ar frio é perdida rapidamente para o ambiente que usualmente está em temperatura superior.

## 2.5 COMPRESSOR DE CAPACIDADE VARIÁVEL

Este modelo de geladeira foi selecionado pois ele utiliza um compressor alternativo do tipo *capacidade variável* instalado pelo fabricante. Este compressor é capaz de variar a rotação de seu rotor, variando assim, a quantidade de golpes de pistão por minuto e por conseguinte, o fluxo de massa de gás comprimido. Para fins de uma modelagem mais profunda de compressores, ver (GOMES, 2006).

Um inversor de frequência elétrica se faz necessário para variar a rotação de rotor e, dada a natureza do motor elétrico e dos conhecimentos de controle de motor a ímã permanente, sabe-se que a rotação real do rotor é diretamente proporcional à frequência elétrica de fase do

motor síncrono do compressor. Esta relação é definida por:

$$Rot(f_f) = \frac{60}{p} \cdot f_f \quad rpm \quad (4)$$

com  $p$  sendo o número de pares de polos magnéticos do motor do compressor e  $f_f$  a frequência elétrica (Hz) de fase do motor.

A rotação *instantânea* do compressor em um ciclo elétrico, mesmo que o sistema esteja em equilíbrio térmico em um calorímetro, varia abruptamente para extremos. Em um ciclo de compressor, a fase de admissão impõe pouca carga ao motor o que faz o rotor acelerar e, quando a fase compressão sobrecarregar novamente o rotor, este desacelera. Este perfil de carregamento do rotor acontece em uma revolução mecânica do rotor do motor. Felizmente, esta variação abrupta de rotação não influencia a temperatura porque a dinâmica de um sistema térmico é “lenta” se comparada à dinâmica elétrica.

## 2.6 DUTOS

Um duto é o caminho-guia do ar entre compartimentos de um refrigerador. A Figura 11 ilustra a distribuição do fluxo do ar em duto reto.

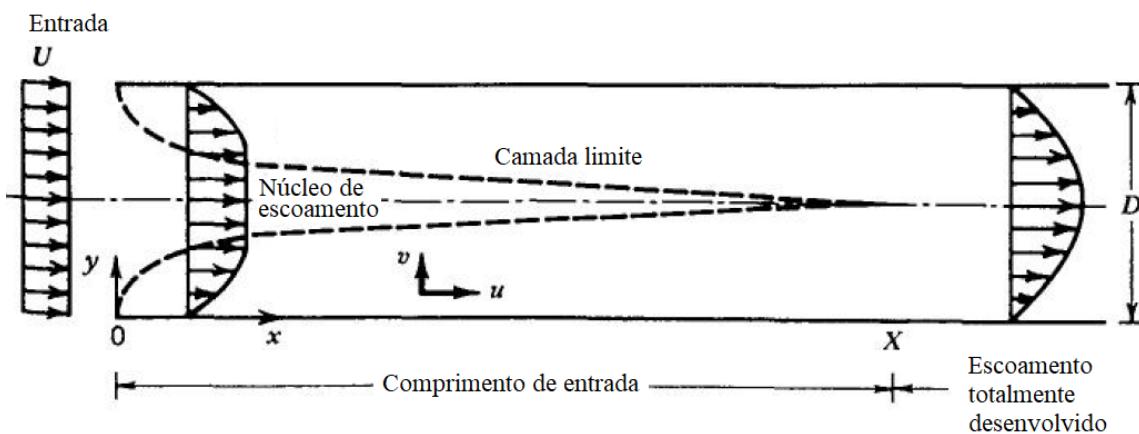


Figura 11 – Fluxo laminar em dutos, adaptado de (BEJAN, 2013).

O fluxo de ar  $U$  é gerado pelo ventilador que empurra o ar frio para dentro de um duto de comprimento  $X$  e altura  $D$ . Sem perda de generalização, o conceito está ilustrado em duas dimensões espaciais.

Como o fluxo de ar na entrada  $U$  é constante, o formato das linhas de fluxo sofrem modificações ao longo do duto. O fluxo de ar mais ao centro do duto terá uma velocidade maior de saída, pois, os fluxos adjacentes às paredes sofrem perdas de velocidade por atrito, porém a velocidade média das linhas de fluxo são constantes (BEJAN, 2013).

Por convecção, há perdas térmica para as paredes dos dutos e esta é relativamente baixa dada a substância superficial dos dutos ter uma baixa condutividade térmica e ser encoberta com material isolante poroso.

## 2.7 INSTRUMENTAÇÃO

Instrumentar significa implementar sensores e atuadores para que auxiliem a alcançar o objetivo esperado. O protótipo é implementado a partir de um produto comercial, que originalmente contém sensores instalados de fábrica, porém, foram adicionados mais sensores para capturar outras informações relevantes aos experimentos. A Tabela 1 contém a lista de todos os sensores.

Tabela 1 – Sensores para aquisição de dados.

#	Grandezas	Descrição
1	Temperatura [ $^{\circ}\text{C}$ ]	Temperatura de saída do difusor de ar frio
2	Digital [ <i>Open/Closed</i> ]	Sensor de <i>status</i> de porta aberta
3	Temperatura [ $^{\circ}\text{C}$ ]	Temperatura de saída do evaporador, usada pela rotina de degelo
4	Temperatura [ $^{\circ}\text{C}$ ]	Temperatura do ar ambiente
5	Temperatura [ $^{\circ}\text{C}$ ]	Temperaturas das linhas de sucção e descarga do compressor (colado nos tubos metálicos)
6	Temperatura [ $^{\circ}\text{C}$ ]	Temperatura de entrada e saída do evaporador (colados nos tubos metálicos)
7	Temperatura [ $^{\circ}\text{C}$ ]	Temperatura no centro geométrico do compartimento superior e intermediário do refrigerador
8	Temperatura [ $^{\circ}\text{C}$ ]	Temperatura no centro geométrico da gaveta superior do congelador
9	Temperatura [ $^{\circ}\text{C}$ ]	Temperatura de retorno do refrigerador para o congelador
10	Temperatura [ $^{\circ}\text{C}$ ]	Temperatura de retorno do ar do ventilador do congelador
11	Tensão [V]	Tensão média da rede
12	Frequência [Hz]	Frequência elétrica da fase do compressor
13	Potência ativa [W]	Potência elétrica de <i>entrada</i> do inversor

O sensor que está posicionado em fluxo mais alto de ar - próximo à saída do difusor de ar - necessita de atenção especial pois se ele se deslocar espacialmente, leituras divergentes de temperatura entre testes poderão ocorrer. Este deslocamento espacial incorre em valores diferentes de convecções, por exemplo, na Figura 11, a velocidade do vento é mais alta ao centro do tubo, e.g. na *linha pontilhada “Core”* e, mais baixa próximo às paredes do tubo, o que faz o sensor “sentir” temperaturas diferentes pois eles sofrem distintas transferências de calor por convecção.

### 3 IDENTIFICAÇÃO DE SISTEMAS

A planta a ser identificada é a geladeira descrita no Capítulo 2. Apesar de ela ser um sistema térmico com dinâmicas *lentas*, ela é multidisciplinar ao envolver variáveis térmicas, mecânicas e elétricas. O objetivo é desenvolver um preditor de temperaturas futuras baseadas no histórico de medições das grandezas conforme será abordado neste capítulo.

#### 3.1 DESAFIOS DA MODELAGEM TÉRMICA

Conforme apresentado no Capítulo 2, modelagem térmica implica em inúmeros desafios devido à dificuldade de efetuar medições de estados internos da planta, como rotação instantânea real do compressor, geometrias com tolerâncias diferentes entre unidades, empuxo de ventiladores, etc. Todavia, a identificação deve considerar apenas as informações relevantes para o problema proposto.

Muitos desafios podem ser enumerados quando se considera variação e tolerância entre refrigeradores. Restringindo os trabalhos a apenas um refrigerador disponível no laboratório da universidade, ainda haverão desafios a serem cobertos ou mesmo delimitados.

Ao observar o refrigerador, elencam-se algumas hipóteses que afetam diretamente ou indiretamente as grandezas de interesse:

- rotação instantânea do compressor variando de -40% a +30% dentro de uma revolução mecânica resultando em variações instantâneas do fluxo de massa de gás refrigerante dentro do sistema de refrigeração;
- densidade do isolante térmico não homogênea dentro das paredes do refrigerador ocasionando diferentes perdas de calor ao longo do produto para o ambiente;
- evaporador e condensador com gradiente térmico durante o transitório de temperatura implicando em dificuldade de modelagem e seus efeitos pontuais deste gradiente;
- rotação de ventilador do evaporador com variação não-linear de velocidade ocasionada pelas variações normais de tensão de alimentação e frequência;
- gradiente de fluxo de ar dentro do duto com saída para o difusor de ar do refrigerador;
- posicionamento físico do sensor de temperatura dentro da tubulação, vide item anterior;
- variação da temperatura e umidade ambientes bem como fluxo de ar do mesmo.

Muitos dos efeitos elencados são modelados com alto nível de confiabilidade utilizando a técnica de modelagem da dinâmica de fluido computacional, do inglês *Computational Fluid Dynamics - CFD*. *CFD* tem por objetivo soluções numéricas de equações diferenciais que regem o fluxo de massa, momento e energia em fluidos (DATE, 2005). A técnica de modelagem *CFD*

consome muito recurso computacional e o seu escopo está além desta tese. Mais detalhes sobre *CFD* podem ser vistos em (SHARMA, 2017).

Uma contribuição significativa, tornando atraente a metodologia proposta, advém do fato que, toda a complexidade de modelagem de um sistema térmico, somada à necessidade de obter a temperatura interna para controle, pode ser abstraída pelo modelo identificado nesta seção. Para fins de comercialização, o sensor de temperatura pode ser removido, acarretando em custos de componente, montagem e falhas de campo. Caso mantenha-se o sensor, esse pode ser usado como entrada para o sistema identificado para prever temperaturas futuras tal qual o controle requisita e também, alimentar outros modelos para detectar falhas, como por exemplo, evaporadora bloqueada, perda de gás do sistema de refrigeração entre outros. Valendo-se da baixa complexidade computacional e do fato das dinâmicas térmicas serem lentas, a sua implementação em microcontroladores convencionais torna-se atraente para a sua comercialização.

Com o objetivo de relaxar os requisitos para clarear a tonalidade da caixa que está sendo identificada, são considerados os princípios físicos para restringir o espaço de inferência. As grandezas que variam instantaneamente serão tratadas como grandezas médias para o processo de identificação. Por exemplo, rotação média será considerada, pois a temperatura sentida pelo sensor varia muito mais devagar que a rotação instantânea do compressor, todavia, o uso da rotação média de vários segundos minimiza ruídos de medição da rotação instantânea.

Por fim, o modelo deve ter baixa complexidade computacional para ter sua implementação factível em um processador de sistema embarcado, conforme será visto nas próximas seções.

## 3.2 REDES NEURAIS ARTIFICIAIS

Uma Rede Neural Artificial é extremamente flexível para realizar regressão ou classificação; esta característica habilita a sua seleção com ferramenta para o problema proposto. Isso é muito interessante pois abre caminho para identificar sistemas não-lineares sem apresentar singularidades em seu polinômio equivalente onde a RNA será usada como um regressor.

Com a evolução dos computadores, novas funções de ativação foram desenvolvidas, e que divergiram do conceito bioinspirado e são puramente matemáticos, porém com desempenho superior tanto em treinamento quanto em predição (NIELSEN, 2015). A divergência da essência bioinspirada por modelos puramente matemáticos fez com que alguns autores renomeassem neurônios como *unidades*.

### 3.2.1 Topologias

A topologia de uma RNA é dada pelo esquema de ligação das unidades, quantidade de unidades por camada, o número de camadas de entrada e saída, e de camadas ocultas. Entende-se por camada oculta as camadas que estão entre as camadas de entrada e saída, pois, ela não estaria “visível” para estas extremidades. O treinamento para ambas redes é feito da mesma forma onde o erro é retropropagado para o ajuste de parâmetros.

Avaliaram-se duas topologias: a clássica RNA com múltiplas camadas (do inglês *Multi-layer Perceptron (MLP)*) onde esta tem várias unidades por camada bem como várias camadas ocultas e a RNA totalmente conectada em cascata (do inglês *Fully Connected Cascaded (FCC)*). Esta última topologia apresenta uma capacidade maior para modelar dinâmicas usando menos neurônios (WILAMOWSKI, 2009). Esta característica é interessante pois exigirá menos esforço computacional para executar as previsões em tempo real.

A Figura 12 ilustra uma rede MLP.

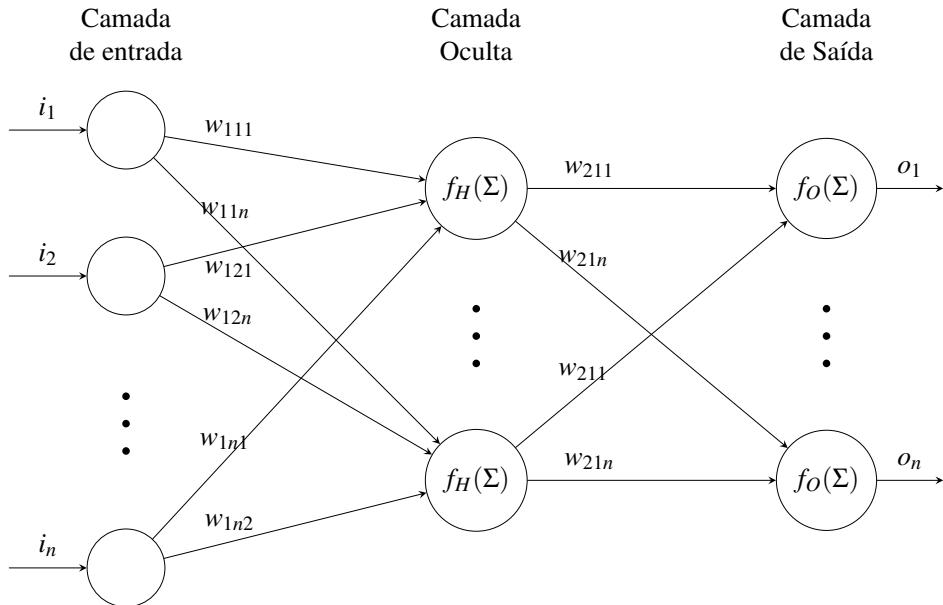


Figura 12 – Multilayer perceptron MLP. Fonte: AUTOR (2021).

No caso de uso de camadas ocultas, haverá também potenciais de ativação ocultos nos quais serão computados. Para facilitar a implementação, faz-se uso de notação matricial, onde:

$$\mathbf{I} = \begin{bmatrix} i_1 \\ i_2 \\ \vdots \\ i_n \end{bmatrix} \quad \mathbf{O} = \begin{bmatrix} o_1 \\ \vdots \\ o_n \end{bmatrix}$$

definem as entradas  $I$  e saídas  $O$  da rede neural, e:

$$\mathbf{W}_1 = \begin{bmatrix} w_{111} & w_{112} & \cdots & w_{11n} \\ w_{121} & w_{122} & \cdots & w_{12n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{1n1} & w_{1n2} & \cdots & w_{1nn} \end{bmatrix} \quad \mathbf{W}_2 = \begin{bmatrix} w_{211} & w_{212} & \cdots & w_{21n} \\ w_{221} & w_{222} & \cdots & w_{22n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{2n1} & w_{2n2} & \cdots & w_{2nn} \end{bmatrix}$$

definem os ganhos entre as ligações de cada unidade de cada camada. A matriz  $W_1$  conecta a camada de entrada para a camada oculta e  $W_2$  conecta a camada oculta para a camada de saída.

Note que serão requisitados mais matrizes de ganho caso haja mais camadas ocultas. O potencial de ativação  $\Sigma$  de cada camada é definido por:

$$\Sigma_H = W_1 \cdot I \quad ; \quad \Sigma_O = W_2 \cdot O_H$$

no qual, o vetor  $O_H$  é definido com o vetor de saída da camada oculta com os valores *ativados* da camada anterior. As funções  $f_H(\Sigma)$  e  $f_O(\Sigma)$  são nomeadas como *função de ativação* e estas funções são personalizadas de acordo com o propósito da rede.

### 3.2.2 Funções de Ativação

A função de ativação recebe esse nome pois ela é usada para *ativar* cada unidade de acordo com o seu potencial de entrada. O termo *ativação*, de acordo com a sua inspiração biológica, descrevia a sinapse de um neurônio, assim o termo *função de ativação* será mantido para manter coerência com a literatura.

Foram usadas as seguintes funções de ativação: 1) *Rectified Linear Unit - ReLU*; 2) *Hyperbolic Tangent* e, 3) *Linear*. Estas funções são definidas, respectivamente como  $\max(0, \Sigma)$ ,  $\tanh(\Sigma)$  e  $\Sigma$ , onde  $\Sigma$  é o potencial de ativação. A Figura 13 ilustra o formato destas funções (AGGARWAL, 2018), (PATTERSON, 2017) e (AGUIRRE, 2015).

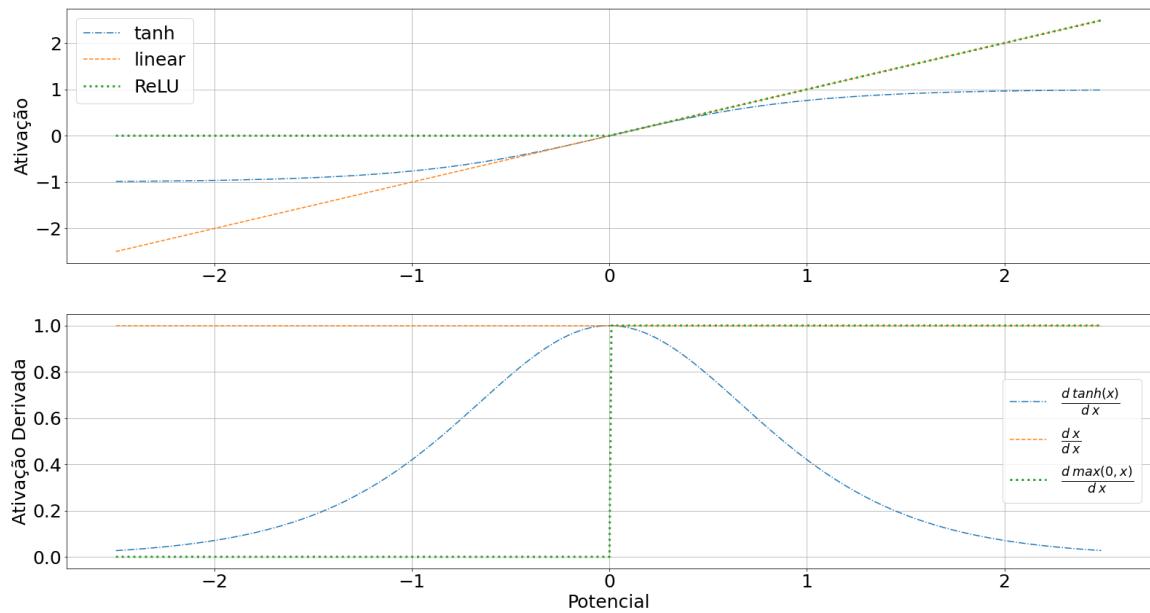


Figura 13 – Funções de ativação e suas derivadas. Fonte: AUTOR (2021).

A função de ativação tangente hiperbólica ( $\tanh$ ) é bioinspirada, ou seja, a sua modelagem matemática foi inspirada em comportamento de ativação de neurônios de cérebros de seres vivos. As funções de ativação *linear* e *ReLU* não são bioinspiradas; i.e. elas são puramente matemáticas. A função de ativação *ReLU* (HAHNLOSER RAHUL SARPESHKAR, 2000) demonstrou desempenho superior tanto em treinamento quanto em execução das redes neurais artificiais. Outro benefício da *ReLU* é que as entradas não necessitam ser normalizadas entre

$\pm 1.0$  conforme exige a  $tanh$  da Equação (5). Note também que essa função satura seus valores na unidade e isto pode implicar em zerar o gradiente descente durante o treinamento; problemas de regressão usam, por praxe, a função de ativação linear na camada de saída e  $tanh$  ou  $ReLU$  em suas camadas ocultas.

A outra rede avaliada é a rede de topologia FCC, que é ilustrada na Figura 14. Esta topologia difere da MLP onde a camada de entrada é conectada em cada camada “oculta” até mesmo na camada de saída. Note que esta característica viola a definição do que seria camada oculta para uma MLP.

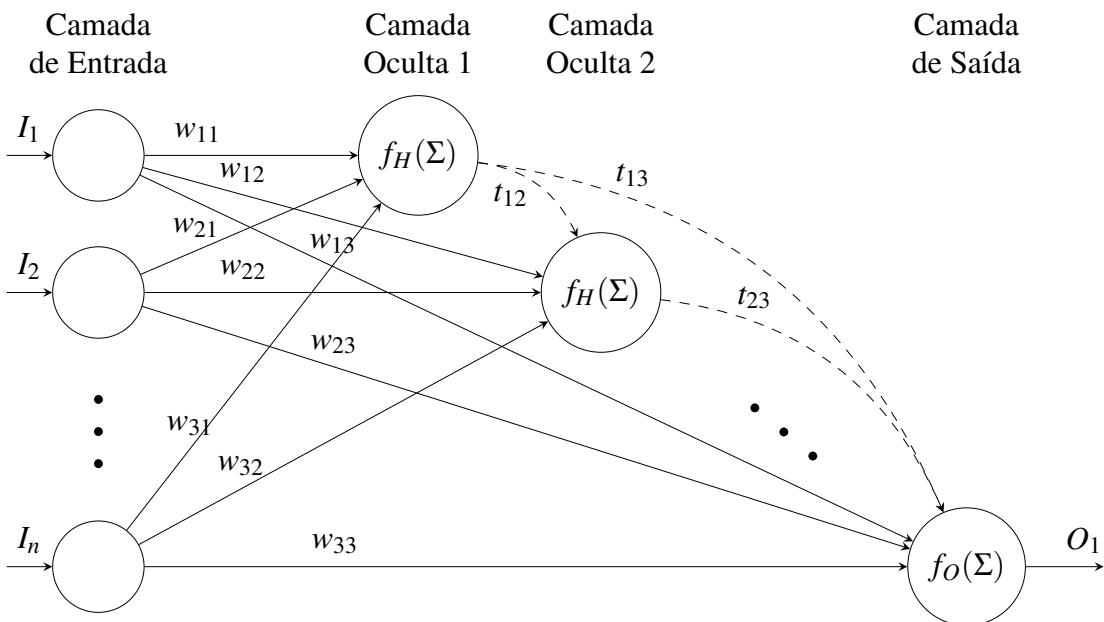


Figura 14 – RNN totalmente conectada em cascata - FCC. Fonte: AUTOR (2021).

Dada a matemática envolvida nas unidades da RNA, é necessário normalizar os dados adquiridos, para isto utiliza-se:

$$S_{scaled} = \frac{S_{real} - Min}{Max - Min} \quad (5)$$

A Equação (5) fará com que os valores sejam escalonados entre  $[0, 1]$  e os valores  $Min$  e  $Max$  são definidos como *base* de um sistema *por unidade (pu)*.

### 3.2.3 Polinômio Equivalente

O polinômio equivalente da rede MLP apresentada é dado por:

$$\mathbf{O} = f_O(\mathbf{W}_2 \cdot f_H(\mathbf{W}_1 \cdot \mathbf{I})) \quad (6)$$

Para o propósito de encontrar o polinômio equivalente de uma rede FCC, usa-se, sem perda de generalização, uma saída escalar. Torna-se mais interessante observar o cálculo pelas

entradas de cada unidade ao invés de suas saídas. Assim, cada entrada de camada de unidade  $l$  é denotada por  $f^l(\mathbf{I}; \mathbf{w})$ , com  $I$  como vetor de entrada,  $w$  ganho ligando as unidades da camada  $l$  para as unidades da camada seguinte. Para esta dedução completa e com múltiplas saídas veja em (CHENG, 2017). Então para  $l = 1, \dots, L$  e  $r$  como a ligação entre a camada  $l$  até a entrada considerada e,  $L$  o número de camadas, tem-se:

$$f^l(\mathbf{x}; \mathbf{w}) = w_{l,0} + \sum_{i=1}^n w_{l,i} + \sum_{r=1}^{l-1} w_{l,n+r} \cdot f_H(f_H(\mathbf{x}; \mathbf{w})) \quad (7)$$

com  $f_H$  sendo a função da ativação para cada camada *oculta* e de saída.

Nota-se que para cada camada oculta, acrescenta-se uma multiplicação de matrizes e, funções de ativação para cada camada.

### 3.3 RECORRÊNCIA

RNA recursiva *RNN* é uma classe de RNA temporais. Por definição, uma RNN usa a predição do instante anterior como entrada da rede para a predição atual. A RNN tem sido usada na identificação de sistemas de séries temporais (MANDIC, 2001). A recorrência de uma RNA pode ser feita em qualquer unidade em si ou pela saída com a entrada. O caso da recorrência feita na unidade configura-se como uma rede *Elman*, e entre saída e entrada configura-se como uma rede do tipo *Jordan*. A RNN *Jordan* foi inicialmente proposta em (JORDAN, 1986) em uma MLP tendo esse conceito estendido para uma FCC nesta tese.

Nas Figuras 15 e 16, as recorrências de uma unidade são ilustradas nas ligações pontilhadas.

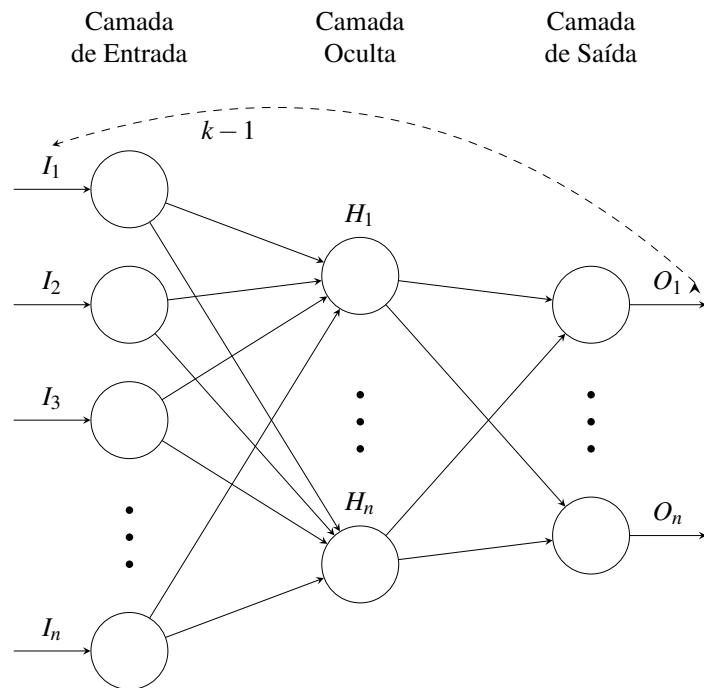


Figura 15 – RNN MLP com recorrência do tipo Jordan. Fonte: Autor (2021).

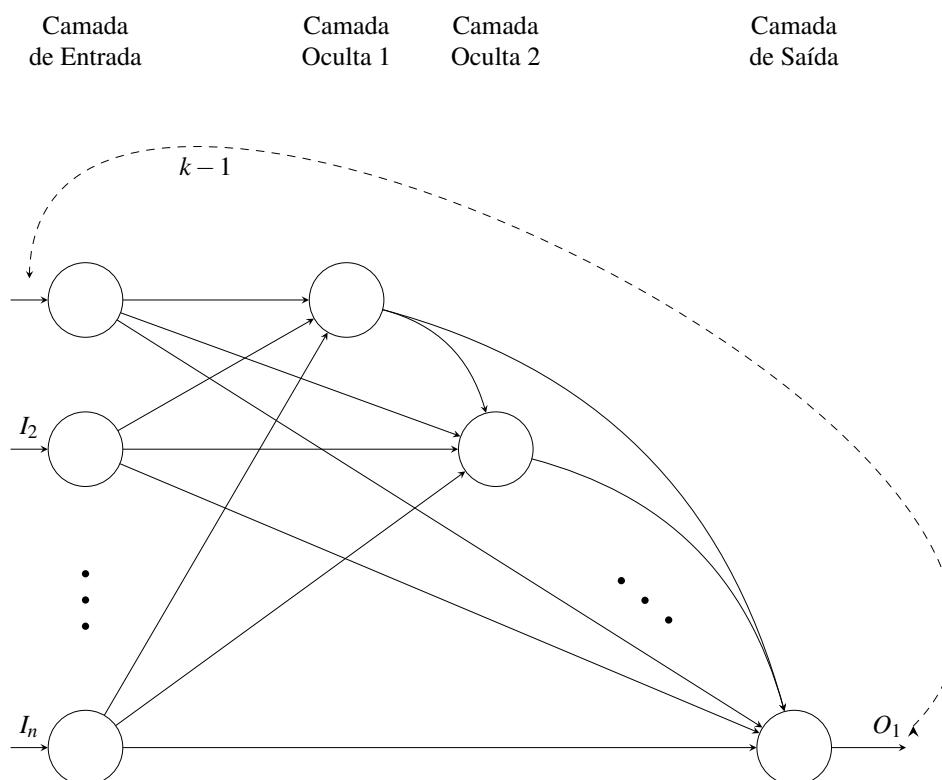


Figura 16 – RNN FCC com recorrência do tipo Jordan. Fonte: AUTOR (2021).

### 3.4 TREINAMENTO - BACKPROPAGATION

Para uma máquina “aprender” é necessário que ela seja “treinada”, pois ela não é dotada de inteligência. No contexto de *aprendizado de máquina*, treinar uma máquina significa apresentar dados de entrada e saída para que o algoritmo mapeie adequadamente esses dados e valide cada atualização dos ganhos da rede de tal forma que haja uma boa correlação.

No caso de RNA, o conceito de treinamento se trata em ajustar os ganhos numéricos das matrizes  $W$  da rede de tal maneira que os erros entre valores das previsões e medidos sejam minimizados. Salienta-se porém que este erro é estocástico, ou seja, o erro a ser minimizado é computado a partir de todo o conjunto de dados e o erro será calculado pelo erro quadrático médio (em inglês, *Mean Squared Error - MSE*).

Este ajuste de ganhos implementa o algoritmo chamado de *backpropagation*, em tradução livre *retropropagação*, que consiste em dois passos genéricos: 1) calcular o erro da previsão no caminho direto da RNA para então 2) calcular a(s) derivada(s) do erro e retropropagar para cada camada da rede; cada passo retropropagado altera os ganhos da rede seguindo uma regra matemática.

As flechas pontilhadas na Figura 17 ilustram os caminhos direto (*forward*) e reverso (*backward*). Note que, para o primeiro cálculo no caminho direto é necessário que os ganhos sejam iniciados com valores aleatórios e diferentes de zero, para permitir que a RNA sofra ajustes adequados em cada passo de treinamento.

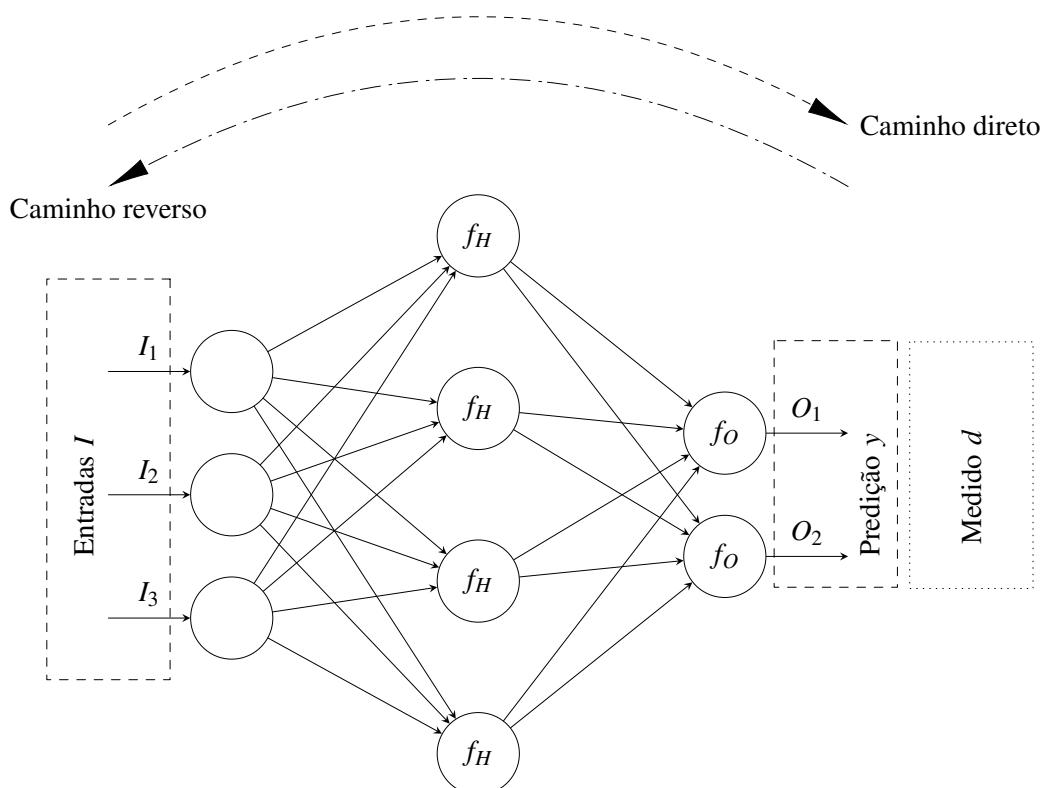


Figura 17 – Caminhos direto e reverso de treinamento. Fonte: AUTOR (2021).

A RNA é dita “treinada” quando o erro está minimizado, ou seja, este é um problema de minimização com a função custo configurada como o *MSE*.

O sinal de erro na saída da rede MLP, de uma unidade  $j$  a cada iteração  $n$  é definido pelas Equações (8) e (10) e o somatório de todos os erros da camada de saída e suas  $n$  iterações define o MSE, mais detalhes em (HAYKIN, 1998).

$$e_j = d_j - o_j \quad (8)$$

$$\varepsilon = \frac{1}{2} \sum_{j \in C} e_j^2 \quad (9)$$

$$MSE = \frac{1}{N} \sum_{n=1}^N \sum_{j \in C} e_j^2(n) \quad (10)$$

no qual,  $C$  contém todos as unidades da camada de saída e, no exemplo, existem duas unidades apenas. Neste exemplo, para cada camada, tem-se dois potenciais de ativação  $\Sigma_O$ , um entre a camada de entrada e a camada oculta e entre a camada oculta e a camada de saída. As funções de ativação da camada oculta  $f_H$  e de saída  $f_O$  são derivadas, porém, usando a regra da cadeia para poder derivar os erros de saída  $e_j(n)$  pelos pesos  $w$  da rede, tem-se:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \cdot \frac{\partial e_j(n)}{\partial y_j(n)} \cdot \frac{\partial y_j(n)}{\partial \Sigma_{O_j(n)}} \cdot \frac{\partial \Sigma_{O_j(n)}}{\partial w_{ji}(n)} \quad (11)$$

Desenvolvendo as equações parciais e fazendo as substituições pertinentes, chega-se à *regra delta* da Equação (12). Ver (HAYKIN, 1998) para a dedução completa do algoritmo de retropropagação em RNA MLP.

$$\Delta w_{ji}(n) = -\eta \cdot e_j(n) \cdot f'_x(\sum(n)) \quad (12)$$

O sinal negativo implica em buscar o mínimo da função custo, a constante  $\eta$  é definida como a taxa de aprendizado,  $f'_x$  é a derivada das funções de ativação definidas para cada camada oculta e de saída; diferentes funções de ativação podem ser empregadas conforme visto na Figura 13. Esta regra é para a última camada, e no caso de haver camadas ocultas, é necessário calcular as derivadas parciais da camada mais próxima da saída pela camada  $j$  em questão. Assim, chega-se a seguinte regra:

$$\delta_j(n) = f'(\sum(n)) \cdot \sum_k \delta_k(n) w_{kj}(n) \quad (13)$$

onde  $\delta_j$  é o gradiente da camada oculta  $j$  e  $k$  é a camada mais próxima da saída da RNA, no caso à direita da camada  $j$  e  $y_j(n)$  é a entrada da camada  $j$ . A *regra delta* para camadas ocultas é então dada por:

$$\Delta w_{ji}(n) = -\eta \cdot \delta_j(n) \cdot o_j(n) \quad (14)$$

O algoritmo de retropropagação de uma RNA MLP pode ser alterado para treinar uma RNA FCC, sua dedução completa se encontra em (CHENG, 2017).

O valor calculado do *MSE* é atualizado ao apresentar todas as amostras do conjunto de treino, este passo é chamado de *época*. Após uma época, calcula-se o valor do *MSE* e caso ainda não satisfaça os parâmetros de convergência, uma nova época é iniciada com os valores de ganhos  $w$  ajustados na época anterior, como condição inicial dos ganhos na época que se inicia.

É necessário ter dois conjuntos de dados, um para o treinamento e outro para validação. Pelas boas práticas, os dados apresentados para o ajuste dos ganhos são diferentes dos dados usados para validar os ganhos, pois, é possível testar o desempenho do treinamento e validação concomitantemente.

A validação do treinamento é útil para verificar a generalização da rede quando utilizar dados não apresentados à rede durante o treinamento. Ela também é útil para detectar *overfitting* e *overtraining* durante o treinamento. Estes efeitos indicam um desempenho insatisfatório da rede, pois ela está altamente especializada aos dados apresentados no treinamento, i.e., impacta negativamente na capacidade de generalização da rede durante as previsões.

Quando os parâmetros de convergência fornecidas à rede forem alcançados pelo processo de treinamento, é importante verificar se os ganhos ajustados são zeros ou se são valores demasiadamente grandes. Ganhos zeros implica em perder unidades (capacidade de previsão) e, ganhos grandes e pequenos na mesma rede implica em problemas numéricos.

### 3.5 RNA MALHAS ABERTA E FECHADA

Os treinamentos desenvolvidos na Seção 3.4 utilizam os dados prévios para então serem supridos aos algoritmos. Contudo, quando há o uso de recorrência, é necessário adicionar alguns passos ao treinamento.

Para treinar uma rede neural recorrente é preciso que: ou 1) após executar o passo direto de treinamento, guarda-se o valor da previsão para então alimentar no próximo passo no caminho direto ou 2) alimentam-se a saída medida como entrada passadas de recorrência. O método 2) apresenta desempenho superior tanto em treinamento quanto em previsão pois a RNN é treinada com valores mais próximos do esperado (NARENDRA; PARTHASARATHY, 1991).

Nomeando os algoritmos, tem-se: *treinamento em malha aberta* o algoritmo que utiliza as saídas medidas ao invés da previsão, e *malha fechada*, o algoritmo que utiliza a previsão no algoritmo das saídas passadas ao invés das saídas medidas.

Por fim, define-se o seguinte fluxograma de treinamento da Figura 18. Salienta-se que o algoritmo é válido para treinar ambas RNN MLP e FCC alterando-se apenas, os artifícios matemáticos para cada uma, conforme explanado anteriormente.

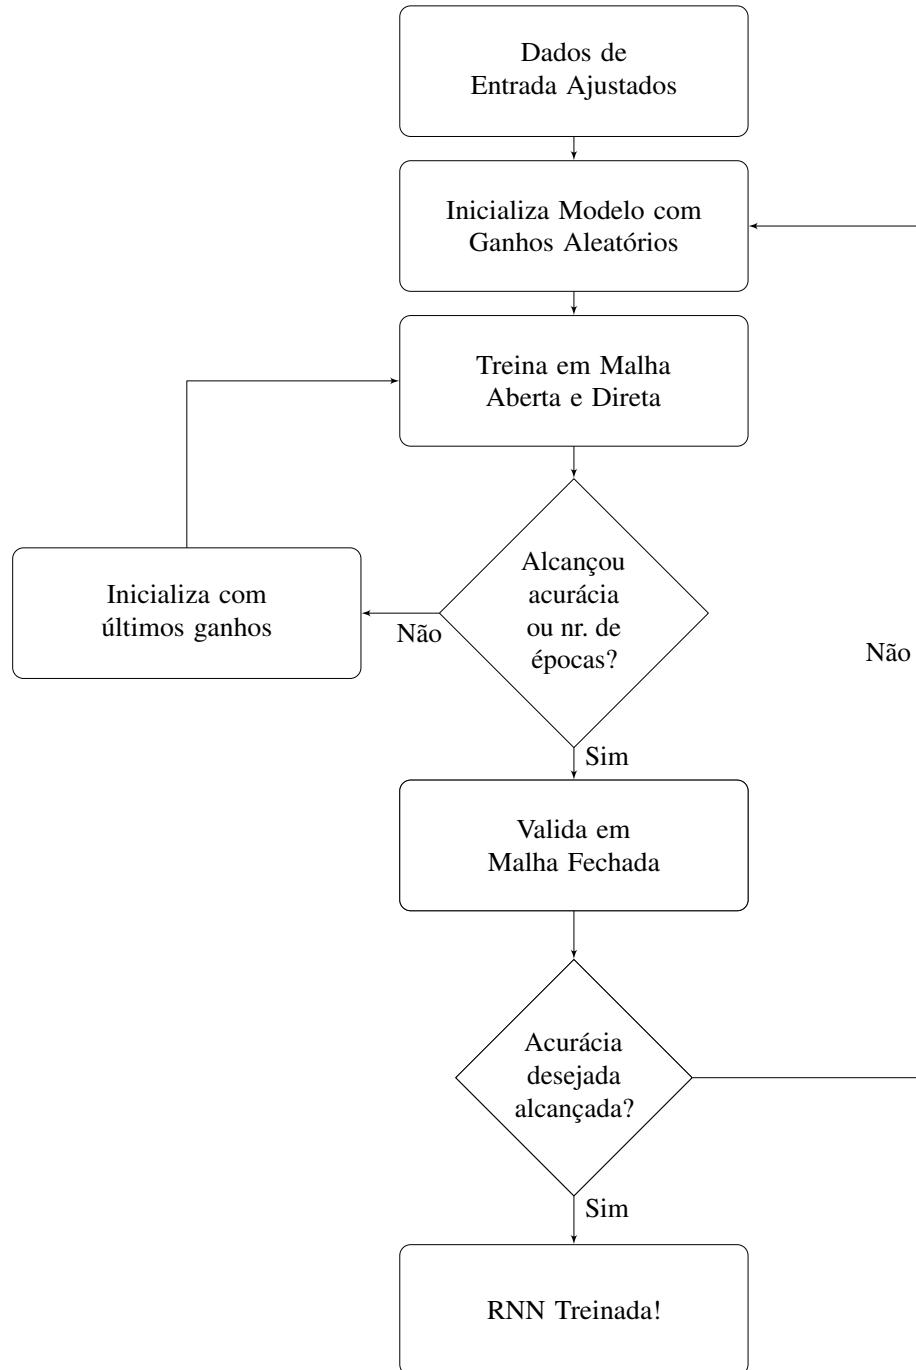


Figura 18 – Algoritmo de treinamento de retropropagação do erro. Fonte: AUTOR (2021).

### 3.6 SELEÇÃO DO NÚMERO DE CAMADAS E UNIDADES

O número de camadas e unidades por cada camada compõe o polinômio final, e assim, as dinâmicas que almeja-se identificar. Para fins de implementação e comercialização, deseja-se o

menor custo computacional, i.e., o menor número possível de camadas e unidades sem perder a qualidade das grandezas ora estimadas. Apesar de não existir na literatura um procedimento descrevendo a seleção da quantidade de unidades por camada bem como a quantidade de camadas para determinado problema, a seleção é feita manualmente com tentativa e erro envolvendo diversos treinamentos para encontrar um modelo adequado. Para este fim, o *MSE* é utilizado como métrica de avaliação da topologia da rede. Um algoritmo comum a ser empregado é iniciar com redes de baixa complexidade, i.e., poucas camadas e unidades e aumentar gradativamente até o *MSE* ao longo desta evolução não apresentar melhoras significativas na validação do modelo.

### 3.7 FREQUÊNCIA DE AMOSTRAGEM

O tempo de amostragem é o tempo transcorrido entre duas amostras consecutivas e, a frequência de amostragem é o inverso deste tempo, ou seja,  $f_s = 1/T_s$ . Esta tese usará frequência fixa de amostragem para todos os experimentos pois este tempo ditará a base para o controle que será abordado na sequência. Além disso, a RNA fará predições da temperatura interna a partir de sinais e suas derivadas temporais.

A planta que está sob análise é classificada como não-linear por ter constantes de tempo diferentes para aquecimento e resfriamento e, ganho variável em regime permanente. Todavia, a frequência de amostragem deve ser suficientemente alta para capturar as dinâmicas mais rápidas e baixa o suficiente para a rede não perceber ruídos inerentes ao sistema ou mesmo sensores como parte das dinâmicas de interesse. Neste caso, cita-se (AGUIRRE, 2015) que demonstra que a frequência de amostragem pode ser encontrada como o primeiro mínimo das autocorrelações lineares e não-lineares quando forem aplicados degraus à planta. As autocorrelações linear e não-linear são definidas, respectivamente, em (15) e (16).

$$r_{y^*}(\tau) = E \left[ \left( y^*(k) - \overline{y^*(k)} \right) \left( y^*(k - \tau) - \overline{y^*(k)} \right) \right] \quad (15)$$

$$r_{y^*2}(\tau) = E \left[ \left( y^{*2}(k) - \overline{y^{*2}(k)} \right) \left( y^{*2}(k - \tau) - \overline{y^{*2}(k)} \right) \right] \quad (16)$$

com  $y^*$  como o sinal de interesse, os sinais  $\overline{y^*(k)}$  e  $\overline{y^{*2}(k)}$  são as médias,  $k$  é definido como o instante de amostragem,  $\tau$  o deslocamento relativo com o instante  $k$ , e o operator  $E$  é a esperança do valor com o requisito dos sinais serem ergódicos<sup>1</sup>.

### 3.8 SINAIS DE EXCITAÇÃO

É necessário que a identificação de sistema seja alimentada com as saídas do sistema e com as entradas que causaram tais saídas. Para tal, é de vital importância que os sinais de

<sup>1</sup> Ergodicidade é uma propriedade do sinal onde seus parâmetros são considerados constantes, i.e., o valor esperado pode ser intercambiado com o valor médio (AGUIRRE, 2015).

entradas excitem ao máximo a planta para garantir a qualidade dos dados dentro do espaço de inferência de interesse. (AGUIRRE, 2015) propõe usar um sinal pseudo aleatório, do inglês *Pseudo Random Binary Signal - PRBS* para excitar a planta.

Um sinal PRBS é dito pseudo aleatório pois ele é digital e, por ser digital, tem número limitado de combinações factíveis e repetir-se-á após este dado número de combinações; característica esta que violará o conceito de aleatoriedade (AGUIRRE, 2015). A aleatoriedade do sinal de entrada é importante para não ter correlação com o sinal de saída, consequentemente, apenas as dinâmicas da planta serão capturadas. Todavia, o sinal é projetado para ser aleatório dentro do tempo de interesse ou seja, o plano de testes da planta é desenhado de tal maneira que dentro do tempo de teste, a PRBS não apresente repetições de combinações.

O gerador de uma PRBS está ilustrado na Figura 19, onde é feita uma chamada do programa para nova geração de saída da PRBS a cada  $T_s$ .

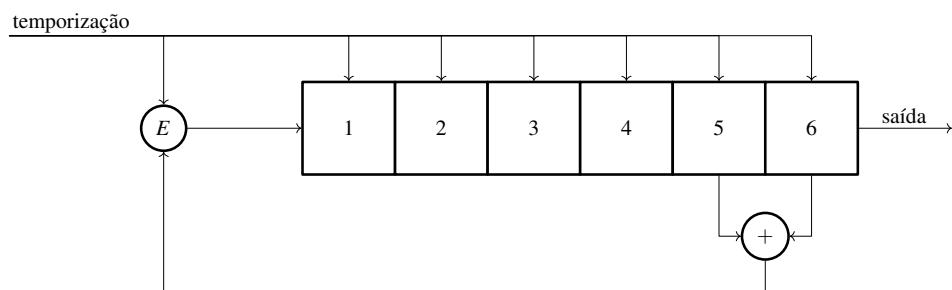


Figura 19 – Gerador de PRBS. Fonte: (AGUIRRE, 2015)

A sequência do sinal PRBS da Figura 19 pode ser alterada de acordo com a Tabela 2.

Tabela 2 – Parâmetros da sequência PRBS, baseado em (AGUIRRE, 2015).

$n_b$	$N_b = 2^{n_b} - 1$	bits usados pela porta XOR
2	3	1 e 2
3	7	2 e 3
4	15	3 e 4
5	31	3 e 5
6	63	5 e 6
7	127	4 e 7
8	255	2,3,4 e 8
9	511	5 e 9
10	1023	7 e 10
11	2047	9 e 11

sendo  $n_b$  o número de *bits* da sequência PRBS,  $N_b$  é o total de combinações possíveis com  $n_b$ . O tempo total da sequência PRBS é dada por  $T_{PRBS} = N_b \cdot T_s$  e este valor deve ser maior que o tempo de teste da planta.

Uma limitação da PRBS é em ter opções de *altura* restritas a duas possibilidades, ou seja, ela fornece apenas dois valores binários e seria necessário gerar muitas PRBS com alturas

diferentes para varrer o espaço de inferência da planta para extrair as diferentes constantes de tempo para cada ponto de operação. Conforme (NEGRI et al., 2017), usam-se as referências de rotação de compressor ilustradas na Figura 20.

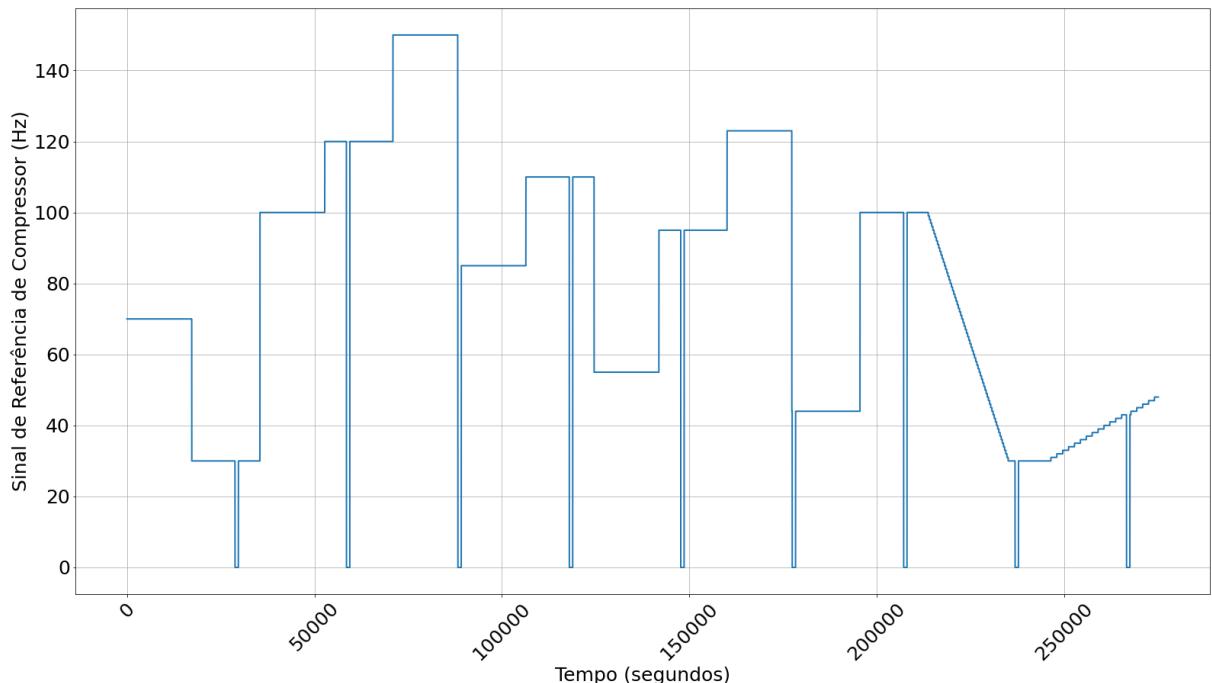


Figura 20 – Referência de Frequência para o Compressor. Fonte: AUTOR (2021).

Estas referências exploram o máximo possível do espaço de inferência dentro da região de interesse e ainda excitam as dinâmicas em todo o seu alcance. As alterações abruptas do sinal de referência, que partem de um dado valor para zero e então retornam para o valor anterior, são devidas à rotina de degelo de evaporador. A lógica desta rotina é a cada 8 horas de compressor ligado; ela desliga o compressor e ventilador, liga a resistência de descongelamento e aguarda ou 15 minutos ou temperaturas da evaporadora maiores que 15°C. Salienta-se que esta rotina é importante, pois, a evaporadora com gelo formado degradaria o desempenho do refrigerador e o colocaria fora da operação normal, alterando a qualidade dos modelos identificados.

Para expandir ainda mais o espaço de inferência dentro da operação normal do produto, perturba-se a planta alterando-se os valores da temperatura ambiente e carregamento térmico dentro do produto. Garrafas de água de 500 ml foram usadas como cargas térmicas e a perturbação é realizada ao adicionar ou retirar determinada quantia dessas garrafas. Buscou-se manter a aleatoriedade de carregamentos durante o experimento para simular o uso mais próximo do real. O carregamento foi definido como sendo: vazio (nenhuma garrafa dentro do congelador e refrigerador), baixa carga 7 garrafas no congelador e 7 no refrigerador; média com 14 no congelador e 21 no refrigerador, média-alta com 21 no congelador e 28 no refrigerador e alta com 21 no congelador e 35 no refrigerador.

A temperatura ambiente e a umidade são fatores determinantes para definir a quantidade de calor rejeitada para o ambiente, i.e., quanto mais alta a temperatura ambiente, menor será

a rejeição de calor. Quanto maior for o carregamento térmico, mais potência é demandada do compressor para retirar o calor da carga térmica. O ato de abrir a porta de algum dos compartimentos implica também em expulsar a massa de ar frio para o ambiente e, para evitar eventuais distorções de modelo causadas pela necessidade de trocar o carregamento térmico, então, via planejamento dos testes, minimiza-se as trocas de carregamento e quando forem feita as trocas, estas devem ser feitas antes de iniciar o teste.

## 4 CONTROLE PREDITIVO

Controle Preditivo é também um *controle ótimo*, com este *ótimo* sendo regido pelo histórico dos estados da planta, pelo *futuro* baseado nos modelos, e pela heurística do projetista para alcançar o desempenho esperado. Filosoficamente, o MPC imita o comportamento humano, pois, as ações de controle são entendidas como as melhores previstas para alcançar o resultado esperado dentro de um horizonte limitado (ROSSITER, 2018). Esta heurística pode incluir o caráter da física da planta, do controlador, aspectos financeiros, etc., ou mesmo todas estas áreas concomitantemente (MACIEJOWSKI, 2000). Esta fusão de áreas concomitantes é chamada *modelo interno*, e utiliza-se o modelo identificado através das técnicas do Capítulo 3.

Todos os algoritmos de MPC utilizam em comum os elementos listados abaixo, e diferentes opções podem ser escolhidas para cada elemento de acordo com os requisitos e objetivos. Esta combinação de elementos geram diferentes algoritmos (CAMACHO, 1999). Estes elementos são:

- Modelo de previsão ou modelo interno;
- Função objetivo;
- Obtenção de malha de controle.

Os elementos são interconectados conforme ilustrado na Figura 21 com o MPC implementado no bloco de linha pontilhada. O sinal de referência é definido a partir dos requisitos da aplicação.

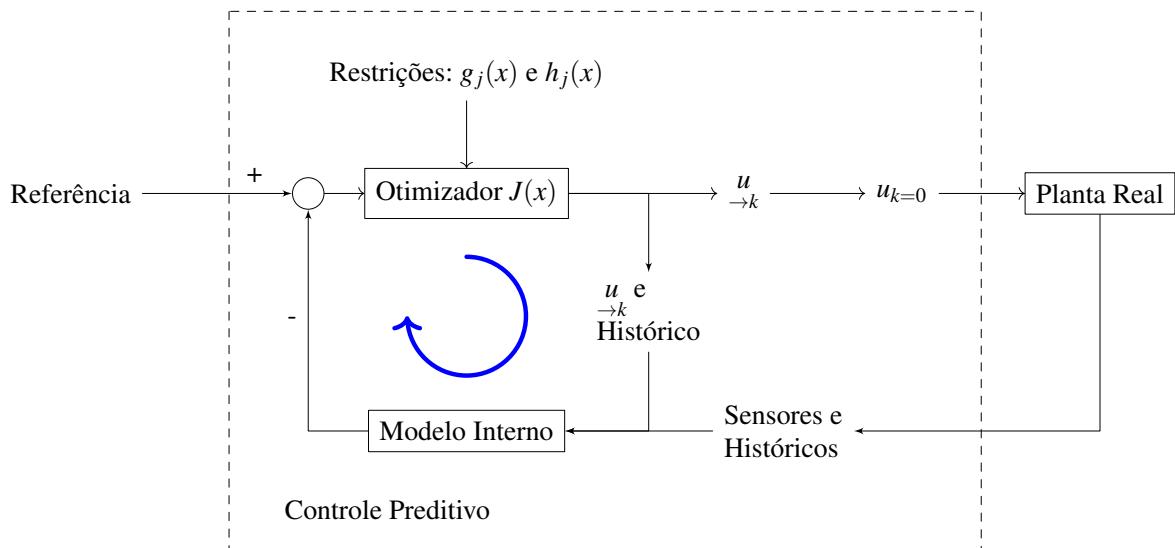


Figura 21 – Diagrama de Blocos de um Controle Preditivo. Fonte: AUTOR (2021).

A cada execução do controlador preditivo, ressalta-se que, o otimizador e modelo interno serão executados muitas vezes até que o otimizador ou convirja ou suas condições de término sejam satisfeitas, e esta operação é ilustrada pela flecha circular. Como é de se esperar, este

procedimento é o fator limitante para a seleção de controlador preditivo, pois esta técnica de controle demanda alto poder computacional para executar as instruções em tempo real.

Ao estabelecer a heurística do controlador MPC, requisita-se que o problema de controle seja *bem posto*, ou seja, que as suas regras de controle não sejam *confitantes* entre si. Caso contrário, o controle buscará pela solução *ideal* que satisfaça ambas heurísticas concomitantemente. Por exemplo, uma situação onde o andarilho da Figura 3 tem as seguintes heurísticas de controle: 1) andar bem devagar por cima de uma ponte estreita e, 2) em caso de chuva, ele corra o mais rápido possível. Então, imaginando os seguintes cenários para o seu ambiente; em um dia de sol, sobre a ponte, ele andaria devagar sem problemas. Em um dia de chuva na estrada, ele correria sem problemas. Porém, ele encontraria problemas de decisão ao caminhar sobre a ponte em um dia de chuva.

#### 4.1 HORIZONTE RETROCEDENTE

O conceito de horizonte retrocedente está ilustrado na Figura 3 e nesta seção, expande-se os conceitos de horizontes retrocedentes de controle e de predição.

*Horizonte de Controle* -  $N_u$  define quantos passos de controle à frente o andarilho da Figura 3 considerará para a tomada de decisão. Este horizonte deve considerar as especificações de projeto de planta bem como do seu uso. Por exemplo, se o andarilho correr, então ele precisará considerar uma distância maior à sua frente pois ele terá dificuldade de desviar abruptamente da pedra devido à alta energia cinética acumulada em seu corpo. Este parâmetro também define o comprimento do vetor de controle *futuro*, logo seu comprimento é  $N_u$ . Este vetor contém informações de; ou o incremento do sinal de controle  $\Delta_k u$  ou o sinal absoluto de controle  $u_k$ . A seleção de  $\Delta_k u$  ou  $u_k$  é feita de acordo com a modelagem matemática do controlador que será abordada a seguir.

*Horizonte de Predição* -  $N_y$  define quantos passos preditos de estados da planta considerando sinais de controle futuros que *seriam* aplicados à mesma. Na analogia da Figura 3, este horizonte define o comprimento do facho de luz da lanterna, e obviamente, este torna visível os eventuais obstáculos que serão enfrentados no caminho. O vetor de predições tem comprimento definido por  $N_y$  no qual contém as saídas futuras/preditas a partir do modelo interno, onde o modelo interno considera a aplicação de sinais *otimizados* de entradas futuras.

A *Seleção de horizontes* é vital para o desempenho e estabilidade do controlador. Os horizontes de predição e controle estão intimamente ligados entre si e às especificações funcionais e de ambiente do controlador. Por exemplo, o horizonte de predição deve ser grande o suficiente para cobrir uma eventual parada do andarilho caso ele veja o obstáculo e ao mesmo tempo, o horizonte de controle necessita ser longo o suficiente para controlar as pernas para que o andarilho pare de forma segura, caso seja necessário. Estados mais suaves podem ser obtidos com horizontes de predição maiores (CAMACHO, 1999) e ao mesmo tempo, com horizontes de controle mais curtos implica em variações maiores do sinal de controle (ROSSITER, 2018). O

projetista tem uma ampla gama de fatores a serem considerados para alcançar o desempenho esperado do andarilho. Fatores como modelo com confiabilidade razoável da planta dentro do horizonte esperado, de conforto de passos ao andar mais suavemente, ou mesmo econômicos, como desgaste acelerado da sola do sapato do andarilho devido à mudanças bruscas de passadas podem também ser considerados nesta seleção de horizontes. Salienta-se que erros de modelagem implicam em estados *não ótimos* encontrados durante a otimização, e tais erros degradam o desempenho do controlador ou mesmo instabilizam o sistema.

Estipula-se que  $N_y \geq N_u$  (ROSSITER, 2018), o que faz total sentido, pois o andarilho que caminha pela rua escura não poderia prever mais passos das pernas (controle) além do que seus olhos poderiam abstrair (predizer) devido ao facho de luz ser mais curto.

## 4.2 OBTENÇÃO DA MALHA DE CONTROLE

Um modelo linear de planta será usado para obter as malhas de controle preditivo para ilustrar o conceito, e então, o conceito será expandido para modelos não-lineares. A literatura do MPC emprega algumas topologias de modelos, tais como espaço de estados, resposta ao degrau, resposta ao impulso, etc.; e ilustra-se o controle desta tese com o modelo *CARIMA*<sup>1</sup>.

$$a(z)y_k = b(z)u_k + T(z)\frac{\zeta_k}{\Delta_k} \quad (17)$$

com  $a(z)$  e  $b(z)$  sendo polinômios com o modelo das dinâmicas da planta,  $y_k$  e  $u_k$  são sinais de saída e entrada, respectivamente, no instante  $k$ .  $\zeta_k$  é uma variável randômica com média nula, e  $T(z)$  pode ser gerado a partir da identificação da planta, mas na prática é parâmetro ajustado pelo projetista para melhorar o desempenho da planta (CAMACHO, 1999) e  $\Delta_k = 1 - z^{-1}$ .

A Equação (17) faz previsões de *um passo*, ou seja,  $(k+1)$  e, para evidenciar este efeito, consideram-se as expressões em (18).

$$\begin{aligned} a(z) &= 1 + a_1z^{-1} + \dots + a_{n_c}z^{-n_c} \\ b(z) &= b_1z^{-1} + \dots + b_{m_c}z^{-m_c} \end{aligned} \quad (18)$$

e, reescrevendo a equação com um passo de previsão à frente, tem-se:

$$y_{k+1} + a_1y_k + \dots + a_{n_c}y_{k-n_c+1} = b_1u_k + b_2u_{k-1} + \dots + b_{m_c}y_{k-m+1} + d_k \quad (19)$$

com  $d_k = T(z)\frac{\zeta_k}{\Delta_k}$  sendo o modelo do ruído. O único termo que está à frente no tempo é  $y_{k+1}$ , isolando este termo, tem-se:

$$y_{k+1} = b_1u_k + b_2u_{k-1} + \dots + b_{m_c}y_{k-m+1} + d_k - a_1y_k - \dots - a_{n_c}y_{k-n_c+1} \quad (20)$$

Em termos práticos, o MPC usa *variações*<sup>2</sup> do sinal de entrada ao invés de valores absolutos (ROSSITER, 2018). Ao multiplicar ambos os lados da Equação (17) por  $\Delta_k$  e considerando

<sup>1</sup> CARIMA, do inglês *Controlled Auto-Regressive Integrated Moving Average*

<sup>2</sup> Ao imitar um humano, é interessante que o MPC empregue variáveis *relativas*, por exemplo, o andarilho sabe quantos passos à frente ele necessita usar para controlar seu movimento, mas ele não sabe quantos passos foram dados desde o início da sua jornada.

que as previsões têm médias nulas ( $\zeta_k = 0$ ), chega-se à:

$$\begin{aligned} a(z)\Delta_k y_k &= b(z)\Delta_k u_k + T(z)\zeta_k \xrightarrow{0} 0 \\ A_c(z)y_k &= b(z)\Delta_k u_k, \text{ com } A_c(z) = a(z)\Delta_k \end{aligned} \quad (21)$$

retrabalhando a equação com  $\Delta_k$ , e utilizando notação matricial para auxiliar na recorrência de mais passos à frente:

$$\begin{aligned} y_{k+1} + A_{c1}y_k + \dots + A_{cn_c}y_{k-n_c+1} &= C_A \begin{bmatrix} y_{k+1} \\ y_{k+2} \\ y_{k+3} \\ y_{k+4} \end{bmatrix} + H_a \begin{bmatrix} y_k \\ y_{k-1} \\ y_{k-2} \\ y_{k-3} \end{bmatrix} \\ y_{k+2} + A_{c1}y_{k+1} + \dots + A_{cn_c}y_{k-n_c+2} &= C_A \begin{bmatrix} y_{k+2} \\ y_{k+3} \\ y_{k+4} \end{bmatrix} + H_a \begin{bmatrix} y_{k-1} \\ y_{k-2} \\ y_{k-3} \end{bmatrix} \\ y_{k+3} + A_{c1}y_{k+2} + \dots + A_{cn_c}y_{k-n_c+3} &= C_A \begin{bmatrix} y_{k+3} \\ y_{k+4} \end{bmatrix} + H_a \begin{bmatrix} y_{k-2} \\ y_{k-3} \end{bmatrix} \\ y_{k+4} + A_{c1}y_{k+3} + \dots + A_{cn_c}y_{k-n_c+4} &= C_A \begin{bmatrix} y_{k+4} \end{bmatrix} + H_a \begin{bmatrix} y_{k-3} \end{bmatrix} \\ b_1 u_k + b_2 u_{k-1} + \dots + b_{m_c} y_{k-m+1} &= C_b \begin{bmatrix} \Delta u_k \\ \Delta u_{k+1} \\ \Delta u_{k+2} \\ \Delta u_{k+3} \end{bmatrix} + H_b \begin{bmatrix} \Delta u_{k-1} \\ \Delta u_{k-2} \\ \vdots \\ \Delta u_{k-m_c+1} \end{bmatrix} \\ b_1 u_{k+1} + b_2 u_k + \dots + b_{m_c} y_{k-m+2} &= C_b \begin{bmatrix} \Delta u_{k+1} \\ \Delta u_{k+2} \end{bmatrix} + H_b \begin{bmatrix} \Delta u_{k-2} \\ \vdots \end{bmatrix} \\ b_1 u_{k+2} + b_2 u_{k+1} + \dots + b_{m_c} y_{k-m+3} &= C_b \begin{bmatrix} \Delta u_{k+2} \end{bmatrix} + H_b \begin{bmatrix} \vdots \end{bmatrix} \\ b_1 u_{k+3} + b_2 u_{k+2} + \dots + b_{m_c} y_{k-m+4} &= C_b \begin{bmatrix} \Delta u_{k+3} \end{bmatrix} + H_b \begin{bmatrix} \Delta u_{k-m_c+1} \end{bmatrix} \end{aligned} \quad (22)$$

onde as matrizes  $C_A$ ,  $H_A$ ,  $C_b$  e  $H_b$  são definidas como:

$$\begin{aligned} C_A &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ A_{c1} & 1 & 0 & 0 \\ A_{c2} & A_{c1} & 1 & 0 \\ A_{c3} & A_{c2} & A_{c1} & 1 \end{bmatrix} \\ H_a &= \begin{bmatrix} A_{c1} & A_{c2} & \dots & A_{n_c-4} & A_{n_c-3} & \dots & A_{n_c-1} & A_{n_c} \\ A_{c2} & A_{c3} & \dots & A_{n_c-3} & A_{n_c-2} & \dots & A_{n_c} & A_{n_c} \\ A_{c3} & A_{c4} & \dots & A_{n_c-2} & A_{n_c-1} & \dots & 0 & 0 \\ A_{c4} & A_{c5} & \dots & A_{n_c-1} & A_{n_c} & \dots & 0 & 0 \end{bmatrix} \\ C_b &= \begin{bmatrix} b_1 & 0 & 0 & 0 \\ b_2 & b_1 & 0 & 0 \\ b_3 & b_2 & b_1 & 0 \\ b_4 & b_3 & b_2 & b_1 \end{bmatrix} \\ H_b &= \begin{bmatrix} b_2 & b_3 & \dots & b_{m_c-4} & b_{m_c-3} & \dots & b_{m-1} & b_m \\ b_3 & b_4 & \dots & b_{m_c-3} & b_{m_c-2} & \dots & b_{m-1} & 0 \\ b_4 & b_5 & \dots & b_{m_c-2} & b_{m_c-1} & \dots & 0 & 0 \\ b_5 & b_6 & \dots & b_{m_c-1} & b_{m_c} & \dots & 0 & 0 \end{bmatrix} \end{aligned} \quad (23)$$

adotando a notação de (ROSSITER, 2018) para expressar previsões “ $\rightarrow$ ” e grandezas presentes e passadas “ $\leftarrow$ ”:

$$\begin{aligned} C_A \underset{\rightarrow k+1}{y} + H_a \underset{\leftarrow k}{y} &= C_b \Delta_k u + H_b \underset{\leftarrow k-1}{\Delta u} \\ C_A^{-1} C_b \Delta_k u + C_A^{-1} H_b \underset{\leftarrow k-1}{\Delta u} - C_A^{-1} H_a \underset{\leftarrow k}{y} &= \end{aligned} \quad (24)$$

$$\underset{\rightarrow k+1}{y} = C_A^{-1} C_b \Delta_k u + C_A^{-1} H_b \underset{\leftarrow k-1}{\Delta u} - C_A^{-1} H_a \underset{\leftarrow k}{y}$$

o vetor de predições de  $\Delta_k u$  faz parte do conjunto solução a ser otimizado pela função objetivo.  
Substituindo matrizes para simplificar a Equação (24), chega-se em:

$$\begin{aligned} \underset{\rightarrow k+1}{y} &= H_{CAR} \underset{\rightarrow k}{\Delta_k u} + P_{CAR} \underset{\leftarrow k-1}{\Delta u} - Q_{CAR} \underset{\leftarrow k}{y} \text{ com} \\ &H_{CAR} = C_A^{-1} C_b \quad P_{CAR} = C_A^{-1} H_b \quad Q_{CAR} = C_A^{-1} H_a \end{aligned} \quad (25)$$

Para otimizar este problema de encontrar o mínimo de sistema linear empregado no MPC, pode-se empregar a *programação quadrática* (do inglês *Quadratic Programming - QP*) com a seguinte formulação (ROSSITER, 2018).

$$\min_{\Delta_k u} \underset{\rightarrow k}{\Delta_k u}^T \underbrace{(H^T H + \lambda I)}_{S_{GPC}} \underset{\rightarrow k}{\Delta_k u} + \underset{\rightarrow k}{\Delta_k u}^T \underbrace{2H^T [P \underset{\leftarrow k-1}{\Delta u} + Q \underset{\leftarrow k}{y} - r_k]}_{P_{GPC}} \quad (26)$$

reescrevendo esta equação com as devidas substituições e, adicionando restrições:

$$\min_{\Delta_k u} \underset{\rightarrow k}{\Delta_k u}^T S_{GPC} \underset{\rightarrow k}{\Delta_k u} + \underset{\rightarrow k}{\Delta_k u}^T P_{GPC}; \quad S_{GPC} > 0 \quad \text{e} \quad C_c \underset{\rightarrow k}{\Delta_k u} \leq f_k \quad (27)$$

$S_{GPC} > 0$  garante que o problema de otimização terá convergência para o ponto de mínimo. Mais detalhes sobre o processo de otimização serão discutidos na Seção 4.4.

### 4.3 FUNÇÃO OBJETIVO

A função objetivo<sup>3</sup> pondera os parâmetros dados pelo projetista, pelos requisitos e pelos comportamentos históricos e futuros dos estados da aplicação. Os tipos variados de algoritmos de MPC implementam diferentes tipos de funções objetivo para obter a lei de controle (CAMACHO, 1999).

Para rastrear a saída da planta de acordo com um sinal de referência, considerando também o *esforço* do controlador, usa-se a seguinte função objetivo *total*.

$$\begin{aligned} J &= J_e + J_u + J_{\Delta u} \\ J_e &= \left[ \begin{array}{c} Y \\ \vdots \\ \rightarrow k+j \end{array} \right]_{(N_y - N_{y0}), N_o}^T W_y \left[ \begin{array}{c} Y \\ \vdots \\ \rightarrow k+j \end{array} \right]_{(N_y - N_{y0}), N_o} \\ J_u &= \left[ \begin{array}{c} U \\ \vdots \\ \rightarrow k+j \end{array} \right]_{N_u, N_i}^T W_u \left[ \begin{array}{c} U \\ \vdots \\ \rightarrow k+j \end{array} \right]_{N_u, N_i} \\ J_{\Delta u} &= \left[ \begin{array}{c} \Delta U \\ \vdots \\ \rightarrow k+j \end{array} \right]_{N_u, N_i}^T W_{\Delta u} \left[ \begin{array}{c} \Delta U \\ \vdots \\ \rightarrow k+j \end{array} \right]_{N_u, N_i} \end{aligned} \quad (28)$$

neste contexto,  $N_i$  e  $N_o$  são o número de entradas e saídas respectivamente de um caso de sistemas de múltiplas entradas e saídas (MIMO),  $J_e$  como a parcela da função objetivo referente ao erro

<sup>3</sup> Também conhecida por função custo ou mesmo índice de desempenho.

de rastreio (ou seguimento) sendo penalizado pelo ganho  $W_y$ ,  $J_u$  a parcela da função objetivo referente ao esforço *absoluto* do controlador penalizado pelo ganho  $W_u$ , e  $J_{\Delta u}$  representa a parcela referente ao *incremento* do sinal de controle sendo penalizado pelo ganho  $W_{\Delta u}$  ajustado pelo usuário. Usualmente, faz-se o parâmetro  $N_{y0} = 1$  mas valores grandes implica em desconsiderar os erros nos primeiros instantes após a predição, porém o sistema apresentará respostas mais *suaves* ao configurar valores altos para  $N_{y0}$  (CAMACHO, 1999).

A parcela de erro de rastreio  $J_e$  da função objetivo na Equação (28) inclui saídas futuras do modelo a partir dos sinais de controle utilizados durante a otimização. Assim, a acurácia das predições do modelo interno está vinculada diretamente à qualidade dos pontos ótimos que serão aplicados à planta. O descasamento entre modelo e planta implica em aplicar sinais de controle que levam o sistema à condição *sub ótima* ou, em casos extremos, à instabilidade. Sensores são utilizados para minimizar o descasamento entre modelo e planta porém, ainda cabe ao projetista adequar ambas as matrizes de ganho  $W$  e tamanho de horizontes na função objetivo. Ilustrando as incertezas pelo caso do andarilho, quanto maiores forem as incertezas em distâncias maiores devido à uma miopia ou ao alcance do facho da lanterna, então, reduz-se os horizontes para diminuir a influência dos erros de descasamento.

É atribuição do projetista definir a heurística para configurar tais vetores de ganhos e horizontes. As plantas que apresentam atraso de transporte, i.e. atrasos entre a variação do sinal de saída  $y$  a partir da variação de entrada em  $u$ , requisitam que o valor de  $N_{y0} \geq d$ , pois, a saída não evoluirá até o instante  $k + d$ . Este tempo é expresso como  $T_d = k \cdot d$  (CAMACHO, 1999). O horizonte de predição  $N_y$  deve ser definido longo o suficiente para cobrir a convergência da saída ao degrau e o horizonte de controle  $N_u$  para amenizar variações abruptas do sinal de controle. Não obstante, é necessário executar simulações para verificar se o desempenho esperado será alcançado (ROSSITER, 2018).

Os ganhos  $w_y(j)$ ,  $w_u(j)$  e  $w_{\Delta u}(j)$  são matrizes diagonais, simétricas que definem o comportamento futuro, geralmente valores constantes ou exponenciais, por exemplo,  $w_y(j) = \alpha^{N_y-j}$ . Valores de  $0 < \alpha < 1$  implicam em ganhos maiores e mais longes do instante  $k$  resultando em controle mais suave pois os erros mais distantes são penalizados. Valores de  $\alpha > 1$  implicam em ganhos maiores e mais próximos do instante  $k$  causando um controle mais agressivo (CAMACHO, 1999). A Figura 22 ilustra o caso com  $N_y = 20$  com  $\alpha = 0,5$ ,  $\alpha = 1,0$  e  $\alpha = 1,5$ . Para fins didáticos, os valores da escala vertical foram omitidos.

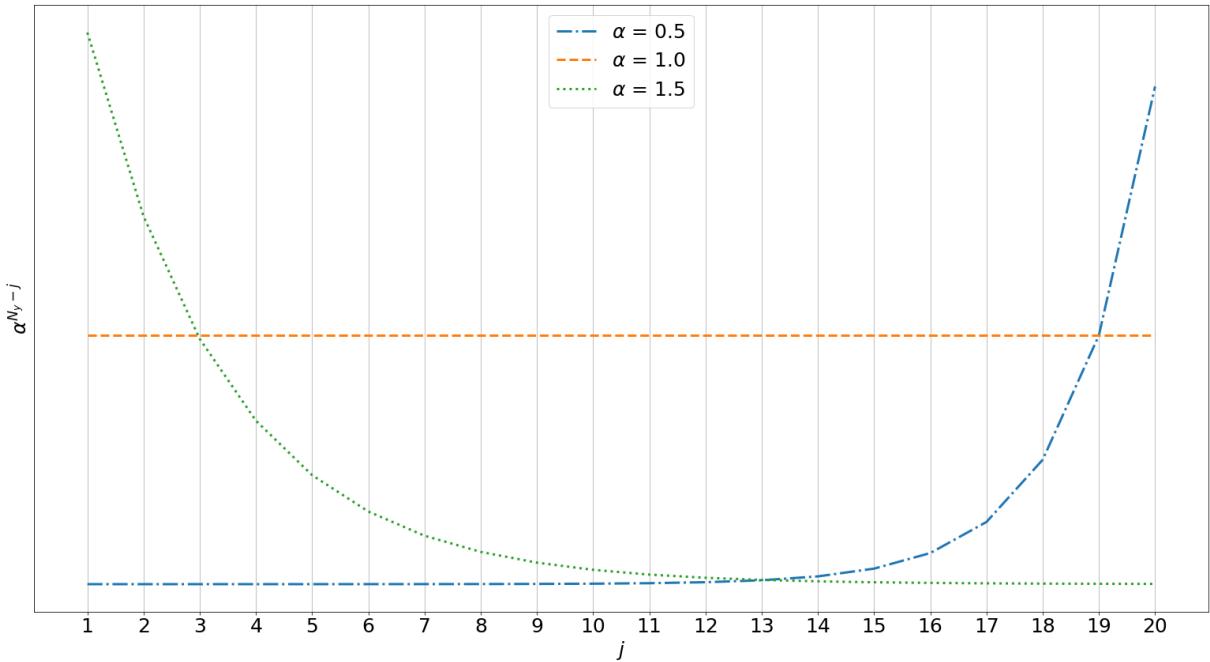


Figura 22 – Ganhos com  $N_y = 20$ . Fonte: AUTOR (2021).

#### 4.4 OTIMIZADOR

Otimização é definida como um procedimento matemático para encontrar a solução ótima de uma função objetivo, e esta solução estará contida em um espaço de busca. A otimização da função objetivo pode ser de *maximização* ou *minimização*, i.e. os valores encontrados pelo otimizador resultam em um ponto máximo ou mínimo, respectivamente.

O conceito de otimização numérica é ilustrado a partir de conceitos lineares e com apenas uma variável. A função objetivo  $J(x) = x^2$  está ilustrada na Figura 23, e observa-se que a função objetivo apresenta um *ponto de mínimo* e um *ponto de máximo no infinito*, porém, ao se limitar o espaço de busca das variáveis entre  $\pm 2,0$ , obtém-se dois *pontos de máximo*.

Para otimizar, é necessário implementar um algoritmo computacional, e o seguinte pseudo-algoritmo implementa a busca utilizando derivadas.

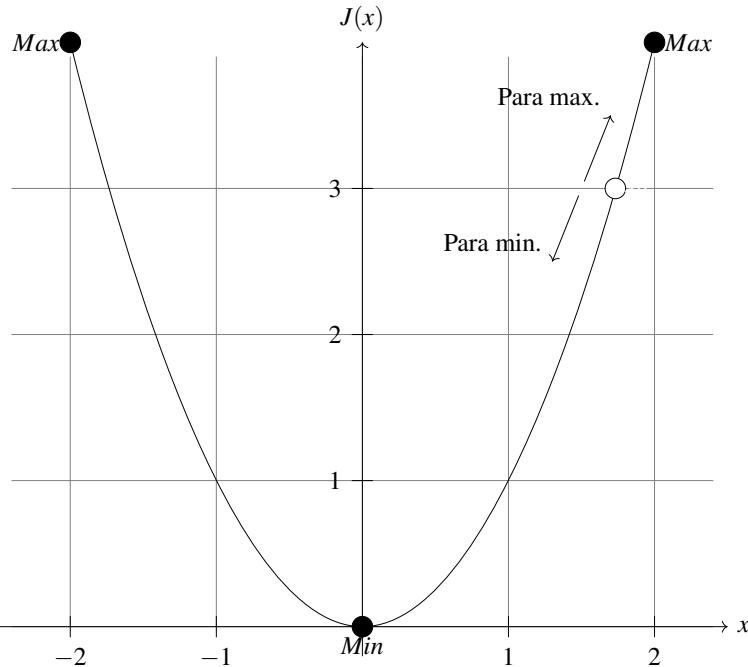


Figura 23 – Função objetivo linear e convexa. Fonte: AUTOR (2021).

---

**Algorithm 1:** Otimização Numérica de  $J(x) = x^2$ . Fonte: AUTOR (2021).

---

```

1  $Jacob(x) = 2 \cdot x$                                 // Calcula a Jacobiana de J(x)
2  $h_{int} = Param_h$                                 // Parâmetro de usuário - passo de integração
3  $Tol = ParamTol$                                 // Parâmetro de usuário - tolerância
4  $x_{Início} = random [-2,2]$                   // Inicia aleatoriamente dentro do espaço
5  $J(x) = x_{Início}^2$                             // Atualiza o valor da função objetivo
6 while Otimizando... do
7   if Maximização then
8      $J(x) = J(x) + h_{int} \cdot Jacob(x)$       // Integra positivo - "Para max."
9     /* Verifica se o valor máximo foi encontrado? */
10    if  $J(x) \geq Tol$  then
11      return = x                                // Valor ótimo
12      break                                    // Interrompe busca
13  else if Minimização then
14     $J(x) = J(x) - h_{int} \cdot Jacob(x)$       // Integra negativo - "Para min."
15    /* Verifica se o valor mínimo foi encontrado? */
16    if  $J(x) \leq Tol$  then
17      return = x                                // Valor ótimo
18      break                                    // Interrompe busca

```

---

Da Figura 23 e do Algoritmo 1, nota-se que a otimização numérica demanda iterações até o objetivo ser atingido; no caso de minimização, a função tem apenas um mínimo em  $J(0) = 0$ ,

e este ponto de mínimo, com as tolerâncias suas determinadas pelo usuário, sempre será atingido independentemente da localização do ponto de partida  $x_{\text{Inicio}}$ . O Ponto de partida está ilustrado pelo marcador bolinha branca. Isso não é verdade para o caso de maximização, pois a função apresenta dois pontos de máximo. Pela Figura 23, o máximo (2,4) seria atingido, ou seja, o ponto de máximo atingido depende do ponto de partida.

Define-se como ponto de *mínimo global*, como o ponto com menor valor calculado de  $J(x)$ , seja este um extremo da função (derivada nula) ou um dos pontos da restrição do espaço de busca, e mínimo local qualquer extremo da função  $J(x)$ , dentro do espaço de busca, que não seja um mínimo global. Na Figura 23, os mínimos global e local são coincidentes.

As matrizes de ganho -  $W_y$ ,  $W_{\Delta u}$  e  $W_u$  - ajustadas pelo projetista na função objetivo da Equação (28) devem ser *positivas definidas*. Esses ganhos em conjunto com convexidade da função garantem que a solução do otimizador *fluirá* para o ponto de mínimo global.

A *convexidade* de um problema de otimização é definido como a propriedade de sua função objetivo ser convexa em relação às suas variáveis de decisão. Uma função é convexa se uma linha conecta dois pontos arbitrários estiver acima ou sobre a própria função dentro do intervalo de busca, ou seja, a *convexidade* é  $(x_1, J(x_1))$  e  $(x_2, J(x_2))$  que estabelecem uma reta regida por  $x_C = \lambda x_2 + (1 - \lambda)x_1$  para todo  $0 \leq \lambda \leq 1$  (ROSSITER, 2018).

Formalmente, a otimização numérica é o processo de 1) formular e 2) encontrar a solução de um problema restrito definido na forma geral a seguir (SNYMAN, 2018).

$$\min_x J(x), x = [y, u, \Delta u]^T \in \mathbb{R}^{n_{\text{opt}}} \quad (29)$$

sujeito às restrições:

$$\begin{aligned} g_j(x) &\leq 0, \quad j = 1, 2, \dots, m \\ h_j(x) &= 0, \quad j = 1, 2, \dots, r \end{aligned} \quad (30)$$

sendo que  $J(x)$  é nomeada como a função objetivo,  $g_j(x)$  e  $h_j(x)$  são arranjadas em *matrizes colunas* em função de  $x$  e definidas com as restrições de otimização; estas últimas serão abordadas na próxima seção.

Para ilustrar o processo de otimização *não-linear* e as dificuldades enfrentadas, a Figura 24 apresenta uma função  $J(x)$  não-linear com apenas uma variável de entrada e com múltiplos pontos de mínimo e máximo.

Nota-se que a função objetivo apresenta três pontos de mínimo e quatro pontos de máximo. O uso do Algoritmo 1 é válido porém, não há garantia de convergência para ponto de mínimo global. A aleatoriedade da inicialização de  $x_0$  pode atribuir valores entre -2 e 2, e este valor inicial obviamente ditará se a otimização convergirá para o mínimo (ou máximo) local ou global. Nota-se ainda que este problema é também *não convexo*, ou seja, não é possível traçar uma reta entre dois pontos arbitrários sem que esta cruze a função objetivo.

Uma função objetivo não-linear, além de não ter garantias de convergência para mínimo (ou máximo) global, ela ainda pode apresentar diferentes derivadas de acordo com o ponto na

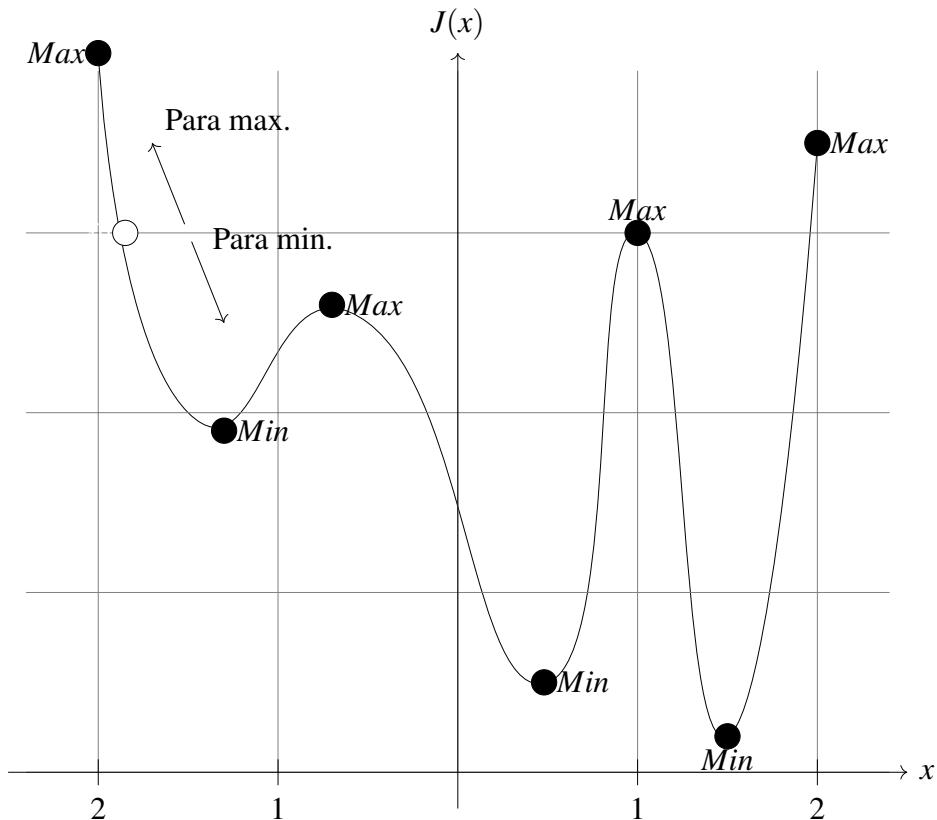


Figura 24 – Função objetivo não-linear. Fonte: AUTOR (2021).

iteração; isto implica que o algoritmo de otimização terá diferentes tempos de otimização de acordo com a condição inicial - este efeito é indesejável para aplicações *online*.

Para expandir o conceito de monovariável para multivariável, bastaria adicionar mais um eixo de variável de otimização implicando em um problema tridimensional; ou com mais  $n$  variáveis, em problema  $n$ -dimensional. Para visualização, usa-se a função de teste de otimizadores conhecida por *Himmelblau* e esta função objetivo é definida por  $f(x, y) = (x^2 + y - 11)^2 + (x + y^2 - 7)^2$ , e está ilustrada na Figura 25.

Adicionar mais dimensões (ou variáveis de otimização) torna o problema difícil de ser representado graficamente, porém, todos os conceitos expostos continuam válidos. Adicionar mais variáveis de otimização, ou mesmo, função objetivo de ordem mais alta implica em custo mais alto. Como o espaço de busca cresce com a ordem da informação de um problema multivariável, o mesmo acontece com o espaço de busca que cresce substancialmente com o problema da dimensionalidade; este efeito é conhecido por *maldição da dimensionalidade*, nomeado por Bellman em 1957 (SNYMAN, 2018). Salienta-se ainda que, quanto maior for a dimensionalidade, maior será o tempo de otimização e sem garantias de sua convergência.

Esta característica do tempo de otimização contrasta diretamente na seleção dos horizontes, pois, por um lado quanto mais longos forem os horizontes que implicam em respostas suaves, e por outro lado, mais esforço computacional será exigido.

O processo de otimização utilizado é de *minimização*, então, deste ponto em diante,

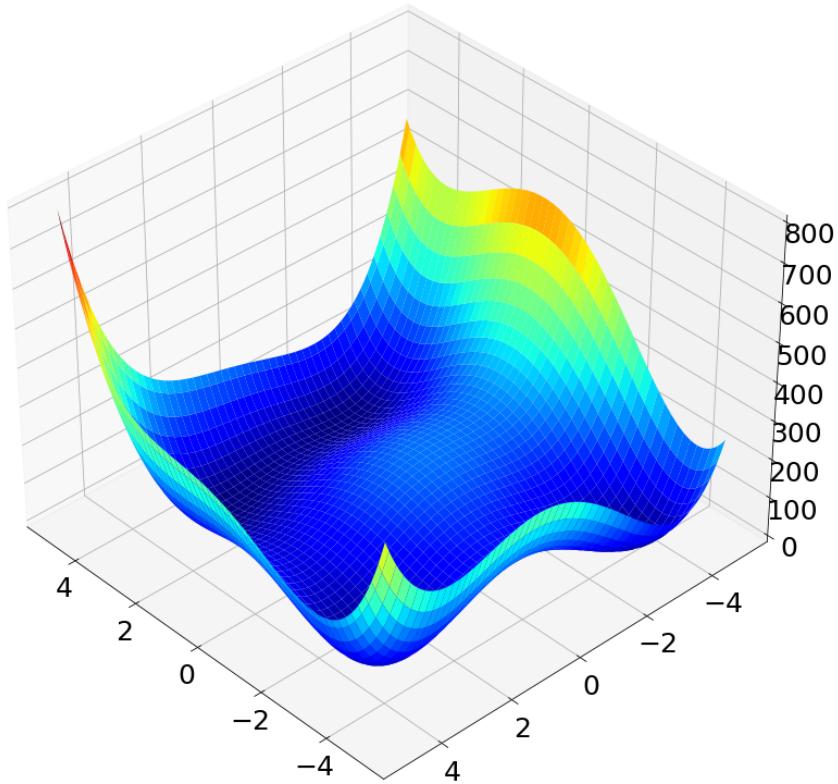


Figura 25 – Função objetivo de testes de otimizador - *Himmelblau*. Fonte: AUTOR (2021).

discorre-se apenas sobre minimização. Infelizmente, com a ausência de garantia de convergência com o uso de derivadas, é necessário buscar algoritmos de otimização mais sofisticados e robustos para convergir para pontos de mínimo global sem o uso de derivadas, como por exemplo Algoritmos Genéticos (*GA*)(CHARBONNEAU, 2002) ou mesmo o *COBYLA* (*Constrained Optimization BY Linear Approximations*)(JOHNSON, 2020).

#### 4.4.1 Restrições

As restrições de otimização tem por objetivo, como o seu nome próprio sugere, restringir o espaço de busca dentro da função objetivo. A interpretação geométrica deste espaço é chamado de *polítopo*, e um polítopo é uma figura geométrica de paredes hiperplanares com cada vértice definido pelas combinações da variáveis de busca  $x$ . A *dimensão* de um polítopo  $\mathcal{P}$  definida por  $\dim(\mathcal{P})$ , é uma unidade menor que o número máximo de pontos independentes em  $\mathcal{P}$ . O polítopo  $\mathcal{P} \subset \mathbb{R}^n$  é *completamente dimensional* se  $\dim(\mathcal{P}) = n$ . As equações lineares do polítopo são *linearmente independentes* se os pontos  $(\alpha^i, \beta_i) \subset \mathbb{R}^{n+1}, i = 1, 2, \dots, m$  forem linearmente independentes (LEE, 2004),

$$\sum_{j=1}^n \alpha_j x_j = \beta_i, \quad i = 1, 2, \dots, m \quad (31)$$

O polítopo é dito *não convexo*, se ao menos uma reta  $x_C$  não puder ser definida entre dois pontos  $x$  arbitrários.

As restrições  $g_j(x)$  e  $h_j(x)$  da Equação (30) são definidas e ajustadas pelo projetista. Para fins didáticos, utiliza-se uma restrição ilustrada pela linha pontilhada que corta a função objetivo  $J(x)$ , conforme ilustrada na Figura 26.

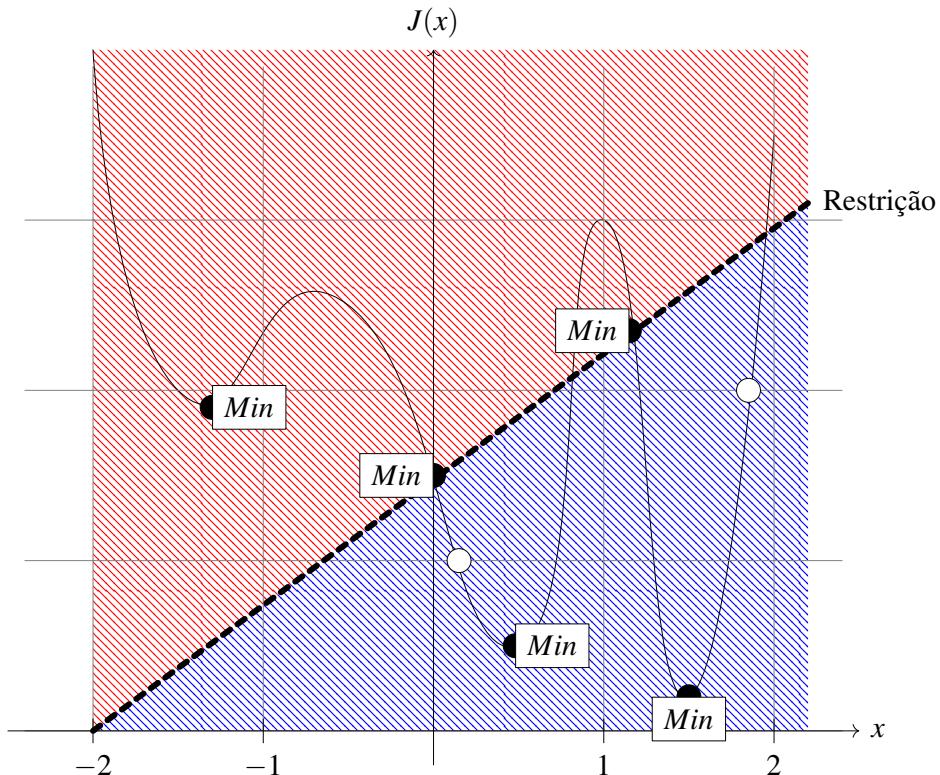


Figura 26 – Função objetivo não-linear com restrições. Fonte: AUTOR (2021).

De acordo com os requisitos de aplicação, o projetista escolherá entre selecionar o espaço de busca acima (vermelho) ou abaixo (azul) da linha de restrição, e esta seleção se faz através do conjunto de equações e inequações das restrições. Selecionando arbitrariamente o espaço de busca abaixo da linha (azul): a curva de otimização terá dois pontos de mínimo, e caso a otimização use derivadas, esta convergirá para o mínimo de acordo com a sua inicialização. Os pontos brancos são exemplos de pontos inciais para duas otimizações distintas, e nota-se que apenas a otimização à direita convergirá para o ponto de mínimo global. Ressaltando novamente que, algoritmos de otimização livre de derivadas são necessários, pois, o desempenho de otimização será severamente impactado. Ainda exemplificando, tomando o caso do espaço acima (vermelho) de busca; este apresenta três pontos de mínimo, sendo dois nas intersecções da linha de restrição com a função objetivo e, obviamente, a sua convergência depende diretamente do valor inicial da variável de busca.

As restrições desempenham um papel muito importante dentro do contexto do MPC, pois elas encontram o ponto *ótimo* de operação da planta de acordo com as condições de contorno naquele instante. Por exemplo, define-se como restrição a *taxa* máxima do sinal de controle  $\Delta_k u$  de um compressor recíproco de acordo com as suas especificações ou mesmo outras considerações, como por exemplo, condições comerciais onde deseja-se diminuir desconforto

sonoro devido ao ruído acústico ocasionado por variações abruptas de velocidade.

Serão consideradas dois tipos de restrições: 1) *rígida (hard)*, e 2) *maleável (soft)*. As restrições do tipo *hard* são restrições que não podem ser violadas, caso isto ocorra, modos severos de falha atuam e prejuízos à planta poderão ocorrer; por exemplo, na Figura 3 o andarilho está sobre uma ponte, e obviamente, se ele pisar fora dos limites da ponte devido a um *overshoot* de posição no *eixo vertical*, ele cairá e se machucará gravemente. As restrições do tipo *soft*, são penalizações adicionais ao controle que força o sistema para *longe* do ótimo de operação sem grandes adversidades. No exemplo do andarilho, ele desvia da pedra com um erro maior de posição ao longo do eixo vertical, e obviamente, se isto ocorrer implicaria apenas em um aumento do gasto de energia para efetuar o mesmo deslocamento, não obstante, seus dedos dos pés ficarão protegidos e ele seguramente cruzará a ponte.

As restrições *hard* são as funções que limitam o espaço de busca através das funções  $g_j(x)$  e  $h_j(x)$  e estas restrições usam horizontes finitos (ROSSITER, 2018). Como por exemplo, *máximas taxas de variação* do sinal de entrada  $\Delta u_k$ , *valor absoluto* do sinal de entrada  $u_k$ , e *absolutos* do sinal de saída  $y_k$ .

As *máximas taxas de variação* do sinal de entrada são definidas, em forma matricial de desigualdade entre seus valores mínimos  $\underline{\Delta u}$  e máximos  $\overline{\Delta u}$ :

$$\underline{\Delta u} \leq \Delta_k u \leq \overline{\Delta u}$$

$$\underbrace{\begin{bmatrix} \underline{\Delta u} \\ \underline{\Delta u} \\ \vdots \\ \underline{\Delta u} \end{bmatrix}}_{L\underline{\Delta u}} \leq \underbrace{\begin{bmatrix} \Delta u_k \\ \Delta u_{k+1} \\ \vdots \\ \Delta u_{k+N_u-1} \end{bmatrix}}_{\Delta_k u} \leq \underbrace{\begin{bmatrix} \overline{\Delta u} \\ \overline{\Delta u} \\ \vdots \\ \overline{\Delta u} \end{bmatrix}}_{L\overline{\Delta u}} \quad \text{com } L = \begin{bmatrix} I \\ I \\ \vdots \\ I \end{bmatrix} \quad (32)$$

as dimensões da matriz  $L$  são definidas pelo horizonte  $N_u$ . Reescreve-se a Equação (32) em conjunto de inequações.

$$\underbrace{\begin{bmatrix} I \\ -I \\ \vdots \\ C_{\Delta u} \end{bmatrix}}_{\rightarrow k} \Delta_k u - \underbrace{\begin{bmatrix} L\overline{\Delta u} \\ -L\underline{\Delta u} \end{bmatrix}}_{d_{\Delta u}} \leq 0 \quad C_{\Delta u} \Delta_k u \leq d_{\Delta u} \quad (33)$$

Os *valores máximos* do sinal de entrada são definidas em forma matricial de desigualdade também, todavia, é necessário expressar as restrições *futuras* em função do sinal de entrada  $\Delta_k u$  ou  $u_k$ . Para isto, dado  $u_{k+i} = u_{k-1} + \Delta_k u_k + \dots + \Delta_k u_{k+i}$  (ROSSITER, 2018), tem-se:

$$u_k = C_{I/\Delta} \Delta_k u + \underbrace{\begin{bmatrix} I \\ I \\ \vdots \\ I \end{bmatrix}}_L u_{k-1}; \quad C_{I/\Delta} = \begin{bmatrix} I & 0 & \dots & 0 \\ I & I & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ I & 0 & \dots & 0 \end{bmatrix} \quad (34)$$

com  $C_{I/\Delta}$  sendo uma matriz *Toeplitz* baseada em  $I/(1-z^{-1})$  e por isto, é uma matriz triangular inferior preenchidas com matrizes identidades. Estipulando-se limites  $\underline{u} \leq u_{k+i|k} \leq \bar{u}$ ,  $\forall i \geq 0$ , tem-se:

$$\underbrace{\begin{bmatrix} \underline{u} \\ \underline{u} \\ \vdots \\ \underline{u} \end{bmatrix}}_{Lu} \leq \underbrace{\begin{bmatrix} u_k \\ u_{k+1} \\ \vdots \\ u_{k+N_u-1} \end{bmatrix}}_{\overset{\rightarrow}{u}} \leq \underbrace{\begin{bmatrix} \bar{u} \\ \bar{u} \\ \vdots \\ \bar{u} \end{bmatrix}}_{L\bar{u}} \quad \text{ou } Lu \leq \underset{\rightarrow k}{u} \leq L\bar{u} \quad (35)$$

Substituindo a Equação (34) em (35), tem-se  $L\underline{u} \leq C_{I/\Delta} \Delta_k u + Lu_{k-1} \leq L\bar{u}$ , rearranjando os termos chega-se em:

$$\underbrace{\begin{bmatrix} C_{I/\Delta} \\ -C_{I/\Delta} \end{bmatrix}}_{C_u} \underset{\rightarrow k}{u} + \underbrace{\begin{bmatrix} L \\ -L \end{bmatrix}}_{d_{Lu}} u_{k-1} \leq \underbrace{\begin{bmatrix} L\bar{u} \\ -Lu \end{bmatrix}}_{d_u} \quad \text{ou } C_u \underset{\rightarrow k}{u} \leq d_u - d_{Lu} u_{k-1} \quad (36)$$

As restrições de limites para entradas absolutas apresentam inequações que são variantes no tempo devido à dependência de  $u_{k-1}$ , diferentemente da inequação que restringe o valor máximo da taxa do sinal de entrada, pois é uma matriz de constantes.

Para fechar o conjunto de restrições, definem-se as restrições dos valores *máximos absolutos* de saída da planta  $y_k$ . Para esta tarefa, usa-se o modelo da Equação (24) e reescrito por conveniência.

$$\underset{\rightarrow k+1}{y} = H_{CAR} \Delta_k u + P_{CAR} \underset{\leftarrow k-1}{\Delta u} - Q_{CAR} \underset{\leftarrow k}{y} \quad \text{com} \quad (37)$$

$$H_{CAR} = C_A^{-1} C_b \quad P_{CAR} = C_A^{-1} H_b \quad Q_{CAR} = C_A^{-1} H_a$$

e para os limites da saída  $y_k$ , tem-se:

$$\underbrace{\begin{bmatrix} \underline{y} \\ \underline{y} \\ \vdots \\ \underline{y} \end{bmatrix}}_{Ly} \leq \underbrace{\begin{bmatrix} y_{k+1} \\ y_{k+2} \\ \vdots \\ y_{k+N_y} \end{bmatrix}}_{\overset{\rightarrow}{y}} \leq \underbrace{\begin{bmatrix} \bar{y} \\ \bar{y} \\ \vdots \\ \bar{y} \end{bmatrix}}_{L\bar{y}} \quad \text{ou } Ly \leq \underset{\rightarrow k+1}{y} \leq L\bar{y} \quad (38)$$

substituindo o modelo de predição da Equação (37) em (39), tem-se as inequações para restringir a saída máxima da planta.

$$\underbrace{\begin{bmatrix} H \\ -H \end{bmatrix}}_{C_y} \Delta_k u + \underbrace{\begin{bmatrix} P \\ -P \end{bmatrix}}_{d_{yu}} \Delta_{k-1} u + \underbrace{\begin{bmatrix} Q \\ -Q \end{bmatrix}}_{d_{yy}} \underset{\leftarrow k}{y} \leq \underbrace{\begin{bmatrix} L\bar{y} \\ -Ly \end{bmatrix}}_{d_y} \quad \text{ou } C_y \Delta_k u \leq d_y - d_{yu} \Delta_{k-1} u - d_{yy} \underset{\leftarrow k}{y} \quad (39)$$

e neste contexto, as matrizes  $C_y$ ,  $d_y$ ,  $d_{yu}$  e  $d_{yy}$  são matrizes invariantes no tempo, porém, as inequações são variantes no tempo devido às matrizes  $\Delta_k u$  e  $y$ .

Para as restrições de tipo *soft* ( $J_{soft}$ ), existem inúmeras possibilidades de implementação pois somam-se penalizações à função objetivo com alguma heurística de interesse. Para esta tese, considera-se dois tipos de restrições *soft*: 1) soma de constante:  $J_{cte} = K_{soft}$  e 2) através de uma barreira numérica; por exemplo,  $J_{barr} = \frac{1}{(x - x_{barr})}$  ilustrada na Figura 27.

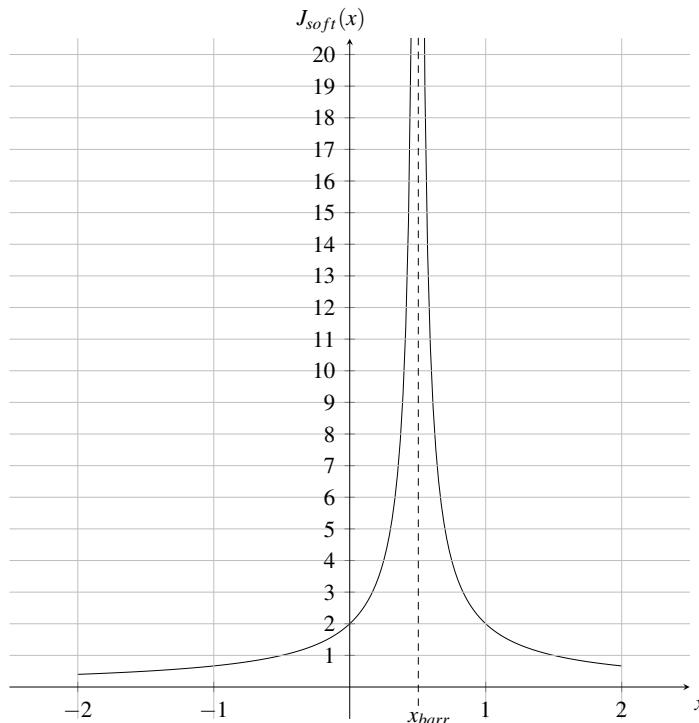


Figura 27 – Restrição do tipo *soft* - penalização adicional à função objetivo. Fonte: AUTOR (2021).

Esta restrição deve ser acoplada à Equação (28), então:

$$J = J_e + J_u + J_{\Delta u} + J_{soft}$$

$$J_{soft} = J_{barr} = \frac{1}{(x - x_{barr})} \quad (40)$$

A barreira numérica penaliza a função objetivo  $J$  com uma função exponencialmente crescente com  $x \rightarrow x_{barr}$ , i.e. a barreira força o otimizador a se afastar das regiões próximas às restrições estipuladas por  $x_{barr}$ . Por fim,  $x_{barr}$  é uma constante ajustada pelos requisitos do projeto e também, para auxiliar o otimizador a convergir numericamente.

Uma função objetivo com múltiplos pontos de mínimo causa resultados abruptos devido à natureza aleatória de inicialização das variáveis de busca. Para evitar tal efeito, inicializa-se as variáveis de busca com os valores encontrados no instante anterior. Esta abordagem encurta o tempo de convergência, pois a tolerância requisitada ao final é prontamente atendida. Salienta-se que esta abordagem é justificada pelo fato de que a taxa de chamada de controle é rápida o suficiente para cobrir a dinâmica *mais rápida* da planta.

Dentro do contexto de chamadas do laço de controle do MPC, após o processo de otimização dado pela Equação (27), um vetor com  $\Delta_k u$  com  $N_u$  elementos *futuros* serão retornados. Este vetor contém a predição dos instantes ( $k$ ) e demais predições futuras e, obviamente, apenas o sinal otimizado  $\Delta_k u(0)$  será aplicado à planta. A cada chamada do laço de controle do MPC, o otimizador será executado diversas vezes até convergir para a solução especificada, porém, há casos onde o otimizador não convergirá ou mesmo não terá soluções. Nestes casos, usa-se a heurística *online*: 1) repetir o sinal de controle otimizado no instante anterior, ou seja,  $(k - 1)$ ; 2) aplicar o sinal de controle  $(k + 1)$  otimizado no instante anterior; 3) revisitar os parâmetros de restrições e dados de usuário como, por exemplo, tolerância e otimizar novamente; 4) reinicializar o otimizar com outro ponto de partida. Os Itens 3) e 4) são alternativas factíveis apenas e somente se houver tempo disponível para uma nova otimização no laço de controle. Na prática, os otimizadores retornarão a informação de sucesso ou o motivo da falha de otimização.

Por fim, deve-se considerar se as restrições são factíveis do ponto de vista físico da planta, ou seja, se restrições não são demasiadamente severas para enfraquecer os *atratores* da planta, a tal ponto que o controle ou mesmo a sua estabilidade sejam comprometidos.

#### 4.5 CONTROLE NÃO-LINEAR

Na natureza, a grande maioria dos processos são não-lineares em maior ou menor grau de *não-linearidade*. É necessário entender os modos de operação da planta para obter adequadamente a melhor malha de controle; salienta-se que uma geladeira é um sistema não-linear e bem comportado<sup>4</sup>. Como será visto mais adiante, a geladeira implementa uma rotina denominada *degelo*, causando uma variação abrupta da temperatura. Para capturar essa dinâmica rápida durante o degelo e também as grandezas térmicas adequadamente, utilizar-se-á uma rede neural artificial. A geladeira está sempre operando em modo dinâmico; seja por perturbações como abertura de porta, com variações de carregamento térmico, oscilações de tensão na rede, variação de temperatura ambiente ou mesmo alterações de configurações por parte do usuário. Neste contexto, empregar técnicas de controle linear não serão efetivas, então, controladores não-lineares serão essenciais para garantir o desempenho superior ou simplesmente para garantir a sua estabilidade (CAMACHO, 1999).

Os elementos-chave do controlador linear MPC são expandidos, sem perda de generalização, para o caso não-linear. Seus funcionamentos internos precisarão ser revistos para acomodar tais diferenças, seja pelo otimizador livre de derivadas ou mesmo pelo modelo interno não-linear; este último não será expresso por matrizes de elementos constantes.

Esta tese utiliza uma Rede Neural Artificial Recursiva como modelo interno para predizer as grandezas futuras de interesse. Para *acoplar* a RNN na malha de controle, um laço de programação do tipo *for* é utilizado, e cada chamada deste laço equivale ao avanço de um passo

<sup>4</sup> Sistemas *bem comportados* são sistemas naturalmente estáveis e com boa aproximação por sistemas de primeira ordem.

de predição à frente a partir do instante ( $k$ ). As restrições continuam lineares pois não houve necessidade de empregar equações não-lineares; restrições *soft* do tipo *barreira* são utilizadas para encontrar pontos de solução ótimos que sejam longes dos pontos de operação indesejados.

A RNN como modelo interno considerada pode ser modelo de baixa ou alta qualidade. Modelo de baixa qualidade é menos complexo e menos preciso, porém este modelo auxilia no processo de otimização ao demandar menos esforço computacional. Usualmente, modelos de baixa qualidade apresentam maior robustez frente às variações paramétricas. Em contrapartida, modelos de alta qualidade explicam com mais precisão as dinâmicas, todavia demandam mais esforço computacional por parte do otimizador e apresentam sensibilidade à variação paramétrica (ROSSITER, 2018).

Em contraste com as predições, sensores são empregados para diminuir a complexidade matemática dos modelos, diminuir erros advindos de variação paramétrica, bem como a diminuir a demanda de esforço computacional.

As referências *futuras* utilizadas com o modelo interno para predizer os erros futuros são constantes no instante  $k$ , em outras palavras, a cada chamada do laço de controle, cria-se um vetor de referências futuras de comprimento  $N$  e amplitude da *referência* do instante da chamada do laço de controle.

#### 4.6 INTEGRADOR NO LAÇO EXTERNO

Para manter a planta em um ponto de operação com erro *zero* em regime permanente, faz-se necessário o uso de um integrador. Esse integrador podendo ser intrínseco ao modelo, ou mesmo artificialmente implementado no controle.

A teoria de controle preditivo provê uma técnica denominada *estado aumentado* na qual implementa-se um integrador ao adicionar um estado ao modelo interno. Porém, uma RNA não dispõe desse artifício, exigindo que o integrador do erro seja implementado externamente ao controle, conforme ilustrado na Figura 28.

Algumas modificações pontuais são feitas no controle para acomodar esse requisito. O otimizador, além de otimizar os erros futuros, ele otimizará também a integral dos erros futuros.

Por comodidade, reescreve-se a equação do controle preditivo, ver Equação (41), e as alterações necessárias na Equação (42).

$$\begin{aligned} \min_u J(k) = & \sum_{i=0}^N \left( \rho_e \cdot e_{k+1 \rightarrow}^2 \right) + \rho_m \cdot \sum_{i=0}^M u_{k+1 \rightarrow}^2 \\ & \text{sujeto a } g_i \leq 0 \text{ e } h_j = 0 \end{aligned} \quad (41)$$

$$\begin{aligned} \min_u J(k) = & \sum_{i=0}^N \left( \rho_e \cdot e_{k+1 \rightarrow}^2 + \rho_{ei} \cdot \int_{k+1 \rightarrow} e_{k+1 \rightarrow}^2 \right) + \rho_m \cdot \sum_{i=0}^M u_{k+1 \rightarrow}^2 \\ & \text{sujeto a } g_i \leq 0 \text{ e } h_j = 0 \end{aligned} \quad (42)$$

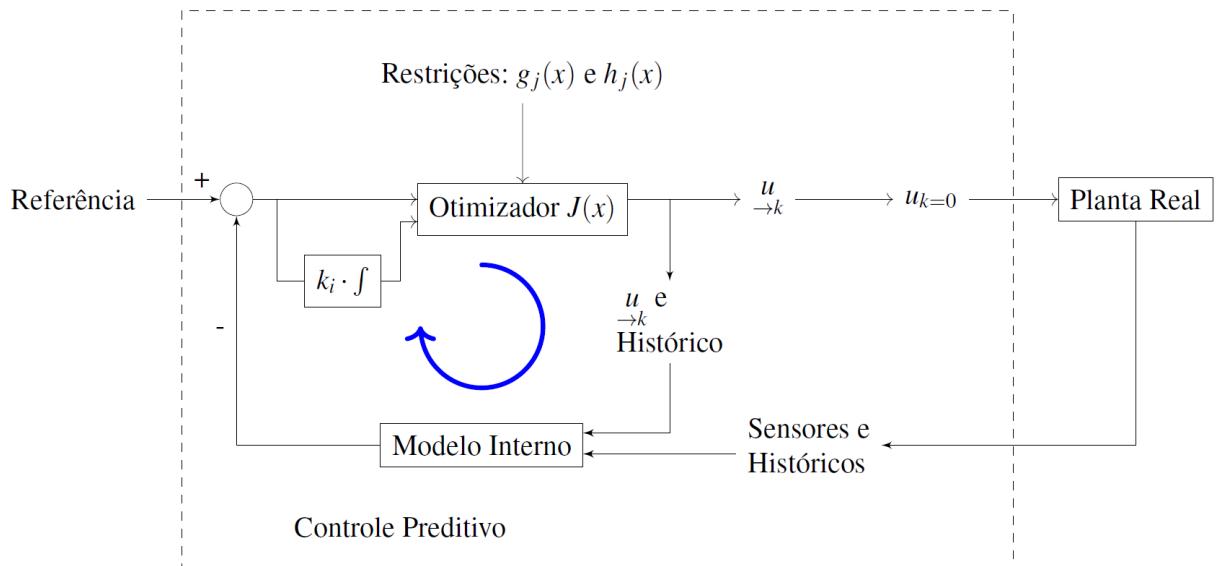


Figura 28 – Diagrama de Blocos de um Controle Preditivo implementando laço integrador externo. Fonte: AUTOR (2023).

O ganho  $k_i$  do integrador é necessário ser ajustado concomitantemente com os ganhos do controle preditivo, aumentando assim, a complexidade da sintonia de todos os ganhos.

## 4.7 AVALIAÇÃO DE ESTABILIDADE

Um controle estável é um controle confiável e replicado em outras aplicações. Dedica-se então, essa seção para avaliar a sua estabilidade dentro das especificações nas quais ele será submetido.

### 4.7.1 Condição de Lipschitz

Um dos critérios empregados é a condição de *Lipschitz*, onde ela afirma que a existência de uma solução, e a partir de uma condição inicial, será única caso a condição da Equação (43) seja satisfeita (KHALIL, 2002).

$$\|f(t, x) - f(t, y)\| \leq L\|x - y\| \quad \forall x, y \in B = \{x, y \in \mathbb{R}^n\}, \forall t \in [t_0, t_1], L \geq 0 \quad (43)$$

A constante de *Lipschitz*  $L$  encapsula o máximo que a função resulta a partir de qualquer entrada dentro dos limites estabelecidos, em outras palavras, a sua importância advém da esperança de que os modelos matemáticos com entradas limitadas ao seu espaço de entrada, proveja resultados contidos em outro espaço de saída.

### 4.7.2 Planta térmica aproximada com BIBO

Um sistema é chamado de estável com entrada limitada e saída limitada (em inglês, *BIBO* - *Bounded input, bounded output*) se uma entrada limitada resulta em uma saída limitada para todos os estados iniciais (ÅSTRÖM, 2021).

Discorrendo sobre a natureza da planta, conclui-se que a planta térmica aproxima-se razoavelmente por um sistema de primeira ordem, com ambos ganho em regime permanente e constante de tempo variáveis. Sem perda de generalização, a planta é aproximada pela resposta ao degrau conforme a Equação (44).

$$T(t) = T_\infty + (T_0 - T_\infty)e^{-t/\tau} \quad \tau > 0, \quad T_\infty < 0 \quad (44)$$

Nesse caso, os termos  $T_\infty$  (ganho em regime permanente) e  $\tau$  (constante de tempo) são variáveis em funções de parâmetros como temperatura externa, carregamento térmico, condição inicial, etc., todavia, salienta-se que esses termos não tem natureza oscilatória.

Considerando que  $T_\infty$  e  $\tau$  são limitadas a um determinado intervalo - intervalo esse identificado via experimentos - conclui-se que todas as funções de primeira ordem terão seus pólos equivalentes no semiplano esquerdo, i.e., a parte real dos pólos será negativa, caracterizando a sua estabilidade. Então, ao aplicar um sinal limitado à sua entrada, resultará em uma saída também limitada.

### 4.7.3 Redes Neurais

Encontra-se a constante de *Lipschitz*  $L$  a partir do valor máximo possível para cada entrada e viés das unidades da RNA no polinômio equivalente, ver Equação (6). A topologia de

RNA (RNN FCC) utilizada nessa tese implementa nas camadas ocultas uma função de ativação com saída limitada a  $\pm 1.0$ , e na última camada, a função de ativação *linear*, sendo esta última, uma *função aberta*. Mesmo que o treinamento empregue valores unitários, para tanto as entradas como as saídas, a saída poderá extrapolar a unidade, mas ainda será limitada a  $L$ ; Uma inspeção do polinômio equivalente revela que não há singularidades matemáticas, i.e. é diferenciável em todo o seu domínio. Assim sendo,  $L$  é determinado por (45), e o polinômio equivalente da RNA é uma *função de Lipschitz*.

$$w_{io} \cdot n_{\text{Unidades de Entrada}} + w_{co} \cdot n_{\text{Camadas Ocultas}} \leq L \quad (45)$$

sendo  $w_{io}$  os ganhos que conectam as unidades da camada de entrada com a unidade de saída, e  $w_{co}$  os ganhos que conectam as saídas de cada camada oculta com a unidade de saída.

A estabilidade da rede neural é determinada, porém seus resultados são fortemente dependentes do treinamento e por conseguinte, a sua qualidade de predição. Salienta-se, porém, que um descasamento severo entre planta e modelo levará o controle à instabilidade.

#### 4.7.4 Controle

A estabilidade do controle preditivo está ligada à estabilidade da planta, ao tempo de execução factível e robustez do otimizador, à qualidade do modelo interno (incerteza de estados do preditor), robustez às perturbações, e às incertezas de medição (sensores). As incertezas podem surgir de diferentes maneiras: o sistema pode ter uma perturbação aditiva desconhecida, o estado do sistema não ser perfeitamente conhecido ou imprecisão do modelo do sistema utilizado (RAWLINGS DAVID Q. MAYNE, 2019). Todavia, esta seção aborda os critérios utilizados para avaliar a estabilidade do controle implementado.

Existem algumas alternativas para avaliar a estabilidade de um controlador preditivo; citando algumas como *Estocástica*, *Robusta* e “*Tubos*”. A avaliação *Estocástica* implica em determinar as trajetórias futuras de estados e soluções baseada em probabilidades, já a avaliação *Robusta* implica em avaliar todas as alternativas futuras incluindo as restrições. Em ambos casos, demanda-se grande esforço computacional para avaliar todos os casos.

A avaliação por *Tubos* especifica regiões nas quais os estados e soluções futuras se encontrarão, e depende do engenheiro responsável pelo projeto; assim sendo, essa avaliação torna-se difícil de realizar até mesmo para sistemas lineares (RAWLINGS DAVID Q. MAYNE, 2019), porém, ela fornece um excelente caminho para entender as regiões dos atratores. A Figura (29) ilustra o conceito dos tubos, onde se tem 3 passos de predição à frente, e cada passo de predição futura, implica em *alargar o tubo* para conter as possibilidades mais prováveis.

O diâmetro desses *tubos* é determinado pelo erro de predição do modelo interno. A quantificação desse erro será discutido mais adiante; felizmente, manteve-se o sensor, e este usa-se para corrigir eventuais desvios ao *zerar* o erro de condição inicial para as predições.

A planta é um sistema não-linear *bem comportado* aproximada por sistemas de primeira de ordem. Para cada conjunto de  $T_\infty$  e  $\tau$  tem-se um sistema linear de primeira ordem com a sua

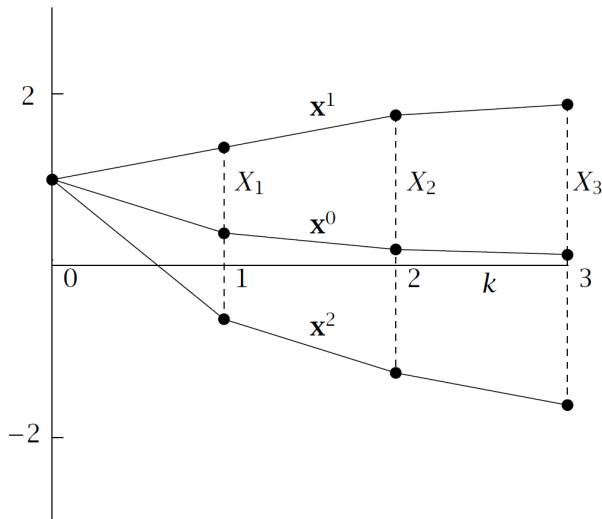


Figura 29 – Ilustração de “Tubos” para avaliar a estabilidade de um controle preditivo. Fonte: (RAWLINGS DAVID Q. MAYNE, 2019).

dinâmica ditada pelas matrizes de ganho do controlador ( $W_y$ ,  $W_u$  e  $W_{\Delta u}$ ) e do integrador externo  $k_i$ . Considerando que essas matrizes são positivas e definidas, a solução subótima existirá e será única dentro do intervalo de previsão, garantindo a estabilidade da mesma.

O ruído inerente ao sensor é mitigado ao treinar a RNA com sinais filtrados usando grandezas futuras durante a limpeza para tratar os dados, conforme será discutido na Seção 5.2.2.

Por se tratar de sistemas não-lineares, a prova de estabilidade e da convergência em sistemas com ruído fica comprometida, porém, as abordagens de ajustar o número máximo de iterações, critérios de convergência e configurações das condições iniciais de otimização, ajudam a aumentar a robustez. A estabilidade do otimizador dar-se-á via avaliação dos resultados reais pós experimentos dentro das condições na qual o sistema foi implementado.

## 5 RESULTADOS EXPERIMENTAIS

Os resultados experimentais são divididos em três seções a saber: 1) os detalhes de instrumentação do protótipo, 2) a identificação de sistemas e, 3) os resultados com o controle preditivo MPC.

### 5.1 PROTÓTIPO

A geladeira foi instrumentada tanto com sensores como *atuadores*, pois, ela é um produto comercial sem acesso externo para seus componentes. Os sensores de temperatura foram adicionados nos pontos de interesse onde um replica a leitura do produto e os outros, são usados para verificar outras grandezas. O inversor *original* do produto foi trocado por outro no qual aceita referências de velocidade de compressor a partir um sinal  $f_{in}$  de frequência variável e *duty cycle* constante nesse caso, o inversor utiliza a frequência desse sinal para ajustar a referência de velocidade mecânica do compressor. Em outras palavras, a frequência elétrica desse sinal de referência determina a frequência elétrica de saída do inversor.

Este novo inversor infelizmente não disponibiliza grandezas elétricas, calculadas internamente em seu *DSP*, como por exemplo, velocidade de motor, potências, entre outras. Para registrar estas grandezas, um *wattímetro* - *Yokogawa WT500* foi adicionado ao protótipo.

O diagrama com as ligações está representado na Figura 30.

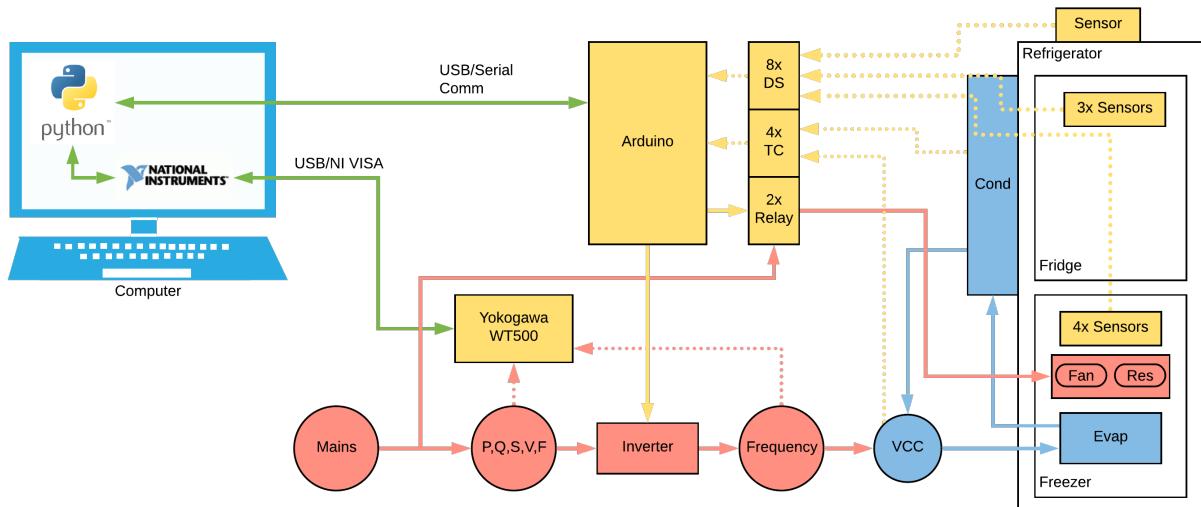


Figura 30 – Diagrama de ligação. Fonte: AUTOR (2021).

Além do wattímetro, utilizou-se kit comercial *Arduino* para interfacear o computador com as grandezas físicas do produto. O *Arduino* desempenha a função de ler todos os sensores, comandar os relés, gerar o sinal *PWM*, receber comandos, e enviar valores sensoreados e receber comandos do computador via porta *USB* utilizando protocolo próprio para essa aplicação.

No computador, instalou-se programas para comunicar com *Arduino* e o wattímetro, e executar tanto a identificação de sistema quanto o controle preditivo. As rotinas desenvolvidas

foram implementadas em Python 3.x Anaconda (FOUNDATION, 2019). Para a comunicação com o wattímetro, foram instaladas as bibliotecas da National Instruments - VISA (INSTRUMENTS, 2020) que estão disponíveis gratuitamente para o público. As funções dos componentes de *software* estão sumarizadas na Tabela 3.

Tabela 3 – Sumário das funções de Computador, Arduino e Wattímetro WT500. Fonte: Autor (2021).

Dispositivo	Função
Computador	Executar algoritmos de identificação de sistemas Executar algoritmos de controle preditivo Salvar dados dos equipamentos e variáveis internas
Arduino	Medir temperatura de ambiente (externo) ( $^{\circ}\text{C}$ ) Medir temperatura de saída do difusor de ar (geladeira) ( $^{\circ}\text{C}$ ) Medir temperatura no centro geométrico da gaveta superior (geladeira) ( $^{\circ}\text{C}$ ) Medir temperatura do retorno de ar (geladeira) ( $^{\circ}\text{C}$ ) Medir temperatura centro geométrico da gaveta superior (congelador) ( $^{\circ}\text{C}$ ) Medir temperatura de entrada do evaporador/sensor de degelo (congelador) ( $^{\circ}\text{C}$ ) Medir temperatura de saída do evaporador (congelador) ( $^{\circ}\text{C}$ ) Medir temperatura de insuflador (congelador) ( $^{\circ}\text{C}$ ) Medir temperatura na de sucção (compressor) ( $^{\circ}\text{C}$ ) Medir temperatura na de descarga (compressor) ( $^{\circ}\text{C}$ ) Medir temperatura de entrada do condensador ( $^{\circ}\text{C}$ ) Medir temperatura de saída do condensador ( $^{\circ}\text{C}$ ) Habilitar tensão 220V AC para ventilador interno Habilitar tensão 220V AC para resistência de degelo Enviar sinal <i>PWM</i> de frequência (velocidade) de referência
WT500	Registrar tensão de rede eficaz (ou <i>rms - root mean square</i> ) ( $\text{VAC}_{\text{rms}}$ ) Registrar frequência da tensão de alimentação da rede elétrica ( $\text{Hz}$ ) Registrar potência ativa de entrada do inversor de frequência ( $\text{W}$ ) Registrar potência reativa de entrada do inversor de frequência ( $\text{VAr}$ ) Registrar potência aparente de entrada do inversor de frequência ( $\text{VA}$ ) Registrar frequência da corrente de saída do inversor ( $\text{Hz}$ )

O programa foi estruturado em camadas e orientação a objetos para flexibilizar a execução de testes de identificação de sistemas e do controle preditivo. A Figura 31 ilustra estas camadas de *software*.

O computador pessoal utiliza o sistema operacional multitarefa *Windows* e este não é considerado um sistema de tempo real. Esta característica impacta em sistemas que demandam baixa variação temporal das rotinas de controle, porém, a planta térmica é um sistema *relativamente lento*, com sua constante térmica de ordem de várias dezenas de segundos como será visto a seguir. Esta característica da planta térmica habilita o sistema de aquisição a fazer uma leitura a cada alguns segundos de tal forma que eventuais desvios temporais sejam tratados como ruído de aquisição ou mesmo desprezados.

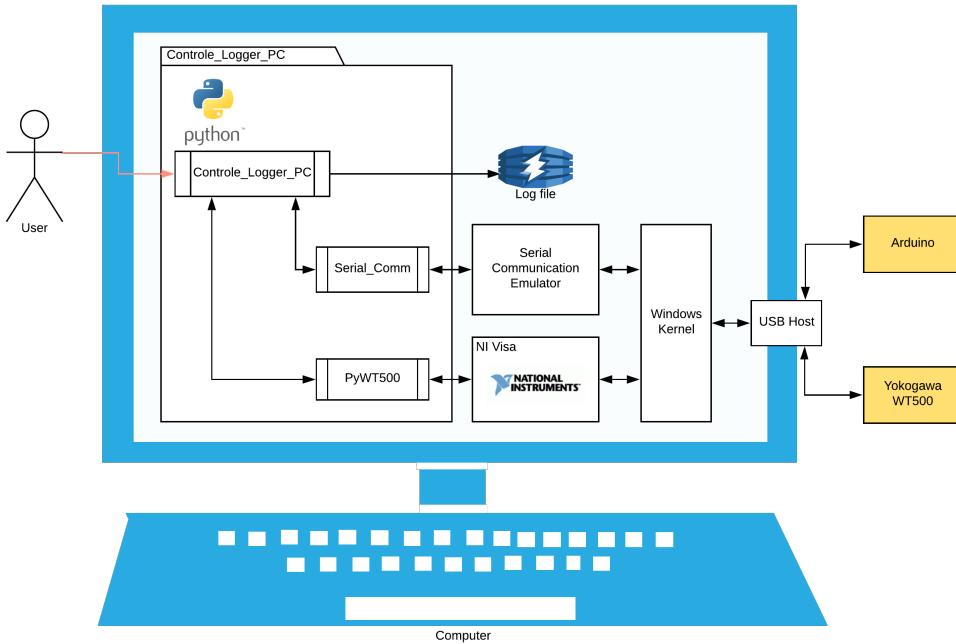


Figura 31 – Estrutura do programa principal. Fonte: AUTOR (2021).

Para diminuir estas possibilidades de desvio temporal, alterou-se as permissões e prioridades do programa em Python para a mais alta disponível. Para verificar a estabilidade temporal do sistema de aquisição, todos os arquivos de registro de dados armazenam a data e hora de cada amostra e então calcula-se o intervalo de tempo transcorrido entre duas amostras consecutivas. A Tabela 4 contém o sumário estatístico de 91632 amostras da taxa de amostragem da aquisição de dados.

Tabela 4 – Sumário do Tempo de Amostragem.

Info	Valor
média	3.001373
desvio padrão	0.002656
mínimo	3.000061
máximo	3.649580

Com a taxa de amostragem configurada em 3 segundos, observa-se o desvio-padrão de 0.0027 segundos o que indica estabilidade. O *pior caso* de 3.65 segundos é devido à execução de rotinas de atualização, todavia, 0.65 segundos de desvio temporal é irrelevante. Salienta-se ainda que o programa compensa estes desvios temporais, por exemplo, se o tempo de amostragem apresentar um desvio de 0.65 segundos mais longo, então este desvio será compensado de tal forma que o intervalo seguinte seja 0.65 mais curto; esta abordagem minimiza efeitos de acúmulo de desvios temporais, i.e. minimiza desvio temporal por tendência (*drift*).

## 5.2 IDENTIFICAÇÃO DE SISTEMAS

Esta seção apresenta resultados e desafios do que foram expostos teoricamente no Capítulo 3. Lembrando que a identificação de sistemas busca explicar as principais dinâmicas do sistema usando grandezas que sejam pertinentes à ela. No caso, o tema abordado no Capítulo 2 indica quais grandezas do protótipo serão computadas para identificar e validar o modelo da planta.

### 5.2.1 Frequência de Amostragem

A frequência de amostragem mais alta disponível no protótipo para adquirir as informações é 1/3 Hz, e assume-se que este tempo é suficiente, pois não foi detectada nenhuma dinâmica térmica mais rápida de tal forma que este tempo de amostragem fosse um impedimento. Dito isto, é necessário avaliar o protótipo para identificar qual é o tempo de amostragem mínimo necessário para capturar as dinâmicas térmicas. Uma regra para ajustar o tempo de amostragem é que este tempo seja rápido o suficiente para capturar as dinâmicas mais altas, e lento o suficiente para ruídos não serem *confundidos* com dinâmicas da planta (AGUIRRE, 2015).

Conforme a abordagem ilustrada na Seção 3.7, aplicou-se degraus de referência de velocidade do compressor, vide Figura 32.

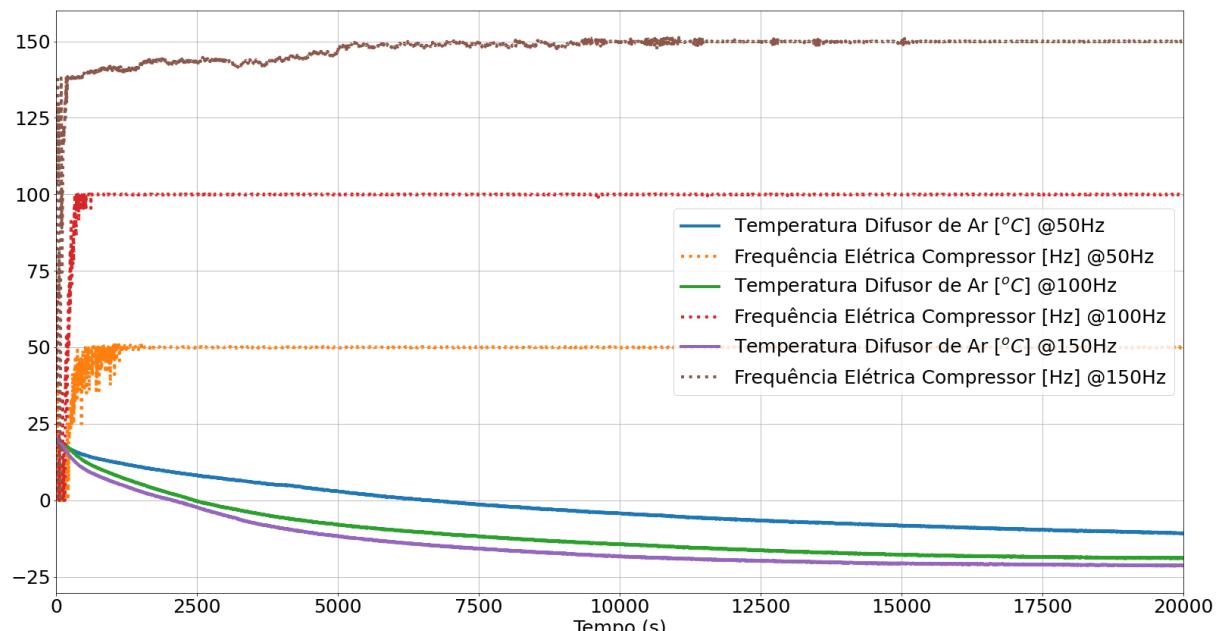


Figura 32 – Degraus *negativos* de velocidade de referência do compressor: a) 50 Hz, b) 100 Hz, c) 150 Hz. Fonte: AUTOR (2021).

Observa-se que para cada degrau, tanto o tempo de convergência da temperatura quanto o valor em regime permanente são diferentes, o que comprova a não-linearidade do sistema por violar o conceito da *superposição*, i.e. constantes de tempo e ganhos variáveis de acordo com o sinal de entrada. A Figura 33 ilustra os resultados das correlações linear (15) e não-linear (16) para cada degrau.

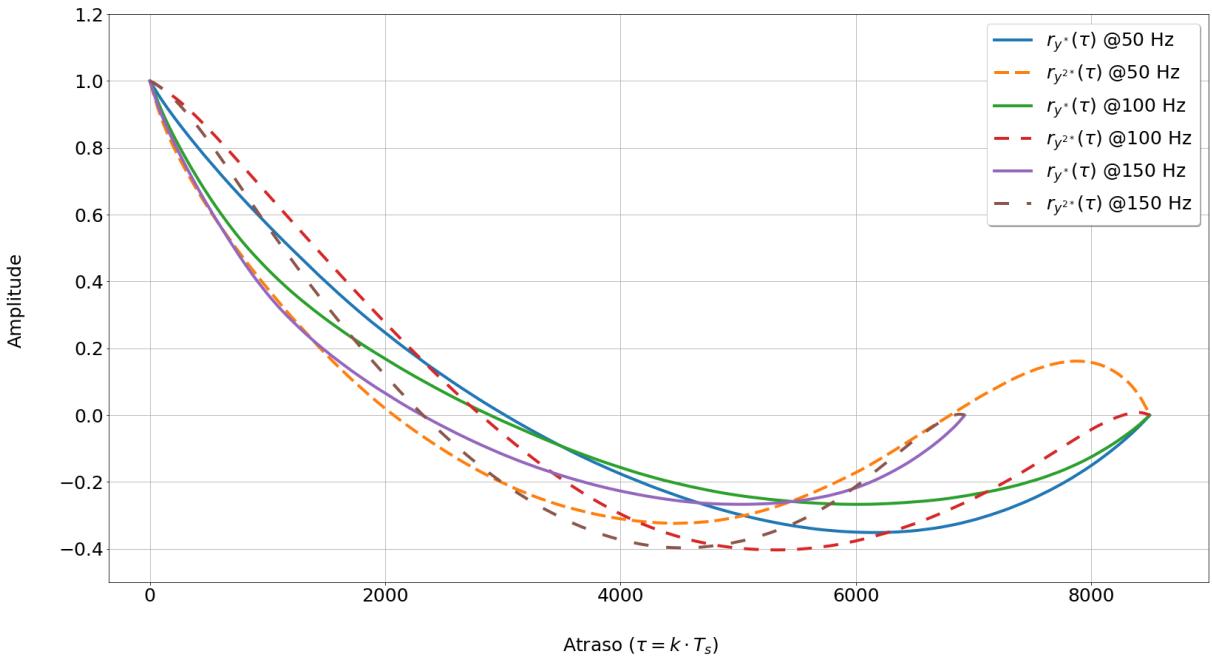


Figura 33 – Correlações linear e não-linear com degraus de compressor: 50, 100 e 150Hz. Fonte: AUTOR (2021).

Para calcular a frequência de amostragem, usa-se o *menor mínimo* de todas as correlações calculadas, pois ele será suficiente para capturar todas as dinâmicas ilustradas em qualquer ponto de operação (AGUIRRE, 2015).

Da Figura 33, o menor mínimo acontece em  $\tau = 4410$  com o tempo de amostragem de 3 segundos entre duas amostras consecutivas. Então, o tempo mais curto para alcançar o regime permanente é de 13230 segundos. Neste caso, aproxima-se o sistema como um de primeira ordem para calcular a constante de tempo, assim  $4T_{cid} = 98\%$  o que implica em uma constante de tempo  $T_{cid} = 3307,5$  segundos (aprox. 55 minutos). Uma regra de relaxamento (AGUIRRE, 2015) é empregada e optou-se por um fator de 10 para relaxar, ou seja, o tempo de amostragem térmica é dado por  $T_s = \frac{T_{cid}}{10} \approx 330$  segundos (aprox. 5,5 minutos) - salienta-se que a rede neural será utilizada apenas com a porta fechada.

### 5.2.2 Limpeza e Preparação de Dados

Durante processo de identificação de sistemas, é natural que algumas *exceções* ocorram como equipamentos registrando informações divergentes ou mesmo inválidas. A limpeza de dados implica em conferir manualmente cada arquivo buscando por tais entradas de dados. Por exemplo, o wattímetro registra *inf* (*infinito*) ou *NaN* (*not a number*) quando este tem alguma dificuldade para calcular as grandezas. A heurística de limpeza não deve influenciar os resultados e ela substitui o valor *inf* por 0, pois o wattímetro registra este valor quando o compressor é desligado e não há corrente elétrica sendo injetada no motor. Valores de *NaN* são de tensões medidas e são substituídos pelo valor imediatamente anterior, pois, 3 segundos de tempo de amostragem é rápido o suficiente para que a evolução do sistema térmico seja desprezível.

O sinal elétrico de um inversor contém ruídos elétricos devido à sua modulação da tensão *DC* para *AC*, para então ajustar os níveis e frequência de corrente no motor; então, o wattímetro terá leituras com alto conteúdo de harmônicos que necessitam ser filtrados. A Figura 34 contém a evolução da frequência elétrica do motor do compressor, a potência ativa e os seus valores filtrados via filtro passa-baixas usando média móvel, conforme a Equação (46) com  $n_{ma} = 200$  ou 600 segundos.

$$y_f(k) = \frac{\sum_{i=0}^{n_{ma}} y_f(k-i)}{n_{ma}} \quad (46)$$

O filtro de média móvel é atualizado na mesma taxa de amostragem do sistema, i.e. a cada 3 segundos. Salienta-se que todo filtro inclui distorções em ganho e em fase, e estes efeitos de distorções serão compensados pela RNN durante o seu treinamento.

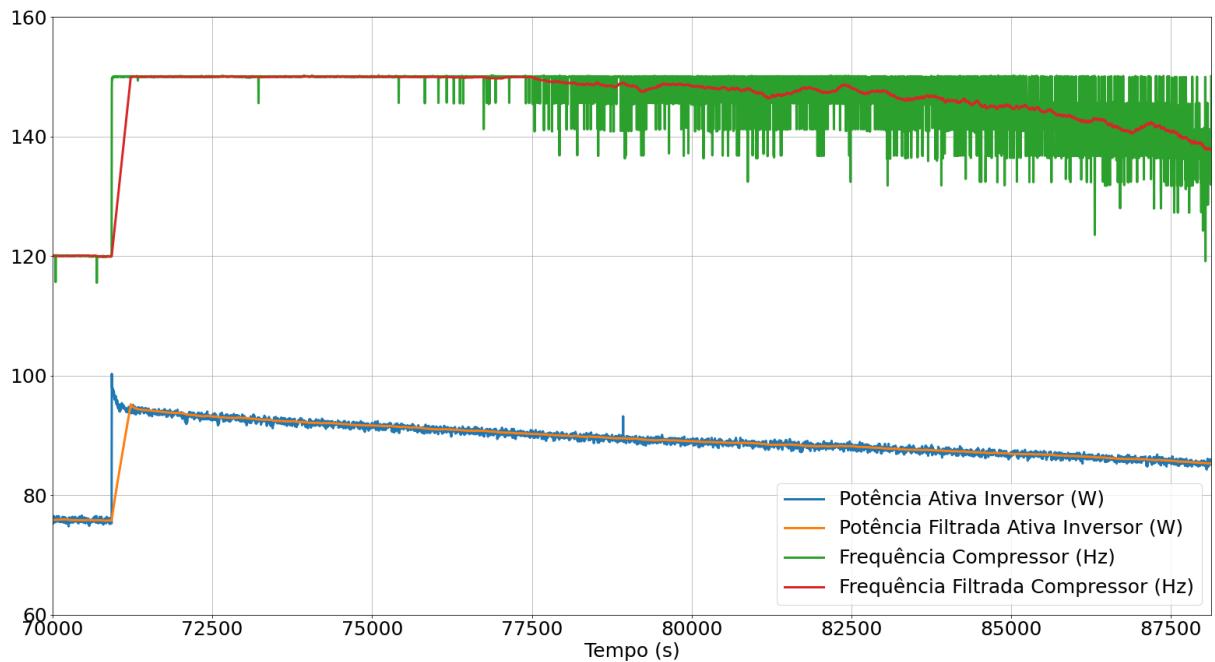


Figura 34 – Exemplo de uso de filtro nos sinais adquiridos. Fonte: AUTOR (2021).

Como a taxa de aquisição é muito mais rápida que o modelo, então, pode-se fazer subamostragem dos dados adquiridos para gerar mais arquivos de treinamento e validação de modelo; i.e. para formar um conjunto de dados, usa-se uma amostra para treino e validação e ignora-se as próximas 110 amostras.

Além disto, é necessário preparar os arquivos para auxiliar na execução dos algoritmos de identificação. Um cuidado especial; são adquiridos múltiplos arquivos e estes tem dependência temporal, ou seja, é necessário iniciar cada arquivo de forma adequada antes de empilhá-los.

Conforme explanação na Seção 3.3, a RNN usará valores de instantes anteriores como entradas recorrentes durante o treinamento e validação em *malha aberta*. A Figura 35 ilustra um arquivo adquirido e com as colunas deslocadas de um intervalo de amostragem para a coluna à direita. Neste exemplo, as entradas grafadas em amarelo são as entradas, e a verde, a saída para a rede neural.

Entradas			Saída
Frequência Elétrica de Compressor [Hz](k)	Frequência Elétrica de Compressor [Hz](k-1)	Frequência Elétrica de Compressor [Hz](k-2)	Temperatura Difusor de Ar [degC](k)
0	0	0	0.510272727
0.451540071	0	0	0.501727273
0.451606703	0.451540071	0	0.494909091
0.451594071	0.451606703	0.451540071	0.488090909
0.451597806	0.451594071	0.451606703	0.481272727
0.45158529	0.451597806	0.451594071	0.476090909
0.451576877	0.45158529	0.451597806	0.470454545
0.451581574	0.451576877	0.45158529	0.463636364
0.451576252	0.451581574	0.451576877	0.459090909
0.451589948	0.451576252	0.451581574	0.454
0.451575619	0.451589948	0.451576252	0.451727273
0.451563103	0.451575619	0.451589948	0.446

Figura 35 – Lógica de empilhamento e preparação de arquivos. Fonte: AUTOR (2021).

Ao total, foram gerados quatro arquivos, e cada um com 3240 pontos; sendo um arquivo para treinamento e três arquivos para validação da RNN<sup>1</sup> e as bases utilizadas pelo escalonamento da Equação (5) são arbitrariamente definidas como:  $Frequencia_{BASE} = 155Hz$ ,  $Temperatura_{BASE} = 55^{\circ}C$  e  $Potencia_{BASE} = 200W$ .

### 5.2.3 Seleção de Entradas e Saídas da RNN

Um requisito para o modelo identificado é ter baixa complexidade computacional. Há apenas uma variável de predição (saída da RNN) e é a temperatura de difusor de ar. A identificação resume-se em avaliar quais grandezas deverão ser medidas para que consigam predizer adequadamente com o mínimo de complexidade numérica.

Os conceitos expostos do Capítulo 2 auxiliam nas intuições acerca do princípio físico a ser considerado:

- Temperatura Ambiente [ $^{\circ}C$ ]; esta é inversamente proporcional à quantidade de calor rejeitado ao ambiente. Neste caso, quanto mais alta a temperatura, menor será a quantidade de calor rejeitado;
- Potência Ativa de Entrada do Inversor [W]; diretamente proporcional ao trabalho injetado pelo compressor no sistema térmico. Quanto mais alto este for, maior será o calor absorvido pelo evaporador;
- Frequência realizada pelo motor do compressor [Hz]; indica a velocidade do compressor e o fluxo de massa e é diretamente proporcional ao calor absorvido. Quanto mais alta, mais calor absorvido;

<sup>1</sup> Os dados utilizados para o treinamento e validação são diferentes.

- Sinal referência para a frequência de entrada para o compressor [Hz]; este não tem princípio físico envolvido em si, porém, o erro entre a referência e frequência realizadas é um indicativo da *saturação* do compressor;
- Derivadas temporais de potência, frequência e temperatura; estas derivadas capturam as constantes de tempo variáveis e, que estão conectadas ao ponto de operação e carregamento do produto.

Para determinar quais variáveis recursivas, tanto recursão na entrada quanto na saída pela entrada proverão a melhor qualidade do modelo. Assim, as variáveis foram determinadas empiricamente baseadas no conhecimento prévio de sistemas térmicos e inversores, para então treinar e validar o desempenho da RNA. A combinação das entradas é definida pela lista a seguir:

- Temperatura Ambiente [ $^{\circ}\text{C}$ ](k);
- Sinal de Frequência de Entrada para o Compressor [Hz](k);
- Potência Ativa de Entrada do Inversor [Watts](k);
- Potência Ativa de Entrada do Inversor [Watts](k-2);
- Frequência de Rotação do Compressor [Hz](k);
- Frequência de Rotação do Compressor [Hz](k-1);
- Frequência de Rotação do Compressor [Hz](k-2);
- Temperatura do Difusor de Ar do Refrigerador [ $^{\circ}\text{C}$ ](k-1);
- Temperatura do Difusor de Ar do Refrigerador [ $^{\circ}\text{C}$ ](k-2).

Observa-se que a recorrência da RNN se dá pelo uso do valor predito em  $(k - 1)$  e  $(k - 2)$  para fazer uma nova predição em  $(k)$ .

#### 5.2.4 Treinamento e Validação da RNN

O plano de testes empreendido nesta tese está definido na Tabela 5. Para todas as topologias, a unidade de saída implementa a função de ativação linear. O número de épocas foi configurado para 75 e o tamanho do lote (*batch size*) foi, arbitrariamente, configurado para 32, pois esse tamanho de lote apresentou execução temporal mais curta para convergir aos valores finais do treinamento. A coluna “Nr. Param.” contém a quantidade de parâmetros (matrizes  $W$  de ligações entre unidades) a serem ajustados durante o processo de treinamento. Quanto mais parâmetros, maior o grau do polinômio equivalente, implicando em maior o esforço computacional.

Tabela 5 – Plano de teste para seleção de parâmetros da RNN. Fonte: AUTOR (2021).

#	Topologia	Nr. Camadas	Unid./Camada	Ativação Oculta	Nr. Param.
1	MLP	3	9	tanh	280
2	FCC	18	1	tanh	361
3	FCC	3	1	tanh	46
4	FCC	3	1	ReLU	46
5	FCC	2	1	ReLU	33
6	MLP	2	3	ReLU	46
7	MLP	2	3	tanh	46
8	MLP	2	4	tanh	65
9	MLP	2	4	ReLU	65

O treinamento em malha aberta e em malha fechada utilizou o *MSE*, todavia para extrair mais informações do desempenho da RNN, implementou-se métricas adicionais para avaliar o sinal de erro entre a predição e medição. As métricas adicionais são:

- *rms* do erro, indica o quanto longe estão as predições das medições;
- *média* do erro, indica se há desvios das médias (*offsets*);
- *desvio padrão* do erro, indica o quanto ruidosas são as predições (impacto na generalização).

Após limpar, preparar os arquivos e realizar o *downsampling* de 3 segundos para 330 segundos, foram usadas 3242 conjuntos de treino e 9725 para validação. Neste contexto, *downsampling* significa diminuir a taxa de amostragem ao considerar uma amostra a cada 330 segundos. Iniciou-se a busca pelos parâmetros com mais camadas e unidades para então, diminuir estes números até o *MSE* degradar severamente. Os resultados se encontram na Tabela 6 onde MA significa Malha Aberta e MF, Malha Fechada.

Dos resultados de treinamento, nota-se que todas as configurações são capazes de explicar as dinâmicas do ar frio do difusor a partir de grandezas elétricas e temperatura externa. As métricas adicionais de validação divergiram porém, foram consistentes.

Para fins de ilustração, a partir da Tabela 6 escolhem-se a “melhor RNN” como sendo “#3-#2 MF” e a “pior RNN”, “#6-#3 MF”. As evoluções dos *MSEs* dos treinos da “melhor” e da “pior” RNN estão ilustradas nas Figuras 36 e 37, respectivamente.

Nota-se nas Figuras 36 e 37 que estender o treino acima de 75 épocas não haveria melhorias porque o valor do *MSE* se aproxima de uma assíntota.

As Figuras 38 e 39 ilustram as predições em *malha fechada* com “melhor” e “pior” caso, respectivamente.

A Figura 38 apresenta resultados bons de predição, e rastreia bem as dinâmicas do ar frio do difusor de ar do refrigerador. O erro de temperatura está contido, na maior parte do tempo, entre os limites de  $\pm 1.0^{\circ}\text{C}$ , não obstante, os instantes que erro alcançou valores maiores são devidos a alguns fatores em particular; sendo estes fatores:

Tabela 6 – Resultados da seleção de parâmetros da RNN. Fonte: AUTOR (2021).

#	<i>val. dados</i>	<i>rms</i>	<i>mean</i>	<i>std dev</i>	#	<i>val. dados</i>	<i>rms</i>	<i>mean</i>	<i>std dev</i>
1	#1 MA	0.2373	-0.1455	0.4650	6	#1 MA	1.4722	0.1296	1.2066
	#2 MA	0.1573	-0.1450	0.3692		#2 MA	1.3014	0.1306	1.1334
	#3 MA	0.2524	-0.1483	0.4801		#3 MA	1.5153	0.1280	1.2245
	#1 MF	0.6633	-0.2785	0.7655		#1 MF	2.2012	0.1753	1.4735
	#2 MF	0.4391	-0.2901	0.5958		#2 MF	1.9512	0.1703	1.3867
	#3 MF	0.5544	-0.2966	0.6831		#3 MF	2.2053	0.1708	1.4754
2	#1 MA	0.1559	0.0228	0.3943	7	#1 MA	0.3153	-0.0089	0.5615
	#2 MA	0.0905	0.0228	0.3000		#2 MA	0.2596	-0.0104	0.5095
	#3 MA	0.1720	0.0198	0.4143		#3 MA	0.3226	-0.0094	0.5680
	#1 MF	0.8491	0.1153	0.9144		#1 MF	0.5678	-0.0085	0.7536
	#2 MF	0.4482	0.0945	0.6629		#2 MF	0.4402	-0.0142	0.6634
	#3 MF	0.5839	0.0925	0.7587		#3 MF	0.5042	-0.0148	0.7100
3	#1 MA	0.2260	0.0127	0.4753	8	#1 MA	0.1903	0.0557	0.4327
	#2 MA	0.1829	0.0130	0.4275		#2 MA	0.1317	0.0563	0.3585
	#3 MA	0.2266	0.0114	0.4760		#3 MA	0.1995	0.0541	0.4435
	#1 MF	0.5190	0.0344	0.7197		#1 MF	0.9750	0.1836	0.9703
	#2 MF	0.3734	0.0278	0.6105		#2 MF	0.5732	0.1653	0.7390
	#3 MF	0.4217	0.0252	0.6490		#3 MF	0.6749	0.1588	0.8061
4	#1 MA	0.3105	0.0989	0.5484	9	#1 MA	0.2231	-0.0698	0.4672
	#2 MA	0.2346	0.0998	0.4741		#2 MA	0.1890	-0.0696	0.4292
	#3 MA	0.3328	0.0962	0.5689		#3 MA	0.2301	-0.0709	0.4745
	#1 MF	0.4317	0.1318	0.6438		#1 MF	0.9831	-0.1474	0.9807
	#2 MF	0.3259	0.1290	0.5562		#2 MF	0.7775	-0.1593	0.8674
	#3 MF	0.4296	0.1258	0.6434		#3 MF	0.8224	-0.1611	0.8926
5	#1 MA	0.2054	-0.0458	0.4510					
	#2 MA	0.1440	-0.0460	0.3767					
	#3 MA	0.2119	-0.0469	0.4580					
	#1 MF	0.5413	-0.0673	0.7327					
	#2 MF	0.3362	-0.0789	0.5745					
	#3 MF	0.4205	-0.0794	0.6437					

- na inicialização da RNN ( $t = 0$ ); o histórico das recorrências em  $(k - 1)$  e  $(k - 2)$  não foi computado ainda, porém, a rede converge rapidamente;
- mudança abrupta do sinal de referência de velocidade. Uma sequência de degraus foram aplicados à planta, conforme ilustrado na Figura 20;
- ativação do degelo; esta rotina desliga o compressor e o ventilador, e a potência e frequência são zerados. Mesmo que este efeito implique em treinamento de entradas iguais (ambas 0) e com saídas diferentes (temperaturas distintas) por curtos intervalos de tempo; a recorrência da rede ainda prediz razoavelmente a temperatura.

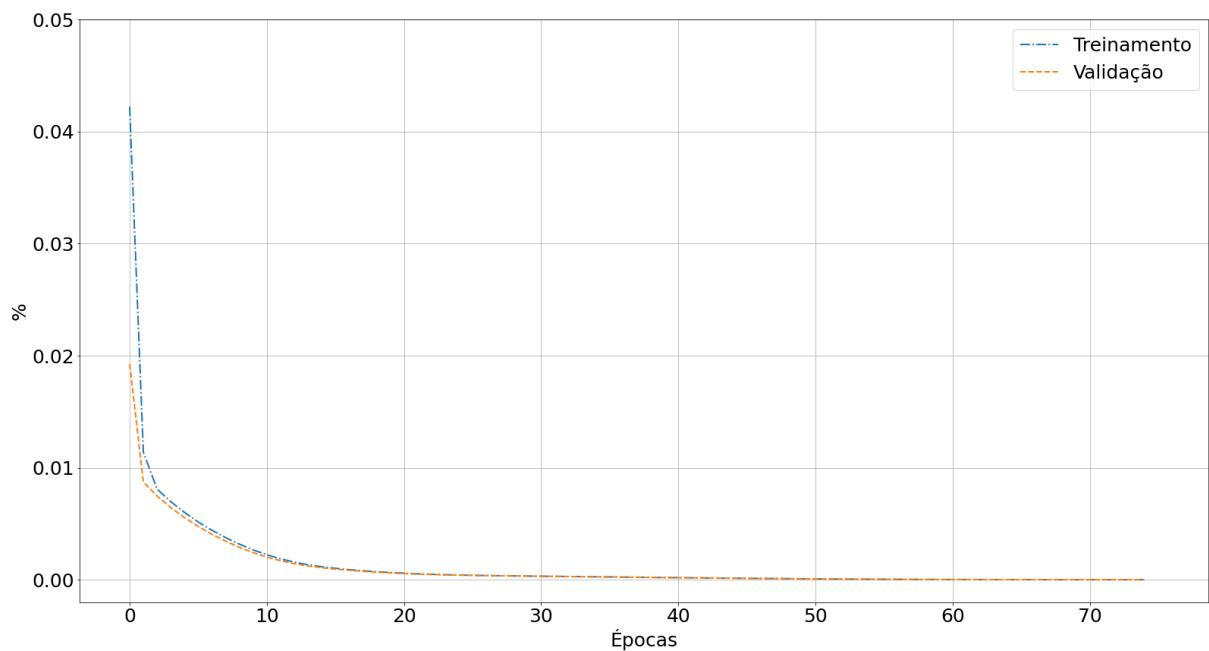


Figura 36 – Evolução do *MSE* do “melhor” resultado de treinamento. Fonte: AUTOR(2021).

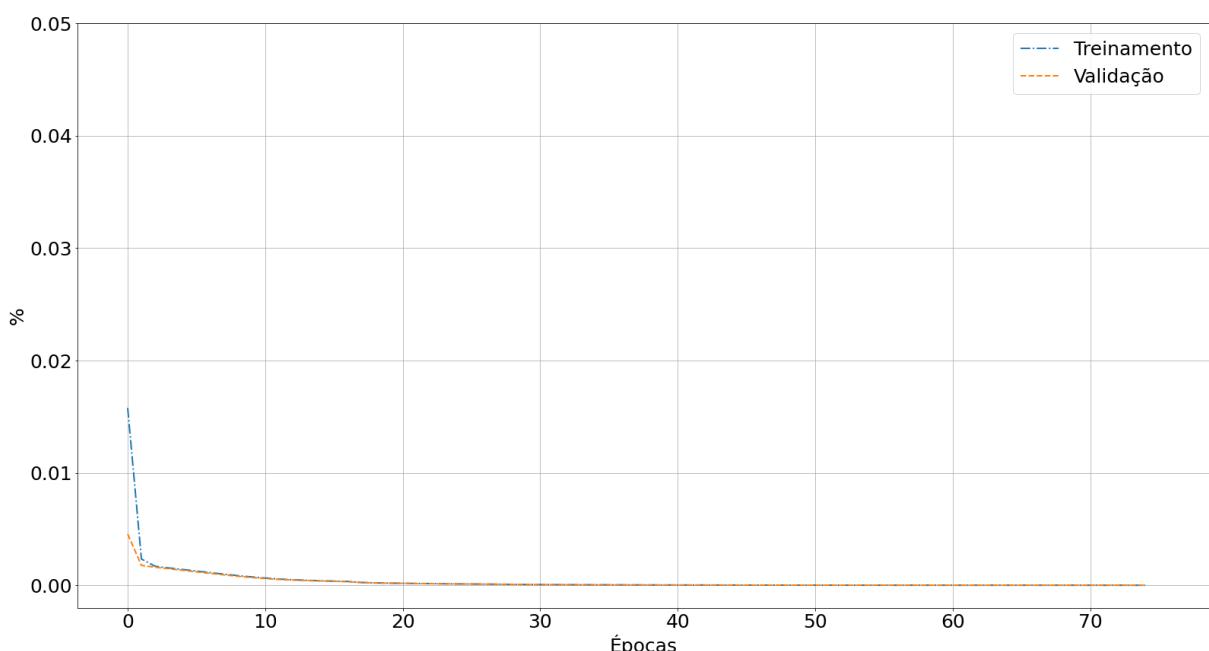


Figura 37 – Evolução do *MSE* do “pior” resultado de treinamento. Fonte: AUTOR(2021).

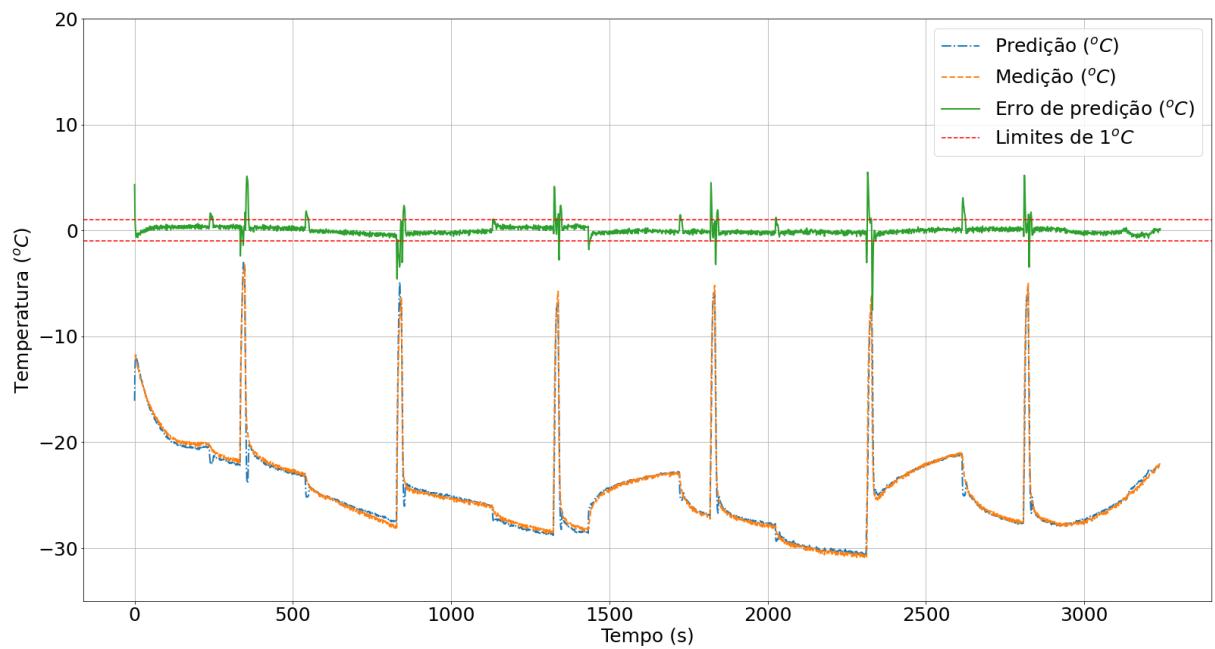


Figura 38 – “Melhor” caso de predição da RNN. Fonte: AUTOR (2021).

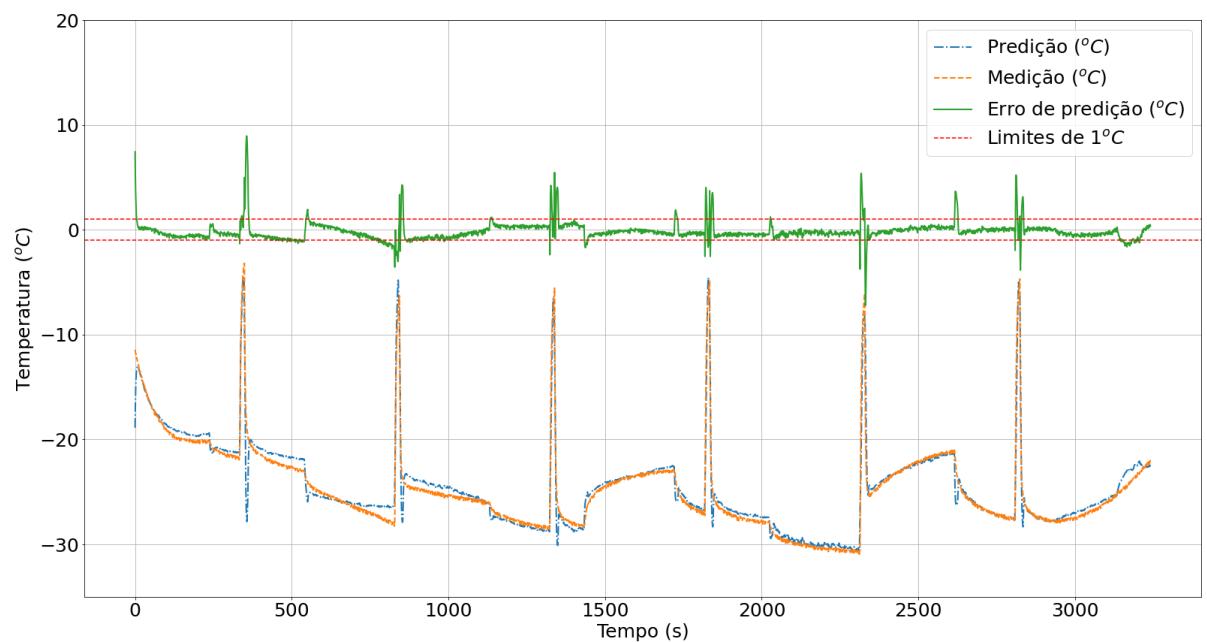


Figura 39 – “Pior” caso de predição da RNN. Fonte: AUTOR (2021).

## 5.3 CONTROLE PREDITIVO

Essa seção indicará a validação do funcionamento adequado do algoritmo preditivo projetado, através de resultados obtidos durante alguns ajustes de ganhos de controlador, discorrendo também sobre percalços e oportunidades encontrados durante a realização dos testes.

O tempo médio de duração de cada teste foi de 14 horas, com um mínimo de 7 horas e máximo de 60 horas consecutivas em um laboratório de uso compartilhado com outros acadêmicos. Esse compartilhamento introduziu ruídos nos testes, nos quais, o controle foi capaz de superar, conforme será visto mais adiante. Eventualmente, testes foram interrompidos por atualização automática de sistema operacional, falhas de comunicação USB ou mesmo quedas de energia devido à manutenção de energia elétrica das dependências do *campus*.

Vale salientar de antemão que, o controle foi mantido ligado durante a execução da rotina de degelo, ou seja, mesmo com a saída calculada não sendo aplicada ao controle do compressor, as grandezas como integradores foram calculadas para serem usadas imediatamente após o fim desta rotina.

### 5.3.1 Partida do controle

Para executar os laços de controle, é necessário que seus filtros e recorrências de preditor interno estejam devidamente inicializados. O tempo de partida foi calculado a partir da quantidade de amostras necessárias para preencher os históricos (*buffers*), e durante esse tempo inicial, o sinal de referência de velocidade fixo foi aplicado à planta. Essa referência foi arbitrariamente configurada para 80Hz.

### 5.3.2 Ajuste de Horizontes M e N

Os ajustes dos horizontes de controle e predição influenciam diretamente o desempenho dos regimes transitório e permanente, porém, esse ajuste implica em complexidade matemática dos modelos a serem otimizados.

Da teoria, sabe-se que os horizontes devem ser compridos o suficiente para cobrir todo o regime transitório para calcular os pontos ótimos futuros. Porém, sabe-se também que descasamento entre planta e modelo poderá levar a respostas sub-ótimas ou mesmo, em casos extremos, à instabilidade. Definir horizontes curtos implica em variações mais agressivas das grandezas de controle, i.e., mudanças bruscas da velocidade de referência  $u$  do compressor.

Para utilizar apenas a metade do tempo de transitório, ajustaram-se os horizontes  $M = N = 5$  e avaliou-se o tempo de otimização, com esse último, representando menos da metade do tempo de amostragem do controle. Salienta-se que é boa prática de sistemas de *tempo real* usar 50% do tempo exclusivamente para processamento pois garante uma certa margem para casos excepcionais sem provocar "estouros temporais" em *thread* do controle, por exemplo, o controle acoplado a uma *thread* temporizada com período de 330 segundos com o otimizador utilizando em média 150 segundos para a otimização. Eventualmente, o ponto ótimo dele estaria

em uma região do polítopo onde o tempo de convergência do otimizador utilizaria mais que 330 segundos na busca, ocasionado o *estouro* dessa *thread*.

### 5.3.3 Configuração das referências

A referência de temperatura é configurada como dois degraus negativos; um degrau de  $-14^{\circ}C$  no início dos testes ( $t_0$ ), seguido por outro degrau negativo de  $-18^{\circ}C$  em  $t = 3.5h$

A seleção dessas referências explica-se pela restrição de disponibilidade de câmara climática. Sendo assim, foi necessário ajustar temperatura de referência de início com a rotação mínima permitida ( $40rpm$ ) no controle permitindo que o controle operasse corretamente. Em outras palavras, temperatura de referência mais baixa que a mínima rotação de controle não fosse capaz de superar. Salienta-se que câmara climática permite ajuste de temperatura e umidade de ambiente, i.e., pode-se expor o protótipo a vários pontos de operação, dispensando as tentativas de controlar tais pontos manualmente.

### 5.3.4 Restrições

Como as restrições rígidas (*hard*) delimitam as regiões de operação do controlador, e as grandezas de ambiente não foram controladas adequadamente, i.e. experimentos em câmara climática; configurou-se as restrições com a seguinte heurística:

- A velocidade mínima (Hz) deve ser alta o suficiente para não ativar as proteções do inversor. Por exemplo, proteções contra velocidades mais baixas desligam o compressor. Assim, a restrição inferior para velocidade foi ajustada em 40 Hz;
- A velocidade máxima (Hz) deve ser baixa o suficiente para executar experimentos longos sem ativar proteções que desligam ou diminuem drasticamente a potência entregue ao compressor. Nesse caso, a restrição superior de velocidade foi ajustada para 90 Hz;
- A variação da velocidade de referência deve ser suave entre duas chamadas consecutivas do controle. Então, a restrição da diferença de referências de velocidade consecutivas de econtrolle foi ajustada, i.e.,  $\Delta_{umax} = 5.5Hz$ .

Vale salientar que, as restrições provocaram uma região de exclusão, em outras palavras, testes em dias consecutivos foram inviabilizados porque iniciar um teste a 40Hz para cargas frias implica em a temperatura ficar permanentemente abaixo da referência de  $-14^{\circ}C$ , e ainda essa restrição conflita com o fato de o compressor não ser desligado durante os testes.

Nenhuma restrição maleável (*soft*) foi implementada.

### 5.3.5 Ajuste do ganho do integrador externo

Esse ganho demonstrou alta influência no controlador, pois, a sua energia acumulada durante o transitório precisa apresentar uma dinâmica compatível com a dinâmica real da planta,

de tal forma que se evitem efeitos indesejados como *overshoot* e concomitantemente, mitigue o erro de regime e rejeite pertubações de forma satisfatória. Lembrando que, alta energia acumulada implica em *overshoot/undershoot*, necessidade de *anti windup* ou *reset* de integrador; baixa energia acumulada implica em tempos demasiadamente longos para o objetivo ser alcançado.

A sintonia desse ganho é iterativa, pois, é necessário avaliar o desempenho após alterar esse ganho concomitantemente com os ganhos internos do controlador. Para tal, usou-se uma abordagem empírica considerando alguns ganhos a serem avaliados. Lembrando ainda que, o modelo pode induzir a erros de variações paramétricas devido ao modelo em si e às perturbações como carga interna e temperatura ambiente variável.

Número alto de combinações de ganhos implica em inúmeros testes e vários dias para encontrar a solução. Alguns experimentos iniciais foram feitos e testou-se arbitrariamente dois ganhos, 0.03 e 0.05. O ganho 0.05 foi selecionado pois esse mostrou tempo de resposta mais curto e com *overshoot* menor. O *overshoot* pôde ser minimizado ao sintonizar os ganhos do controlador e *reset* deste integrador.

### 5.3.6 Ajuste dos ganhos do Controle Preditivo

Os ganhos *internos* do controlador, associados ao ganho do integrador externo compõe o conjunto de ganhos empreendidos pelo controle preditivo para realizar as dinâmicas desejadas. Com o ganho do integrador externo já ajustado, pode-se então iniciar os ajustes dos ganhos internos ao controle. Neste contexto, os ganhos são  $\rho_e$ ,  $\rho_{ei}$ ,  $\rho_m$  e estão definidos na Equação (42) que é reescrita por comodidade do leitor em (47). Essa abordagem de sintonia sequencial dos ganhos, do integrador externo para então os internos, amenizou a necessidade de realizar excessiva quantidade de experimentos.

$$\begin{aligned} \min_u J(k) = \sum_{i=0}^N \left( \rho_e \cdot e_{k+1 \rightarrow} + \rho_{ei} \cdot \int_{k+1 \rightarrow} e \right) + \rho_m \cdot \sum_{i=0}^M u_{k+1 \rightarrow} \\ \text{sujeito a } g_i \leq 0 \text{ e } h_j = 0 \end{aligned} \quad (47)$$

Foi necessário delimitar algumas grandezas para o protótipo trabalhar dentro de uma área coerente com o seu funcionamento. Citando alguns exemplos de como esse limite foi feito; a temperatura ambiente acima de  $23^\circ C$  com rotação mínima de compressor em  $40Hz$  para que a temperatura interna atingida com a mínima potência do compressor não alcançasse a referência, de tal forma que o compressor permanecesse sempre ligado. Além desse ajuste, encontrou-se limitações de recursos de laboratório, como: controle de temperatura de ar usando um aparelho condicionador de ar convencional sem condições de aquecer, ou mesmo baixar significativamente, a temperatura ambiente; cargas térmicas implementadas com garrafas PET de 600ml com água para simular o carregamento e a perturbação do sistema térmico, a ausência de controlador de umidade de ambiente, e restrição ao fluxo de pessoas durante execução de experimentos.

De início, as restrições foram ajustadas para as máximas de operação, i.e., entre  $40\text{Hz}$  e  $150\text{Hz}$ . A Figura 40 contém o resultado desse teste. Note que após o controle começar a atuar ( $t = 1500\text{s}$ ), ele levou a variável de controle (referência de velocidade repassada ao inversor) ao máximo e lá ficando até a energia dos integradores serem dissipadas ( $t = 6800\text{s}$ ) para então diminuir gradualmente a variável de controle que é a referência de velocidade do compressor. Esses ganhos implicaram em *overshoot* que permaneceram por tempo muito longo, pois ele iniciou enquanto a temperatura de referência estava em seu primeiro degrau ( $-14^\circ\text{C}$ ).

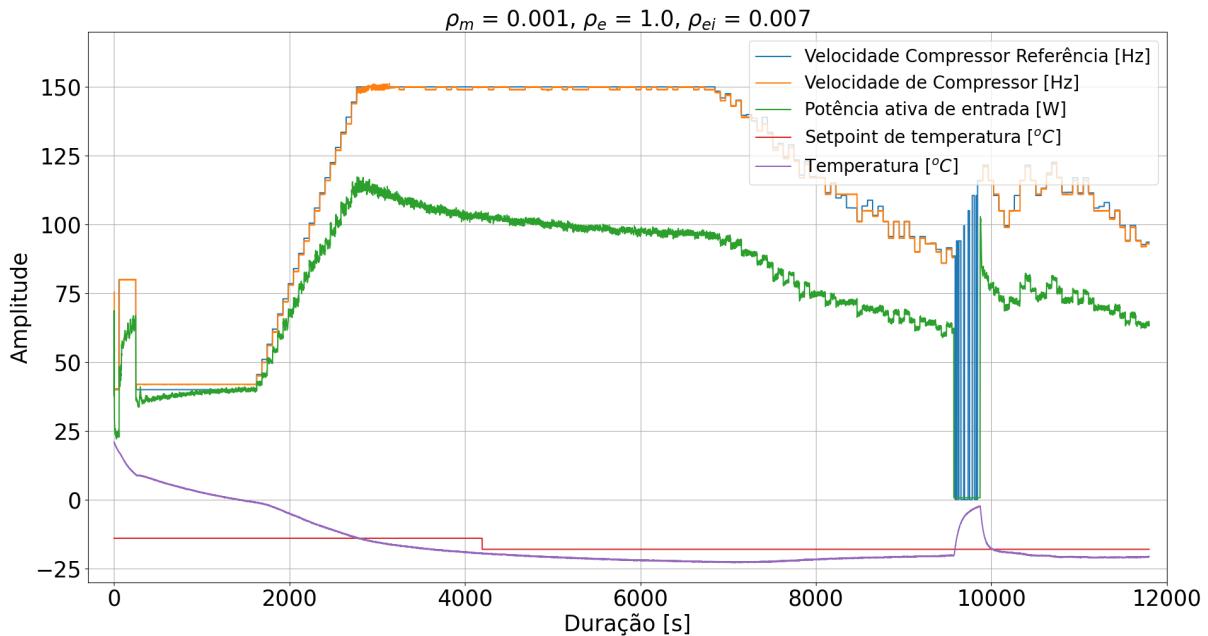


Figura 40 – Resposta temporal restrições ao seu valor máximo.  
 $\rho_e = 0.001$  ,  $\rho_{ei} = 1.0$  ,  $\rho_m = 0.007$  Fonte: AUTOR (2023).

Para resolver o impacto do *overshoot*, diminui-se o ganho do integrador de erros futuros. Como o sistema estava com baixo carregamento térmico, restringiu-se o sistema à operação até  $90\text{Hz}$  de velocidade de comando, conforme pode ser visto na Figura 41. Nota-se ainda que houve uma diminuição do *overshoot* porém há a dificuldade em abstrair a causa raiz; podendo esta ser devido à restrição mínima de  $40\text{Hz}$ , ou o ganho do integrador de erros futuros, ou mesmo interação entre ambos. Essa configuração causou um *overshoot* com amplitude menor, porém os tempos continuaram demasiadamente longos para alcançar o objetivo.

O teste fora interrompido após algumas horas, pois, manter esse teste por tempos superiores com a velocidade operando na restrição mínima, faria com que a temperatura diminuísse além da temperatura objetivo, o que invalidaria o próprio experimento, em outras palavras, a restrição mínima de  $40\text{Hz}$  seria o suficiente para manter a temperatura levemente inferior a  $-18^\circ\text{C}$ , acumulando valores tendendo ao infinito no integrador.

Ao diminuir o ganho  $\rho_{ei}$  pela sua metade e mantendo os demais ganhos, praticamente mitigou o *overshoot*. Notou-se ainda que a condição incial desse experimento foi diferente das anteriores, pois, as cargas já estavam resfriadas. Iniciar o experimento com cargas resfriadas

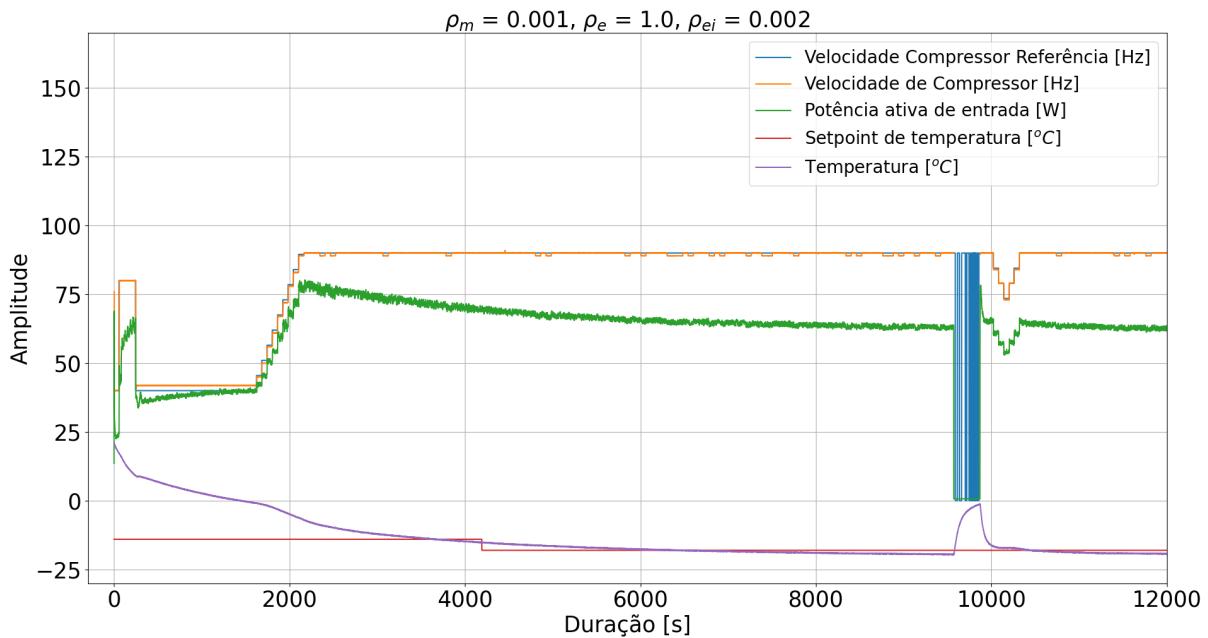


Figura 41 – Resposta temporal restrições aplicadas.  $\rho_e = 0.001$  ,  $\rho_{ei} = 1.0$  ,  $\rho_m = 0.002$  Fonte: AUTOR (2023).

implica em dinâmicas mais rápidas contribuindo para que o controle atue mais “cedo” em relação ao primeiro degrau de referência de temperatura; todavia ainda sendo possível ocorrer mais um *overshoot*.

O principal fator que causa *overshoot* em sistemas de controle de malha fechada é o integrador. Uma técnica comum para mitigar o *overshoot* é o *reset de integrador*; todos os testes até momento foram conduzidos com o integrador puro, ou seja, sem limitações ou modificações. Essa técnica de *reset* será explanada na seção seguinte.

### 5.3.7 Reset de integrador do laço externo

Quando o sistema apresenta uma dinâmica transitória mais acentuada, é comum que ocorra *overshoot* da variável a ser controlada até que a energia do integrador seja dissipada, ou mesmo zerada (“*resetada*”). A vantagem dessa implementação é de ser simples com a vantagem de descarga “instantânea da energia” acumulada no integrador.

A heurística adotada é definida como: habilita-se o *reset* apenas quando a referência sofrer alguma alteração e zera-se o integrador apenas uma vez quando a grandeza controlada se encontrar dentro de  $\pm 5\%$  do *setpoint*. A Figura 43 ilustra os momentos em que o *reset* ocorre, bem como a resposta do sistema.

### 5.3.8 Otimizador

O otimizador livre de derivadas selecionado para essa tese foi o *COBYLA* (*Constrained Optimization BY Linear Approximations*) (POWELL, 1964)(POWELL, 1994)(POWELL, 1998),

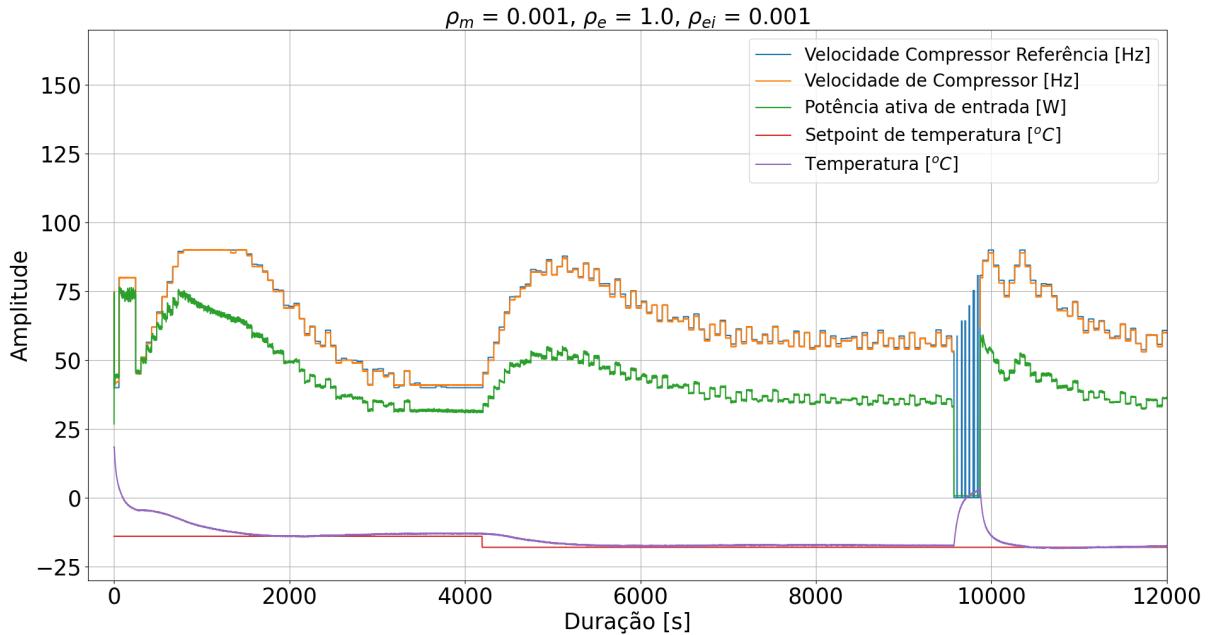


Figura 42 – Resposta temporal restrições aplicadas.  $\rho_e = 0.001$  ,  $\rho_{ei} = 1.0$  ,  $\rho_m = 0.001$  Fonte: AUTOR (2023).

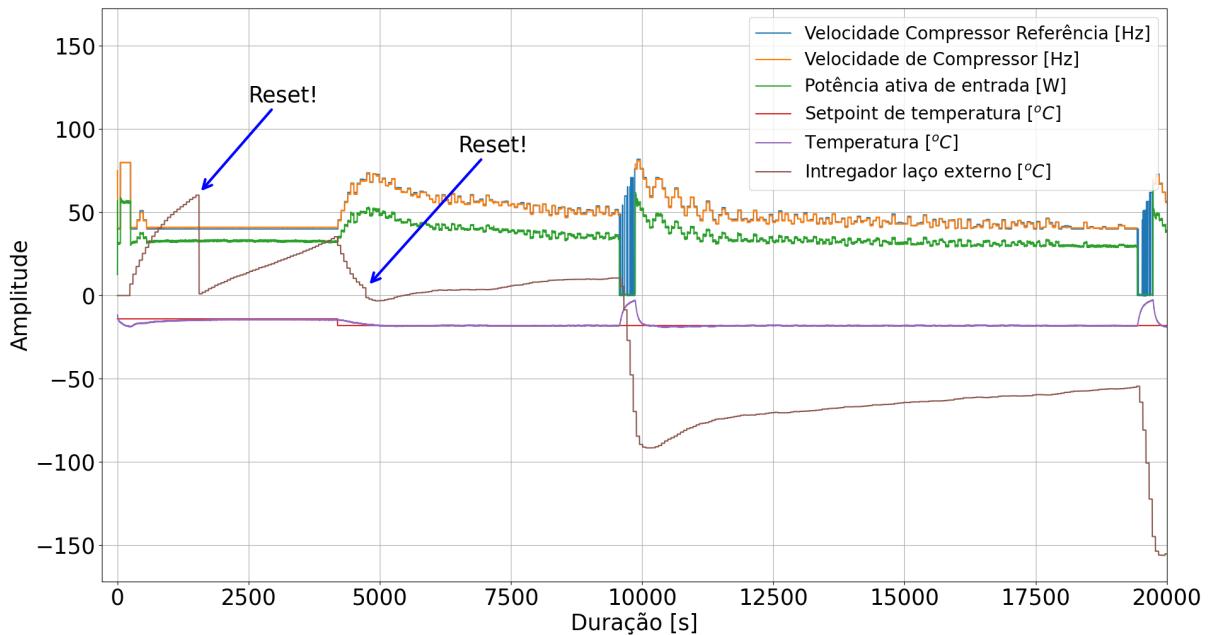


Figura 43 – Resposta temporal com o reset de integrador do laço externo. Fonte: AUTOR (2023).

pois é um otimizador de teoria e como robustez bem disseminadas, além de ter bibliotecas com suas implementações disponíveis (COMMUNITY, 2023)(JOHNSON, 2020).

O algoritmo COBYLA apresenta alta robustez com baixo número de variáveis otimizadas com performance aceitável (POWELL, 1994), e optou-se pelo uso da implementação nativa do módulo *Python-SciPy*.

### 5.3.9 Tempo de otimização

O otimizador é peça fundamental no controle preditivo e o seu tempo de execução é o desafio mais alto a ser transposto. Em alguns testes, detectou-se que o otimizador consumiu tempo em excesso ultrapassando o tempo de amostragem do controlador, e a planta manteve-se sob controle. Todavia, foi necessário ajustar seus parâmetros para garantir que o tempo máximo de execução do otimizador, convergido ou não, seja inferior ao tempo de amostragem do controle.

O tempo excessivo é detectado de duas formas: 1. pelo erro que ficou “travado” em um dado valor na Figura 44, onde o erro da temperatura não foi registrada continuamente, vide entre barras verticais pontilhadas, e nos arquivos de registro do experimento onde esse assumiu valores demasadiamente longos. Apesar do erro de temperatura travar num dado valor, as outras grandezas continuaram a ser registradas, pois o programa implementado utiliza o conceito de *threads*, i.e., se a *thread* do controle parar por tempo excessivo devido ao otimizador, as outras *threads* de comunicação com o Arduino e o watímetro continuam funcionando corretamente.

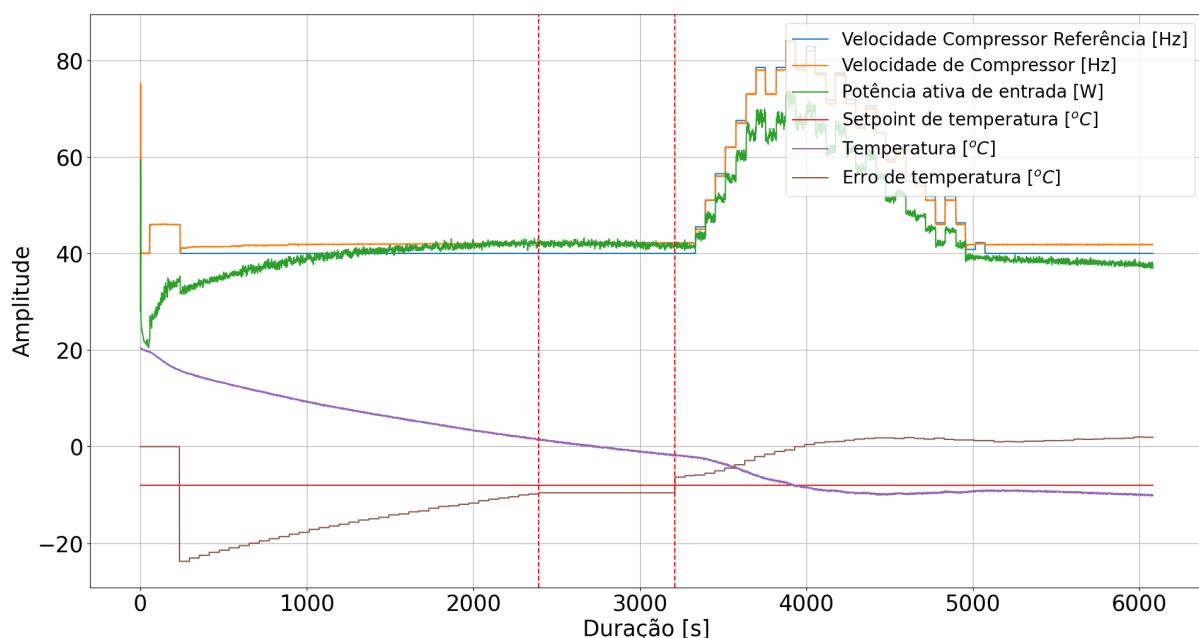


Figura 44 – Tempo excessivo de otimização violando os tempos de amostragem. Fonte: AUTOR (2023).

A partir de todos os arquivos de registro, calcula-se o tempo médio de otimização de 24.90 segundos com desvio padrão de 33.34 segundos. Com o tempo máximo, ou pior caso de tempo de otimização, de 2464 segundos. Após as modificações de parâmetros do otimizador, o tempo máximo detectado foi de 170 segundos sendo esse limitado pelo número de iterações limitada em 1000 iterações.

### 5.3.10 Condição Inicial

Conforme explanado no Capítulo 4, recomenda-se que a condição inicial seja definida utilizando a última solução válida. Esta abordagem porém, apresentou problemas ao encontrar

*mínimos locais* indesejados quando o controle está operando próximo à restrição superior de rotação. Uma vez encontrando esse mínimo local, o controlador caminhou para a restrição superior e lá ficando.

Para contornar esse problema, e tendo em mente que rotação mínima implica em mais eficiência, a condição inicial foi ajustada para os valores das restrições inferiores, i.e. 40 Hz, resolvendo o problema de mínimo local indesejado.

### 5.3.11 Avaliação da Estabilidade

Conforme fora avaliado, a estabilidade do controle preditivo está fortemente vinculada à estabilidade e qualidade de previsões. Salienta-se que, para todos os testes realizados dentro do espaço de inferência do treinamento da RNA, nenhuma grandeza anômala fora de cotação e em todos os casos, o otimizador convergiu para a solução final.

### 5.3.12 RNN fora do seu espaço de inferência de treinamento

Durante a partida, notou-se que o controle demorava a impor sinais mais altos de referência à planta. Esse fato é explicado pelo fato da RNN estar operando fora do seu espaço de inferência e o otimizador encontrar a solução trivial  $\Delta_u = 0$  como solução ótima. A seção delimitada entre barras vermelhas verticais, na Figura 45 ilustra essa operação. Ao final dessa seção de linhas pontilhadas e após a temperatura e potência atingirem valores compatíveis com os valores treinados pela RNN, o controle responde aumentando o valor de referência de velocidade do compressor.

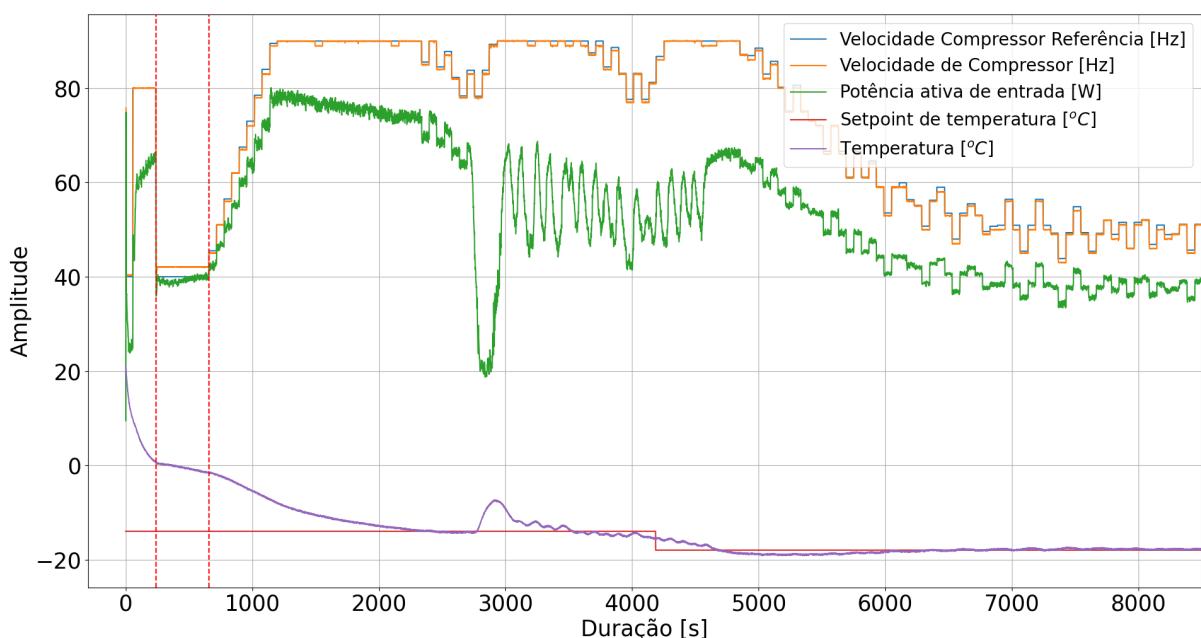


Figura 45 – Atuação da RNN fora do espaço de atuação. Fonte: AUTOR (2023).

### 5.3.13 Ventilação forçada sobre o evaporador

O Capítulo 2 explanou que o calor absorvido internamente da geladeira necessita ser rejeitado e que a sua capacidade de rejeição está vinculada à temperatura externa. Durante os testes, o ar condicionado do laboratório foi, inadvertidamente, ligado com a sua saída de ar frio apontada diretamente para o evaporador do produto. A ventilação forçada soprando ar frio em cima do evaporador colocou o protótipo em um ponto de operação na qual não fora projetado, lembrando que, a geladeira e seus componentes são comerciais e livres de qualquer modificação.

A seção delimitada por duas linhas verticais pontilhadas na Figura 46 demonstra os momentos de ligar e desligar o ar condicionado, indicando também, alterações abruptas da temperatura ambiente.

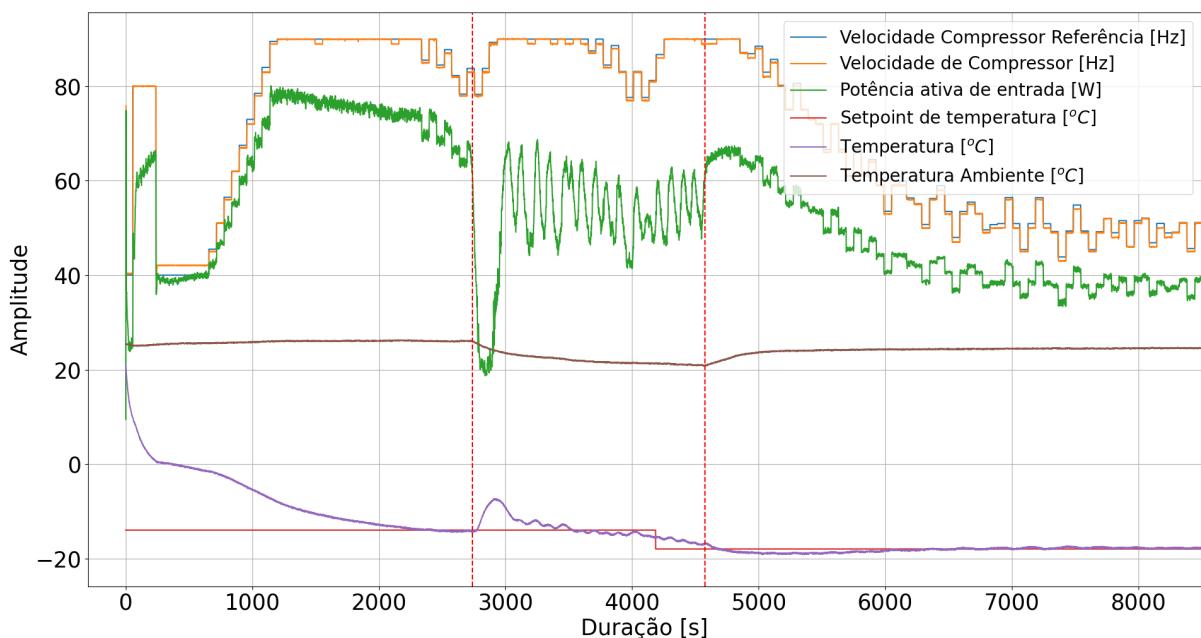


Figura 46 – Perturbação com ar condicionado no laboratório. Fonte: AUTOR (2023).

Logo antes do início da ativação da perturbação do ar condicionado, o controle deu início à desaceleração do compressor pois a temperatura encontrou a referência, porém, logo após a perturbação ser ativada, o compressor reagiu à esta perturbação e ativou sua proteção interna ao diminuir a potência aplicada ao compressor. Salienta-se que a RNN não foi treinada nessas condições e, como consequência, a temperatura interna subiu e o controle tentou compensar o aumento da temperatura ao requisitar mais rotação do compressor. Durante a perturbação, o controle e o compressor mantiveram suas rotações no limite superior de 90 Hz, porém, a potência apresentou um comportamento errático pois a sua proteção estava sendo ativada. Tão logo a perturbação cessou e a temperatura alcançou a sua referência, o controle operou dentro da normalidade.

### 5.3.14 Controle com evaporador bloqueado

Entende-se evaporador bloqueado como formação de gelo entre as aletas do evaporador bloqueando a passagem de ar pelo mesmo. Lembrando-se que o ventilador acoplado ao evaporador tem por função empurrar o ar frio do compartimento do congelador para o refrigerador.

Operar uma geladeira com o evaporador bloqueado é uma falha grave. Esse modo de falha implica em geladeira que nunca atingirá o *setpoint* de temperatura, pois, a ventilação forçada sobre as aletas do evaporador será incapaz de empurrar de ar conforme o esperado.

Ao executar dois experimentos; no primeiro utilizou-se, a velocidade máxima de compressor por dois dias com a porta do congelador accidentalmente aberta, interrompendo o teste sem executar a rotina de degelo após esse período. Esse experimento foi suficiente para acumular gelo, para então, inadvertidamente, executar o próximo experimento com a porta fechada, ver Figura 47.

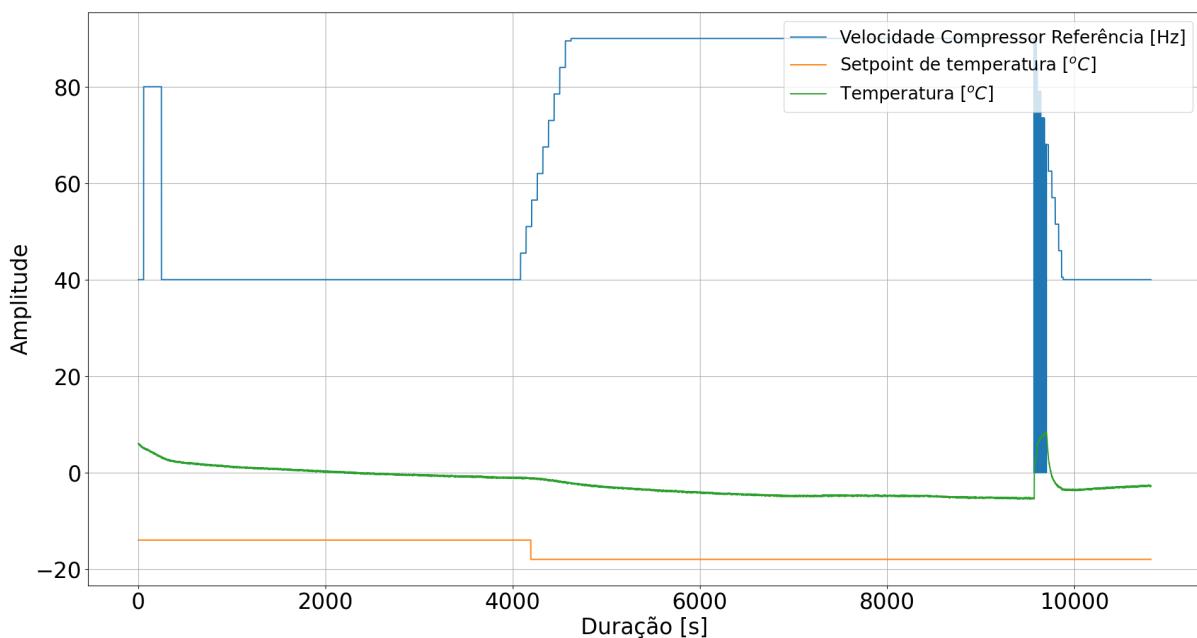


Figura 47 – Experimento com evaporador bloqueado. Fonte: AUTOR (2023).

Note que, o controle aguardou mais tempo para aplicar referências de velocidade maiores ao compressor, pois, a temperatura do sensor demorou mais para entrar dentro do espaço de inferência devido ao bloqueio do evaporador. Após o acréscimo das referências, a temperatura abaixou levemente e após algum tempo, o controle reagiu à essa interferência não mapeada pela rede neural e desacelerou o compressor até o valor mínimo da restrição de 40 Hz. Salienta-se que, o compressor seria automaticamente desligado se não houvesse restrição mínima de velocidade.

## 6 CONCLUSÕES E CONSIDERAÇÕES FINAIS

Esta tese demonstra a factibilidade de implementação em um aplicação comercial com técnicas sofisticadas e solidificadas na academia com possibilidades de comercialização pela indústria, em produtos acessíveis por grande parte da população. Para atingir esse objetivo, esta tese é um trabalho de ordem prática e teórica, para ser avaliadameticulosamente minimizando, ou mesmo mitigando, os efeitos indesejados do "mundo real". A fusão de várias áreas como: controle preditivo baseado em modelos, técnicas de identificação de sistemas, otimização numérica, apredizado de máquinas via redes neurais recursivas comprovam a sua unicidade.

Nesse contexto, realizar o controle preditivo baseado em modelos, que por sua vez demanda alto esforço computacional em uma aplicação cotidiana é um feito interessante, pois, abre novos caminhos de pesquisas que visarão acomodar demandas futuras sem demandar modificações expressivas ao controlador, i.e., preços variáveis de energia, produtos "inteligentes" de linha branca, requisitos de usuário e etc. serão levadas em consideração e aplicadas como restrições ao controlador; e este, por sua vez, desempenhará satisfatoriamente ao acomodar concomitantemente todas essas restrições.

O MPC exige um modelo fiel à planta para efetuar suas previsões adequadamente, para isso, exige-se uma rigidez de experimentação visando garantir que o processo de medição das grandezas registradas seja realizado de maneira consistente. Sendo assim, foi necessário mergulhar na física termodinâmica para precocemente ajustar algumas premissas a todo o experimento, por exemplo, determinar a frequência de amostragem das temperaturas de tal forma que esta não seja rápida demais para haver tempo disponível para cálculos do controlador e também não tratar ruídos de medição como dinâmica da planta, e ainda, não ser lenta demais a ponto de a planta mudar de estado sem que esta dinâmica seja considerada pelo controlador.

Uma vez com as grandezas devidamente adquiridas, realizam-se as regressões numéricas para mapear as entradas adquiridas com as saídas esperadas. Uma saída que contenha ruído precisa ser filtrada e, emprego de filtros numéricos implica em distorções de ganho e de fase. Novamente e precocemente, ajusta-se as premissas de que as regressões compensarão essas distorções se todos os sinais forem devidamente tratados. Ainda nestas premissas, avalia-se qual a topologia melhor do regressor, e neste caso, uma rede neural recursiva que seja otimizada para mapear as entradas e saídas, dentro do espaço de inferência, de tal forma que o seu erro seja o menor possível com o menor esforço computacional.

Após esse esforço *offline* preparando toda a base da funcionalidade do controle preditivo acoplado ao produto, é chegada a hora de sintonizar os parâmetros para que, os atratores do controlador imponham dinâmicas projetadas às grandezas desejadas. Essa etapa define o real desempenho a ser verificado, e que culminam na atratividade da tese pela academia e pela indústria.

A topologia de rede neural recursiva mostrou-se capaz de explicar as dinâmicas de interesse e manter o erro de previsão dentro dos limites de  $\pm 1.0^{\circ}\text{C}$  quando não há sinais

abruptos em suas entradas (degraus dos sinais de referência), e após os dados da recursão estarem devidamente inicializados. Estes erros são minimizados ao restringir adequadamente variação do sinal de controle pelo parâmetro  $\bar{\Delta}u$ .

Os testes de identificação foram realizados com a porta fechada e com o ventilador ligado, pois, o controle preditivo atua apenas com o compressor ligado com a intenção de circular o ar frio. Mesmo durante a ativação das rotinas de degelo, que desliga ambos compressor e ventilador, os testes mostraram que a RNN ainda é capaz de predizer a temperatura e esta informação pode ser usada para outras lógicas de produto.

O controle provou ser factível dentro das restrições e limites estabelecidos. Ele ainda desempenhou satisfatoriamente sob eventos e regiões na qual não fora projetado. Não obstante, mais trabalhos devem cobrir tais regiões para atingir todo o alcance da especificação do produto. Atenção especial ao tempo de otimização, que limitaria aplicações do controle.

Por fim, esta tese é um ponto inicial e a partir deste, faz-se sugestões de trabalhos futuros. Os testes de identificação foram realizados com temperatura ambiente de aproximadamente  $23^{\circ}C$  sem controlar a umidade da sala, todavia, a umidade foi tratada como ruído para o modelo de identificado. Para obter modelo em todo o alcance das variáveis de ambiente, deve-se expor o protótipo à condições extremas e para tal, é necessário testar em uma câmara climática que seja dotada com controle independente de umidade e temperatura.

O preditor utiliza sensores de temperatura interna e de ambiente, e com o auxílio de testes em condições extremas, sugere-se a completa remoção destes sensores do modelo identificado; para tal, será necessário revalidar o modelo identificado, e também, verificar eventos de confundimentos de fatores e suas interações no processo de identificação.

Sugere-se também, rotinas de detecção de saturação de componentes térmicos, como compressor, evaporador, condensador, etc. Por exemplo, o dimensional e os aspectos construtivos do evaporador implicam em uma taxa máxima de absorção de calor que variam com o ponto de operação e, com este modelo pode-se realimentar a informação desta saturação como restrições para o controle preditivo para auxiliar na eficiência.

A métrica de desempenho de sistemas térmicos conhecida por coeficiente de *performance* - *COP* poderia ser identificado e realimentado como restrição, ou especificação de trajetórias para o controle preditivo.

Como todos os testes consideraram produto operacional, sugere-se então, rotinas de detecção de falhas de ventilador, de compressor e de gacheta provocando vazamentos de ar frio e, por fim, controle tolerante à falhas.

Na presente tese, o equipamento wattímetro WT500 foi usado para medir potência e frequências e estas medidas podem ser feitas pelo próprio inversor e este mesmo, publicar via comunicação digital.

A abordagem apresentada é uma aplicação de um conjunto de tecnologias sofisticadas para possibilitar sua comercialização. As técnicas apresentadas para identificação de sistemas poderão ser utilizadas para estimar temperaturas internas, até arriscando que, prover a total

remoção do sensor de temperatura interna dos refrigeradores domésticos; mesmo que o custo de um sensor de temperatura seja bem acessível, esse fato por si só se justifica, pois em produção de larga escala (centenas de milhares de produtos produzidos por ano) provê uma quantia alta ligada diretamente ao componente, além dos custos indiretos como falhas de componente em campo, times de assistência técnica, etc. O otimizador necessitaria ser escrito de forma personalizada com o modelo interno, e de forma eficiente objetivando o menor tempo possível de execução. Para melhorar os resultados, recomenda-se repetir a metodologia para capturar as variações de produtos e suas combinações, seja *dentro*, *entre* seus componentes em múltiplos produtos.

## REFERÊNCIAS

- AGENCY, International Energy. **Electricity Market Report 2021**. [S.I.], 2021. Citado na página 20.
- AGENCY, International Energy. **Buildings**. 2022. Disponível em: <<https://www.iea.org/reports/buildings>>. Citado na página 20.
- AGGARWAL, Charu C. **Neural Networks and Deep Learning. A Textbook**. [S.I.]: Springer, 2018. ISBN 978-3-319-94463-0. Citado na página 41.
- AGUIRRE, Luis Antonio. **Introdução a Identificação de Sistemas - Técnicas Lineares e Não Lineares: Teoria e Aplicação**. [S.I.: s.n.], 2015. Citado 10 vezes nas páginas 9, 12, 21, 22, 30, 41, 49, 50, 77 e 78.
- ÅSTRÖM, Richard M. Murray Karl Johan. **Feedback Systems: An Introduction for Scientists and Engineers, Second Edition**. 2. ed. [S.I.]: Princeton University Press, 2021. ISBN 0691193983; 9780691193984. Citado na página 71.
- BEJAN, Adrian. **Convection Heat Transfer**. 4. ed. [S.I.: s.n.], 2013. Citado 4 vezes nas páginas 9, 30, 32 e 36.
- BEJARANO, Guillermo et al. Benchmark for pid control of refrigeration systems based on vapour compression. **IFAC-PapersOnLine**, v. 51, n. 4, p. 497–502, 2018. ISSN 2405-8963. 3rd IFAC Conference on Advances in Proportional-Integral-Derivative Control PID 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2405896318304415>>. Citado na página 21.
- BRASTEMP. **Geladeiras e Refrigeradores**. 2021. Disponível em: <<https://www.brastemp.com.br/geladeira-brastemp-inverse-422-litros-inox-bre50nr/p>>. Citado 2 vezes nas páginas 9 e 35.
- CAMACHO, C. Bordons E. F. **Model Predictive Control**. [S.I.]: Springer, 1999. (Advanced textbooks in control and signal processing). ISBN 9783540762416,3-540-76241-8. Citado 8 vezes nas páginas 24, 25, 53, 54, 55, 57, 58 e 68.
- ÇENGEL, Michael A. Boles Yunus A. **Thermodynamics: An Engineering Approach**. 8. ed. [S.I.]: McGraw-Hill Science/Engineering/Math, 2014. ISBN 0073398179,9780073398174. Citado 7 vezes nas páginas 9, 27, 30, 31, 32, 33 e 34.
- CHARBONNEAU, Paul. **An Introduction to Genetic Algorithms for Numerical Optimization**. Boulder, Colorado, 2002. [Http://cobweb.cs.uga.edu/potter/CompIntell/no\\_tutorial.pdf](http://cobweb.cs.uga.edu/potter/CompIntell/no_tutorial.pdf). Citado na página 63.
- CHENG, Yiping. Backpropagation for fully connected cascade networks. **Neural Process Lett**, v. 46, p. 293–311, 2017. Citado 2 vezes nas páginas 43 e 47.
- COMMUNITY, The SciPy. **SciPy Documentation: Optimization and root finding - cobyla**. 2023. Disponível em: <<https://docs.scipy.org/doc/scipy/reference/optimize.minimize-cobyla.html>>. Citado na página 91.
- DATE, Anil W. **Introduction to Computational Fluid Dynamics**. [S.I.]: Indian Institute of Technology, 2005. Citado na página 38.

DUPONT, J. et al. The role of refrigeration in the global economy—38th informative note of refrigeration technologies. **International Institute of Refrigeration**, 2019. Disponível em: <<https://iifir.org/en/fridoc/the-role-of-refrigeration-in-the-global-economy-2019-142028>>. Citado na página 20.

FOUNDATION, Open Source. **Anaconda Python**: Anaconda distribution. 2019. Disponível em: <<http://anaconda.com/>>. Citado na página 75.

GOMES, Alberto Régio. **Análise Comparativa de Mecanismos de Compressão Para Aplicação em Refrigeração Doméstica**. Dissertação (Mestrado) — UFSC, Novembro 2006. Citado na página 35.

GREBLICKI, M. Pawlak W. **Nonparametric System Identification**. [S.l.]: Cambridge University Press, 2008. Citado na página 21.

HAHNLOSER RAHUL SARPESHKAR, Misha A. Mahowald Rodney J. Douglas & H. Sebastian Seung Richard H. R. Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit. **Nature**, v. 405, p. 947–951, Junho 2000. Citado na página 41.

HAMID, Noor Hayatee Abdul; KAMAL, Mahanijah Md; YAHAYA, Faieza Hanum. Application of pid controller in controlling refrigerator temperature. **IEEE International Colloquium on Signal Processing and Its Applications (CSPA)**, 2009. Citado na página 21.

HAYKIN, Simon. **Neural Networks - A Comprehensive Foundation, Second Edition**. 2. ed. [S.l.]: Prentice Hall, 1998. Citado na página 46.

HOLMAN, Jack Philip. **Transferência de Calor**. [S.l.: s.n.], 1983. Citado 5 vezes nas páginas 27, 30, 31, 32 e 34.

INCROPERA FRANK P., DeWitt David P. Bergman Theodore L. Lavine Adrienne S. **Fundamentals of Heat and Mass Transfer**. 7ed.. ed. [S.l.]: Wiley, 2011. Citado 8 vezes nas páginas 9, 27, 28, 29, 30, 31, 33 e 34.

INSTRUMENTS, National. **NI-VISA**. 2020. NI-VISA provides support for customers using Ethernet, GPIB, serial, USB, and other types of instruments. Disponível em: <<https://www.ni.com/pt-br/support/downloads/drivers/download.ni-visa.html>>. Citado na página 75.

JOHNSON, Steven G. **The NLOpt nonlinear-optimization package**. 2020. Disponível em: <<http://github.com/stevengj/nlopt>>. Citado 2 vezes nas páginas 63 e 91.

JORDAN, Michael I. Attractor dynamics and parallelism in a connectionist sequential machine. In: **roceedings of the Eighth Annual Conference of the Cognitive Science Society**. [S.l.: s.n.], 1986. v. 79, p. 531–546. Citado na página 43.

JUNG, Young-Mi; JEONG, Seok-Kwon; YANG, Joo-Ho. Pi controller design of the refrigeration system based on dynamic characteristic of the second order model. **Journal of the Korean Society for Power System Engineering**, v. 18, n. 6, p. 200–206, 2014. Citado na página 21.

KHALIL, Hassan K. **Nonlinear Systems**. 3rd ed. ed. [S.l.]: Prentice Hall, 2002. ISBN 0130673897; 9780130673893. Citado na página 71.

LEE, Jon. **A first course in combinatorial optimization.** [S.l.]: Cambridge University Press, 2004. (Cambridge texts in applied mathematics). ISBN 0521010128,978-0-521-01012-2,0521811511. Citado na página 63.

LIMA, Vladimir Rodrigues de. **Desevolvimento e Avaliação de Ssitema Neural para Redução de Tempo de Ensaio de Desempenho de Compressores.** Dissertação (Mestrado) — UFSC, Florianópolis, 2010. Citado na página 21.

MACIEJOWSKI, Jan. **Predictive Control with Constraints.** [S.l.]: Prentice Hall, 2000. ISBN 0201398230,9780201398236. Citado na página 53.

MANDIC, Jonathon A. Chambers Danilo P. **Recurrent Neural Networks for Prediction.** [S.l.]: John Wiley & Sons Ltd, 2001. Citado na página 43.

MARCATO, Luciano. **Eficiência energética ganha cada vez mais importância no setor de refrigeração FEBRAVA.** 2019. Disponível em: <<https://abrava.com.br/eficiencia-energetica-ganha-cada-vez-mais-importancia-no-setor-de-refrigeracao-febrava/>>. Citado na página 20.

MATTIA, Edoardo Di et al. Predictive controller for refrigeration systems aimed to electrical load shifting and energy storage. **MDPI energies**, September 2022. Citado na página 21.

MCCULLOCH, Walter Pitts Warren S. A logical calculus of the ideas immanent in nervous activity. **Bulleting of Mathematical Biophysics**, v. 5, 1943. Citado na página 23.

NARENDRA, Kumpati S.; PARTHASARATHY, Kannan. Learning automata approach to hierarchical multiobjective analysis. **IEEE Transactions on Systems, Man and Cybernetics**, v. 20, n. 1, p. 263–272, February 1991. Citado na página 47.

NEGRI, Gabriel Hermann et al. Evaluation of nonlinear model-based predictive control approaches using derivative-free optimization and fcc neural networks. **Journal of Control Automation and Electrical Systems**, v. 28, 06 2017. Citado na página 51.

NIELSEN, Michael A. Neural networks and deep learning. In: \_\_\_\_\_. [S.l.]: Neural Networks and Deep Learning, 2015. Citado na página 39.

PATTERSON, Adam Gibson Josh. **Deep Learning: A Practitioner's Approach.** [S.l.]: O'Reilly Media, 2017. ISBN 1491914254,9781491914250. Citado na página 41.

Jacob Perkin. **Apparatus and means for producing ice, and in cooling fluids.** 1834. 6662. Citado 2 vezes nas páginas 9 e 20.

POWELL, M. J. D. An efficient method for finding the minimum of a function of several variables without calculating derivatives. v. 7, p. 155–162, 1964. Citado na página 90.

POWELL, M. J. D. **A Direct Search Optimization Method That Models the Objective and Constraint Functions by Linear Interpolation.** [S.l.: s.n.], 1994. v. 275. 51–67 p. Citado 2 vezes nas páginas 90 e 91.

POWELL, M. J. D. Direct search algorithms for optimization calculations. **Acta Numerica** Cambridge, v. 7, p. 287–336, 1998. Citado na página 90.

Charles R. Cutler David M. Prett Brian L. Ramaker. **Dynamic Matrix Control Method.** 1982. 4,349,869. Citado na página 24.

QIN, Joe; BADGWELL, Thomas. A survey of industrial model predictive control technology. **Control engineering practice**, v. 11, p. 733–764, 07 2003. Citado na página 24.

RAWLINGS DAVID Q. MAYNE, Moritz M. Diehl James B. **Model Predictive Control: Theory, Computation, and Design**. 2nd. ed. [S.l.]: Nob Hill Publishing, LLC, 2019. Citado 3 vezes nas páginas 9, 72 e 73.

ROSENBLATT, Frank. The perceptron - a perceiving and recognizing automaton (project para). January 1957. Citado na página 23.

ROSSITER, J. A. **A First Course in Predictive Control, Second Edition**. Second edition. [S.l.]: CRC Press, 2018. (Control Series). Citado 10 vezes nas páginas 25, 53, 54, 55, 56, 57, 58, 61, 65 e 69.

SABEGH, Mohammad Reza Zavvar; BINGHAM, Chris. Model predictive control with binary quadratic programming for the scheduled operation of domestic refrigerators. **MDPI energies**, December 2019. Citado na página 21.

SAGE, James L. Melsa Andrew P. **System Identification**. [S.l.]: Academic Press, Inc., 1971. v. 80. Citado na página 22.

SCHNÉ, Tamás; JASKÓ, Szilárd; SIMON, Gyula. Embeddable adaptive model predictive refrigerator control for cost-efficient and sustainable operation. Elsevier Ltd, v. 190, p. 496–507, 2018. ISSN 0959-6526. Citado 2 vezes nas páginas 20 e 21.

SHARMA, Atul. **Introduction to Computational Fluid Dynamics: Development, Application and Analysis**. [S.l.]: John Wiley and Sons Ltd., 2017. ISBN 978-11-1900-299-4. Citado 2 vezes nas páginas 32 e 39.

SNYMAN, Daniel N Wilke Jan A. **Practical Mathematical Optimization: Basic Optimization Theory and Gradient-Based Algorithms**. 2nd ed. 2018. ed. [S.l.]: Springer, 2018. (Springer Optimization and Its Applications). ISBN 3319775855,9783319775852. Citado 2 vezes nas páginas 61 e 62.

STATISTA. **Refrigerator unit sales worldwide from 2012 to 2025**. 2021. Disponível em: <<https://www.statista.com/statistics/1124245/refrigerator-unit-sales-worldwide/>>. Citado na página 20.

WERBOS, Paulo John. **Beyond Regression: New tools for prediction and analysis in behavioral sciences**. Tese (Doutorado) — Harvard University, Agosto 1974. Citado na página 23.

WILAMOWSKI, Bogdan M. Neural network architectures and learning algorithms. 2009. Citado na página 40.

## APÊNDICE A – COMPONENTES DO PROTÓTIPO

### A.0.1 Seleção do produto como protótipo

Uma geladeira do tipo *inverse* com inversor de frequência da marca Brastemp e modelo BRE51NBBNA foi selecionada devido às suas características e disponibilidade pelo fabricante.

O termo *inverse* denomina a organização dos compartimentos do produto, onde o congelador está localizado na parte inferior do produto, e obviamente o refrigerador, na parte superior.

O inversor implementando nessa geladeira é conhecido como “*drop in*”, ou seja, o inversor buscará automaticamente a sua velocidade ao ser energizado. Assim sendo, este inversor foi substituído por outro compatível com o modelo do compressor, que o usuário possa repassar a referência de velocidade.

O inversor de frequência flexibiliza a operação do produto em diferentes de pontos em seu ciclo de refrigeração, pois a velocidade compressor é variável implica em variação da capacidade de refrigeração.

A Figura 48 explicita o diagrama de blocos do protótipo, e como suas partes estão conectadas entre si.

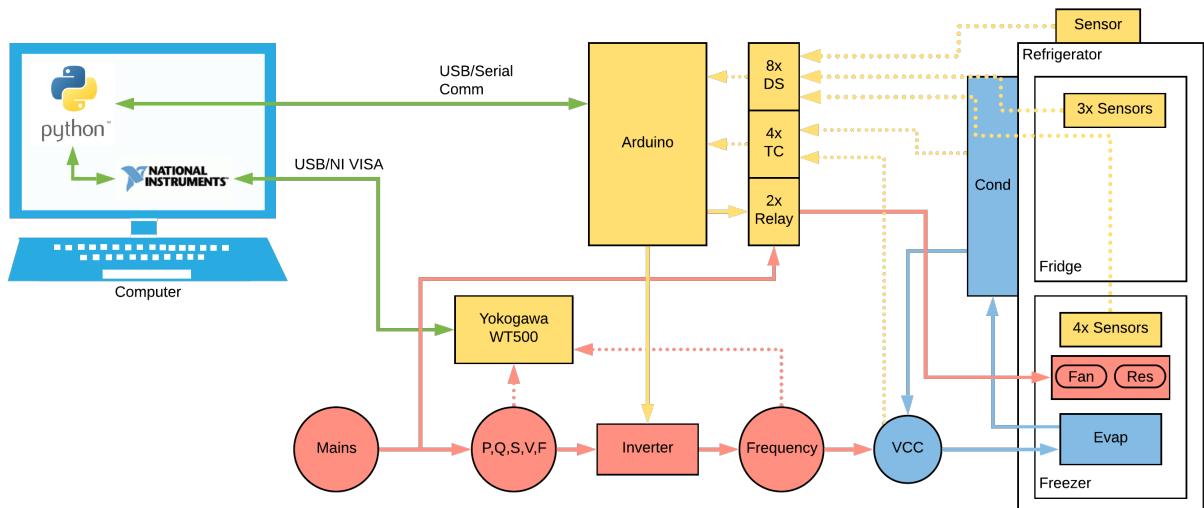


Figura 48 – Diagrama de ligação. Fonte: AUTOR (2021).

As diferentes cores dos blocos identificam indicam a funcionalidade delas, sendo definidas por:

- Amarela: sensores e sinais de baixa potência;
- Azul: circuito térmico de refrigeração;
- Vermelha: sinais não isolados conectados à rede elétrica.

### A.0.2 Arduino

O sistema embarcado selecionado é o Arduino dada a sua flexibilidade e facilidade em adicionar sensores e atuadores. Salientando-se a facilidade em reusar bibliotecas disponíveis para comandar relés, ler termopares e sensores de temperatura DS18B20, e até mesmo personalizar algumas funcionalidades.

Arduino é uma plataforma de *hardware* e *software* abertos com vários modelos disponíveis, e selecionou-se o Arduino Mega 2560 devido ao seu custo baixo, fácil aquisição, e por atender aos requisitos de processamento e memória embarcada.

O Arduino implementa um “escravo”, i.e., ele toma ações apenas a partir de pacotes recebidos do computador. Implementa-se um *timeout* de segurança para as situações onde o Arduino não receba um pacote a cada 30 segundos. Nestes casos, o Arduino desligará automaticamente todas as suas saídas: desligará o compressor, o ventilador e a resistência.

A rotina do Arduino implementa o fluxograma ilustrado na Figura 49.

### A.0.3 Instrumentação com sensores e atuadores no protótipo

A instrumentação é dividida entre sensores e atuadores. Os sensores são:

- Temperatura de partes internas e frias, e externa e ambiente;
- Temperatura de partes externas quentes do circuito de refrigeração;
- Grandezas elétricas como potências, tensões e frequências, e;
- Status de portas (fechadas ou abertas);

e os atuadores:

- Controle de ventilador e de resistência de degelo, e;
- Velocidades de referência do compressor.

as seções a seguir, detalharão estes itens.

### A.0.4 Temperatura das partes frias e externas

Para as partes internas do refrigerador, optou-se por utilizar o sensor DS18B20 por sua flexibilidade, alcance de temperatura e por sua disponibilidade de biblioteca de protocolo *one wire*. Algumas das características principais deste sensor são:

- Tensão de operação: 3,0 a 5,5V;
- Faixa de medição de temperatura:  $-55^{\circ}\text{C}$  a  $+125^{\circ}\text{C}$ ;
- Ponta de aço inoxidável (6 x 50mm);

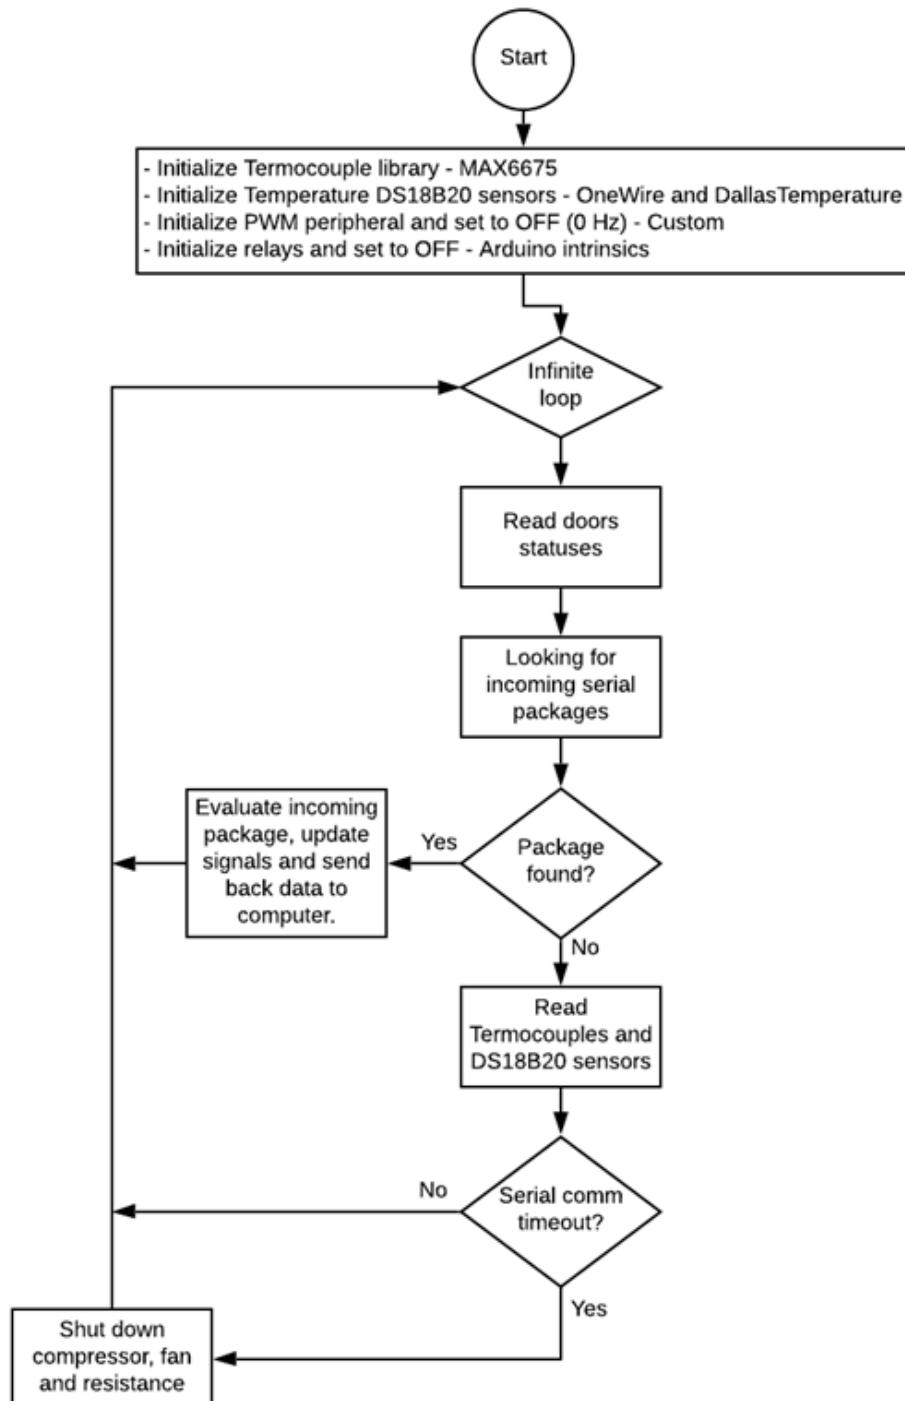


Figura 49 – Fluxograma Arduino. Fonte: AUTOR (2019).

- Cabo de 108 cm de comprimento;
- Endereço *id* único no barramento de comunicação digital.

Devido à sua capacidade de ter endereço único numa rede de sensores, todos os sensores DS18B20 foram conectados em paralelo ao mesmo barramento, diminuindo a complexidade de gerenciamento dos sensores. Segundo o fabricante, até 127 sensores DS18B20 podem ser conectados em paralelo com total suporte ao seu protocolo *one wire*. A conexão de 8 sensores

DS18B20 em paralelo no mesmo barramento aumentou significativamente a capacidade parasita, degradando o sinal, e então demandando o uso de um resistor inferior ( $1,0k\Omega$ ) ao recomendado pelo fabricante ( $4,7k\Omega$ ).

Foi definido um processo de identificação de sensores. Um programa específico foi escrito para cada identificar o *id* usando o próprio Arduino. Cada sensor recebeu um número de identificação de 1 a 8 e um *id* devidamente identificado no programa final. Cada sensor de 1 a 8 implica em uma posição específica no protótipo, e é identificado de acordo no programa principal do computador.

Os sensores pintados de amarelo e identificados por *DS* em 48 denotam os sensores DS18B20. A Figura 51 contém uma foto de um sensor DS18B20.



Figura 50 – Sensor DS18B20. Fonte: Internet (2021).

Os sensores DS18B20 são posicionados dentro do protótipo conforme ilustrado nas figuras abaixo.

#### A.0.5 Temperatura de partes externas e quentes do circuito de refrigeração

A temperatura externa associada ao circuito de refrigeração indica o esforço que o compressor terá ao rejeitar calor para o ambiente, e utilizou-se um sensor DS18B20. Para as partes “quentes”, como pontos de medição do condensador, que não atingem temperaturas negativas, usou-se termopares identificados por *TC* na Figura 48. Para converter o valor de temperatura medido pelos termopares, foi selecionado o seguinte módulo Arduino de acordo com a especificação abaixo:

- MAX6675 interface de conversão para digital;
- Tensão de operação: 3 a 5,5VDC;
- Corrente de operação: 50mA;



Figura 51 – Medições de temperaturas dentro do congelador. À esquerda, freezer com gavetas montadas, ao centro, sem gavetas e com capa plástica e à direita, a evaporadora exposta e insuflador com medição de temperatura. Fonte: AUTOR (2021).



Figura 52 – Medições de temperatura no refrigerador, saída de ar frio e nos centros geométricos (suspenso) dos compartimentos. Fonte: AUTOR (2021).

- Faixa de medição: 0 a  $800^{\circ}\text{C}$ ;
- Precisão:  $\pm 1,5^{\circ}\text{C}$ ;
- Resolução de temperatura de:  $0,25^{\circ}\text{C}$ ;



Figura 53 – Medição de temperatura no retorno de ar "quente" no refrigerador, atrás da gaveta de legumes. Fonte: AUTOR (2021).

- Faixa de compensação de junção fria:  $-20^{\circ}\text{C}$  a  $80^{\circ}\text{C}$ ;
- Interface de comunicação: SPI;

Vale salientar que a interface de comunicação digital utiliza o protocolo SPI (*Serial Peripheral Interface*), tendo seus sinais definidos como:

- SPI *Clock* – sincronização de *bits* para leitura dos dados;
- SPI *MOSI* – (*Master Output Slave Input*) dados enviados pelo Arduino;
- SPI *MISO* – (*Master Input Slave Output*) dados recebidos pelo Arduino;
- SPI *CS* – (*Chip Select*) sinal exclusivo de seleção de dispositivo - cada termopar implementa um sinal de *CS*.

A Figura 54 ilustra um módulo termopar.

Os termopares foram posicionados conforme ilustrado na Figura 55.

Devido aos ruídos eletromagnéticos gerados pelo inversor, a comunicação com os termopares e computadores são aleatoriamente perdidas demandando o uso de alguns capacitores de cerâmica acoplados ao barramento de alimentação do Arduino e à entrada do módulo de termopar.

Bibliotecas nativas do Arduino, que são *open source* da plataforma, foram utilizadas para a comunicação e conversão da temperatura.

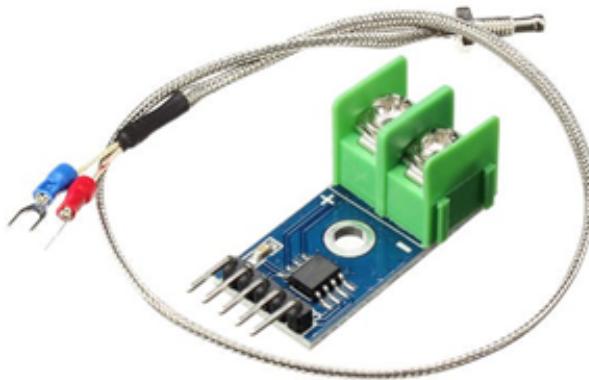


Figura 54 – Módulo Arduino para leitura de temperaturas usando termopares. Fonte: Internet (2021).

#### A.0.6 Status de porta fechada ou aberta

O sensor físico original do produto foi utilizado para este fim, apenas direcionando seu sinal para ser lido pelo Arduino como uma entrada digital.

#### A.0.7 Controle de ventilador e de resistência de degelo

O ventilador e a resistência são alimentadas pela rede 220V a 60Hz que são comandados por relés. A Figura 56 ilustra esse módulo com uma luz *LED* indicando o seu funcionamento.

#### A.0.8 Velocidades de referência do compressor

O inversor implementa sinais de referência externa de velocidade para a sua malha de controle de velocidade. O sinal de referência de velocidade é definido como uma onda quadrada de frequência variável, com *duty cycle* fixo de 50% e tensão de 0 a 5V. A frequência deste sinal define a referência das correntes elétricas de saída do inversor, lembrando que, a frequência das correntes de um motor síncrono definem a velocidade da ponta de eixo do rotor. Por motivos de segurança, a entrada de sinal do inversor é eletricamente opticamente isolada do estágio de potência.

O inversor implementa lógicas de proteção que podem divergir do que é solicitado, i.e., as frequências de referência e de correntes. A Figura 58 ilustra o compressor com inversor bem como o seu posicionamento dentro da geladeira.

As bibliotecas nativas do Arduino foram alteradas para implementar os requisitos do sinal de referência. Foi selecionado um pino conectado com um periférico do tipo *timer* para garantir a estabilidade da geração do sinal de *PWM*, com flutuação da frequência e *duty cycle* desprezível.

#### A.0.9 Grandezas elétricas

Para registrar as grandezas associadas ao compressor, utilizou-se um wattímetro Yokogawa WT500 com comunicação via *USB* com computador. Este wattímetro foi configurado com



Figura 55 – Posicionamento dos termopares no produto indicados pelos círculos vermelhos.  
Fonte: AUTOR (2021).

três medições independentes monofásicas, utilizando apenas duas dessas medições.

Uma medição registra grandezas da rede (entrada do inversor) como: tensão; frequência; corrente; e potências ativa, reativa e aparente. A outra medição registra a amplitude e frequência de corrente, e este wattímetro está ilustrado na Figura 58.



Figura 56 – Módulo de relés para controle de ventilador e resistência de degelo. Fonte: AUTOR (2019).



Figura 57 – Módulo de relés para controle de ventilador e resistência de degelo. Fonte: AUTOR (2019).



Figura 58 – Wattímetro Yokogawa WT500. Fonte: Internet (2019).

## APÊNDICE B – PROGRAMAS – ARDUINO & PYTHON

Um computador pessoal (PC) implementa a lógica de controle, de comunicação e de registro das informações. O Arduino implementa o interfaceamento com sensores e atuadores do protótipo. O PC comunica-se constantemente com o Arduino tanto para ler como enviar comandos, e garantir a verificar se a comunicação válida.

### B.0.1 Python

No computador pessoal, Python 3.x na distribuição Anaconda com um pacote extra para gerenciamento amigável com arquivos (Easygui v0.96) foram selecionados.

Para garantir o escalonamento de reuso do script, uma classe para abstrair cada função do protótipo foi implementada. Um total quatro classes: de controle; de comunicação com serial (Arduino); de comunicação com o wattímetro e de visualização gráfica dos registros. As três primeiras classes, que implementam o controle preditivo, estão interconectadas em camadas (*layers*). A classe de visualização é usada somente para visualizar facilmente os dados adquiridos.

A Figura 59 ilustra as classes e as suas interações com usuários e dispositivos. Salienta-se que a programação foi desenvolvida apenas em “espaço de usuário”, ou seja, sem a necessidade de permissões de administrador ou mesmo de implementar *device drivers* no “espaço de *Kernel*” do Windows.

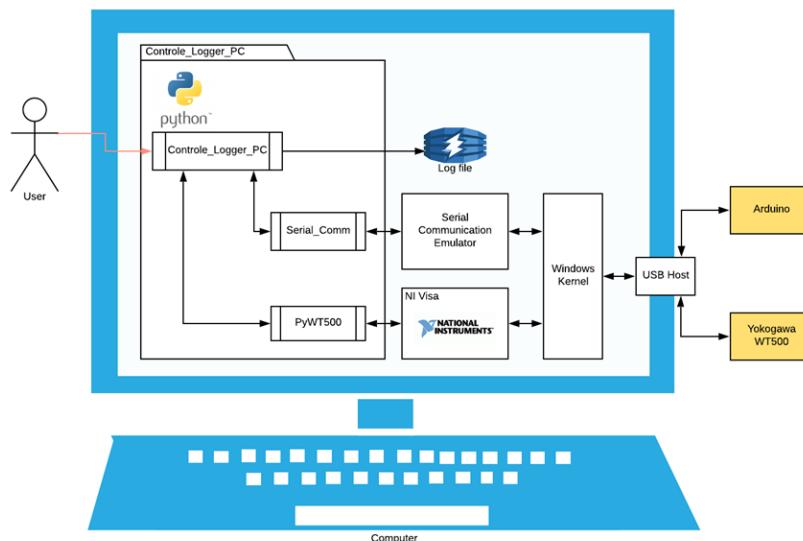


Figura 59 – Diagrama de classes com conexões aos dispositivos. Fonte: AUTOR (2019).

### B.0.2 Camada do controlador

Esta classe que implementa o controle, gerencia os sinais de mais alto nível, suas temporizações e também registra em arquivo todas as informações intercambiadas com o Arduino.

Esta classe está implementada no arquivo *Controle\_Logger\_PC.py*.

### B.0.3 Camada de comunicação serial

O protocolo de comunicação para enviar, receber e “traduzir” os dados do Arduino em informações úteis ao controle é implementada nessa camada. Esta classe está implementada no arquivo *Serial\_Comm.py*.

#### B.0.3.1 Protocolo serial

O protocolo é baseado em textos com marcadores *ASCII* que definem a formatação a ser utilizada para trocar dados. O computador monta e envia o seguinte pacote: *Fxyz,Vw,Rt\n*; sendo que, *Fxyz* define frequência de comando para o inversor, em *xyzHz*; *Vw* comanda a ventilador, onde *V1* significa ventilador ligado e *V0* desligado, e *Rt* controla a resistência com *R1* resistência ligada e *R0* desligada. As frequências de comando seguem a lógica de controle:

$$\begin{cases} 0 & \leq Fxyz < 20 \rightarrow \text{Compressor desligado} \\ 20 & \leq Fxyz < 150 \rightarrow \text{Frequência} = xyz \\ Fxyz & < 150 \rightarrow \text{Frequência} = 150Hz \end{cases} \quad (48)$$

o símbolo “\n” indica quebra de linha com retorno de carro e sinaliza ao Arduino que o pacote foi enviado para ser tratado. Após ser tratado, o Arduino retornará outro pacote contendo todas as informações de suas condições, formtado em uma linha. Para fins de ilustração, essa linha está expressa em múltiplas linhas conforme:

```
Package_Start\t
Fxyz,Vw,Rt,Dp\t
TC0 :25.00\t
TC1 :28.10\t
TC2 :29.00\t
TC3 : -10.00\t
TC4 : -11.00\t
TC5 : -20.00\t
TC6 : -19.00\t
TC7 :5.00\t
TC8 :2.00\t
TC9 :1.00\t
TC10 :0.00\t
TC11 : -19.00\t
Package_End\t\n
```

(49)

Delimita-se o pacote com os símbolos “*Package\_Start*” e “*Package\_End*”. O símbolo “\v” em ASCII indica tabulação, e “\n” a quebra de linha sinalizando que o pacote foi retornado pelo Arduino. O termo “*Fxyz,Vw,Rt,Dpp*” contém o status atual da frequência de comando do inversor, ventilador, resistência, e o status das portas. Interpreta-se os status das portas com dois *bits* em *Dpp*. Por exemplo, D0 = ambas portas abertas, D3 (11 em base binária) ambas portas abertas. D1 (01 binário) e D2 (10 binário) significam porta do refrigerador e freezer abertas respectivamente. O termo *TC0: 25.10* representa a temperatura de 25,1°C no sensor de temperatura 0.

#### **B.0.4 Camada de comunicação com Wattímetro WT500**

O wattímetro da marca Yokogawa WT500 é um equipamento comercial com excelente precisão de medições. Ele dispõe de uma entrada *USB* que implementa o padrão de comunicação *National Instruments VISA*. O seu fabricante fornece gratuitamente em seu sítio, bibliotecas para comunicação. A camada do wattímetro é implementada via uma classe arquivo *PyWT500.py*, que interfaceia os dados lidos do *VISA* com os dados de interesse do controle preditivo.