



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE CIÊNCIAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

**REDES NEURAS ARTIFICIAIS LSTM APLICADAS NA PREVISÃO
DE PADRÕES DE UM FORNO DE REAQUECIMENTO DE TARUGOS**

Nahanni Taynah Jácome Rodrigues

Orientador:

Luis Gonzaga Sales Vasconcelos

Campina Grande – PB

Março/2022

NAHANNI TAYNAH JÁCOME RODRIGUES

**REDES NEURAS ARTIFICIAIS LSTM APLICADAS NA PREVISÃO
DE PADRÕES DE UM FORNO DE REAQUECIMENTO DE TARUGOS**

Dissertação apresentada ao curso de Pós-Graduação de Engenharia Química, da Universidade Federal de Campina Grande, como parte dos requisitos exigidos para a obtenção do título de Mestre em Engenharia Química.

Orientador:

Luis Gonzaga Sales Vasconcelos

Campina Grande - PB

2022

R696r

Rodrigues, Nahanni Taynah Jácome.

Redes neurais artificiais LSTM aplicadas na previsão de padrões de um forno de reaquecimento de tarugos / Nahanni Taynah Jácome Rodrigues. - Campina Grande, 2022.

71 f. il. color.

Dissertação (Mestrado em Engenharia Química) - Universidade Federal de Campina Grande, Centro de Ciências e Tecnologia, 2022.

"Orientação: Prof. Dr. Luis Gonzaga Sales Vasconcelos."

Referências.

1. Engenharia Química. 2. Redes Neurais Artificiais LSTM. 3. Forno de Aquecimento. 4. Controle de Temperatura. I. Vasconcelos, Luis Gonzaga Sales. II. Título.

CDU 66.0(043)

NAHANNI TAYNAH JÁCOME RODRIGUES

**REDES NEURAIAS ARTIFICIAIS LSTM APLICADAS NA
PREVISÃO DE PADRÕES DE UM FORNO DE
REAQUECIMENTO DE TARUGOS**

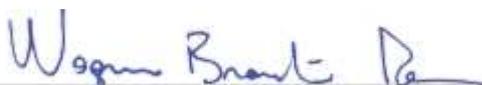
Dissertação apresentada e aprovada em: 25 de Março de 2022

Banca examinadora:



Prof. Dr. Luis Gonzaga Sales Vasconcelos – DEQ/CCT/UFCG

Orientador



Prof. Dr. Wagner Brandão Ramos – DEQ/CCT/UFCG

Examinador interno

ROMILDO PEREIRA
BRITO:41912675404

Digitally signed by ROMILDO
PEREIRA BRITO:41912675404
Date: 2022.08.03 15:10:10
+03'00'

Prof. Dr. Romildo Pereira Brito – DEQ/CCT/UFCG

Examinador interno



Prof. Dr. Arioston Araújo de Moraes Júnior - UFPB

Examinador externo

Dedico esse trabalho a Deus que me deu forças, e sempre mostrou a luz que eu precisava nos momentos difíceis. Ao meu marido Luciano, meu filho Pedro Ian, meus pais Jorailson e Rilda e minha irmã Nahalla por tanto amor e apoio.

AGRADECIMENTOS

Minha gratidão eterna a Deus, por me proporcionar força em momentos tão difíceis como os que vivi ao longo desse mestrado, por não me deixar desistir e seguir firme em busca dos meus sonhos.

Ao meu orientador Luís Gonzaga, que sempre se fez presente nos momentos que precisei, pela paciência e pelas ajudas e contribuições ao longo do desenvolvimento desse trabalho.

Ao apoio financeiro concedido pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

Aos meus pais Jorailson e Rilda, que foram a base de minha educação pessoal e sempre acreditaram que eu podia mais do que eu imaginava. Obrigada por nunca soltarem minha mão, por sempre me incentivarem a crescer mais, e pelo amor dado em toda minha vida.

A minha irmã Nahalla, sempre juntas, nós somos unha e carne e que bom que tenho você comigo. Obrigada por acreditar em mim, por ter sido rocha em momentos de fraqueza que passamos ultimamente. Vejo em você a força que preciso para não desistir de correr atrás dos meus sonhos.

Ao meu marido Luciano, que sempre ver qualidades acima das que eu enxergo em mim, por sempre me apoiar, incentivar, acreditar. Você trouxe sentido a tudo que faço, hoje é por nós, nossa família. Ao meu filho Pedro Ian por ser o sorriso mais lindo que abre as portas do meu coração para seguir em busca de melhorar todos os dias, faço e farei de tudo pra você.

Aos meus colegas de graduação e os conquistados no mestrado, que seguiram comigo durante todo o percurso, seja com apoio, conversas, ajudas, não chegaria até aqui sem vocês.

As minhas amigas, que tenho amor, zelo e dedicação, e que sei que é recíproco. Larissa, Anyelle, Bruna, Danyelle, Mayrla, Nathália, vocês são tesouros na minha vida, que quero manter pra sempre embaixo de sete chaves. Obrigada por cada palavra dita, pelo apoio e incentivo.

A toda minha família, que se importa, que quer ver meu crescimento, que me apoia e que sempre esteve do meu lado, mesmo que por pequenas ações.

A UFCG, em especial a UAEQ e todos os professores que fazem parte desta e que contribuíram para minha formação, tornando possível a concretização de um sonho.

“Todos os seus sonhos podem se tornar realidade se
você tem coragem para persegui-los.” Walt Disney

RESUMO

O processo de reaquecimento de tarugos dentro da indústria de laminação é uma etapa crucial para a obtenção de produtos com a qualidade desejada, visto que ela garante que as peças tenham as propriedades mecânicas ideais, como dureza, elasticidade, ductibilidade e resistência a tração. A temperatura dentro do forno precisa ser controlada dentro de uma faixa de 1000 a 1300°C, que varia de acordo com o funcionamento do forno, para que não ocorra fusão das peças ou perda das propriedades desejadas, assim como desperdício de peças fora de qualidade e de combustível usado para promover transferência de calor através da combustão nas zonas do forno. Desse modo, o presente trabalho apresenta a criação de Rede Neurais do tipo LSTM para previsão de padrões no processo de reaquecimento de tarugos, para que possa ser utilizada na construção de controladores do tipo PI, a serem empregados nas oito zonas presentes do forno em estudo. Diferentes métodos foram utilizados para tratar os dados de entrada para criação do modelo, como normalização, variação da taxa de amostragem, eliminação de valores outliers, com o objetivo de descobrir a influência dos mesmos na acurácia da RNA obtida. Os resultados mostram que as RNA desenvolvidas foram satisfatórias para prever dados de processos complexos que envolvem muitas variáveis, como o estudado, assim como apresenta a obtenção de um controlador PI que permite manter cada zona do forno dentro dos valores de temperatura desejados para a mesma. A RNA obtida para a taxa de amostragem de 30 segundos apresentou um melhor aprendizado dos dados do processo. O controlador desenvolvido foi capaz de manter as temperaturas de setpoint estabelecidas para cada zona, mostrando uma ferramenta eficaz visando obter peças com a qualidade desejada para o laminador, evitando desperdício, aumentando a vida útil do laminador, e consumindo a quantidade necessária dos combustíveis que alimentam o forno e promovem a combustão necessária para transferir calor para as peças.

Palavras-chave: Forno de reaquecimento; Redes Neurais Artificiais LSTM; Controle.

ABSTRACT

The billet reheating process within the rolling industry is a crucial step in obtaining products with the desired quality, as it ensures that the parts have the ideal mechanical properties, such as hardness, elasticity, ductility and tensile strength. The temperature inside the oven needs to be controlled within a range of 1000 to 1300°C, which varies according to the operation of the oven, so that the parts do not melt or lose the desired properties, as well as waste of out-of-quality parts. and fuel used to promote heat transfer to the parts through combustion in the oven zones. Thus, the present work presents the creation of Neural Networks of the LSTM type to predict patterns in the billet reheating process, so that it can be used in the construction of PI type controllers, to be used in the eight zones present in the furnace under study. Different methods were used to process the input data to create the model, such as normalization, sampling rate variation, elimination of outliers, in order to discover their influence on the accuracy of the RNA obtained. The results show that the developed RNA were satisfactory to predict data of complex processes that involve many variables, as the one studied, as well as presents the obtaining of a PI controller that allows to keep each zone of the oven within the desired temperature values for it, however. The RNA obtained for the sampling rate of 30 seconds showed a better learning of the process data. The controller developed was able to maintain the setpoint temperatures established for each zone, showing an effective tool to obtain parts with the desired quality for the mill, avoiding waste, increasing the mill's useful life, and consuming the necessary amount of fuels that feed the oven and promote the combustion necessary to transfer heat to the parts.

Keywords: Reheating oven; LSTM Artificial Neural Networks; Control.

LISTA DE TABELAS

Tabela 1 - Valores de <i>setpoint</i> a serem ajustados no controlador PI.....	39
Tabela 2 - Valores da estatística MAPE obtido no treinamento.....	52

LISTA DE FIGURAS

Figura 1 - Obtenção dos tarugos após lingotamento contínuo.....	15
Figura 2 - Representação de um forno de reaquecimento do tipo <i>Walk bin</i>	16
Figura 3 - Representação da configuração das Zonas de pré-aquecimento, aquecimento e encharque de um forno de reaquecimento para laminação de aço.....	17
Figura 4 - Representação de linha de Tiras a Quente: (a) Forno de Reaquecimento; (b) Laminador Quádruplo Reversível tipo Steckel com seus fornos bobinadeira na entrada e saída do laminador; (c) Bobinadeira.....	18
Figura 5 - Modelo de uma Rede Neural Artificial (RNA).....	25
Figura 6 - Arquitetura básica de uma rede neural recorrente.....	28
Figura 7 - Rede neural recorrente com matrizes de peso responsáveis pela predição.....	28
Figura 8 - Esquema representativo de uma rede recorrente do tipo LSTM.....	29
Figura 9 - Representação de um gráfico <i>boxplot</i> para identificar pontos <i>outliers</i>	31
Figura 10 - Arquitetura da RNA do tipo LSTM desenvolvida em linguagem Python.....	37
Figura 11 - Gráfico da função do custo com um número ótimo de épocas (<i>best fit.</i>).....	38
Figura 12- Perfil de temperatura do forno para as 4 zonas iniciais.....	41
Figura 13 - Perfil de temperatura do forno para as 4 zonas finais.....	42
Figura 14 - Perfil de vazão de gás natural no forno para as 4 zonas iniciais.....	42
Figura 15 - Perfil de vazão de gás natural no forno para as 4 zonas finais.....	43
Figura 16 - Perfil de vazão de gás misto no forno para as 4 zonas iniciais.....	44
Figura 17 - Perfil de vazão de gás misto no forno para as 4 zonas finais.....	44
Figura 18 - Perfil de vazão de ar de combustão no forno para as 4 zonas iniciais.....	45
Figura 19 - Perfil de vazão de ar de combustão no forno para as 4 zonas finais.....	45
Figura 20 - Perfil de temperatura do ar de combustão no forno.....	46
Figura 21 - Perfis de calor gerado e temperatura para as 8 zonas do forno de reaquecimento (a) Zona 1, (b) Zona 2, (c) Zona 3, (d) Zona 4, (e) Zona 5, (f) Zona 6, (g) Zona 7, (h) Zona 8.....	47
Figura 22 - Histogramas das variáveis de entrada e saída dos dados originais, treino e teste para a criação da RNA (a) Zona 1, (b) Zona 2, (c) Zona 3, (d) Zona 4, (e) Zona 5, (f) Zona 6, (g) Zona 7, (h) Zona 8.....	49
Figura 23 - Gráfico da função de custo MAPE obtida pelo treinamento da RNA do tipo LSTM para os dados de treino e teste (a) Zona 1, (b) Zona 2, (c) Zona 3, (d) Zona 4, (e) Zona 5, (f) Zona 6, (g) Zona 7, (h) Zona 8.....	51
Figura 24 - Gráfico de comparação entre os dados obtidos pela RNA e os dados reais do forno (a) Zona 1, (b) Zona 2, (c) Zona 3, (d) Zona 4, (e) Zona 5, (f) Zona 6, (g) Zona 7, (h) Zona 8.....	53
Figura 25 - Gráficos do controle do tipo PI nas 8 zonas para manter o valor de <i>setpoint</i>	55
Figura 26 – Gráfico da função de custo MAPE obtida pelo treinamento da RNA do tipo LSTM para taxa de amostragem de 30 segundos (a) Zona 1, (b) Zona 2, (c) Zona 3, (d) Zona 4, (e) Zona 5, (f) Zona 6, (g) Zona 7, (h) Zona 8.....	57
Figura 27 – Gráfico de comparação entre os dados obtidos pela RNA e os dados reais do forno para taxa de amostragem de 30 segundos (a) Zona 1, (b) Zona 2, (c) Zona 3, (d) Zona 4, (e) Zona 5, (f) Zona 6, (g) Zona 7, (h) Zona 8.....	58
Figura 28 – Gráficos do controle do tipo PI nas 8 zonas para manter o valor de <i>setpoint</i> para taxa de amostragem de 30 segundos.....	59
Figura 29– Gráficos de <i>boxplot</i> para identificação dos valores de <i>outliers</i>	61
Figura 30 – Gráficos de <i>boxplot</i> após tratamento dos valores de <i>outliers</i>	62
Figura 31 – Gráficos de comparação entre os dados obtidos pela RNA e os dados reais do forno após tratamento dos valores de <i>outliers</i>	63

Figura 32 – Gráficos do controle do tipo PI nas 8 zonas para manter o valor de *setpoint* após tratamento dos valores de *outliers*.....64

LISTA DE SIGLAS

PID – Proporcional, Integral e Derivativo

LSTM - *Long Short-Term Memory* (Memória de Curto-Longo Prazo)

PI – Proporcional e Integral

AI - *Artificial Intelligence* (Inteligência Artificial)

RNA – Redes Neurais Artificiais

RNN - *Recurrent Neural Networks* (Redes Neurais Recorrentes)

IQR – Amplitude Interquartilica

ELU – Unidade Linear Exponencial

MAPE - Erro Percentual Absoluto Médio

GN – Gás Natural

GM – Gás Misto

VGN – Vazão de Gás Natural

VGM – Vazão de Gás Misto

VAC – Vazão de Ar de Combustão

TAC – Temperatura do Ar de Combustão

LISTA DE SIMBOLOS

$u(t)$ - Saída do controlador em função do tempo

k_c - Ganho da parte proporcional do controlador

$e(t)$ - Erro entre o processo e setpoint

τ_i - Tempo da ação integral do controlador

u_s - Saída do controlador no regime permanente

x_i - Dado de entrada da RNA

w_{ji} - Pesos da RNA

w_{j0} - Bias (fator de polarização)

u_j - Saída da RNA antes da função de ativação

y_i - Saída da RNA após a função de ativação

m - Número de neurônios da camada i

$\hat{y}^{<t>}$ - Saída de uma RNN

$a^{<t>}$ - Variável de ativação da RNN

$g()$ - Função de ativação escolhida da RNN

b_a - Fator de correção para cálculo de $a^{<t>}$

b_y - Fator de correção para cálculo de $\hat{y}^{<t>}$

x_t - Entrada da rede LSTM

$Q1$ - Quartil 1

$Q3$ - Quartil 3

VN - Valor normalizado

X - Valor real da variável sem normalização

y_i - Valor da variável real do processo

\hat{y}_i - Valor da variável prevista pela RNA

SUMÁRIO

1 INTRODUÇÃO.....	15
1.1 A INDÚSTRIA DE LAMINAÇÃO DE AÇO.....	15
1.2 A INDÚSTRIA 4.0 E A AUTOMAÇÃO INDUSTRIAL.....	19
1.3 MOTIVAÇÃO.....	20
2 OBJETIVOS.....	21
2.1 OBJETIVO GERAL.....	21
2.2 OBJETIVOS ESPECÍFICOS.....	21
3 FUNDAMENTAÇÃO TEÓRICA.....	22
3.1 FORNOS INDUSTRIAIS.....	22
3.1.1 Fornos para laminação de aço	22
3.2 CONTROLE NAS INDUSTRIAS.....	23
3.3 REDES NEURAS ARTIFICIAIS (RNA).....	25
3.3.1 Algoritmos de aprendizado.....	26
3.3.2 Arquitetura das redes.....	27
3.3.2.1 Redes <i>Long Short Term Memory</i> (LSTM).....	29
3.4 PRÉ-PROCESSAMENTO E TRATAMENTO DOS DADOS.....	30
4 METODOLOGIA.....	34
4.1 CRIAÇÃO DE UMA REDE NEURAL RECORRENTE BASEADA EM LSTM.....	34
4.1.1 Dados de entrada.....	34
4.1.2 Normalização dos dados.....	34
4.1.3 Eliminação de ruídos.....	35
4.1.4 Eliminação de <i>Outliers</i>.....	35
4.1.5 Taxa de Amostragem.....	36
4.2 CRIAÇÃO DA REDE NEURAL.....	36
4.3 TREINAMENTO DA REDE LSTM.....	37
4.4 PREDIÇÃO DOS VALORES.....	38
4.5 DESCRIÇÃO DO PROCESSO.....	39
5 RESULTADOS E DISCUSSÕES.....	41
5.1 COLETA E TRATAMENTO DOS DADOS.....	41
5.2 CRIAÇÃO DA RNA A PARTIR DOS DADOS OBTIDOS.....	51
5.3 PREVISÃO DOS DADOS COM USO DA RNA CRIADA.....	53

5.4 UTILIZAÇÃO DA RNA OBTIDA PARA CRIAÇÃO DE CONTROLADOR DO TIPO PI.....	54
5.5 INFLUÊNCIA DA TAXA DE AMOSTRAGEM NA OBTENÇÃO DA RNA.....	56
5.6 INFLUÊNCIA DO TRATAMENTO DE <i>OUTLIERS</i> NA OBTENÇÃO DA RNA.....	61
6 CONCLUSÕES.....	66
7 SUGESTÕES PARA TRABALHOS FUTUROS.....	68
REFERÊNCIAS.....	69

1 INTRODUÇÃO

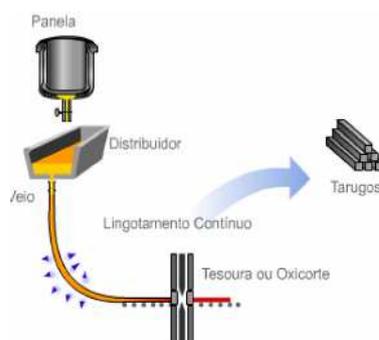
1.1 A INDÚSTRIA DE LAMINAÇÃO DE AÇO

Diversos processos industriais dependem da transferência de calor para diferentes tipos de materiais, em busca de produtos que possuam valor agregado e que atendam à demanda do mercado. Os metais ferrosos são alguns desses materiais, e são um dos que mais exigem grandes quantidade de energia, pois são operados em temperaturas muito elevadas, podendo ser superiores a 1000°C. Com isso, temos que esse tipo de processo demanda de grandes parcelas de consumo de energia de uma indústria. A busca pela otimização desse processo visa não só o aperfeiçoamento das técnicas existentes, como também a inserção de novas formas de reduzir os gastos, ter um maior controle energético do processo e garantir a qualidade do que está sendo produzido (Yukun Hu et al., 2017).

O processo de tratamento térmico do aço é amplamente utilizado na indústria. O mesmo consiste em aquecer e resfriar o material de modo que ele atinja as propriedades mecânicas ideais, como dureza, elasticidade, ductibilidade e resistência a tração. Para que esse tratamento ocorra adequadamente, a etapa de reaquecimento do aço, que ocorre nos fornos de reaquecimento, deve ser feita de forma que todas as regiões do forno recebam a mesma quantidade de calor, visto que o forno possui diferentes zonas de aquecimento com queimadores distribuídos ao longo de seu comprimento (MAGALHÃES, 2001).

Esse tratamento térmico é utilizado nas indústrias de laminação de aço, com o propósito de tornar este material ideal para ser utilizado no processo de laminação. De modo geral, esse processo se inicia ainda na formação dos tarugos, que são as peças provenientes do aço fundido e vazado no lingotamento contínuo, como apresentado na Figura 1. Após essa etapa, os tarugos são armazenados nos pátios de tarugo, onde podem ser utilizados diretamente no laminador, ou ficar armazenados.

Figura 1 – Obtenção dos tarugos após lingotamento contínuo



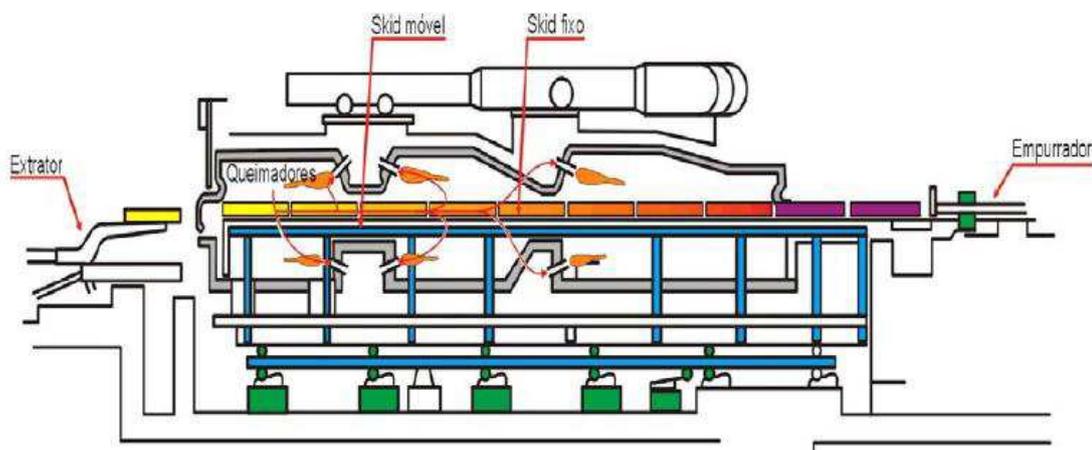
Fonte: LIRA Jr. (2017)

Caso os tarugos fiquem armazenados, para seguir posteriormente para o laminador, precisarão passar pelo forno de reaquecimento para se tornar suficientemente plásticos para serem moldados de acordo com a especificação desejada. Com isso, a alimentação das peças no forno pode ser feita de duas formas: ou através de uma mesa de rolos, que transporta a carga ao longo do comprimento do forno, ou através de grelhas que funciona como um berço metálico, feito de aço laminado, onde sua superfície é cercada por tubos por onde passa um líquido de refrigeração, possibilitando o carregamento dos tarugos ainda quentes, sem causar deformação na estrutura (LIRA JÚNIOR., 2017).

Um forno de reaquecimento de tarugo é o equipamento chave no setor do processo de laminação, e é também o que consome mais energia. As principais características da dinâmica do forno são que eles são não lineares e variáveis no tempo, além de ter diversas variáveis associadas. A uniformidade da temperatura dos tarugos afeta diretamente a qualidade e a quantidade dos produtos siderúrgicos, a quantidade de energia consumida e a vida útil do laminador (LIAO *et. al*, 2006).

Ao entrar no forno de reaquecimento, os tarugos precisam ser aquecidos a temperaturas superiores a 1000 °C, para obter as condições necessárias para serem laminados posteriormente. Esse movimento das peças de tarugos dentro do forno pode acontecer de duas formas: através de uma mesa móvel existente no forno (*Walk bin*), apresentado na Figura 2, ou por um sistema *pusher*, onde o material é empurrado por cilindros hidráulicos, se deslocando ao longo de todo o comprimento do forno.

Figura 2 – Representação de um forno de reaquecimento do tipo *Walk bin*

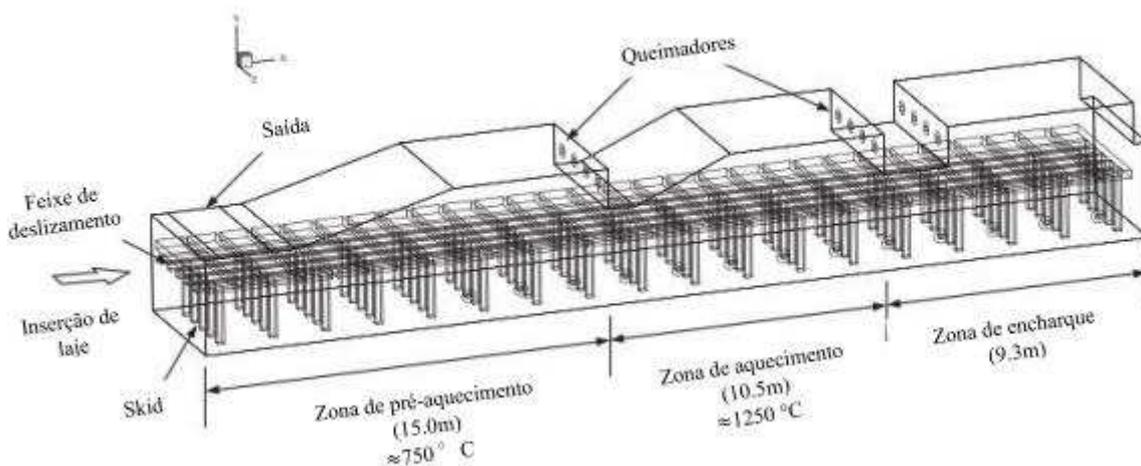


Fonte: LIRA Jr. (2017)

Nesse tipo de forno, as peças se deslocam em seu interior desde a entrada até a saída, de modo que o principal tipo de transporte de calor que ocorre em seu interior é a radiação entre as superfícies das peças, as paredes do forno e os gases de combustão. Assim como se observa transporte de calor por convecção entre os gases de combustão e as superfícies das peças.

Os fornos consistem em três zonas: a de pré-aquecimento, a de aquecimento e a de encharque. Na zona de pré-aquecimento o material entra a temperatura ambiente e é aquecido, em contracorrente, até uma temperatura superior a 700 °C. Esse aquecimento é feito pelos gases da combustão oriundos das demais zonas em direção ao recuperador, onde os mesmos aquecerão o ar de combustão. Na zona de aquecimento é a região onde as peças são aquecidas a temperaturas entre 1000-1300 °C, variando de acordo com o produto desejado. E por último, a zona de encharque é a região onde se consegue fazer com que a diferença entre a temperatura da superfície da peça e o seu interior seja a menor possível, para que se tenha um produto com a qualidade desejada. A Figura 3 representa as três regiões do forno de reauecimento.

Figura 3 – Representação da configuração das Zonas de pré-aquecimento, aquecimento e encharque de um forno de reauecimento para laminação de aço



Fonte: ROSADO (2020)

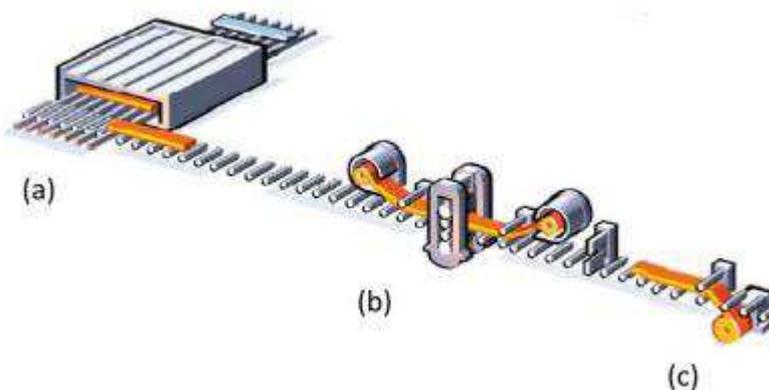
Todas as zonas possuem queimadores distribuídos em sua extensão, onde esses queimadores são posicionados de modo a fornecer a energia necessária em cada zona, para se atingir a temperatura desejada no processo. Os queimadores do forno são ajustados para que não ocorra um aquecimento superior ao necessário sobre o material.

A saída dos tarugos aquecidos é feita por um empurrador lateral no forno, em que uma lança empurra as barras por uma das extremidades, até que a mesma esteja sobre uma mesa de

rolos na saída. Após isso, as peças seguem para uma gaiola de laminação, onde ficarão até serem levadas para o laminador.

No laminador, os tarugos são passados através de grelhas e direcionados para serem prensados por cilindros, que irão aumentar o comprimento da peça e deixar na espessura e formato que se deseja como produto. Posteriormente, as barras seguem para os trens de gaiolas acabadoras, onde serão feitos os últimos ajustes finos para ser repassado de acordo com a necessidade do mercado. A Figura 4 é uma representação do processo entre o forno de reaquecimento e o laminador.

Figura 4 – Representação de linha de Tiras a Quente: (a) Forno de Reaquecimento; (b) Laminador Quádruo Reversível tipo Steckel com seus fornos bobinadeira na entrada e saída do laminador; (c) Bobinadeira



Fonte: Souza *et. al* (2018).

Devido as altas temperaturas existentes nesse processo de reaquecimento, e por ele ser uma etapa crucial antes da laminação, o mesmo necessita de controle para que não ultrapasse os valores ideais. De acordo com Lira Jr. (2007), o diferencial de temperatura existente entre a superfície do tarugo e o seu centro deve ser de 70 °C. Por isso, o aquecimento excessivo não é desejado, pois além de possibilitar a fusão das peças durante o processo de reaquecimento, acaba por consequentemente aumentar o consumo energético da indústria desnecessariamente.

Para garantir a qualidade do processo, um dos principais aspectos necessários para obter produtos com valor agregado e que sejam procurados pelo mercado, é preciso que a etapa de reaquecimento seja monitorada para evitar possíveis falhas e desvios do comportamento esperado para o mesmo. Dessa forma, a observação dos dados disponíveis na planta industrial se torna um aliado na busca pela melhoria contínua (RAMEZANI, J.; JASSBI, J., 2020).

Popularmente, o controlador do tipo PID (Proporcional, Integral e Derivativo) é utilizado para controlar a temperatura nesse processo, a partir dos dados disponíveis do equipamento. Dessa forma, o controlador envia dados de temperatura observados no comprimento do forno, para que o operador saiba o perfil e possa, a partir disso, tomar decisões que levem ao melhor ajuste da proporção de ar e combustível a ser utilizada, de modo que o perfil de temperatura permaneça constante e que a quantidade de combustível utilizada seja a necessária, evitando desperdícios para a indústria (SRISERTPOL, 2010).

Com o avanço da tecnologia e o surgimento da Indústria 4.0, que visa o aperfeiçoamento das ferramentas utilizadas nas indústrias de modo a agregar soluções inteligentes, a Inteligência Artificial busca extrair informações significativas de um grande conjunto de dados que são gerados com frequência nas plantas industriais, de modo que se torne possível detectar instabilidades no processo com o mínimo de tempo e custo, e com máxima precisão (RAMEZANI, J., JASSBI, J, 2020).

1.2 A INDÚSTRIA 4.0 E A AUTOMAÇÃO INDUSTRIAL

A Indústria 4.0 busca automatizar os processos industriais, de forma a reduzir os custos e a evitar que as indústrias precisem passar por pausas no processo devido a falhas nos sensores e atrasos de leitura dos mesmos, que levam os operários a tomar decisões tardias, ou até mesmo precipitadas. Com o avanço da tecnologia, muito se ouve falar sobre a modernização no chão de fábrica, visto que, com isso, existe a possibilidade de agregar mais valor aos produtos devido ao aumento da qualidade no processo, e reduzir insumos graças a possibilidade de se conhecer as condições de operação do processo através dos dados disponíveis nas plantas e utilizá-los para controle da mesma.

O impacto da Indústria 4.0 na fabricação vai além da produção física de bens, envolvendo o direcionamento de todos os processos e funções para alcançar flexibilidade, inteligência, economia e resiliência. A Inteligência artificial e aprendizado de máquina estão entre as tecnologias atuais que podem ser utilizadas para melhorar a qualidade como o coração da manufatura inteligente

Com todos esses avanços ocorrendo ao longo do tempo, a demanda cada vez maior pelo desempenho crescente dos processos e a busca pela excelência em qualidade, assim como a busca pela independência da planta em relação aos operadores humanos, existe o interesse constante de estudos ligados a essas áreas de pesquisa.

1.3 MOTIVAÇÃO

Tendo em vista as observações citadas anteriormente, podemos ver a necessidade do desenvolvimento de estudos ligados a utilização de ferramentas inteligentes dentro da indústria, que visam o aperfeiçoamento do processo, assim como um auxílio na tomada de decisão por parte dos operários da planta. Por motivos de complexidade nesse tipo de estudo, por envolver diversos aspectos térmicos e a dificuldade na modelagem matemática dos problemas físicos ligado a essa área, a busca por utilizar os dados disponíveis na planta, de forma a obter padrões da operação, se torna uma ferramenta extra e de baixo risco e custo a ser implementada para auxiliar no controle desses parâmetros.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Implementar e otimizar uma estrutura de redes neurais do tipo LSTM (*Long Short-Term Memory*), para prever padrões no processo de reaquecimento de peças de aço (tarugos), e a partir desta, desenvolver um sistema de controle do tipo PI para garantir a temperatura de cada zona no valor de *setpoint*.

2.2 OBJETIVOS ESPECÍFICOS

- Escolher técnicas de pré-processamento dos dados disponíveis de forma a tratar pontos extremos (outliers), variar a taxa de amostragem, fazer a normalização dos mesmos, entre outros;
- A partir dos dados tratados, desenvolver a estrutura de Redes Neurais Recorrentes do tipo Long Short-Term Memory (LSTM) com a busca dos melhores parâmetros de modo a prever padrões com melhor acurácia possível;
- Comparar os valores dos parâmetros, assim como acuraria obtida, entre as diferentes estruturas desenvolvidas e utiliza-las para criação de um sistema de controle PI para manter a temperatura de cada zona no forno dentro de seu valor de *setpoint*;
- Comparar o sistema de controle obtido a partir do uso da RNA desenvolvida com outros trabalhos sobre esse tema na literatura.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 FORNOS INDUSTRIAIS

Na indústria, existem diferentes tipos de fornos disponíveis que são de acordo com o produto que é obtido pelo mesmo. De modo geral, os fornos são responsáveis por transferir energia para os materiais com o intuito de promover aumento de temperatura em suas superfícies (LIRA JÚNIOR, 2007). Para que ocorra essa transferência de energia, é necessário que algum tipo de combustível seja queimado, ou então através da utilização de energia elétrica. Os combustíveis normalmente são mais utilizados na indústria pelo fato de apresentar um gasto inferior se comparado a energia elétrica.

Sendo assim, os fornos podem ser escolhidos de acordo com o tipo de combustível que é utilizado, pois sua configuração também sofre influência dessa variável. Outro fator que influencia o tipo de forno escolhido no processo industrial é a direção dos gases de combustão, caso sejam aproveitados na zona de pré-aquecimento do forno.

A escolha dos parâmetros necessários para operação é determinada de acordo com a necessidade do processo, para que então possa ser escolhido o melhor combustível que irá alcançar uma alta eficiência térmica, assim como a escolha do ar que será utilizado para promover a combustão, podendo ele ser ar atmosférico ou oxigênio puro. O ar também pode ser injetado diretamente nos queimadores que estão dispostos ao longo do forno. O fato de a chama ter contato direto ou indireto com o material também causa influência na escolha do forno usado (LIRA JÚNIOR, 2007).

3.1.1 Fornos para laminação de aço

Os fornos de uma indústria de laminação de aço, são do tipo contínuos, por ter um regime de trabalho onde as peças são alimentadas constantemente desde a entrada do forno, até a saída. Nesses fornos, existem diferentes zonas, onde as temperaturas são diferentes entre si, para que as peças possuam um perfil homogêneo de temperatura enquanto passam ao longo do comprimento do forno.

A energia proveniente do ar dos produtos de combustão pode ser reaproveitada de outras formas, como pré-aquecimento do ar a ser injetado nos queimadores ou para aquecimento de água, em caldeiras de recuperação, *reboiler*, em outras etapas do processo industrial, como nos sistemas de secagem.

Os queimadores estão distribuídos ao longo do forno e são separados por zonas, garantindo um perfil ideal de temperatura baseado na curva de aquecimento desejada para o processo. As peças necessitam ter uma homogeneidade no perfil de temperatura, visto que caso aja calor excessivo, as mesmas podem se fundir ou alterar as características necessárias para o produto desejado (GOUVEIA, 2013). O forno em estudo utiliza gás natural e gás misto como combustível para ser usado nos queimadores.

Dessa forma, essa etapa de reaquecimento das peças é crucial para que se obtenha o produto de interesse desse tipo de indústria (MIRANDA *et al.*, 2006). Logo, o controle dos parâmetros dessa etapa é de suma importância para que se tenha o funcionamento contínuo do forno, e maior velocidade de produção.

O controle eficiente e confiável de um forno de reaquecimento é um problema desafiador devido a muitos tipos diferentes de tarugos a processar, uma forte intercorrelação entre variáveis de processo, grande dimensão do espaço de entrada e saída, forte interação entre variáveis de processo, um grande atraso de tempo e um comportamento altamente não linear (KIM *et. al*, 1998).

3.2 CONTROLE NAS INDUSTRIAS

Os processos industriais estão mais complexos com o passar dos anos, e a demanda por qualidade nos produtos é crescente. Com o avanço da tecnologia, todas as etapas industriais passaram a evoluir e os processos que antes eram em sua maioria controlados manual e visualmente, agora trazem consigo a automação industrial, para que as condições ideais sejam majoritariamente alcançadas, e assim, haja diminuição de produtos fora da especificação desejada para o mercado. Para que essas características sejam obtidas, é necessário o controle dos parâmetros importantes para cada tipo de processo.

O controle convencional traz a coleta de dados dos parâmetros mais importantes da planta, como temperatura, pressão, nível de tanques, entre outros. Os sensores são os responsáveis por essa coleta, onde os dados são então enviados para os sistemas de monitoramento, que mostra se os dados observados no processo estão acima, abaixo ou entre os valores considerados limites de operação do equipamento em questão.

A entrada de um controlador é o erro entre a condição ideal que precisa ser alcançada (*setpoint*) e o valor real da variável de saída do processo. O controlador sempre buscará diminuir esse erro, para que a variável de saída do processo esteja sempre controlada, motivo pelo qual

ela é também denominada variável controlada (NEVES, 2016). Os operadores então utilizam essas informações que estão disponíveis na planta para auxiliar na tomada de decisão.

Os controladores do tipo PID (Proporcional, Integral e Derivativo) são os mais utilizados dentro da indústria. Nestes, os dados alimentam o sistema, e o controlador, que possui o *setpoint*, calcula a saída obtida no processo para esses dados, e caso o sistema fuja desse valor ideal, são feitos ajustes na operação. Tais ajustes podem ser manuais, que seriam por exemplo, abertura de válvulas, diminuição de temperatura do equipamento através do sistema de resfriamento feito pelos operários, ou então, nos processos atuais, o próprio sistema de controle já está associado aos equipamentos de modo a fazer essas atuações de forma automática.

A lei PID traduz a ideia de que a variável manipulada será alterada proporcionalmente (P) ao erro que aparece a cada instante, ao acúmulo, integral (I), do erro ao longo do tempo e à taxa de variação do erro da variável controlada (D). Se tratando do sistema de controle abordado no presente trabalho, do tipo PI, temos:

$$u(t) = k_c e(t) + \frac{k_c}{\tau_i} \int_0^t e(t) dt + u_s \quad (1)$$

Onde, $u(t)$ é a saída do controlador em função do tempo, u_s é a saída do controlador no regime permanente, k_c é o ganho da parte proporcional do controlador, τ_i é o tempo da ação integral do controlador e $e(t)$ é o erro entre o processo e setpoint. O valor numérico dessas duas constantes deve ser determinado de maneira que o controlador tenha um bom desempenho, evitando instabilidades no processo. Esse é o problema de controle clássico, o problema de sintonia do controlador.

Outro problema desse tipo de controle convencional se dá pelo fato da possibilidade de os sensores estarem descalibrados, podendo passar dados falhos ou ruídos, ou até mesmo atraso na observação de anomalias no processo, provocando um efeito em cascata que resultaria na tomada de decisão tardia, causando a obtenção de produtos fora da especificação desejada.

Dessa forma, a busca por um sistema de controle cada vez mais avançado e que seja compatível com a complexidade de cada processo industrial faz com que pesquisas sejam desenvolvidas de modo a encontrar soluções e ferramentas eficazes. Uma dessas abordagens é o que se chama de caixa preta, pois nela envolve a coleta de uma quantidade representativa de dados reais da planta a partir dos quais, por meio do uso de ferramentas de identificação do

sistema, como regressão determinística ou técnicas de inteligência artificial (AI), um modelo aproximado do processo real é derivado (Yukun Hu et al., 2017).

Assim, o uso de Redes Neurais Artificiais está em alta, tendo em vista a atual ampliação da capacidade computacional. Oleskovicz et al. (2003) afirmam que de acordo com os recentes avanços relacionados as técnicas de inteligência artificial, é possível encontrar na literatura diferentes modelos dessa natureza, voltados à solução de problemas variados.

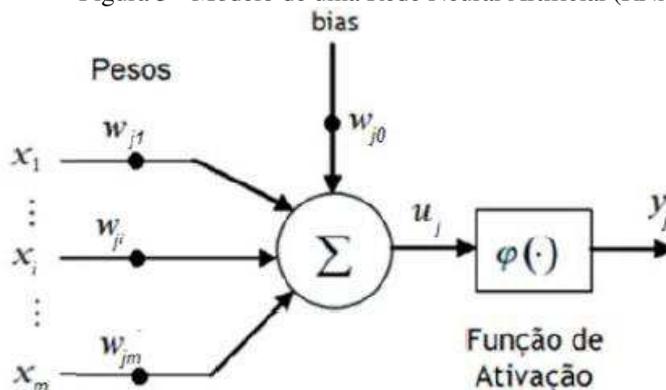
3.3 REDES NEURAIAS ARTIFICIAIS (RNA)

De modo geral, as RNAs são estruturas paralelas, maciçamente distribuídas, constituídas por unidades simples de processamento conhecidas como neurônios (Haykin, 2001). A partir dessas unidades, as RNAs possuem a capacidade de aprender de acordo com o problema no qual é aplicada, através de ajustes nas conexões que são chamadas de pesos sinápticos, que ficam entre as camadas de entrada e saída da rede.

As redes inicialmente recebem dados de entrada, que forma a primeira camada da rede, e então os dados são aplicados a uma determinada função, normalmente não linear, para se obter dados de saída (última camada). Todas as camadas entre a primeira e a última são chamadas de camadas ocultas. Os pesos, que fazem parte da camada oculta, são responsáveis por armazenar o conhecimento adquirido pelo modelo, e por ponderar a entrada recebida por cada neurônio, de modo a determinar se esta fará parte do aprendizado ou não.

O modelo de neurônio mais conhecido foi proposto por McCulloch e Pitts, em 1943. A ideia era construir algo mais próximo possível dos neurônios biológicos, afim de armazenar conhecimento a partir de novas informações. O *perceptron* seria composto por um único neurônio. A Figura 5 exemplifica o funcionamento das RNAs.

Figura 5 - Modelo de uma Rede Neural Artificial (RNA).



Fonte: Adaptado Silva et al. (2010) apud Neves (2016).

Pela figura acima, temos que a representação matemática da saída do j -ésimo neurônio pode ser dada pelas equações (2) e (3):

$$u_j = \sum_{i=1}^m w_{ji}x_i + w_{j0} \quad (2)$$

$$y_i = \varphi(u_j) \quad (3)$$

Onde m indica o número de neurônios da camada i ou número de entradas do neurônio j .

A partir do modelo proposto por McCulloch & Pitts, outros modelos surgiram e tornaram possível a obtenção de uma saída que não necessariamente seja igual a zero ou um, e com diferentes funções de ativação, por exemplo: função linear, função rampa, função degrau e função sigmoideal, entre outras.

A capacidade de aprender através de exemplos, ter saídas coerentes quando apresentada a dados nunca visto antes, e de generalizar este aprendizado é o principal atrativo do uso de *RNAs*. Esta generalização é uma demonstração do que as mesmas podem fazer, e vai muito além do que simplesmente mapear relações entre dados de entrada e saída. As *RNAs* são capazes de extrair informações significativas em uma grande quantidade de dados, e no caso de problemas industriais, buscar instabilidades no processo com o mínimo de tempo e custo e máxima precisão (MORAIS, 2010).

3.3.1 Algoritmos de aprendizado

Para se obter o aprendizado desejado de um problema a partir do uso de *RNAs*, uma série de cálculos iterativos devem ser feitos de forma a ajustar os parâmetros ideais, que são os pesos e bias, para que no final do processo o conhecimento que a rede adquiriu seja guardado e posteriormente utilizado em dados novos do processo, nunca vistos pela rede. Esses procedimentos caracterizam os algoritmos de aprendizado (BRAGA, CARVALHO & LUDERMIR, 2000). A escolha do método de aprendizado é importante, pois a partir desta pode ser feita a escolha do melhor tipo de arquitetura disponível para criação das *RNAs* de acordo com o objetivo desejado.

Existem diversos métodos de treinamento das redes, onde os mesmos podem ser agrupados de duas formas: aprendizado supervisionado e não-supervisionado. No aprendizado

supervisionado, a entrada e saída da rede é fornecida por um supervisor externo. Os parâmetros da rede são ajustados com o objetivo de encontrar o menor erro possível entre a saída desejada e a calculada pela rede. O algoritmo de treinamento tem como objetivo minimizar o erro e uma função de custo definida pelo supervisor. Esse tipo de método será utilizado neste trabalho.

No caso do aprendizado não-supervisionado, não há um supervisor acompanhando o processo de aprendizado. Apenas os dados de entrada estão disponíveis e a rede busca encontrar uma forma de se familiarizar com as características da entrada e, a partir delas, criar novas classes ou grupos de forma automática.

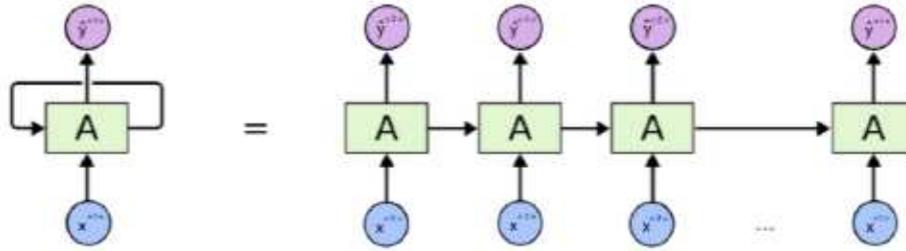
3.3.2 Arquitetura das redes

Em geral, existem três classes fundamentais de arquiteturas de RNAs: rede *feedforward* de única camada, rede *feedforward* de múltiplas camadas e redes recorrentes. As duas primeiras se diferem pelo fato de uma ter apenas entrada e saída, sem presença de camada intermediária, enquanto a outra possui camadas intermediárias, que a torna mais complexa de acordo com a quantidade de camadas ocultas inseridas. Ambas possuem o fluxo de informação apenas em uma direção, que seria desde a entrada até a saída. Como a informação se move de forma unidirecional através da rede, ela nunca passa duas vezes no mesmo neurônio (ARAÚJO NETO, 2018).

As redes *feedforward* são bastante utilizadas, porém, se tratando de resolver problemas com dados sequenciais, as mesmas não apresentam um bom funcionamento, visto que não possuem armazenamento de conhecimento adquirido anteriormente por uma entrada, para lidar com outra que seja sequencial. Nesse tipo de problema, as redes recorrentes apresentam uma vantagem.

As Redes Neurais Recorrentes (RNN) trazem as informações dadas em uma entrada da rede, para obter uma saída, e quando a rede ler a próxima entrada ela carrega com si o conhecimento adquirido na etapa anterior, e assim por diante até o final dos dados sequenciais. De forma esquemática, temos que a rede ler uma *feature* x de um *input* alimentado a uma rede neural denominada pela letra A , e gera um *output* \hat{y} . Quando a rede lê a próxima *feature*, traz consigo a informação do passo anterior para poder gerar o próximo *output* e assim por diante (GOMAA, 2020). A Figura 6 apresenta a arquitetura dessa rede.

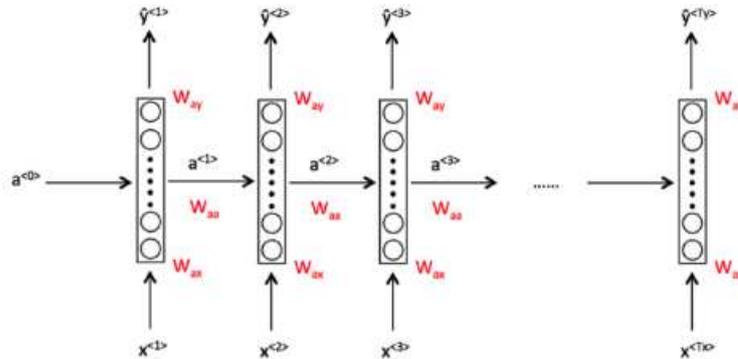
Figura 6 – Arquitetura básica de uma rede neural recorrente



Fonte: GOMAA (2020)

Toda vez que uma RNN calcula uma saída $\hat{y}^{<t>}$, ela passa para o próximo passo com um valor de variável de ativação $a^{<t>}$, que é usada para encontrar a próxima saída da rede. Os dados sequenciais são analisados da esquerda para a direita, onde os pesos usados na etapa 1 são usados na etapa 2, e assim até a etapa t, formando uma matriz de pesos W_{ax} . As conexões horizontais são regidas pela matriz de pesos W_{aa} , enquanto a responsável pela saída é a matriz W_{ay} (CASTELÃO, 2018). A Figura 7 traz a representação da descrição anterior.

Figura 7 – Rede neural recorrente com matrizes de peso responsáveis pela predição



Fonte: CASTELÃO (2018)

A RNN como descrita anteriormente é regida pelas equações (4), (5) e (6):

$$a^{<0>} = \vec{0} \quad (4)$$

$$a^{<t>} = g(W_{aa}a^{<t-1>} + W_{ax}x^{<t>} + b_a) \quad (5)$$

$$\hat{y}^{<t>} = g(W_{ya}a^{<t>} + b_y) \quad (6)$$

Onde $a^{<t>}$ é a variável de ativação, $g()$ é a função de ativação escolhida, b_a é um fator de correção para cálculo de $a^{<t>}$ e b_y é um fator de correção para cálculo de $\hat{y}^{<t>}$.

As redes recorrentes são diferentes das redes *feedforward* pelo *loop* de *feedback* conectado às suas saídas anteriores, ingerindo as mesmas passo a passo como entrada da

seguinte. Essas informações sequenciais são armazenadas nas camadas ocultas da RNN, que consegue passar por muitas etapas de tempo à medida que ela avança em cascata para afetar o processamento de cada novo exemplo.

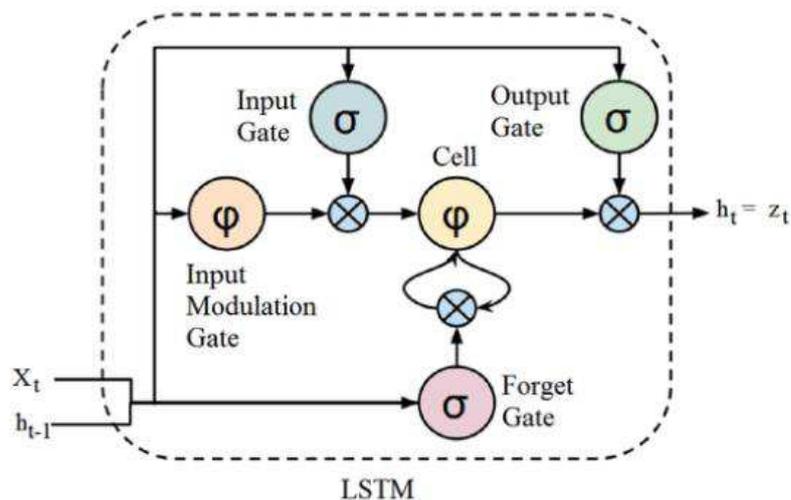
Um dos tipos de RNN são as chamadas LSTM ou *Long Short Term Memory*, usadas em problemas como processamento de linguagem natural, porém vem ganhando espaço na determinação de padrões em plantas industriais justamente pelo fato de conectar informações anteriores a atual e fazer com que essas informações persistam durante o treinamento da rede.

3.3.2.1 Redes Long Short Term Memory (LSTM)

A LSTM é uma arquitetura de RNNs que consegue armazenar valores em intervalos arbitrários. A LSTM é bem adequada para classificar, processar e prever séries temporais com intervalos de tempo de duração desconhecida. Nesse caso, quando a rede “esquece” o que aconteceu anteriormente e não consegue propagar as informações através da sequência inteira, são usadas as LSTMs, que foram introduzidas por Hochreiter & Schmidhuber (1997).

As RNN do tipo LSTM possuem uma estrutura diferente das demais RNN. Nesse tipo, a estrutura é formada por um módulo de repetição, onde existem quatro camadas e uma célula que compõe o bloco de memória da rede. As informações aprendidas pela rede são retidas pelas células e as manipulações de memória são feitas pelos portões, chamados de *gates*. A Figura 8 mostra o esquema de uma rede LSTM. (CASTELÃO, 2018)

Figura 8 – Esquema representativo de uma rede recorrente do tipo LSTM



Fonte: GOMAA (2020)

Como pode ser visto na Figura 8, as LSTM possuem os *gates*, que são responsáveis por proteger e controlar o estado da célula, de modo a permitir ou bloquear que a informação passe a ser aprendida pela rede. A primeira porta é a *Forget Gate*, que remove as informações que

não são mais úteis no estado da célula. Nela, duas entradas são inseridas, sendo x_t a informação nova e $a^{<t-1>}$ saída da célula anterior. Nessa porta, as entradas são multiplicadas por matrizes de zeros e somadas ao bias, passam por uma função de ativação e tem como resposta uma saída binária, onde 0 corresponde a resposta ser esquecida e 1 a ser retida para uso futuro.

A segunda porta, chamada de *Input Gate* é onde as informações são adicionadas ao estado da célula. Primeiro, a informação passa por uma função sigmoide que filtra os valores a serem lembrados de forma similar ao *Forget gate* usando as entradas x_t e $a^{<t-1>}$. Então, um vetor é criado usando a função tanh que tem como saída o intervalo de -1 a +1, que contém todos os valores possíveis de x_t e $a^{<t-1>}$. Os valores do vetor e os valores regulados são multiplicados para obter as informações úteis.

O *Output gate* tem como objetivo extrair as informações úteis para o estado da célula que serão apresentadas como saída da rede. Primeiro, um vetor é gerado aplicando a função tanh na célula. Então, a informação é regulada usando a função sigmoide que filtra os valores a serem lembrados usando as entradas x_t e $a^{<t-1>}$. Os valores do vetor e os valores regulados são multiplicados para serem enviados como uma saída e entrada para a próxima célula.

As setas em loop indicam a natureza recursiva da célula. Isso permite que as informações sejam armazenadas na célula LSTM. É essa estrutura que permite que a mesma seja utilizada em problemas sequencias com dependências de longo prazo, como séries temporais semelhantes ao problema deste trabalho.

3.4 PRÉ-PROCESSAMENTO E TRATAMENTO DOS DADOS

O início do desenvolvimento de uma RNA parte da coleta dos dados que serão utilizados para treinar a mesma. Esses dados, que devem ser históricos e relativos ao problema em questão, devem mostrar o comportamento normal do processo, quando está dentro da idealidade, mas também deve apresentar dados fora da especificação e nos limites do domínio do problema, para fazer com que a rede aprenda toda a complexidade da operação e possa a partir disso, encontrar os melhores parâmetros que caracterizem a mesma.

Porém, esses dados são fornecidos da forma como são captados pelos sensores nos equipamentos, podendo apresentar valores faltantes, ruídos, pontos discrepantes (outliers), em escalas diferentes, entre outros problemas. Dessa forma, para que tenhamos um modelo preditivo confiável e que ao receber dados nunca vistos anteriormente, possam prever a saída

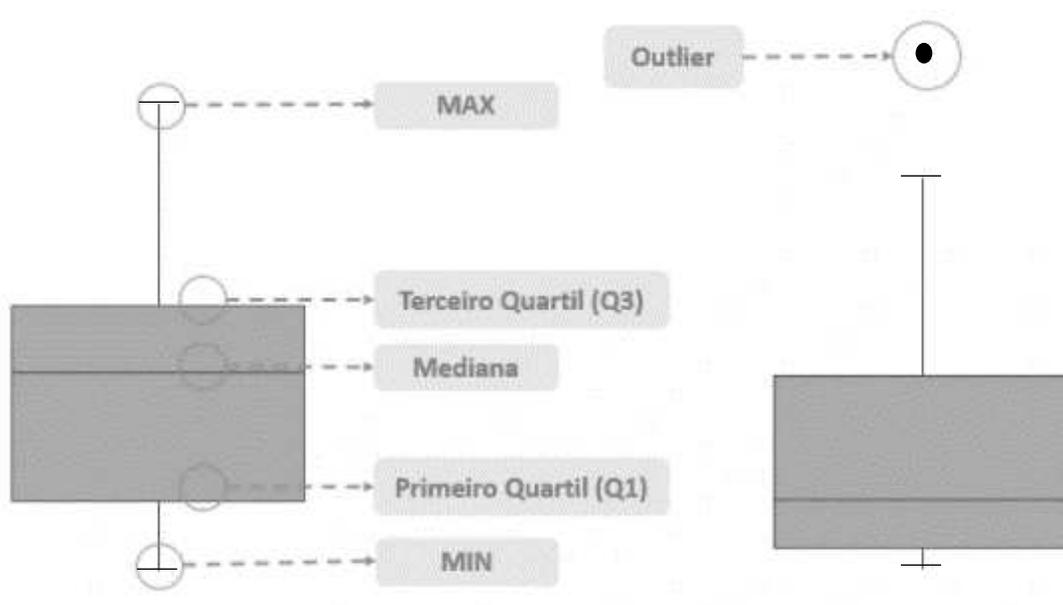
com o menor erro possível, os dados de entrada do modelo devem ser tratados para eliminação dos possíveis obstáculos de se obter uma rede satisfatória.

Existem diversas funções dentro da linguagem Python, que é a utilizada nesse trabalho, que são responsáveis pelo tratamento dos dados. Para dados faltantes, dependendo do problema, ou da quantidade de dados disponíveis para o modelo, pode-se removê-los. Já no tratamento dos ruídos, que possam ser causados por falha nos sensores, condições externas a operação, existem técnicas que permitem a suavização de modo a reduzir o impacto na saída da RNA.

Tratamento de *outliers* é outro ponto importante quando se fala em redes neurais, pelo fato de quanto esse tipo de dado pode ser impactante para a obtenção de uma previsão correta. Esses dados são valores que são considerados fora dos limites de operação do processo. Para encontrar esses pontos, pode-se fazer uso da estatística de modo a encontrar valores que estão fora do padrão observado para alguma variável.

Um dos gráficos mais utilizados para visualizar *outliers* são os chamados de *boxplot*, que se apresenta por uma caixa retangular, cortada pela mediana ao centro e cruzada por uma linha onde marca o limite superior e o limite inferior, todos os valores que estão acima ou abaixo desses limites são os pontos de *outliers*. A Figura 9 representa o gráfico *boxplot*. A partir desses gráficos, pode-se observar pontos extremos e identificar anomalias no processo, porém, dependendo do caso, os valores de outliers são os que se deseja encontrar.

Figura 9 – Representação de um gráfico *boxplot* para identificar pontos *outliers*



Fonte: Próprio autor

Com isso, primeiramente precisamos ordenar os dados do menor ao maior valor, posteriormente calcula-se a mediana dos dados, que será o valor central se a quantidade de dados for ímpar, ou a soma dos dois valores centrais dividido por dois, caso a quantidade de dados seja par.

Depois disso, é preciso encontrar os Quartis dos dados, que separam a região antes e depois da mediana. No caso, o quartil 1(Q1) é o valor central dos dados abaixo da mediana que corresponde a 25% dos dados, e o quartil 3 (Q3) é o valor central aos dados acima do valor da mediana, que corresponde ao valor que está acima de 75% dos dados. A amplitude interquartilica (IQR) é a diferença entre Q3 e Q1. A partir dela e dos valores encontrados anteriormente, pode-se calcular quais são os limites inferior e superior do *box plot*, a partir das equações (7) e (8):

$$Inf = Q1 - 1,5 * IQR \quad (7)$$

$$Sup = Q3 + 1,5 * IQR \quad (8)$$

Após a identificação dos *outliers*, existem diferentes técnicas que podem ser utilizadas para trata-los. A primeira consiste na eliminação de tais pontos, que caso não seja uma grande quantidade de valores, não trará grande impacto sobre o modelo. Outro método é substituição de tais valores. Essa substituição pode ser pela média dos valores da variável em questão, ou pelos limites superiores ou inferiores dependendo onde se encontra o ponto de *outlier*. As três técnicas serão levadas em consideração no presente trabalho para avaliar a eficácia.

Em grande parte dos processos, existem inúmeras variáveis que são levadas em consideração na hora que obter os dados histórico para criação da rede. Porém, quanto mais dados e variáveis diferentes existir em uma RNA, mas trabalhoso é encontrar uma representação confiável e que possua uma alta acurácia. Dessa forma, é importante a avaliação de quais variáveis são realmente importantes para o modelo, quais as que mais influenciam no parâmetro de saída da rede. Existem técnicas utilizadas para encontrar essas correlações e visam reduzir a dimensão de um conjunto de dados.

A eliminação de ruídos que possam estar presentes nos conjuntos de dados visa a eliminação de comportamentos não condizentes com o processo, assim como a suavização de curvas que possam levar o treinamento da rede para um caminho diferente do desejado. Esses ruídos podem ser provenientes de erros de leitura feita pelos sensores, preenchimento dos campos por parte dos usuários do sistema de forma incorreta, falta de coleta de dados em algum momento específico do processo, entre outros.

Outra forma de lidar com grande número de dados é a escolha da melhor taxa de amostragem para ser utilizada na rede. Consiste em escolher o intervalo de tempo mais viável para criação da RNA, de modo que contenha os dados que representem o problema, mas que não seja custoso para fazer o treinamento. De modo geral, o aumento das amostras para treinamento da rede também causa aumento na acurácia do modelo, fazendo com que se obtenha uma rede cada vez mais representativa.

Por isso, o presente trabalho busca esse estudo juntamente com as demais técnicas abordadas anteriormente para criação de uma RNA do tipo LSTM a ser aplicada em dados de um forno de reaquecimento, que tenha a capacidade de aprender os padrões contidos nesses dados e, dessa forma, desenvolver um controlador PI que possa manter a temperatura de cada zona existente no forno dentro do seu valor de *setpoint*.

4 METODOLOGIA

4.1 CRIAÇÃO DE UMA REDE NEURAL RECORRENTE BASEADA EM LSTM

4.1.1 Dados de entrada

Para o presente trabalho, os dados de entrada foram obtidos a partir de dados coletados por sensores distribuídos em um forno de reaquecimento de tarugos. Por se tratar de dados industriais, seus valores são confidenciais, porém, como o objetivo é construir uma RNA a partir deles para prever padrões e observar o comportamento de novos dados nessa rede desenvolvida, dados foram normalizados, onde não se tem o conhecimento dos reais valores, apenas de como estão distribuídos.

Alguns dos passos considerados de extrema importância no processo de desenvolvimento de redes neurais artificiais são: a coleta e limpeza dos dados relativos ao problema e a separação dos mesmos em um conjunto de treinamento e um conjunto de testes. Esta tarefa deve ser cuidadosa, de modo a minimizar ambiguidades e erros nos dados. Além disso, os dados coletados devem ser significativos e cobrir amplamente o domínio do problema.

Normalmente, os dados coletados são separados em duas categorias: dados de treinamento, que serão utilizados para o treinamento da rede e dados de teste, que serão utilizados para verificar seu desempenho sob condições reais de utilização.

Os dados históricos foram disponibilizados em arquivos “.csv”, com informações importantes para o problema deste trabalho, como: temperatura das zonas, vazão de gás natural, vazão de gás misto, vazão de ar de combustão, ambos considerando as oito zonas do forno, e a temperatura do ar de combustão.

Os dados foram tratados após serem adicionados a uma estrutura de *DataFrame* da biblioteca *Pandas*, do *Python*. Foi utilizado a ferramenta de escrita de código na linguagem *Python*, *Jupyter Notebook*. Os gráficos para visualização dos dados foram obtidos a partir da utilização da biblioteca *Pyplot* e *Seborn*.

4.1.2 Normalização dos dados

Os dados obtidos na criação do *DataFrame*, foram transformados em um *Array* pela biblioteca *Numpy*, e as datas correspondentes a coleta do dado foram indexadas. Para normalizar esses dados foi utilizada a função *MinMaxScalar* da biblioteca *Sklearn*, própria para *machine learning*. Essa função tem como objetivo mapear os dados a serem normalizados no intervalo [-1, 1]. Assim, o maior valor do *array* que está sendo normalizado, receberá o valor

de 1, e o menor, o valor de -1, os valores intermediários serão transformados em números dentro desse intervalo.

A normalização é feita quando os dados tem diferentes escalas entre as variáveis dependentes, e com isso, não se pode treinar a rede pois resultará em erros. Como os dados do problema são temperaturas e vazões, que possuem escalas diferentes, é necessário que seja feita essa etapa. A equação para normalização é dada pela equação 9.

$$VN = \frac{X - \text{valor mínimo}}{\text{valor máximo} - \text{valor mínimo}} \quad (9)$$

Após essa etapa, os dados foram convertidos de série temporal para serem utilizados em um problema de aprendizado supervisionado.

4.1.3 Eliminação de ruídos

A eliminação de ruídos consiste na suavização das curvas correspondentes aos dados do problema. Os ruídos são instabilidades que podem surgir nos dados devido à falta de coleta dos dados em certos instantes do processo, pelo erro de leitura dos sensores ou por inconsistências no processo. Esses dados podem prejudicar a qualidade da informação necessária para criação da RNA.

A função da biblioteca Pandas para remoção de ruídos em um *DataFrame* é a *rolling*, onde escolheu-se que a suavização fosse feita considerando um intervalo de dez observações da variável em questão. A RNA foi construída inicialmente sem levar em consideração a eliminação dos ruídos, e posteriormente foi feita essa implementação para avaliar a influência que a mesma possui na obtenção da rede.

4.1.4 Eliminação de *Outliers*

Os *outliers* são pontos extremos, valores discrepantes em relação aos dados do problema. Podem ser causados de forma proposital, por erro de digitação, por erro de leitura dos equipamentos ou por alteração do processo. Esses dados podem afastar o processo em questão da idealidade, ou podem apresentar a resposta que o operador necessita para compreender o andamento do mesmo.

Nesse trabalho, a RNA foi criada inicialmente considerando todos os valores, sem tratamento dos *outliers*, e posteriormente os mesmos foram tratados por três métodos:

- Eliminação dos pontos outliers;

- Substituição desses pontos pelo valor da média dos dados;
- Substituição desses pontos pelo valor máximo ou mínimo dos dados, dependendo de onde estava localizado esses pontos no gráfico *boxplot*.

Foram escritas três funções diferentes para os métodos citados anteriormente para avaliação da significância desse tipo de dado na construção da rede.

4.1.5 Taxa de Amostragem

A taxa de amostragem diz respeito a quantidade de dados que foi considerada para elaboração da RNA. Inicialmente foi considerado uma taxa de amostragem de 1 minuto, ou seja, a cada um minuto, um valor foi coletado do processo. Nessa primeira configuração, as variáveis dependentes possuíam 661 valores, onde posteriormente foram eliminados os valores nulos caso existissem.

A segunda taxa de amostragem considerada foi de 30 segundos, a cada intervalo de tempo, foi coletado um dado no processo, e com isso as variáveis possuíam 1321 valores. Essas taxas de amostragem foram escolhidas de forma arbitrária, e a avaliação dessas considerações foram feitas para testar a influência sobre a construção de rede.

4.2 Criação da Rede Neural

O presente trabalho faz uso de dados coletados de um forno de reaquecimento de tarugos, dessa forma, temos que se trata de um problema complexo, que envolve diversas variáveis e que possui uma complexidade que o torna de difícil estudo, e para que a previsão seja o mais assertiva possível, a rede neural deve levar em consideração os inputs desde o começo do *dataset*. Por esse motivo, foi escolhido uma rede neural com base em LSTMs.

A biblioteca *Keras*, que é própria para *deep learning* (aprendizado profundo), foi utilizada para criação da rede do tipo LSTM. Como estamos trabalhando com séries temporais, foi necessário instanciar um modelo sequencial. Após algumas tentativas, foram escolhidas a criação de duas camadas ocultas onde a primeira possui 200 neurônios e a segunda possui 100. Um *perceptron* foi inserido inicialmente, com função de ativação da camada foi ELU (unidade linear exponencial), e foi instanciado um segundo *perceptron* do tipo *Dense* com 1 unit, que recebe os inputs da rede de LSTMs e devolve um *array* de tamanho 1 com o valor da previsão. A função de ativação foi linear, que simplesmente devolve o valor do input recebido. A Figura 10 apresenta a arquitetura desenvolvida.

Figura 10. Arquitetura da RNA do tipo LSTM desenvolvida em linguagem *Python*

```
# Design network
model = Sequential()
model.add(LSTM(200, return_sequences=True, input_shape=(train_X.shape[1], train_X.shape[2])))
model.add(LSTM(100, return_sequences=False))
model.add(ELU(alpha=1))
model.add(Dense(1, activation='linear'))
model.compile(loss='mse', optimizer='sgd', metrics=['mse', 'mae', 'mape'])

# fit network
history = model.fit(train_X, train_y, epochs=200, batch_size=2, validation_data=(test_X, test_y), verbose=2, shuffle=False)
# plot history
plt.plot(history.history['mape'], label='train')
plt.plot(history.history['val_mape'], label='test')
plt.legend()
plt.show()
```

Fonte: Próprio autor (2022)

Os dados foram divididos em dados de treinamento e dados de teste, onde 70% e 30% dos dados foram separados respectivamente para cada categoria. Essa divisão é abundantemente utilizada em construção de redes neurais.

4.3 TREINAMENTO DA REDE LSTM

Com a criação da rede, foi feita a compilação da mesma a partir do comando *compile* da biblioteca *Keras*. Para que se tenha uma visualização da capacidade de previsão da RNA, é necessário que algumas métricas sejam usadas para mostrar se o valor previsto pela rede se aproxima dos valores reais. Sendo assim, o presente trabalho usou a métricas do Erro Percentual Absoluto Médio (MAPE). A equação 10 corresponde a métrica citada.

$$MAPE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\max(\epsilon, |y_i|)} \quad (10)$$

Onde y_i é a variável real e \hat{y}_i é a variável prevista pela RNA. Logo, para que se tenha um bom modelo é preciso que este seja treinado até o ponto em que a função de custo (MAPE) retorne curvas de decaimento próximas tanto para os exemplos de treino como para os de teste. Essa função faz com que o treinamento termine apenas quando esse erro é suficientemente insignificante. A mesma foi a escolhida pelo fato de que representa a melhor opção para avaliar se a RNA obtida foi satisfatória.

Inicialmente a rede foi treinada com 70% dos dados, sendo considerados do primeiro valor do *dataset* até o último, considerando que estamos lidando com séries temporais. Após o treinamento, a rede foi usada nos 30% restantes dos dados.

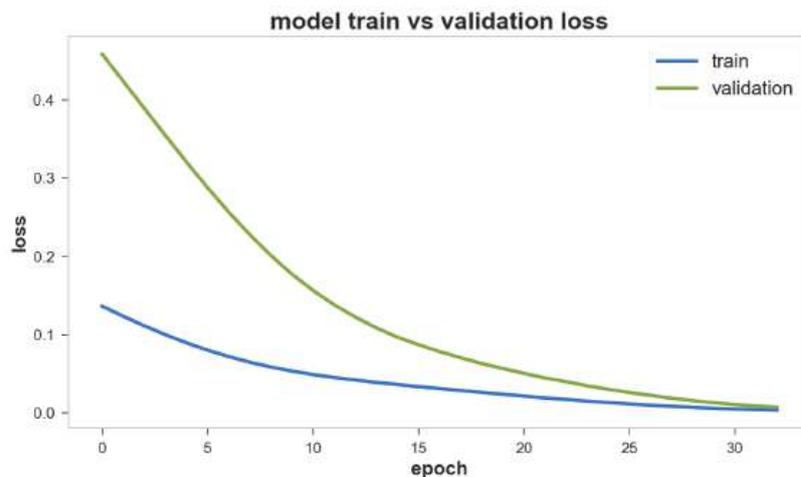
Outros parâmetros que foram inseridos na construção da rede foram: *epochs* e *batch size*. O primeiro corresponde a quantidade de vezes que os dados passam através da RNA a fim de treiná-la. Já o segundo é o tamanho do lote do *dataset* que é passado pela rede, ou seja, por se tratar de problemas com grandes quantidades de dados, é preciso dividi-los em conjuntos menores para poder passar pela rede, de forma a treiná-la com maior precisão.

Após isso, é necessário avaliar como está a predição do modelo a partir dos dados que foram usados para treiná-la, e para que a mesma posteriormente possa prever os dados de teste. Dessa forma, é importante saber se o modelo está sofrendo de *overfitting* ou de *underfitting*.

Overfitting consiste no modelo ter sido treinado excessivamente, de modo que durante essa etapa os erros fossem muito baixos, porém, quando a rede é exposta a dados não vistos anteriormente (dados de teste), os erros se tornam altos. Isso se dá pelo fato da rede ter memorizado os dados de treinamento, mas não ter obtido a capacidade de generalizar o conhecimento obtido. O *underrfitting* é o oposto do que foi descrito anteriormente, onde a rede não tem a capacidade de fazer previsões corretas.

Com o treinamento da rede, uma variável é retornada a cada época, *history*. Nessa variável existe as informações da função de custo que foi definida anteriormente e assim pode-se verificar se o modelo está bem treinado ou não. Um bom modelo é aquele treinado até o ponto em que a função de custo retorna curvas de decaimento próximas, tanto para os exemplos de treino como para os de validação. Isso pode ser observado na Figura 11.

Figura 11 - Gráfico da função do custo com um número ótimo de épocas (*best fit*.)



Fonte: CASTELÃO, 2018

4.4 PREDIÇÃO DOS VALORES

Após as etapas anteriores, onde foram definidas todas as configurações necessárias para criação da rede, os dados de treinamento e teste são usados para realizar as predições. A função *predict* do *Keras* retorna um *array* com os dados de predição do modelo. Depois disso, esse *array* precisa passar por uma conversão para que saiam dos valores normalizados e retornem aos seus valores originais de entrada.

A rede obtida após o treinamento com os dados separados para essa etapa, foi então utilizada para prever a saída quando inserido os dados de testes, não vistos anteriormente pela

rede, de modo a identificar se a mesma possui a capacidade de generalização dos padrões encontrados mesmo quando submetida a dados desconhecidos.

Com o modelo obtido, após o mesmo também ser submetido aos dados de treino e teste, iniciou-se o processo de criação de um sistema de controle para o forno em questão com o objetivo de garantir que o controlador mantenha as oito zonas dentro de seus valores de temperatura considerados ideais (*setpoints*).

Nesse trabalho, considera-se que as zonas não possuem dependência entre si, ou seja, a temperatura de uma zona não interfere nas demais. O controlador estudado é do tipo PI, onde seus valores de K_c , k_i foram obtidos a partir do método de Tyreus-Luyben, e tem como objetivo conduzir o processo de volta ao seu valor de *setpoint*, mesmo quando submetido a perturbações e entrada de novos dados.

4.5 Descrição do processo

O processo de estudo do presente trabalho é um forno de reaquecimento de tarugos, o qual deseja-se implementar uma RNA para encontrar padrão nos dados do mesmo, e a partir disso, poder modelar e otimizar um controlador do tipo PI para fazer o controle da temperatura das 8 zonas dentro dos valores de *setpoint*. Um perfil de temperatura controlado para as peças é necessário para o seu recozimento, sendo necessário expô-la a diferentes níveis de temperatura em cada zona. O gás utilizado nos queimadores é uma mistura de gás natural (GN) e gás misto (GM). O forno possui ajuste entre a proporção desses gases de modo que seja feito para determinar a potência de queima de acordo com o necessário em cada zona do forno.

A criação de um sistema de RNA associado ao controlador PI visa consumir a quantidade de combustível suficiente, sem perdas, para garantir que o processo obtenha a saída de produtos com a qualidade necessária. Ao final da criação da RNA, o valor de *setpoint* para o controlador, , é ajustado de para que os dados de temperatura permaneçam dentro dos limites de operação. A Tabela 1 apresenta os valores de *setpoint* desejados para as zonas.

Tabela 1 – Valores de *setpoint* a serem ajustados no controlador PI

Zona 1	Zona 2	Zona 3	Zona 4	Zona 5	Zona 6	Zona 7	Zona 8
1120° C	1130°C	1143 °C	1189 °C	1154 °C	1155 °C	1155 °C	1155 °C

Fonte: (SILVEIRA & RAFFO, 2017)

Algumas variáveis referentes ao processo podem ser variáveis de perturbação e causar alterações nos dados coletados, como: variação da velocidade das peças dentro do forno (que pode causar variação no perfil de temperatura), variações na pressão interna do forno, e o

acoplamento entre as zonas no forno (devido a conexão física entre as zonas) (SILVEIRA & RAFFO, 2017).

5 RESULTADOS E DISCUSSÕES

Tem-se o objetivo de construir uma RNA que faça previsões de dados nunca vistos, em um forno de reaquecimento, e a partir de seu aprendizado a mesma possa ser usada em conjunto com um controlador do tipo PI para garantir o valor de *setpoint* da temperatura nas 8 zonas do forno em estudo. Inicialmente fez-se a construção da RNA sem considerar as mudanças relacionadas aos tratamentos dos dados que foram descritas na seção 3.

5.1 COLETA E TRATAMENTO DOS DADOS

Os dados disponíveis no formato “.csv” foram adicionados ao código desenvolvido na linguagem *Python*, utilizando a ferramenta *Jupyter Notebook*, onde apenas as colunas de interesse para o problema foram selecionadas, visto que o arquivo continha diversas colunas e linhas de dados onde nem todas eram de interesse para o estudo. Dessa forma, coletou-se os dados de temperatura, vazão de gás natural (VGN), vazão de gás misto (VGM), vazão de ar de combustão (VAC) para as oito zonas distintas do forno, e a temperatura de ar de combustão do forno (TAC). Esses dados foram inseridos em *DataFrames* da biblioteca do *Pandas*, para que fosse possível a manipulação dos mesmos de forma a fazer o tratamento inicial, para posteriormente criar a RNA.

As Figuras 12 e 13 abaixo apresentam os gráficos de perfil de temperatura do forno, de acordo com as oitos zonas de forma individual, sem considerar que existe influencia entre elas. As representações gráficas, presentes nesse trabalho para leitura dos dados, foram separadas de forma que as 4 zonas iniciais ficassem presentes em um gráfico e as 4 últimas em outro, com o objetivo de facilitar a visualização.

Figura 12 – Perfil de temperatura do forno para as 4 zonas iniciais

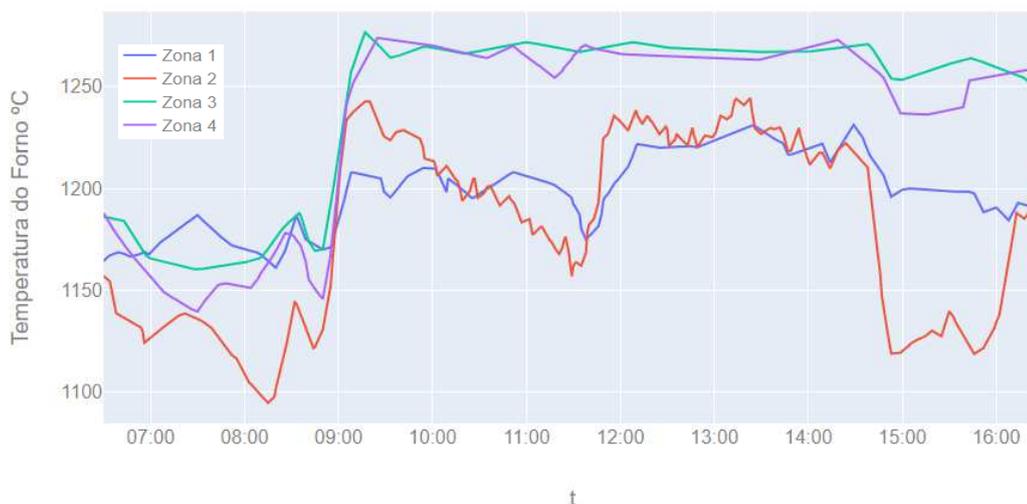
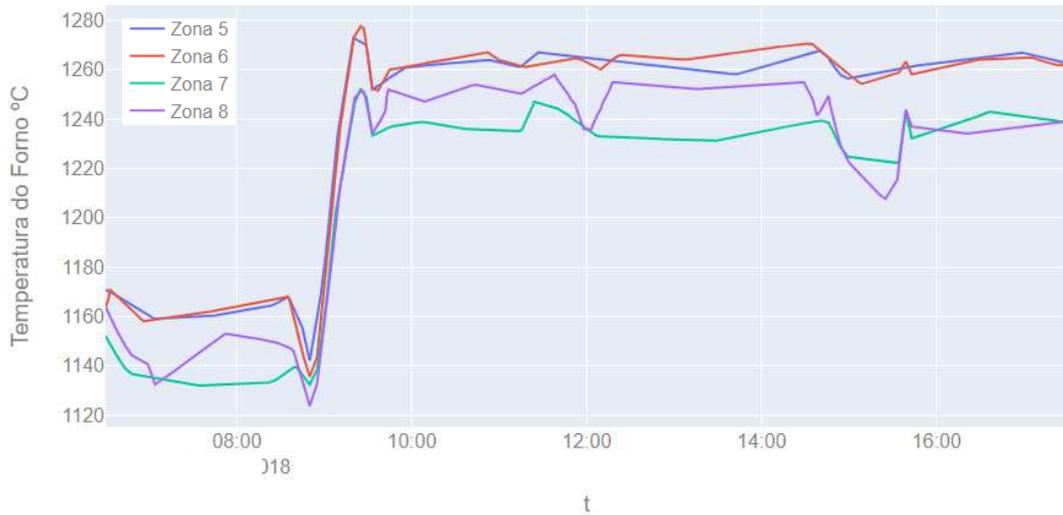


Figura 13 – Perfil de temperatura do forno para as 4 zonas finais



A partir da observação das figuras acima pode-se verificar que a faixa de temperatura das zonas varia de 1090 a 1280 °C aproximadamente, e corresponde a faixa de operação referente aos fornos de reaquecimento de aço, que pode ser entre 1000 a 1300 °C. Essa faixa de temperatura precisa ser mantida para garantir que as peças saiam do forno com as propriedades mecânicas ideais, como dureza, elasticidade, ductibilidade e resistência a tração, para que sejam moldadas de acordo com a necessidade do mercado.

As Figuras 14 e 15 a seguir apresenta os gráficos de perfil de vazão de gás natural nos queimadores presentes nas oitos zonas do forno. O gás natural, quando misturado com o gás misto, é o combustível que junto com o ar de combustão promove a transferência de calor necessária para que as peças sejam aquecidas até a temperatura desejada em cada zona.

Figura 14 – Perfil de vazão de gás natural no forno para as 4 zonas iniciais

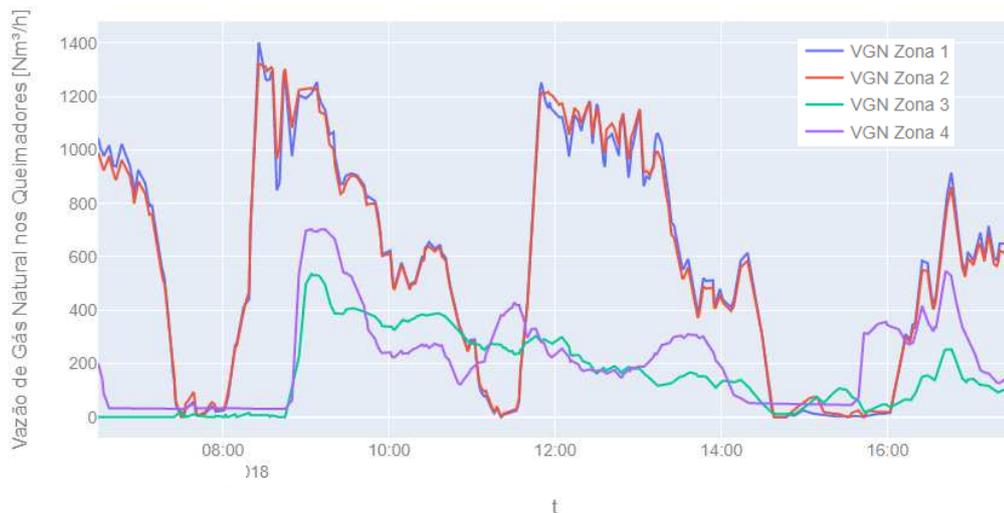
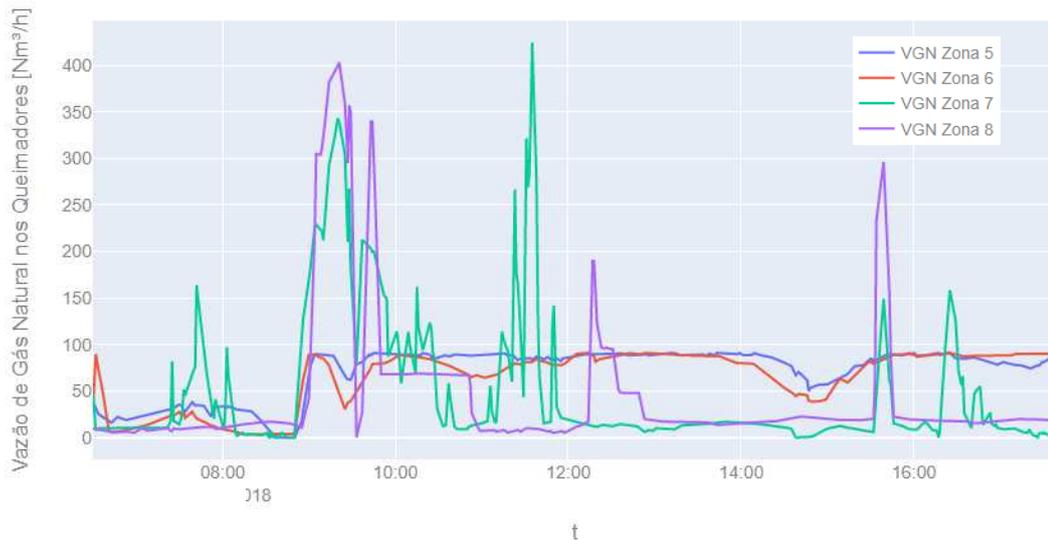


Figura 15 – Perfil de vazão de gás natural no forno para as 4 zonas finais



A partir da observação das figuras acima verificou-se que as faixas de vazão de gás natural nas zonas são diferentes entre si. Isso pode se dar pelo fato de que nas zonas 1 e 2, que correspondem a zona de pré-aquecimento, é necessário que a transferência de calor para as peças seja maior, visto que as mesmas entram a temperatura ambiente. As zonas 3 e 4 possuem valores próximos de vazão de gás natural, e variam de acordo com a necessidade do processo, para garantir um perfil de temperatura das zonas dentro da faixa necessária, que aumenta caso a temperatura caia, ou diminui caso a temperatura comece a aumentar.

A vazão de gás natural nas zonas 5 e 6 são menores em relação as zonas 7 e 8. Estabelecendo uma comparação entre as Figuras 12 e 13, pode-se observar que abaixo das 10h, existe uma diminuição na temperatura das zonas 5, 6, 7 e 8, e coincide com o momento em que há um aumento da vazão de gás natural no forno, com o propósito de aumentar a temperatura das zonas e assim garantir a qualidade do produto do forno.

As Figuras 16 e 17 apresentam os gráficos de perfil de vazão de gás misto para as oito zonas do forno. O gás misto, assim como o gás natural, é utilizado como combustível para promover a transferência de calor necessária para as peças dentro do forno, porém o mesmo é utilizado como o combustível principal para o processo de combustão.

Figura 16 – Perfil de vazão de gás misto no forno para as 4 zonas iniciais

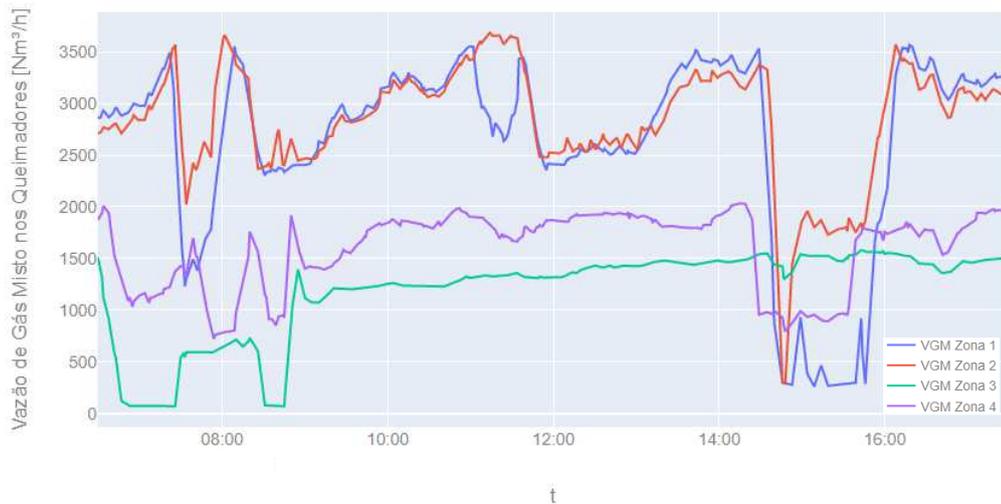
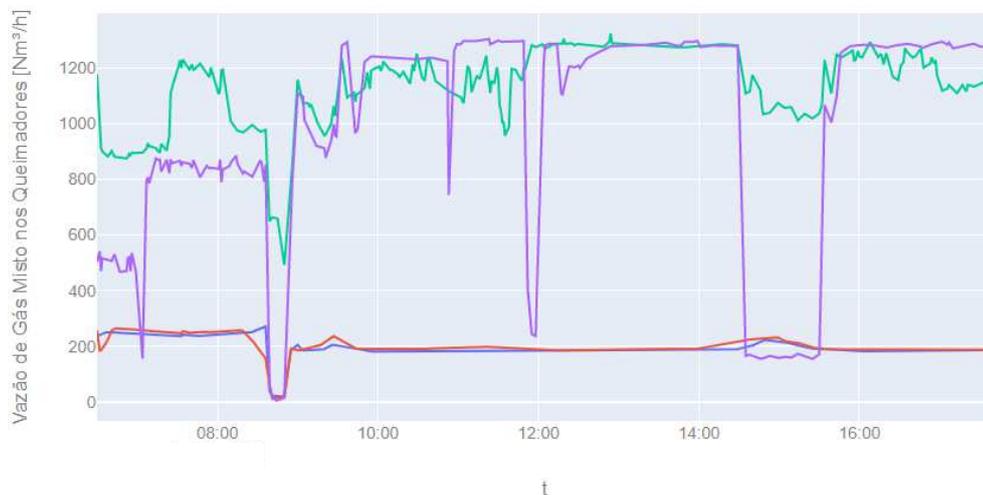


Figura 17 – Perfil de vazão de gás misto no forno para as 4 zonas finais



Analisando as Figuras acima observa-se que as vazões de Gás Misto são maiores se comparadas aos valores das vazões de Gás Natural. Isso se dá pelo fato de que o gás Misto é usado como o combustível primário para realização da combustão no forno, e o Gás natural é inserido quando há necessidade de um complemento para que seja alcançada a temperatura desejada para cada zona. Pode-se observar também que há momentos onde a vazão de Gás Misto tem uma queda brusca, que coincide com os mesmos instantes onde a vazão de Gás natural nas Figuras 14 e 15 reduzem, que podem ser perturbações do processo ou uma forma de garantir que as temperaturas das zonas estejam nas faixas desejadas, de modo a não causar fusão das peças ou perda das características necessárias para a laminação.

As Figuras 18 e 19 apresentam os gráficos de perfil de vazão de ar de combustão para as oito zonas do forno.

Figura 18 – Perfil de vazão de ar de combustão no forno para as 4 zonas iniciais

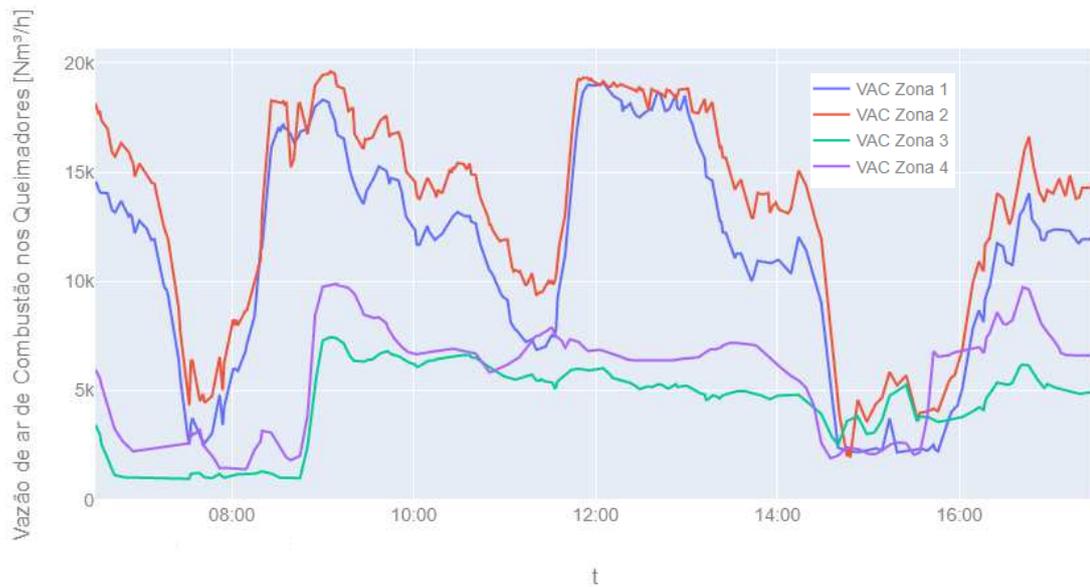
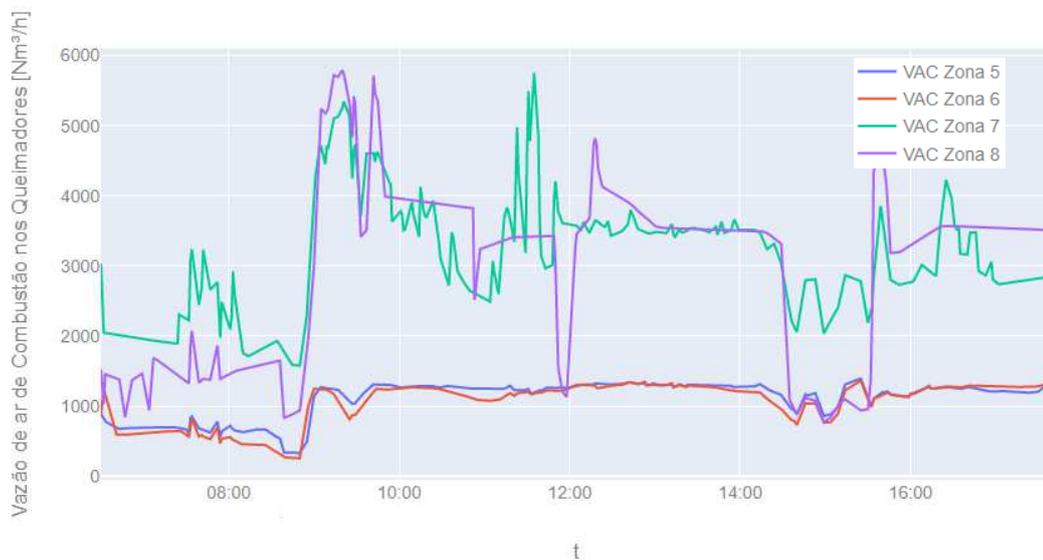


Figura 19 – Perfil de vazão de ar de combustão no forno para as 4 zonas finais

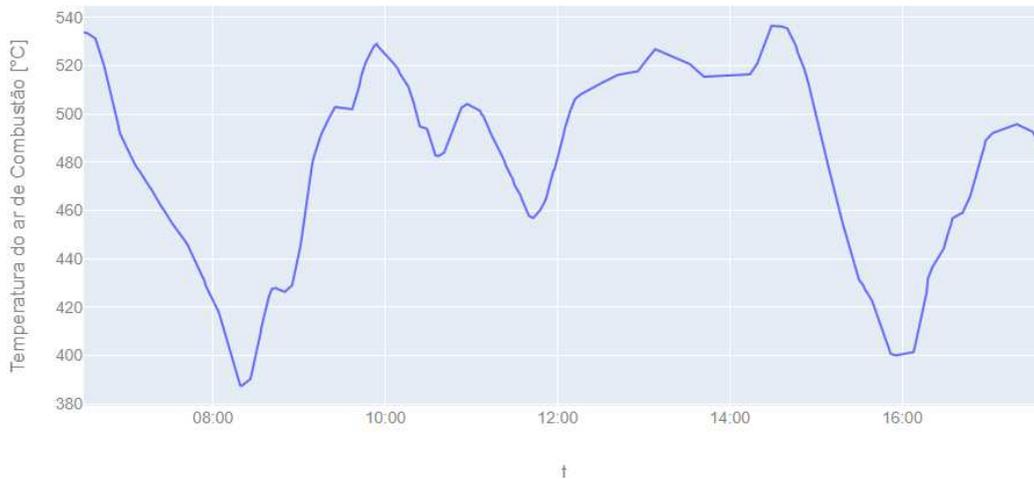


A vazão de ar de combustão apresentada nas Figuras 18 e 19 mostra que nas quatro zonas iniciais existe a necessidade de uma quantidade maior de ar para poder aquecer as peças que entram a temperatura ambiente, e também pelo fato de que o início do forno é onde ocorre o pre-aquecimento das peças, onde se inicia a combustão do forno, sendo assim, o calor se dissipa de forma convectiva para as demais zonas, fazendo com que a necessidade de ar de combustão nas quatro zonas finais seja menor se comparado com as iniciais.

O ar de combustão em conjunto com o Gás natural e o Gás mistos, são responsáveis por promover a combustão necessária para realizar a transferência de calor para as peças dentro do forno, dessa forma, para que a combustão ocorra de forma satisfatória, é necessário que o

percentual adequado de cada um desses componentes seja inserido no forno, de modo a alcançar a temperatura desejada para cada zona. E a partir das Figuras 18 e 19, assim como as anteriores, observa-se momentos em que as vazões aumentam ou diminui de acordo com a necessidade do momento. A Figura 20 apresenta o gráfico do perfil de temperatura do ar de combustão no forno.

Figura 20 – Perfil de temperatura do ar de combustão no forno



Observando a Figura 20, pode-se concluir que o perfil de temperatura do ar de combustão no forno varia ao longo do tempo, não possui um padrão, visto que o ar de combustão é o que é obtido no forno durante o processo e que retorna para que seja alimentado nos queimadores para promover a combustão em conjunto com os gases combustíveis do forno. A vantagem de se aproveitar o ar de combustão proveniente do processo é que economiza em utilidades que seriam usadas para aquecer o ar que seria inserido nos queimadores.

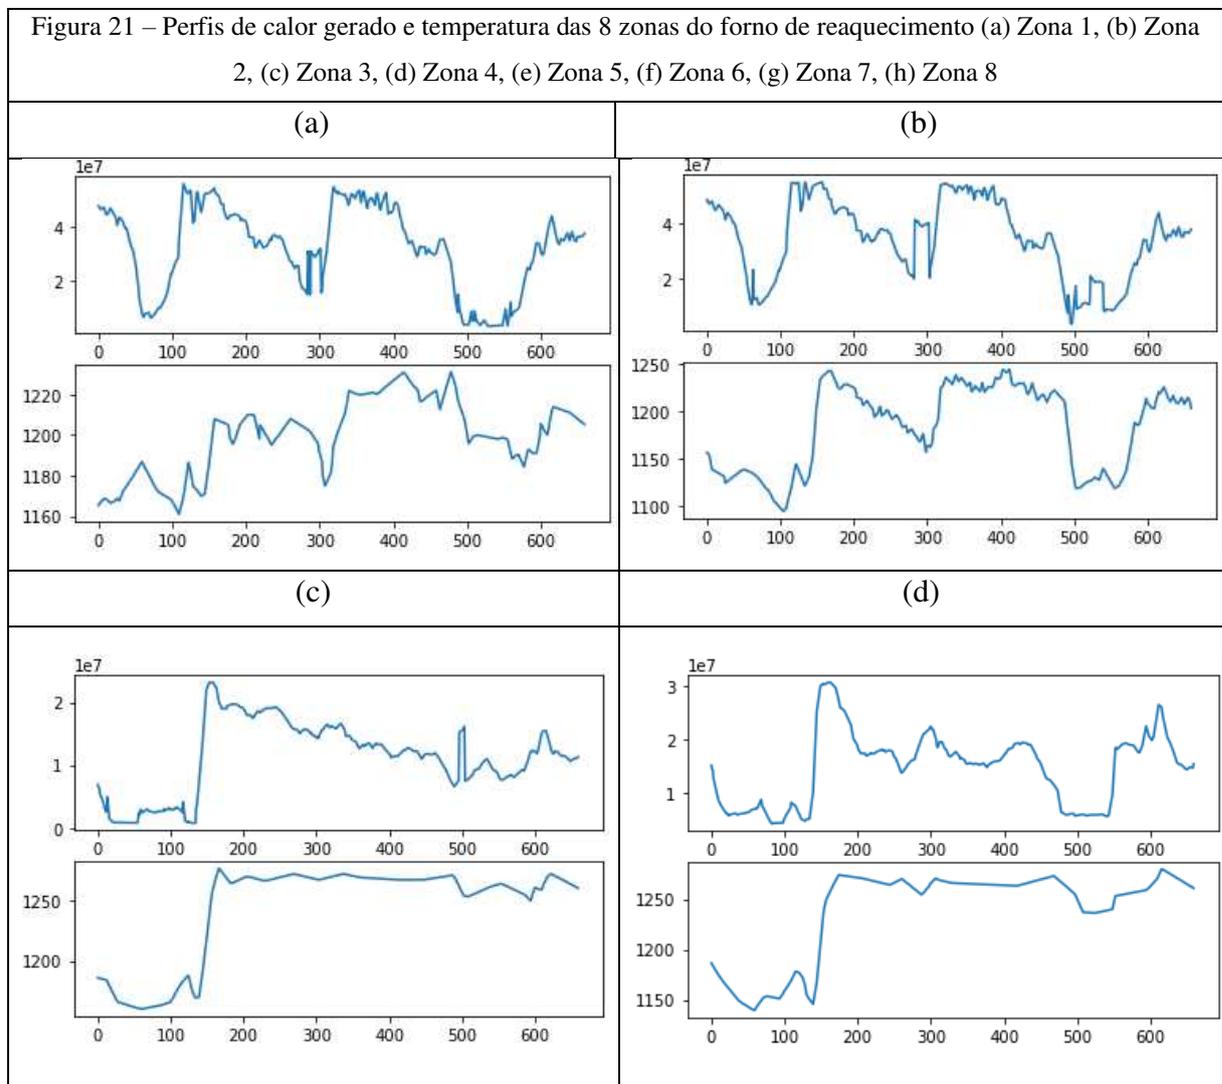
Os dados obtidos na leitura do arquivo “.csv” foram inseridos em uma função de combustão desenvolvida para estudo desse forno específico. Dessa forma, os valores da TAC, VAC, VGM e VGN são usadas na função de combustão para calcular a energia gerada nos queimadores das 8 zonas e a composição dos gases de combustão oriundos da queima dentro do forno, e posteriormente a partir de todos esses resultados, poder calcular o calor obtido no processo de combustão em cada zona.

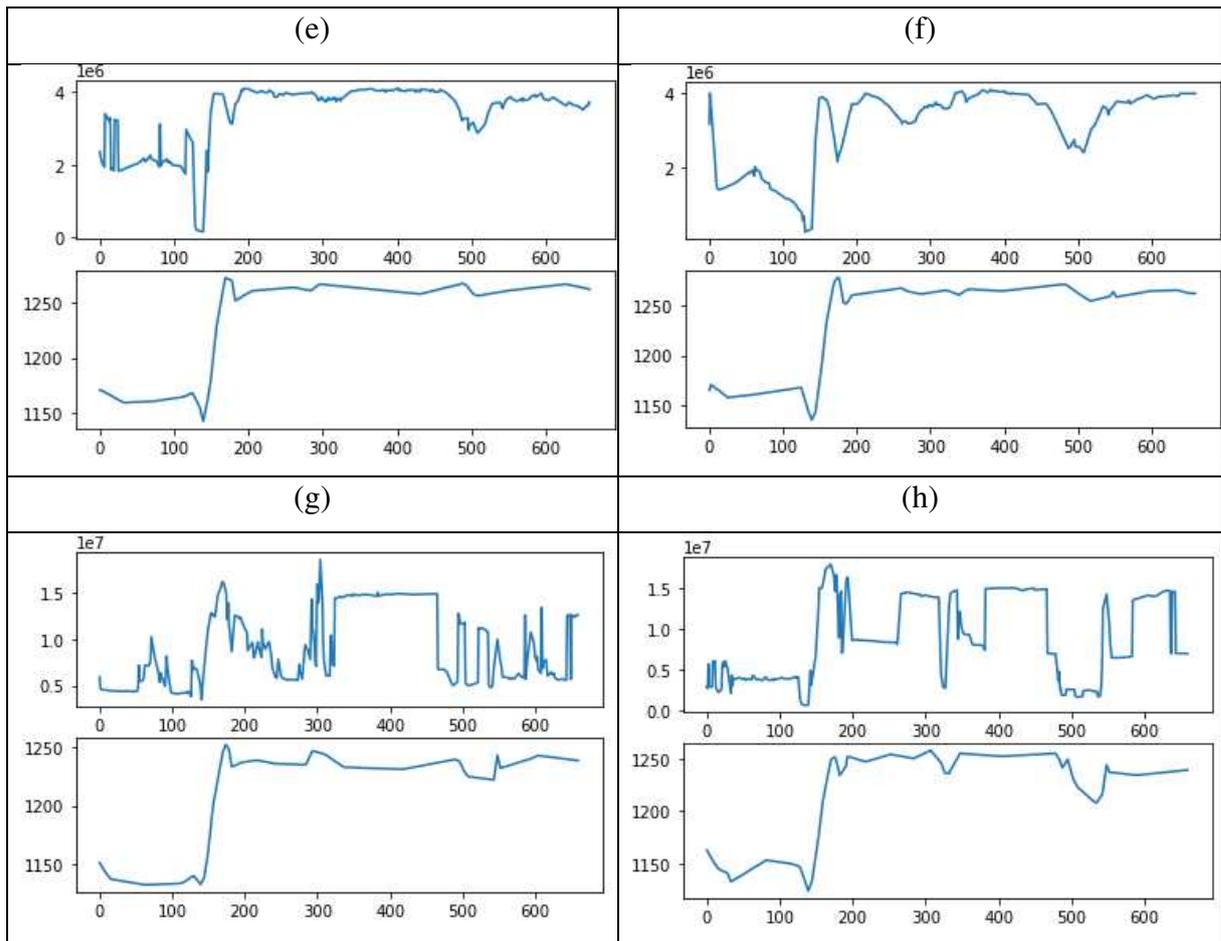
Essa função utiliza como argumento de entrada a composição do Gás misto, do Gás natural, do Ar atmosférico e de Oxigênio, assim como informações como a temperatura desses gases, eficiência da combustão, umidade relativa do ar, pressão do ar para que dê início aos cálculos de modo a verificar se a combustão é completa ou incompleta, se há alimentação de oxigênio puro, calcula a quantidade mínima de ar e oxigênio necessária para se obter a combustão completa, verifica se a alimentação de combustível é diferente de zero para que

possam ser feitos os cálculos, e a partir disso calcular qual a energia que é liberada pelos 8 queimadores em suas respectivas zonas.

Essa resposta da função de combustão (calor gerado) será utilizada como entrada da RNA para determinar a temperatura que é obtida nas zonas e desse modo, estabelecer uma comparação entre o perfil de temperatura obtido pela RNA a partir do calor calculado, e comparar com a temperatura real de cada zona que foi obtida na leitura dos dados do forno.

Os dados de entrada da RNA dessa forma é o calor gerado pela zona correspondente e a saída é a temperatura da zona. Desse modo, antes de criar a RNA, os dados precisam ser tratados, de modo a eliminar os pontos nulos. Os dados de entrada e saída foram então usados para criação de gráficos que permitam a visualização dos perfis e distribuição de cada um. A Figura 21 apresenta os gráficos da variável de entrada e saída da RNA antes de serem normalizados, para as 8 zonas existentes no forno em estudo.

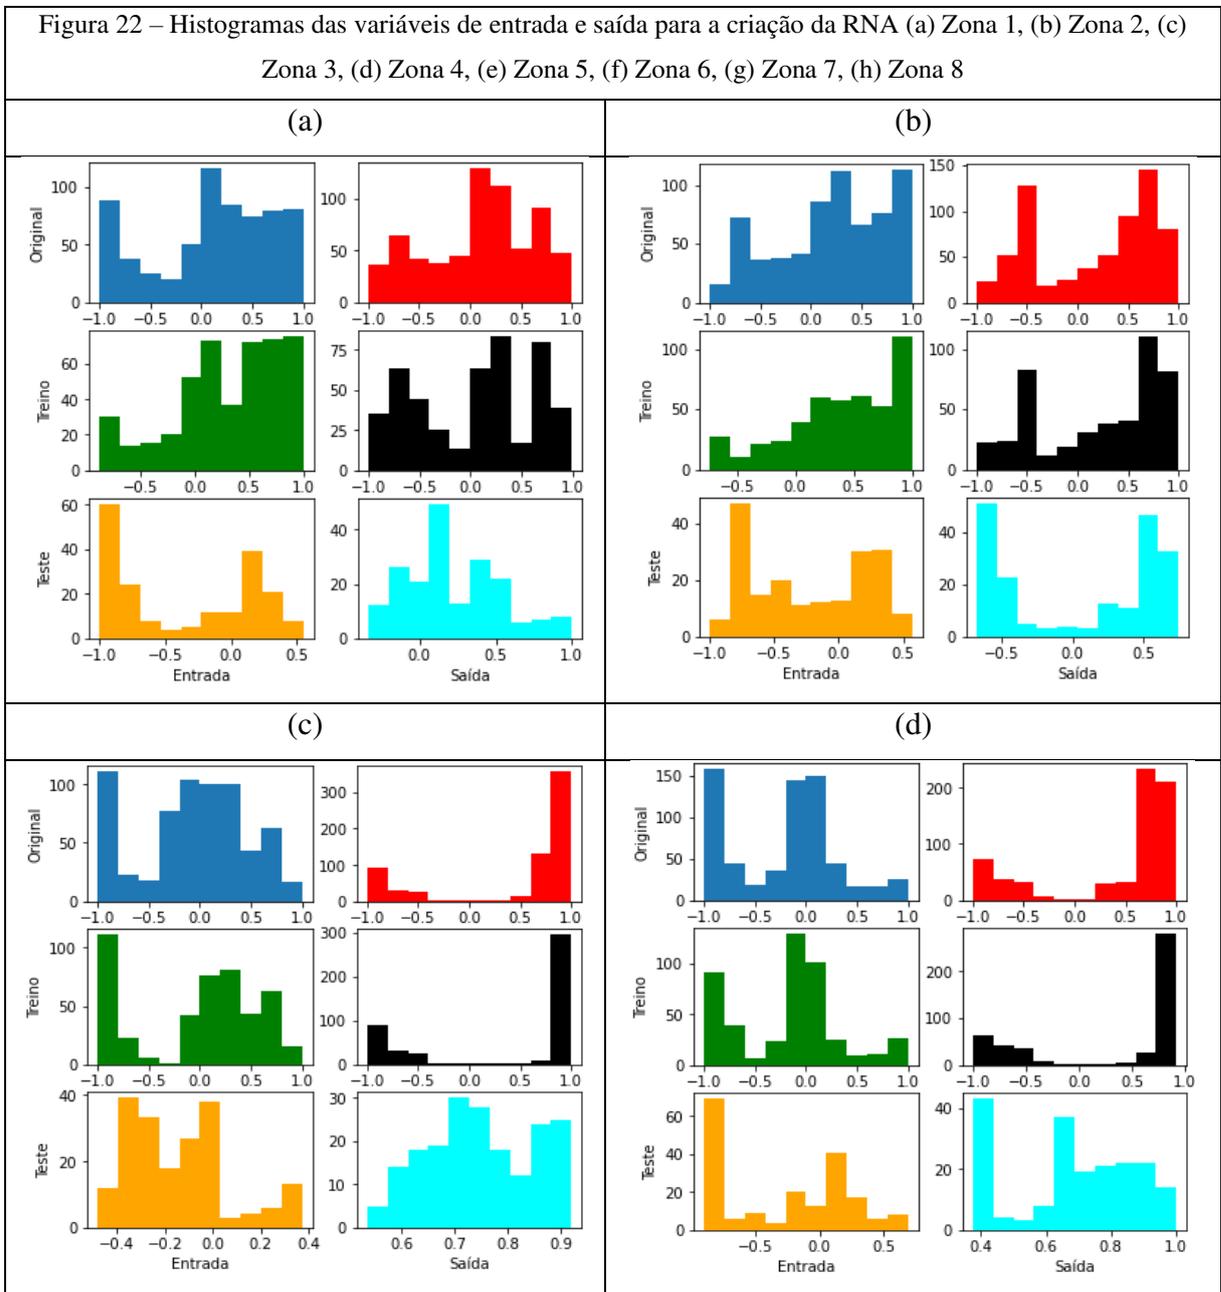


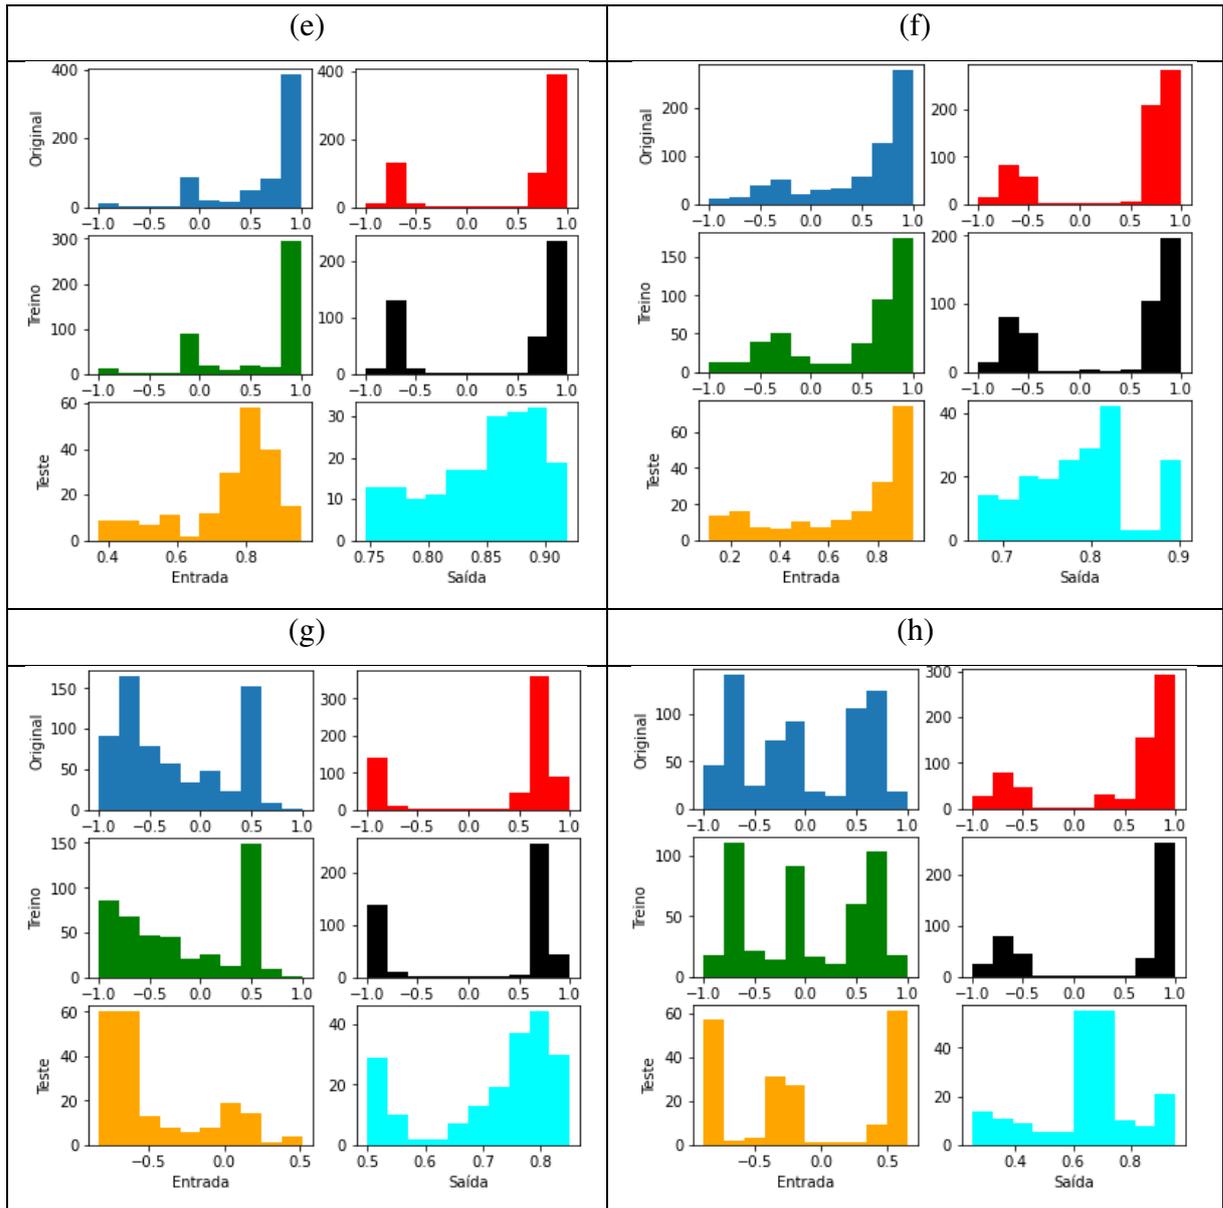


Avaliando os gráficos acima, pode-se observar que as escalas entre as variáveis de entrada e saída do modelo de previsão que será construído, são diferentes entre si, pois a entrada é o calor gerado na combustão de cada zona, que está na faixa de 0 a 5×10^7 , e a saída é a temperatura, que está na faixa de 1000-1300 °C, visto isso, é necessário que os dados sejam passados por uma função de normalização para que estejam entre valores de -1 a 1 e não causassem erros nas previsões da rede. Para isso, foi utilizada a função *MinMaxScaler* da biblioteca *Sklearn*.

Após a normalização, os dados foram convertidos em séries temporais para que então pudessem ser usados para realizar o aprendizado supervisionado a partir da criação da RNA. Em seguida, os dados foram divididos em dados de treinamento e de teste, onde 70% foi separado para dados de treino, e os 30% restante para teste. A configuração escolhida para realizar as previsões foi que 9 valores anteriores ao valor no instante atual (t) foram usados para prever qual seria o valor no instante $t + 1$.

Após isso, foram criados histogramas das variáveis de entrada e saída da RNA antes e depois de serem separados em dados de treino e de teste, para visualizar se ambos possuíam valores que estivessem bem distribuídos para garantir uma previsão satisfatória. Logo a Figura 22 apresenta os histogramas obtidos para as variáveis de entrada e saída, e quando as mesmas foram separadas em dados de treino e teste.





A avaliação dos histogramas acima mostra a distribuição de frequência dos valores das variáveis de entrada e saída da rede, situadas entre o intervalo de -1 a 1. Desse modo, é importante que os valores estejam bem distribuídos dentro desse intervalo, pois dessa forma certifica-se que a rede possui valores que abrangem o problema por completo para que se crie uma rede satisfatória.

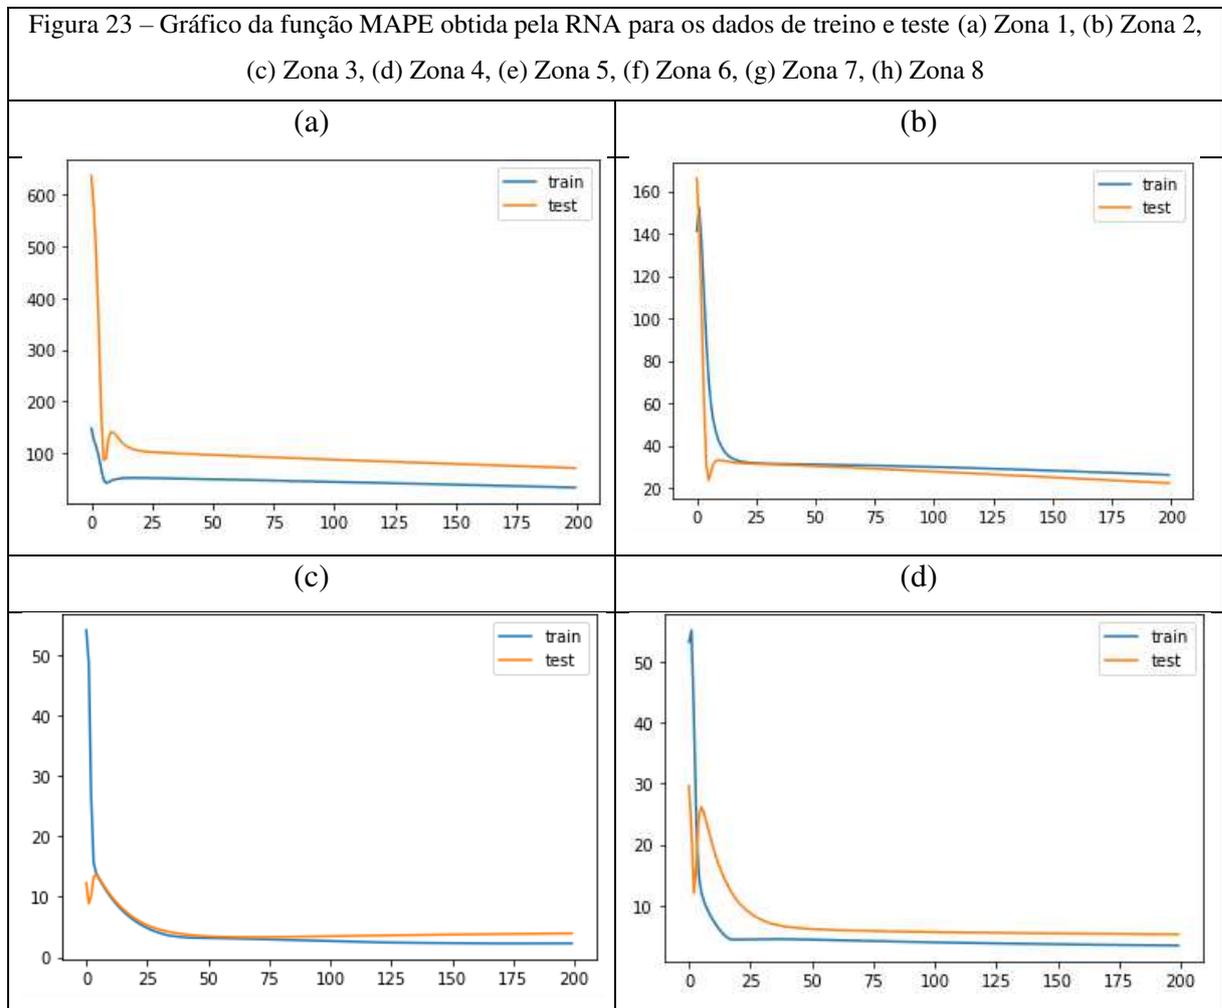
Porém, verifica-se que nem todos os dados de treino e teste estão bem distribuídos entre o intervalo de -1 a 1, visto que a divisão segue a distribuição dos dados originais, que foram coletados do processo, e que sofrem influência de diversas variáveis. Dessa forma, as redes que forem treinadas com dados com uma distribuição maior será mais abrangente e possuirá

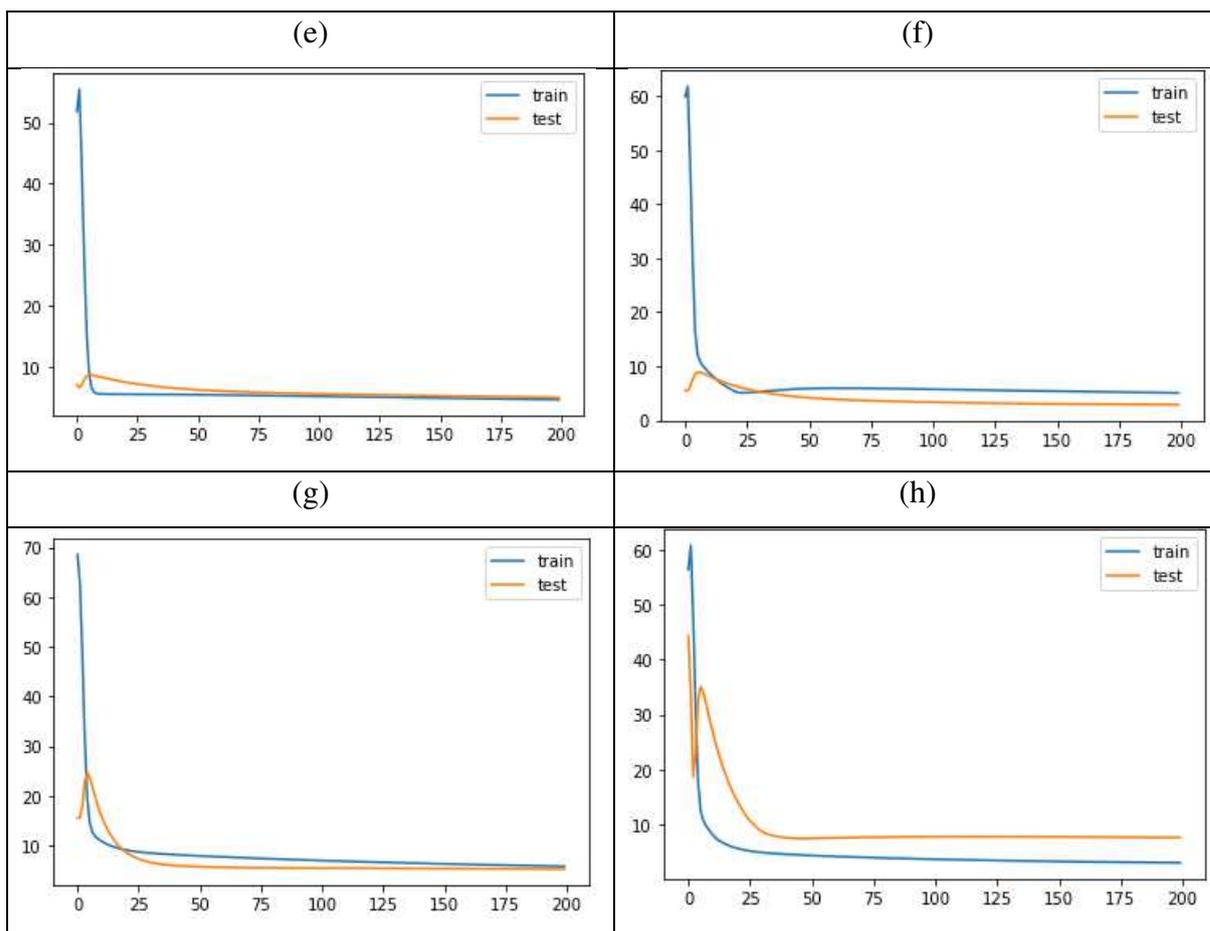
melhores resultados, quando comparadas as redes obtidas a partir de dados com uma distribuição limitada em um pequeno intervalo.

5.2 CRIAÇÃO DA RNA A PARTIR DOS DADOS OBTIDOS

Após as etapas anteriores, iniciou-se a criação da RNA do tipo LSTM. Como descrito na metodologia, a rede criada possui duas camadas ocultas, onde a primeira possui 200 neurônios enquanto a segunda possui 100, seguido pela adição de dois *perceptrons*, o primeiro com a função ELU e o segundo com função linear que retorna o *array* de previsão da rede. Com isso, para que se tenha uma visualização da capacidade de previsão da RNA, é necessário que algumas métricas sejam usadas para mostrar se o valor previsto pela rede se aproxima dos valores reais.

A Figura 23 apresenta os gráficos da função MAPE usada para avaliar a eficiência do modelo nas oito zonas do forno de reaquecimento em estudo, visto que esta abrange de forma mais geral e precisa a avaliação da eficiência do modelo em relação as outras citadas.





Pode-se perceber a partir da avaliação da Figura 23 que o Erro Percentual Absoluto Médio (MAPE) decresce com o passar do número de épocas, apesar de começar com um valor alto. Tendo em vista que esse critério é de interesse para verificar se a rede possui uma eficiência e uma capacidade de generalização, pode-se concluir que tais objetivos foram alcançados com a RNA obtida. . A Tabela 2 apresenta os valores obtidos do MAPE ao final das épocas para as oito zonas.

Tabela 2. Valores da estatística MAPE obtido no treinamento

Zona 1	Zona 2	Zona 3	Zona 4	Zona 5	Zona 6	Zona 7	Zona 8
3,04 %	2,61%	2,27%	3,42%	4,31%	5,07%	5,8%	3,04%

Fonte: Autores (2022)

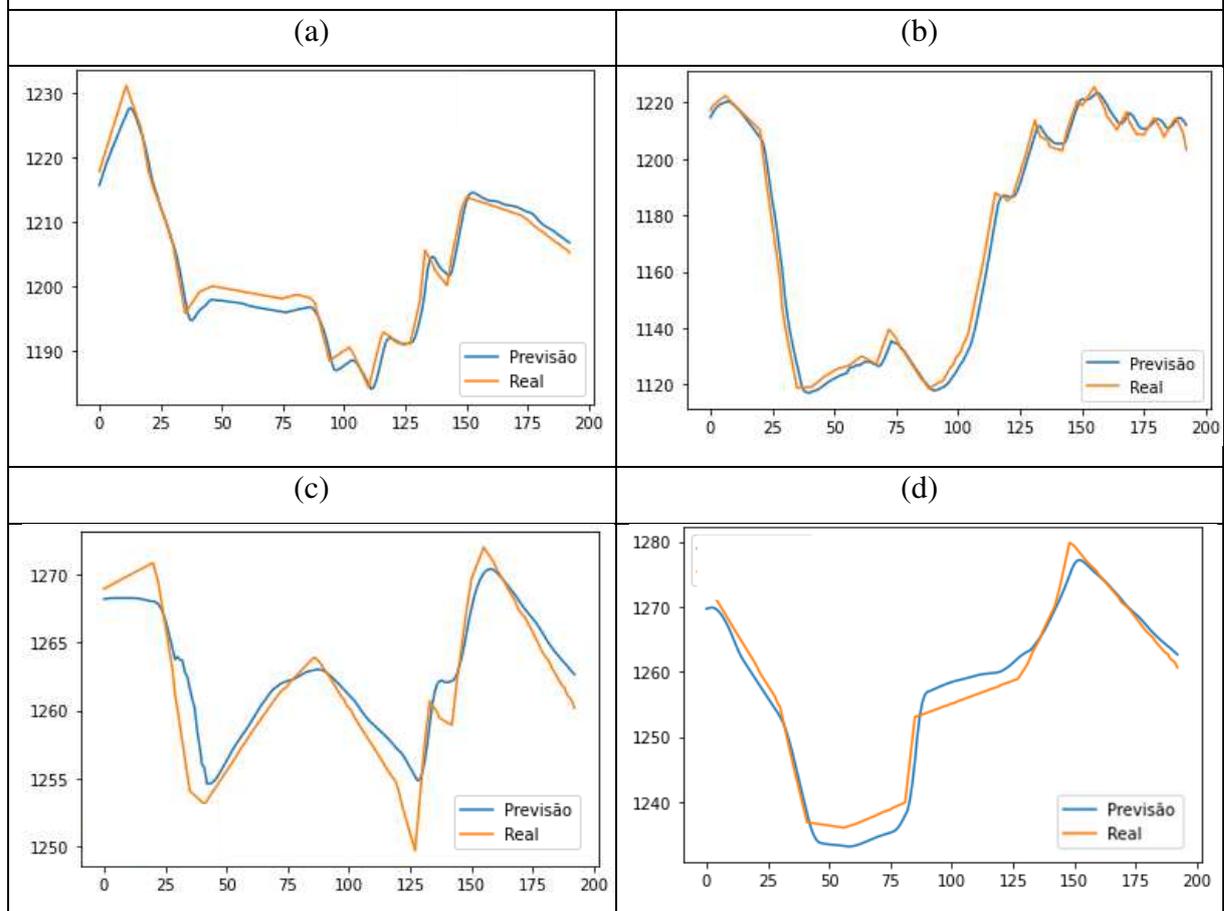
Os resultados obtidos na Tabela 2 apresentam os valores finais da função MAPE ao final das épocas, terminado o treinamento das RNA desenvolvidas nas oito zonas. Observa-se que o maior valor do erro percentual se encontra na zona 7, porém todas as curvas apresentaram o comportamento esperado para se considerar que as redes tiveram um bom aprendizado, as

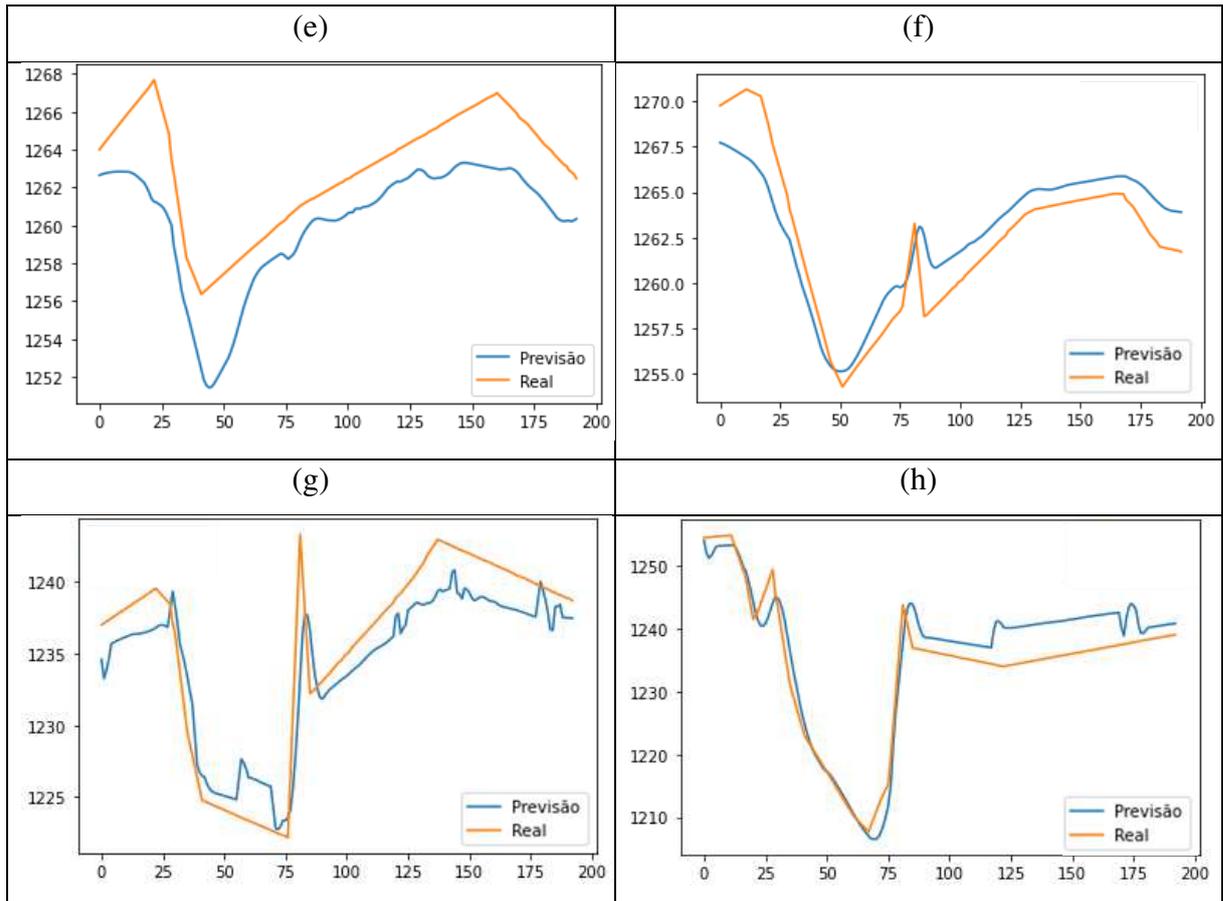
curvas do erro diminuem com o passar do treinamento e se encontram em sua maioria. Outra forma de avaliar a eficiência da RNA é quando comparado o resultado obtido pela rede com os dados de teste.

5.3 PREVISÃO DOS DADOS COM USO DA RNA CRIADA

A partir da RNA obtida para as oito zonas do forno de reaquecimento, esta então é usada para prever os valores de saída, quando submetida a dados de entrada não vistos anteriormente. Dessa forma, os dados de teste são usados na RNA, obtém-se a saída prevista pela rede, e em seguida faz-se a comparação entre o valor previsto e o valor verdadeiro, de modo a verificar se a rede é satisfatória. A Figura 24 apresenta os gráficos de comparação entre os valores previstos pela RNA e os valores reais do problema.

Figura 24 – Gráfico de comparação entre os valores de previsão da RNA e os dados reais do forno (a) Zona 1, (b) Zona 2, (c) Zona 3, (d) Zona 4, (e) Zona 5, (f) Zona 6, (g) Zona 7, (h) Zona 8



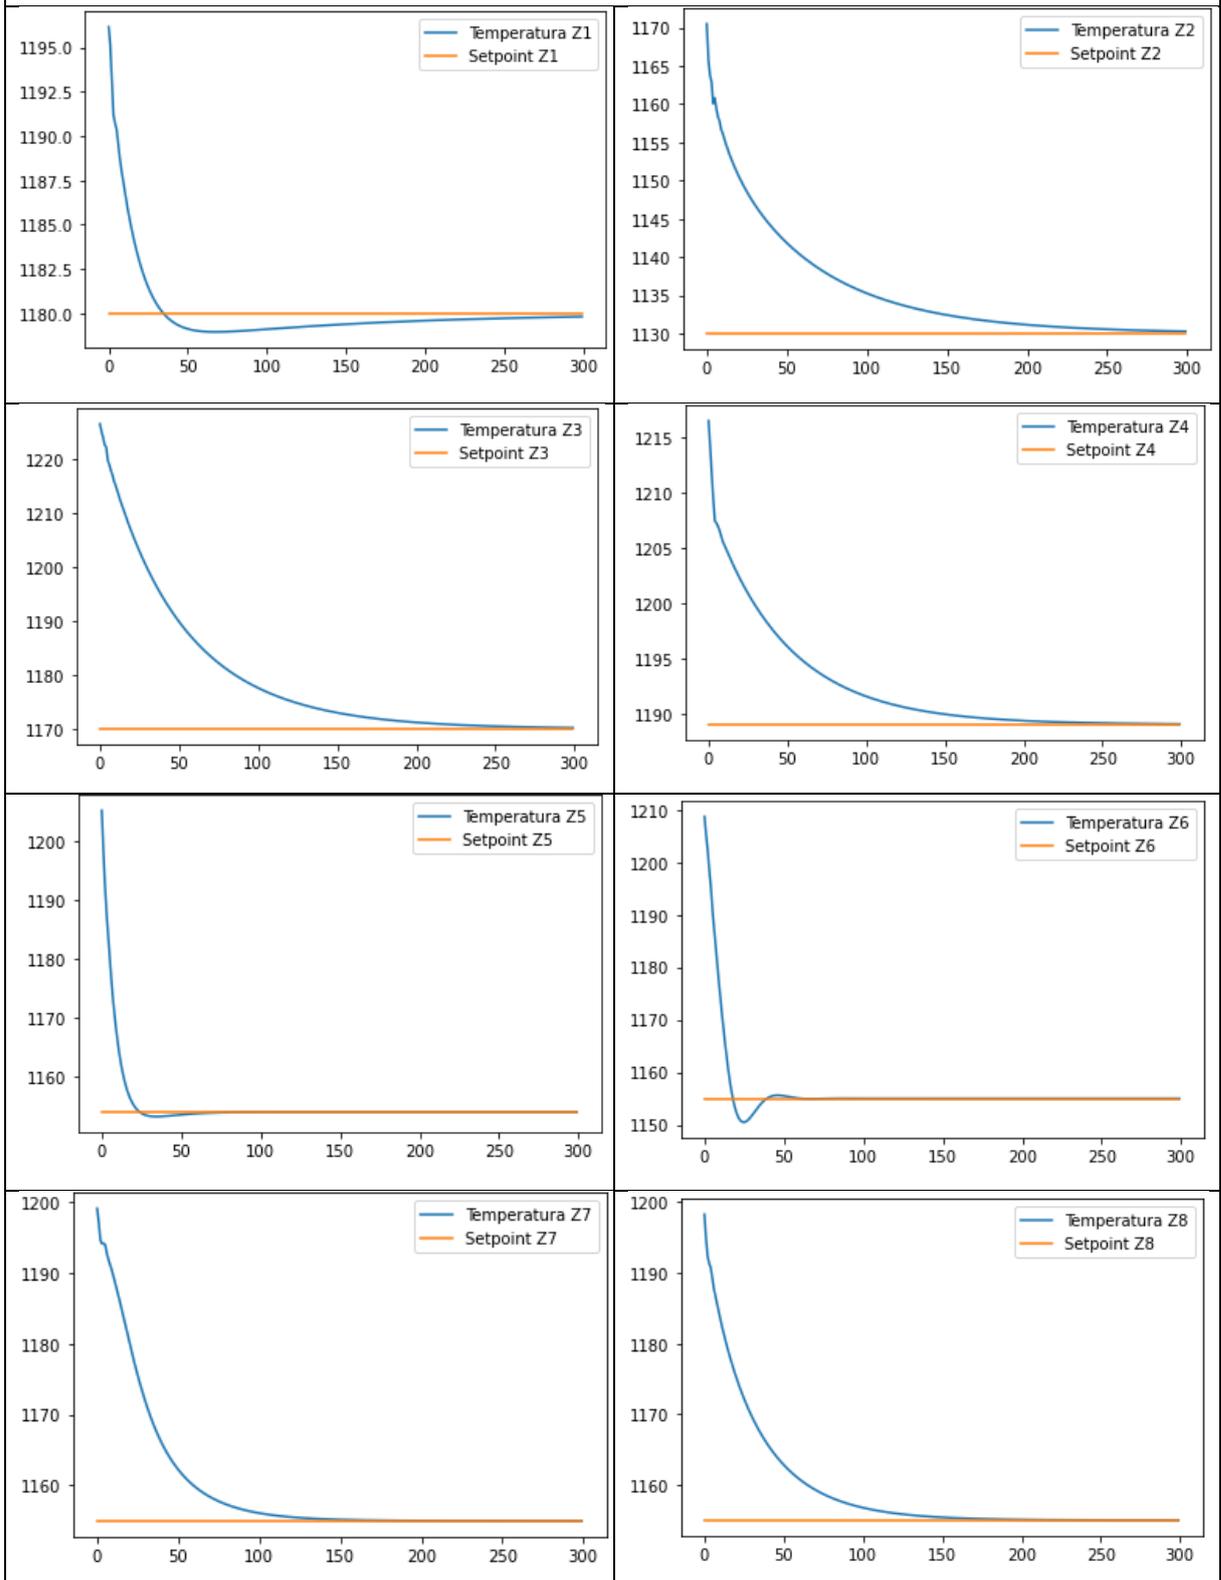


Avaliando a Figura 24, pode-se observar que os valores previstos pela RNA e os valores reais foram próximos, a rede consegue prever a tendência dos dados, apesar de não serem exatos, e a diferença presente entre os dados não é muito significativa, levando em consideração que são os dados de temperatura da zona, a qual pode variar em uma faixa de 1000 a 1300 °C e que nessa faixa é possível obter as peças com as características desejadas. Desse modo, pode-se considerar que a RNA desenvolvida é satisfatória e será usada no desenvolvimento do controlador do tipo PI, que tem função de manter a temperatura de cada zona dentro do valor de *setpoint*.

5.4 UTILIZAÇÃO DA RNA OBTIDA PARA CRIAÇÃO DE CONTROLADOR DO TIPO PI

Dessa forma, a partir da Tabela 1, apresentada na metodologia, tem-se que o objetivo do controlador do tipo PI em cada zona do forno é controlar a temperatura da mesma dentro do valor estabelecido, a partir da RNA obtida. A Figura 25 apresenta os gráficos obtidos para controle de cada zona respectivamente.

Figura 25 – Gráficos do controle do tipo PI nas 8 zonas para manter o valor de *setpoint*



A partir da observação da Figura 25, pode-se concluir que todas as zonas puderam alcançar o seu valor de *setpoint* mesmo quando a zona passou por perturbações, e entrada de dados desconhecidos. Dessa forma, a RNA foi satisfatória.

Visto que os valores de *setpoint* para as zonas 1 e 3 estão fora da faixa de valores disponíveis para essas zonas, onde o mínimo é 1161 °C e 1160 °C, respectivamente, foi escolhido então o valor médio dos dados de ambas as zonas, de forma a estudar se a RNA que foi obtida tinha capacidade de auxiliar o controle de temperatura. Os gráficos anteriores mostram que, após sintonizados, os controladores são capazes de retornar a temperatura das zonas de volta ao valor estabelecido, antes de $t = 300$ que foi o escolhido para o controlador.

5.5 Influência da taxa de amostragem na obtenção da RNA

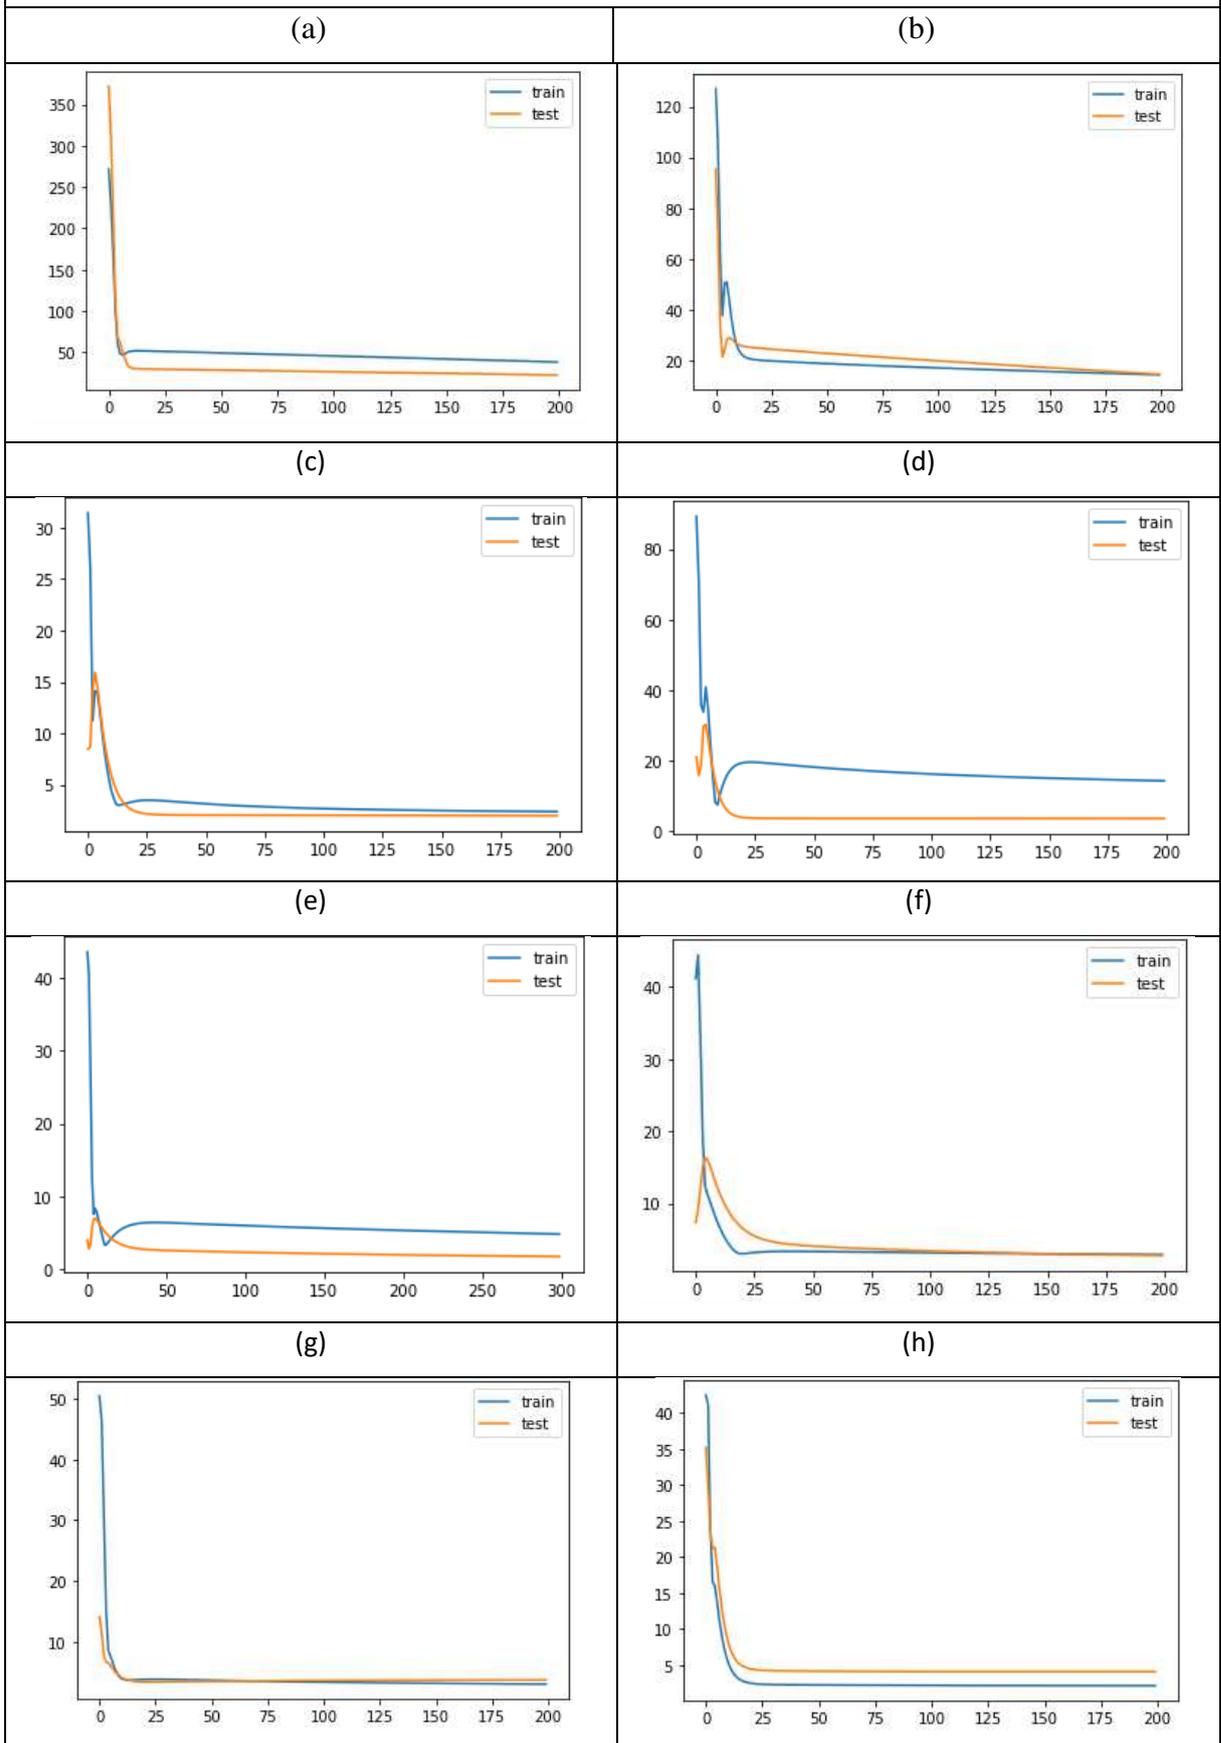
Os resultados anteriores foram obtidos utilizando uma taxa de amostragem de 1 minuto, ou seja, a cada 1 minuto, é coletado um dado de temperatura, VGN, VGM, VAC correspondente para cada zona e de TAC. Nesse caso, foram utilizados 661 dados para desenvolver a RNA que posteriormente foi utilizada na criação do controlador PI.

Nessa sessão, será mostrada a influência de uma diferente taxa de amostragem na obtenção da RNA. A taxa de amostragem utilizada foi então de 30 segundos, o que resultou na coleta de 1321 pontos de dados, onde, após a eliminação dos pontos faltantes que existiam no DataFrame, foram aproveitados 1073 valores.

Os gráficos do perfil de todas as variáveis coletadas, que foram citadas anteriormente, para criação da RNA possuem a distribuição semelhante as Figuras 11 a 19, por isso não serão inseridas nessa sessão. Os gráficos do perfil de calor gerado, calculado a partir da função e combustão, e da temperatura de cada zona, que serão entrada e saída da RNA respectivamente, não apresentam diferenças significativas em relação a Figura 21. Os histogramas dos dados treinamento e teste da RNA para a taxa de amostragem de 30 segundos não apresentaram diferença em relação aos apresentados na Figura 22. Portanto, o foco dessa sessão será a apresentação dos gráficos obtidos na RNA desenvolvida quando utilizada nos dados de teste e do controlador PI utilizado nas zonas.

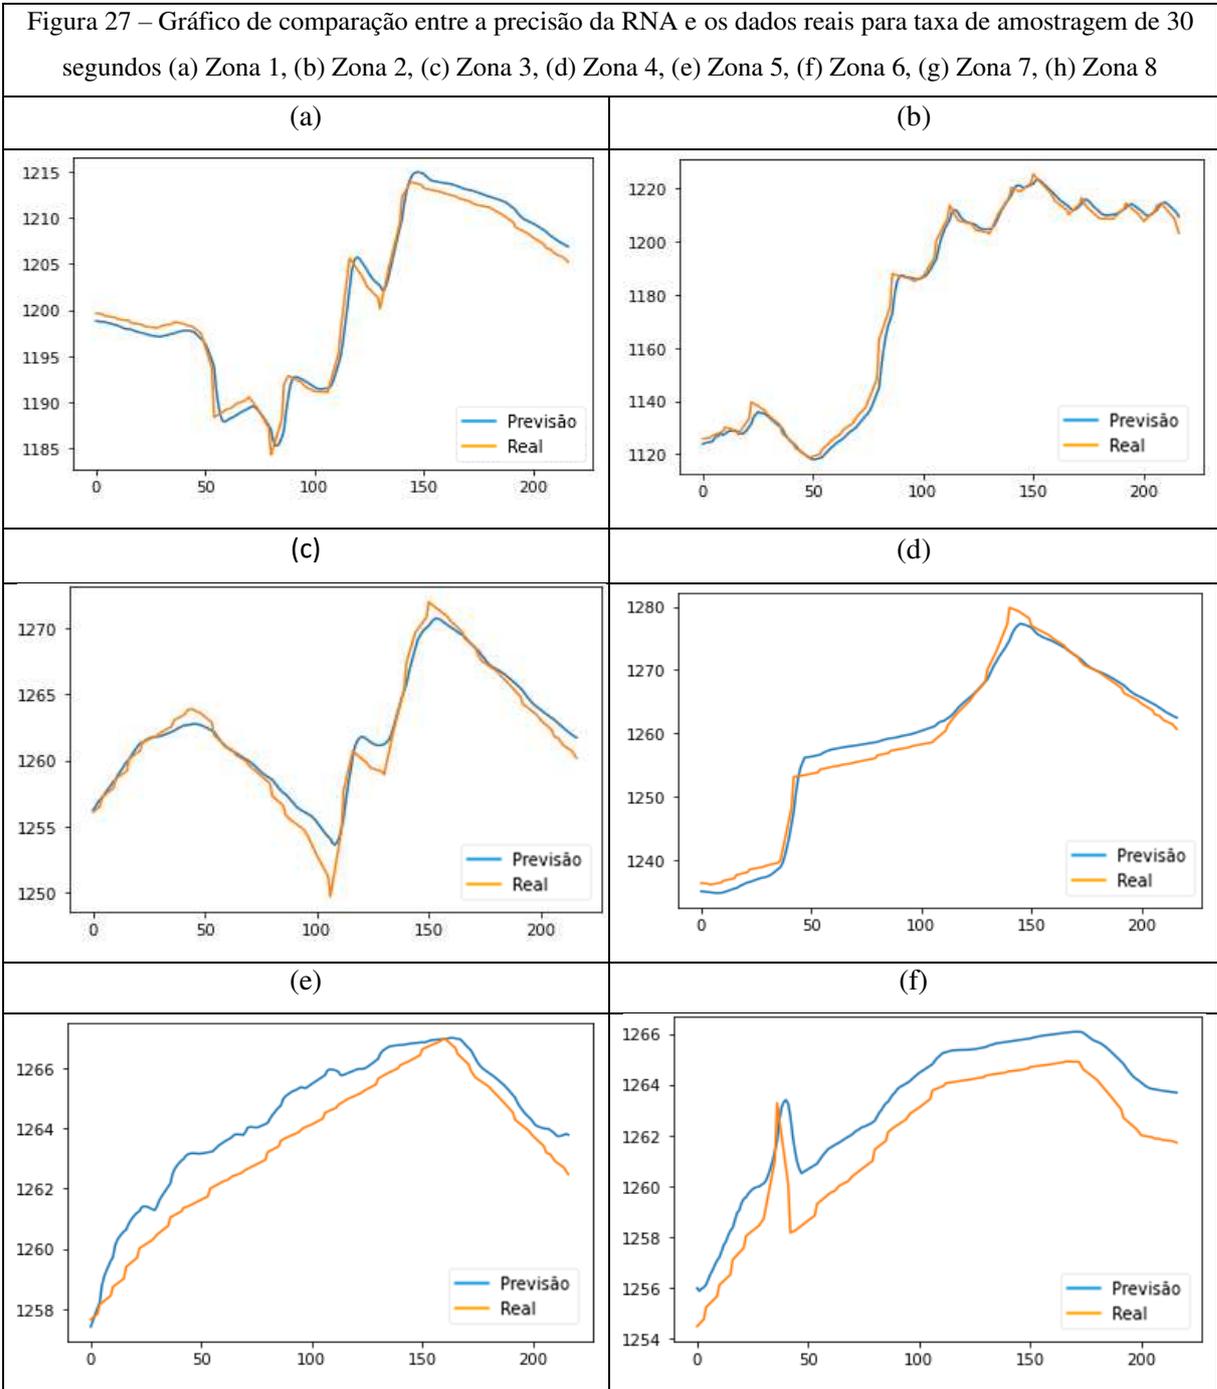
A Figura 26 apresenta os gráficos da função MAPE usada para avaliar a eficiência do modelo nas oito zonas do forno de reaquecimento em estudo.

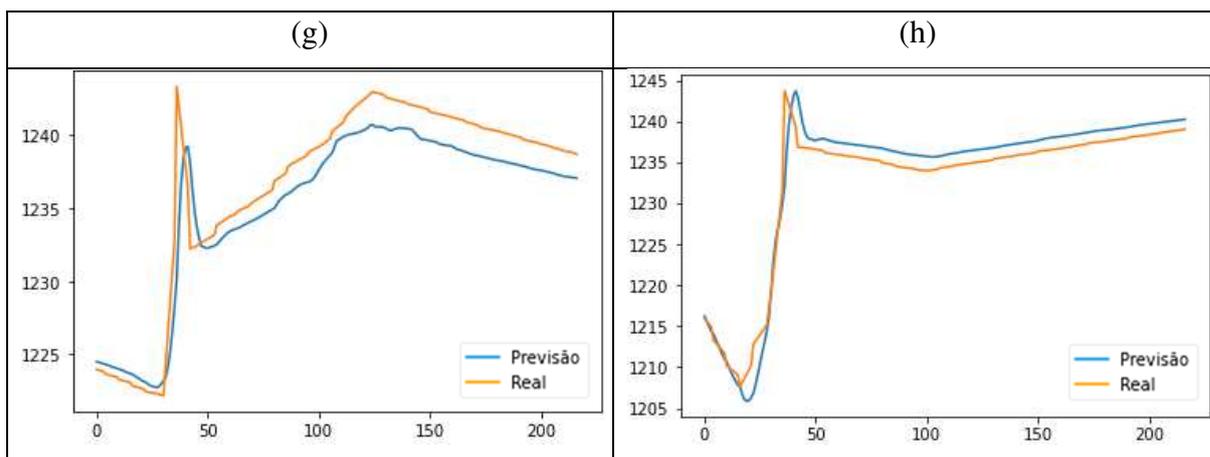
Figura 26 – Gráfico da função de custo MAPE para taxa de amostragem de 30 segundos (a) Zona 1, (b) Zona 2, (c) Zona 3, (d) Zona 4, (e) Zona 5, (f) Zona 6, (g) Zona 7, (h) Zona 8



Pode-se perceber a partir da avaliação da Figura 26 que o Erro Percentual Absoluto Médio (MAPE) decresce com o passar do número de épocas. Tendo em vista que esse critério é de interesse para verificar se a rede possui uma eficiência e uma capacidade de generalização, pode-se concluir que tais objetivos foram alcançados com a RNA obtida.

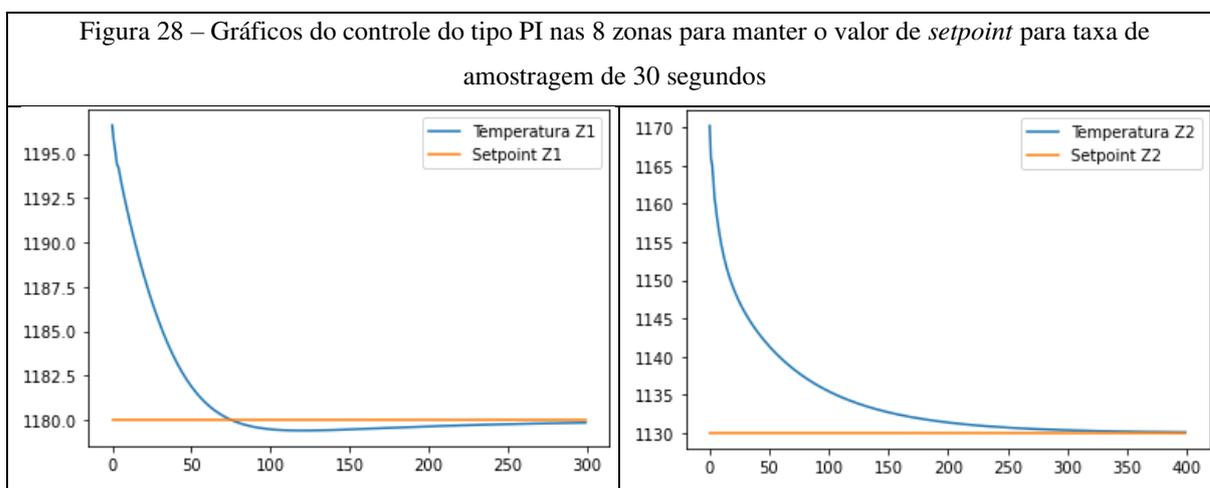
A Figura 27 apresenta os gráficos de comparação entre os valores previstos pela RNA, a partir do uso dos dados de teste, e os valores reais da temperatura de cada zona.

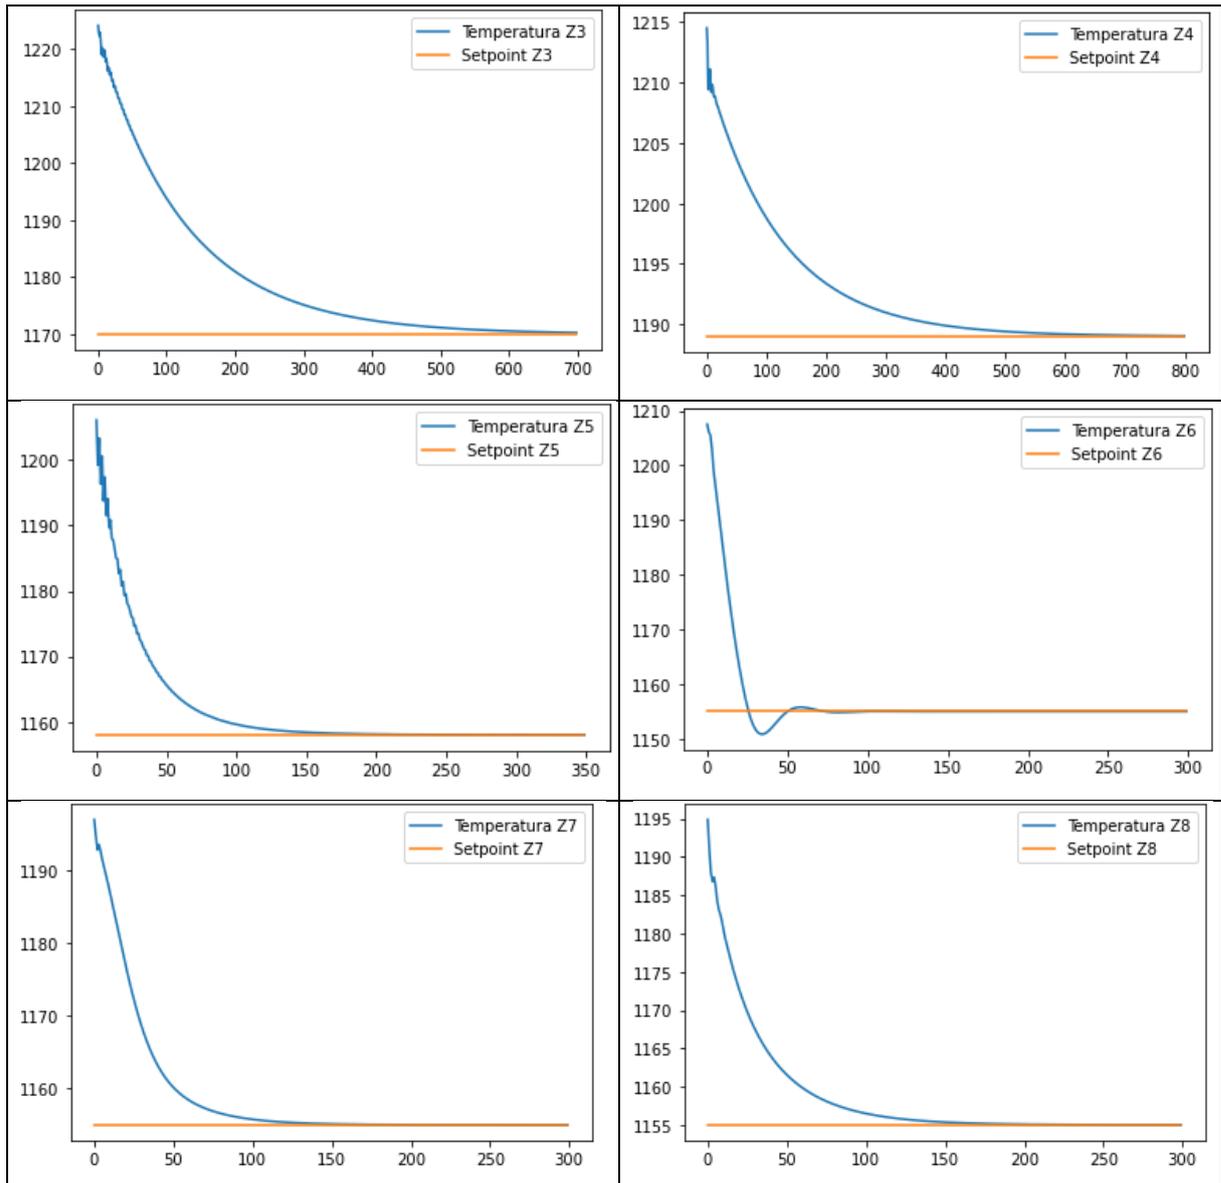




Analisando a Figura 27 pode-se observar que a RNA desenvolvida com os dados obtidos da taxa de amostragem de 30 segundos conseguiu aprender e generalizar o conhecimento a partir dos padrões existente nos dados, e dessa forma, consegue prever a tendencia dos dados, apesar de não serem exatos, mas essa diferença não se torna significativa, levando em consideração que são os dados de temperatura da zona, a qual pode variar em uma faixa de 1000 a 1300 °C.

Comparando a Figura 27 com a Figura 24, onde tem-se os resultados para a RNA com a taxa de amostragem de 1 minuto, pode-se observar que os resultados obtidos para as zonas 5 a 8 foram mais representativos, obtendo uma previsão da tendencia assim como uma aproximação maior em relação aos valores reais das temperaturas dessas zonas. Portanto, a RNA para a taxa de amostragem de 30 segundo conseguiu melhores resultados em seu aprendizado. A Figura 28 apresenta os gráficos obtidos para controle do tipo PI de cada zona respectivamente.





A partir da RNA desenvolvida para a taxa de amostragem de 30 segundos, pode-se utilizá-la para criação do controlador do tipo PI, com o objetivo de manter a temperatura das oito zonas distintas do forno dentro do valor de *setpoint* estabelecido pela Tabela 1. Da mesma forma que justificado na sessão 5.4, as temperaturas de *setpoint* das zonas 1 e 3 precisaram ser modificadas pelo fato de não estarem presentes nos limites de operação dessas zonas nos dados disponíveis para o presente trabalho.

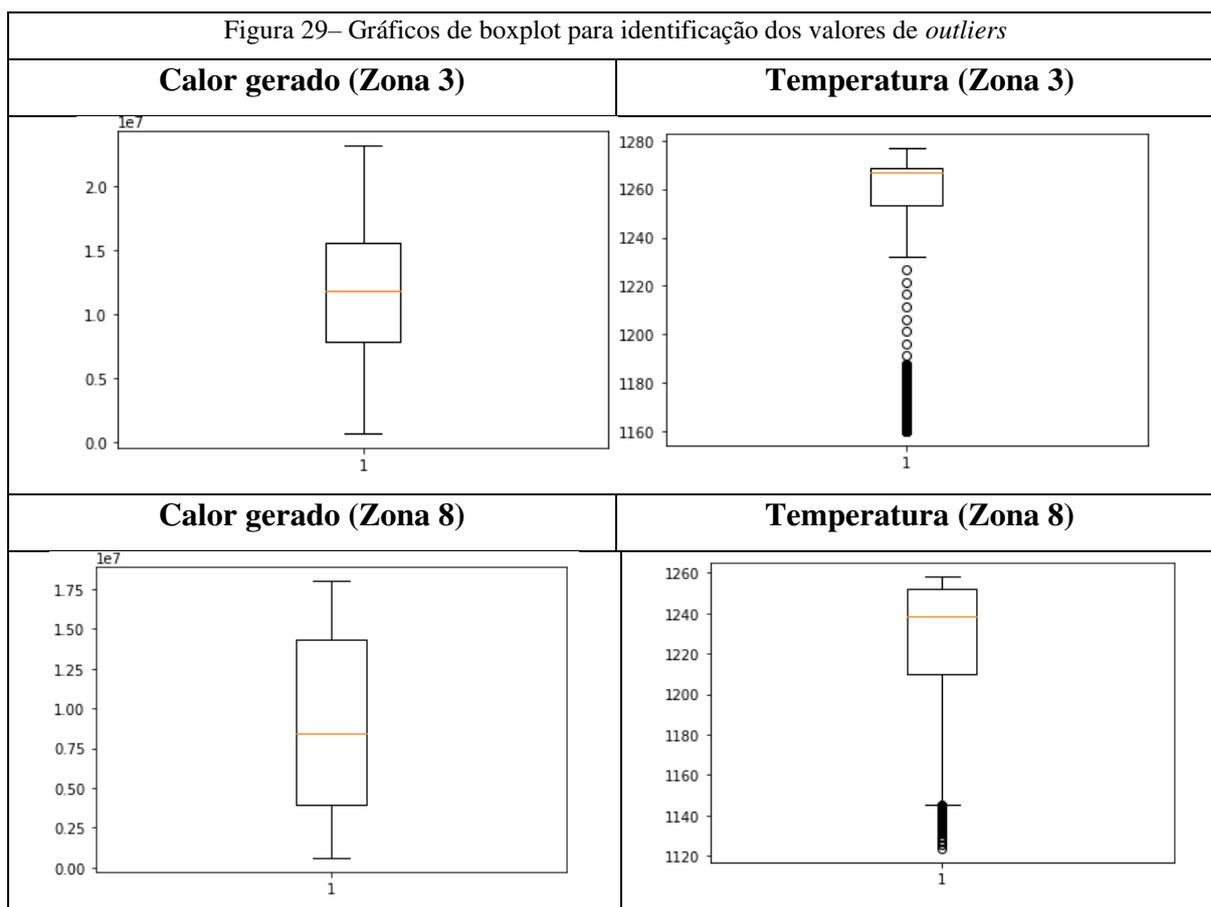
Avaliando a Figura 28, conclui-se que o sistema de controle desenvolvido utilizando a RNA foi satisfatório, pois retornou a temperatura de cada zona para seu valor de *setpoint*, mesmo na presença de perturbações e inserção de dados desconhecidos pela rede, mostrando que a mesma foi capaz de generalizar o conhecimento obtido.

5.6 INFLUÊNCIA DO TRATAMENTO DE *OUTLIERS* NA OBTENÇÃO DA RNA

Os *outliers* são pontos discrepantes, que fogem do padrão da maioria dos dados presentes em um *dataset*. Dessa forma, esses pontos podem causar um erro na obtenção da RNA, fazendo com que a mesma não tenha uma alta acurácia, e não consiga ter uma boa representação dos padrões existentes nos dados. Porém esses dados também podem ser o que se deseja descobrir dentro do processo.

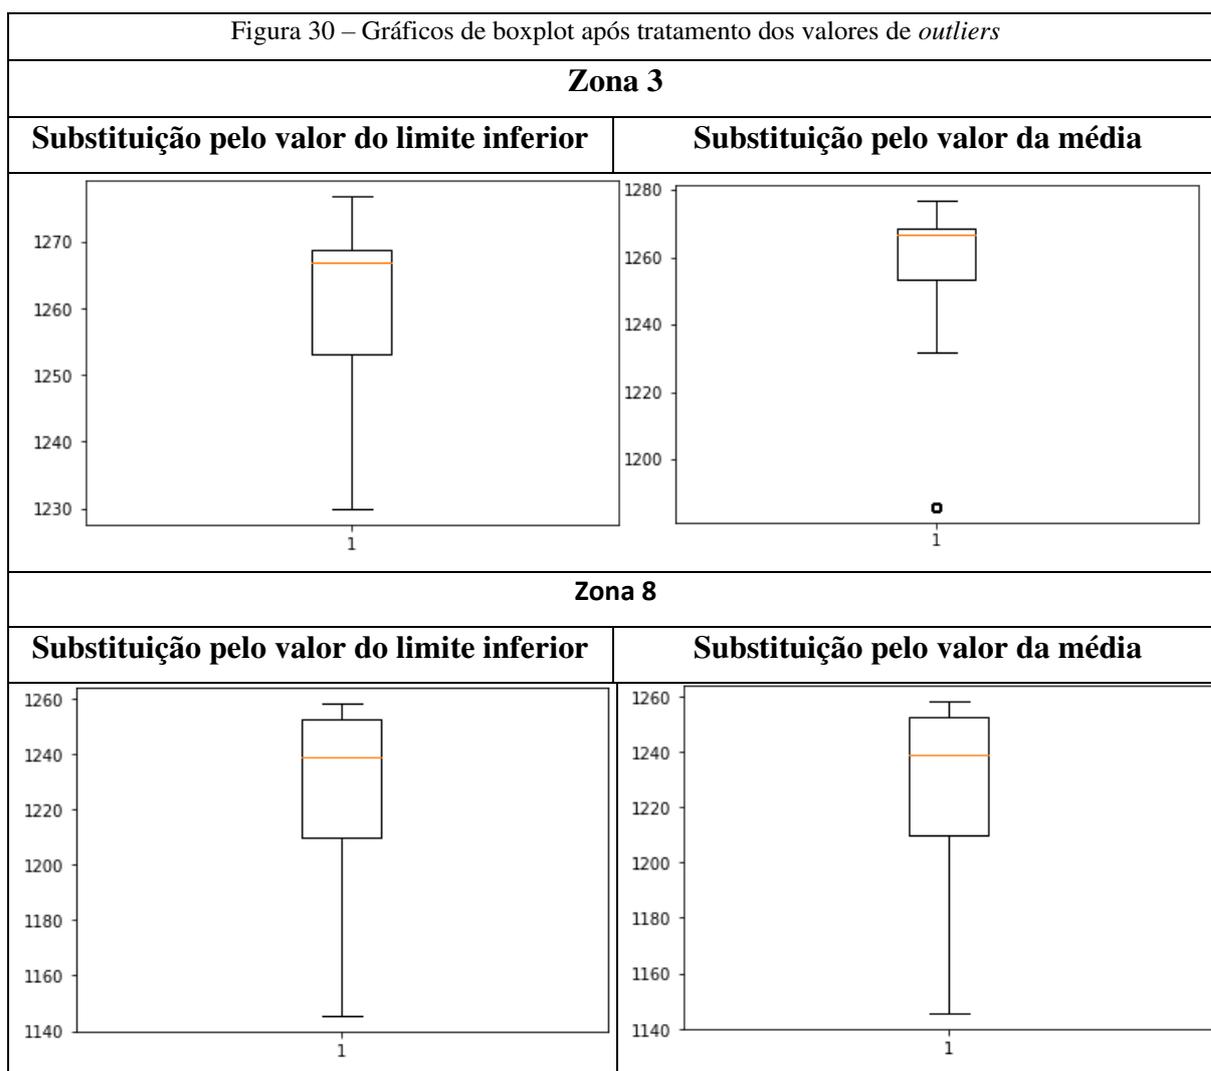
Os dados de entrada e saída da RNA desenvolvida no presente trabalho são o calor gerado em cada zona durante o processo de combustão e a temperatura de cada zona, respectivamente. Os gráficos de *boxplot* é responsável por identificar a existência desses valores de *outliers*. Com isso, para a taxa de amostragem de 1 minuto, foi criado esses gráficos, onde apenas as zonas de 3 a 8 possuem valores discrepantes. Por apresentarem as mesmas conclusões em relação a RNA obtida após o tratamento dos valores de *outlier*, apenas os resultados obtidos nas zonas 3 e 8 serão apresentados.

A Figura 29 apresenta os gráficos de *boxplot* para identificação de *outliers* para as zonas 3 e 8.



Pela Figura 29 observa-se que as temperaturas das zonas 3 e 8 possuem valores considerados *outliers*, dessa forma, dois tratamentos para esses valores foram utilizados afim de verificar se esses pontos tinham influência na obtenção de uma RNA com maior acurácia. O primeiro tratamento consistiu em substituir os pontos discrepantes, que se encontram abaixo do limite inferior do gráfico de *boxplot*, pelo valor do limite inferior, calculado pela equação 7 descrita na sessão 3. O segundo tratamento foi a substituição desses pontos pelo valor da média dos dados.

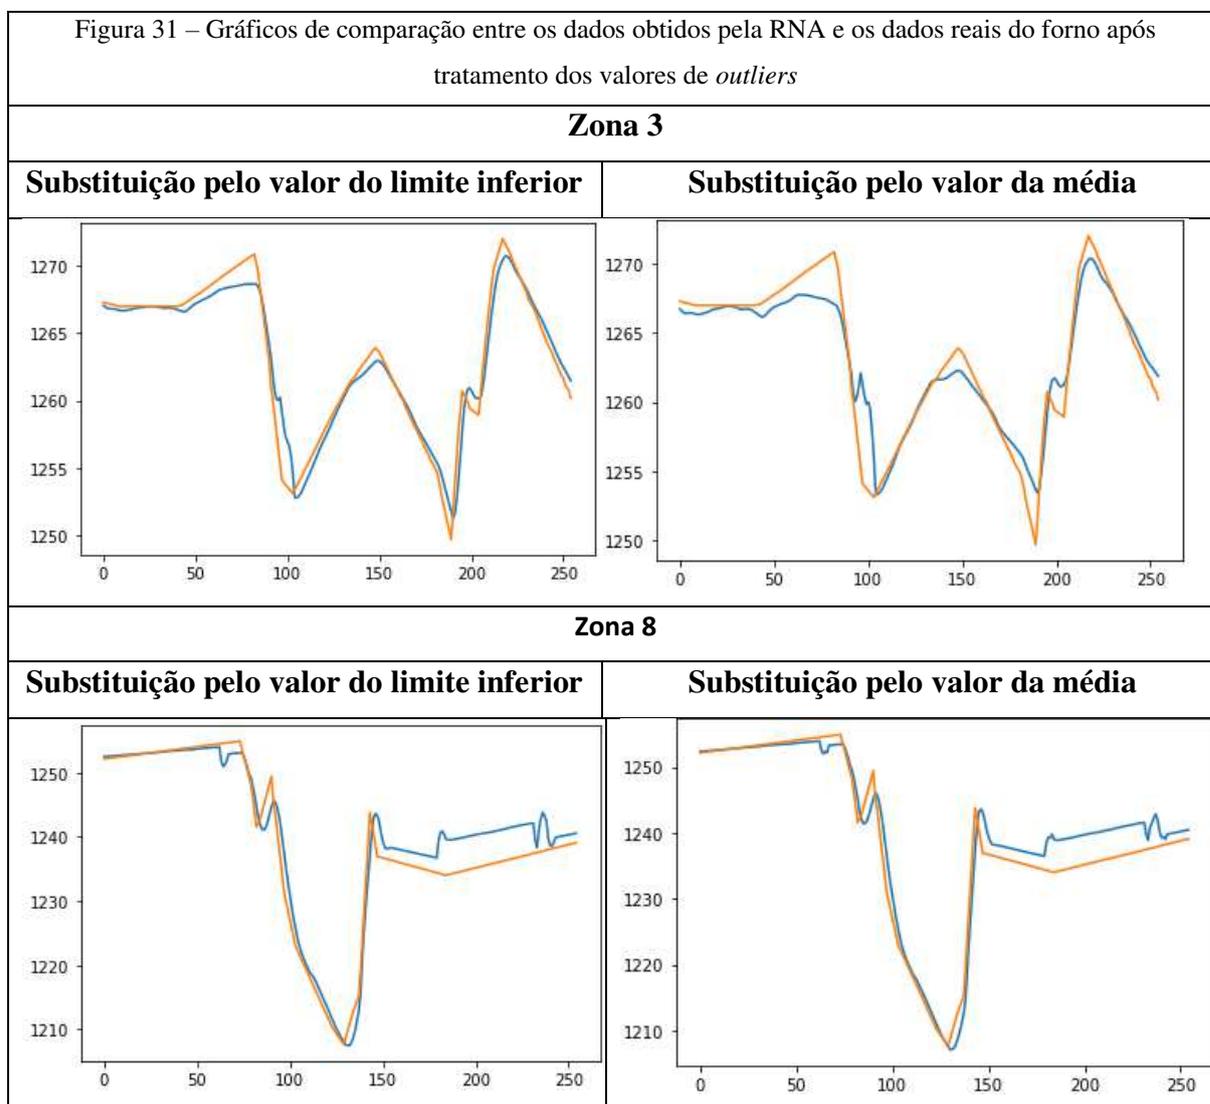
A Figura 30 apresenta os gráficos *boxplot* obtidos após os tratamentos dos valores outliers descritos anteriormente, para as zonas 3 e 8.



Observando a Figura 30, nota-se que para a zona 3, o valor da média dos dados continua como um valor de *outlier*. No caso do tratamento pela substituição do limite inferior, o menor valor de temperatura para essa zona é de 1230 °C. No caso da zona 8 os dois tratamentos

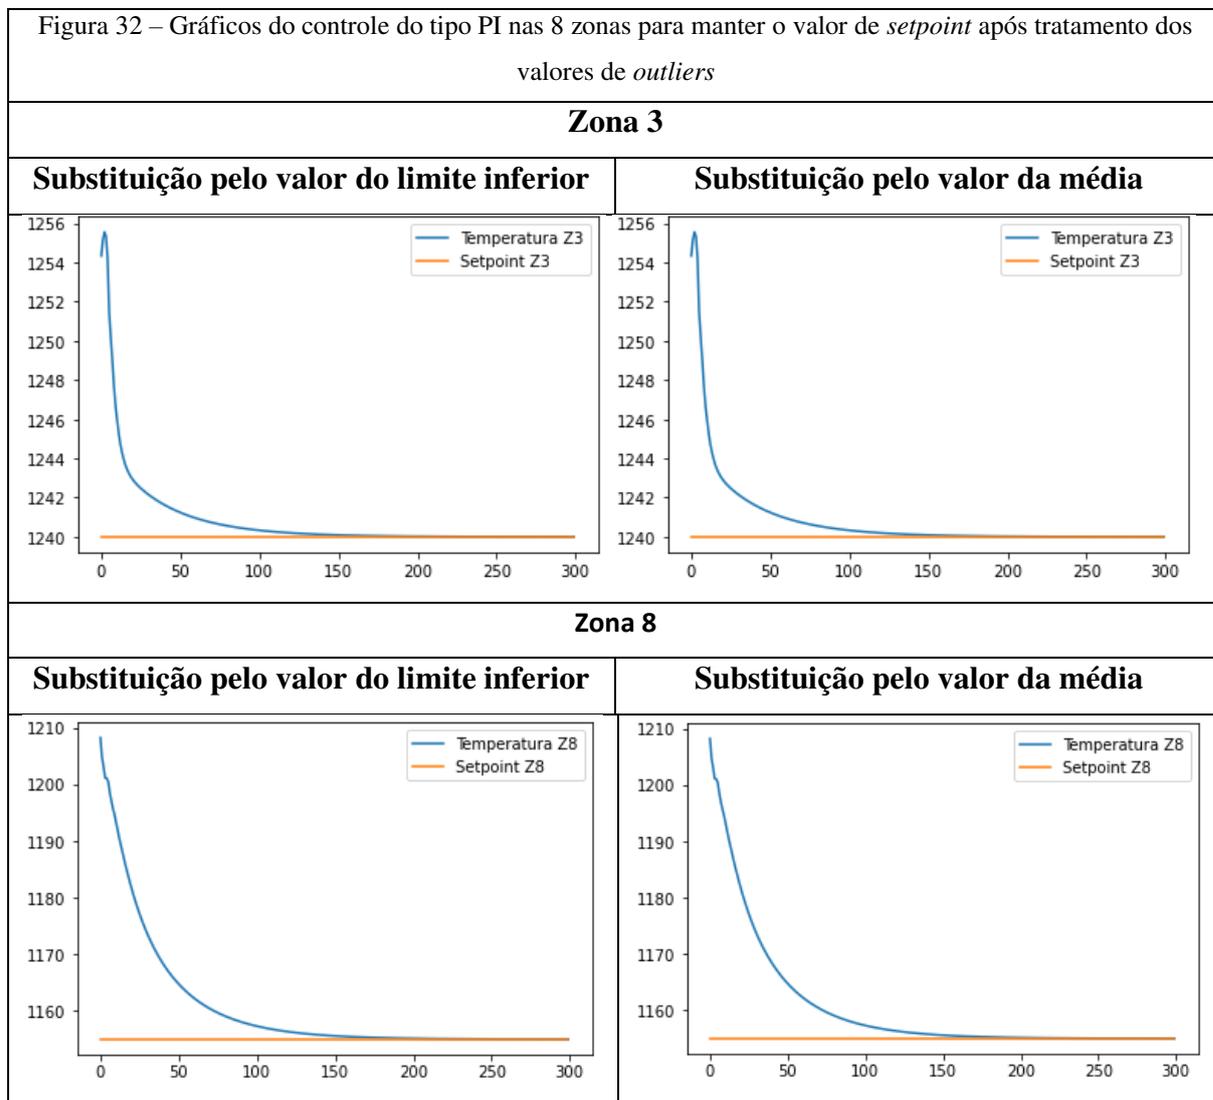
apresentaram resultados semelhantes na obtenção do novo gráfico de *boxplot*, sem presença de outlier, e a menor temperatura é de 1145 °C.

Após esses tratamentos, desenvolveu-se as RNA para as zonas. A Figura 31 apresenta os gráficos de comparação entre os valores previstos pela RNA, a partir do uso dos dados de teste, e os valores reais da temperatura de cada zona.



As RNA obtidas a partir dos dados tratados para os valores de outliers, apresentadas na Figura 31 apresentam resultados satisfatórios, pois conseguem prever a tendência dos dados reais com uma diferença pouco significativa. Em relação a zona 3, o resultado obtido a partir da substituição dos outliers pelo limite inferior foi mais representativo do que o obtido quando o tratamento usado foi a substituição pela média.

A partir das RNAs desenvolvidas para ambos os casos, utilizou a mesma para criação do sistema de controle do tipo PI para as zonas 3 e 8. A Figura 32 apresenta o resultado obtido para o controle das zonas.



Conclui-se a partir da Figura 32 que os sistemas de controles desenvolvidos a partir das RNAs após o tratamento dos valores de *outliers* são capazes de retornar a temperatura das zonas 3 e 8 para os valores de *setpoint* determinados. Porém, no caso da zona 3, ao tratar os valores discrepantes, tem-se que o valor antes inserido como *setpoint* na sessão 5.4 está fora dos limites existentes de temperatura nessa zona, portanto, um novo valor de 1240 foi estabelecido e o controlador conseguiu chegar a esse valor. O mesmo caso aconteceu para as zonas 5 a 7, por isso optou-se por apresentar os resultados apenas da zona 3. No caso da zona 8, após o tratamento, foi possível manter o valor de *setpoint* como 1155 °C apresentado na Tabela 1.

Sendo assim, pode-se concluir que no caso do forno de reaquecimento deste trabalho, os valores coletados que apresentam pontos de *outlier* são a chave para entender o processo, pois o mesmo é multivariável, apresentar um comportamento não linear e dinâmico. Dessa forma, quando utilizou técnicas que pudessem tratar esses valores discrepantes, acabou impossibilitando utilizar os mesmos valores de *setpoint* da Tabela 1, pois não se encontrada dentro dos novos limites existentes para a temperatura nas zonas 3 a 7, mesmo que as temperaturas possíveis estivessem dentro dos valores permitidos no forno de reaquecimento, para obter as peças com a qualidade desejada, que é entre 1000 °C a 1300°C.

6 CONCLUSÕES

O presente trabalho teve como objetivo o desenvolvimento de uma RNA do tipo LSTM, que fosse capaz de aprender e generalizar esse conhecimento adquirido a partir dos dados disponíveis em um forno de reaquecimento de tarugos, onde existiam 8 zonas distintas. Dados importantes para o processo foram coletados e utilizados para calcular as entradas e saídas da RNA, sendo elas o calor gerado pelo processo de combustão em cada zona e a temperatura das mesmas, respectivamente.

Os modelos obtidos para os diferentes métodos utilizados, como a taxa de amostragem de 1 minuto, a taxa de amostragem de 30 segundos e o tratamento dos valores *outliers* apresentaram resultados satisfatórios, pois conseguiram prever a tendência existente nos dados disponíveis para estudo, com erros que podem ser desconsiderados (entre 2,27% e 5,8%), por se tratar de temperaturas que possuem um intervalo de variação aceitável (1000 °C – 1300 °C), no qual ainda se torna possível obter peças com a qualidade necessária para o processo de laminação.

Porém, comparando todos os resultados, os modelos obtidos a partir de uma taxa de amostragem de 30 segundos, no qual foram usados 1073 pontos como entrada da rede, para que a mesma pudesse aprender o padrão existente e a partir disso, fosse capaz de prever novas saídas a partir de dados desconhecidos, foi o mais satisfatório, pois os gráficos de comparação entre os valores previstos pela rede e os valores reais do processo apresentaram uma maior convergência em relação aos demais.

Os modelos desenvolvidos foram utilizados para criação do sistema de controle do tipo PI, com o intuito de manter a temperatura das zonas dentro do valor de *setpoint*, e no caso dos sistemas desenvolvidos quando a taxa de amostragem foi de 1 minuto, quanto para de 30 segundos, esse objetivo foi atingido, mostrando que a RNA desenvolvida pode retornar os valores de temperatura das zonas para o valor desejado mesmo quando sujeito a perturbações no processo e exposta a valores desconhecidos pela rede, mostrando que a mesma possui a capacidade de generalizar.

No caso do sistema de controle desenvolvido a partir da RNA obtida com os dados passando pelo tratamento de *outlier*, conclui-se que foi preciso atribuir valores de *setpoint* diferentes dos definidos na metodologia para as zonas 3 a 7, dessa forma acabou fugindo da

metodologia proposta, mesmo que os novos valores estivessem dentro da faixa de 1000 °C a 1300 °C permitido para esse processo.

Diferentemente de outros trabalhos disponíveis na literatura, nos quais existe a necessidade de conhecer profundamente o processo de reaquecimento do aço, como sua equação de modelo para ser implementada nos controladores, o que torna uma tarefa complexa devido a quantidade de variáveis existentes, a não linearidade do processo, assim como a dinâmica existente nele, este trabalho traz uma técnica para desenvolvimento de um controlador capaz de manter a temperatura de cada zona de um forno de reaquecimento, equipamento chave do processo de laminação de aço, onde estão os maiores gastos energéticos desse setor, a partir de uma RNA criada com os dados disponíveis no equipamento, visando obter peças com a qualidade desejada para o laminador, evitando desperdício, aumentando a vida útil do laminador, e consumindo a quantidade necessária dos combustíveis que alimentam o forno e promovem a combustão necessária para transferir calor para as peças.

7 SUGESTÕES PARA TRABALHOS FUTUROS

Para ampliação do estudo desenvolvido no presente trabalho, as seguintes sugestões para trabalhos futuros são feitas:

- Estudar se existem outras variáveis que devem ser levadas em consideração na criação da rede neural, assim como a utilização de técnicas de seleção de variáveis mais influenciáveis para o processo;
- Desenvolver um modelo matemático através de Redes Neurais Artificiais para o forno de reaquecimento a partir dos dados do mesmo;
- Testar a viabilidade da utilização das Redes Neurais Artificiais desenvolvidas nesse processo para criação de sistemas de Detecção de diagnósticos de falhas.

REFERÊNCIAS

- ARAÚJO NETO, A. P. de. **Redes neurais artificiais aplicadas à mudança de especificação de etanol via destilação extrativa**. Trabalho de Conclusão de Curso (Bacharel em Engenharia Química). Universidade Federal de Campina Grande, Campina Grande, PB, p. 47. 2018.
- BRAGA, A. de.; LUDERMIR, T. B.; CARVALHO, A. C. P. de L. F. **Redes Neurais Artificiais teoria e aplicações**, Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora S.A., 2000.
- CASTELÃO, R. **Utilização de Redes Neurais para Previsões do mercado de ações**. São Paulo: Unicamp, 2018. 30 p. (Relatório Técnico - IC-PFG-18-01).
- GOMAA, Wael Hassan. The Impact of Deep Learning Techniques on SMS Spam Filtering. **International Journal of Advanced Computer Science and Applications**, v. 11, n. 1, p. 544-549. Jan./Feb. 2020.
- GOUVEIA, W. de A. **Modelagem Matemática do Fenômeno de Descarbonetação no Processo de Reaquecimento de Tarugos de Aço SAE1070**. Dissertação (Mestrado em Engenharia de Materiais) – Rede Temática de Engenharia de Materiais. Universidade Federal de Ouro Preto, Ouro Preto, p. 79. 2013.
- HAYKIN, S. **Redes Neurais: Princípios e prática**. Tradução: Paulo Martins Engel. Bookman, 2ª edição. Porto Alegre, 2001.
- Hochreiter, S. and Schmidhuber, J. (1997), **Long Short-Term Memory**, Johannes Kepler
- KIM, Y. II., MOON, K. C., KANG, B. S., HAN, C., CHANG, K. S. Application of neural network to supervisory control of reheating furnace in steel industry. **Control Engineering Practice**. V. 6, p. 1009-1014, 1998.
- LIAO, Y., WU, M., SHE, J. Modeling of Reheating-Furnace Dynamics Using Neural Network Based on Improved Sequential-Learning Algorithm. **IEEE International Conference on Control Applications**. Munich, Germany. 2006.
- LIRA JÚNIOR, J. C. de. **Simulação numérica de um forno de reaquecimento**. Dissertação (Mestrado em Engenharia Mecânica). Universidade Federal de Pernambuco, Pernambuco, p. 100. 2007.
- MAGALHÃES, C. V.; ZIVIANI, M.; SILVA, R. J. **Simulação do aquecimento de tarugos de aço em um forno de reaquecimento – modelo em tempo real**. Disponível em: <http://docplayer.com.br/57766030-Simulacao-do-aquecimento-de-tarugos-de-aco-em-um-forno-de-reaquecimento-modelo-em-tempo-real.html> Acesso em: 25 Out. 2021.
- MIRANDA, L. L.; ZIVIANI, M.; FULLIN JÚNIOR, B. Modelagem matemática do processo do forno de reaquecimento WB2 da LTQ da Acesita. **Tecnologia em Metalurgia e Materiais**, São Paulo, v.3. n.2, p. 34-38, out.-dez. 2006.
- MORAIS, E. C. **Reconhecimento de padrões e redes neurais artificiais em predição de estruturas secundárias de proteínas**. Tese (Doutorado em Engenharia de Sistemas e Computação). Universidade Federal do Rio de Janeiro, Rio de Janeiro, p. 148. 2010.
- NEVES, T.G. **Redes Neurais Artificiais aplicadas ao controle inteligente de Colunas Extrativas**. (Dissertação de Mestrado). Programa de PósGraduação em Engenharia Química,

Centro de Ciências e Tecnologia, Universidade Federal de Campina Grande, Campina Grande - Paraíba - Brasil, p. 78 2016.

OLESKOVICZ, Mário; COURY, D. V.; AGGARWAL, R. K. O emprego de redes neurais artificiais na detecção, classificação e localização de faltas em linhas de transmissão. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, v. 14, p. 138-150, 2003.

RAMEZANI, J., JASSBI, J. Quality 4.0 in Action: Smart Hybrid Fault Diagnosis System in Plaster Production. **Process**. v. 8, n. 634, p. 1-29, Apr-May 2020.

ROSADO, D. J. M., **Economia de Energia em fornos de reaquecimento utilizados na indústria siderúrgica**. Dissertação (Mestrado em Engenharia Mecânica) – Universidade Estadual Paulista. Faculdade de Engenharia de Guaratinguetá, São Paulo, p. 183. 2020.

SILVEIRA, F. A. T., RAFFO, G.V. **Optimal control of fuel gases on continuous annealing furnaces of steel coil strip**. XIII Simpósio Brasileiro de Automação Inteligente. P. 2123-2128 Porto Alegre, Brasil, 1º a 4 de Outubro de 2017.

SRISERTPOL, J., TANTRAIRATN, S., TRAGRUNWONG, P., KHOMPHIS, V. Temperature Control for Reheating Furnace Walking Hearth Type in Heating Curve Up Process. **SELECTED TOPICS in SYSTEM SCIENCE and SIMULATION in ENGINEERING**. P. 464-469. Jan 2010.

Y. Hu, C.K. Tan, J. Broughton, P.A. Roach, L. Varga, Model-based multi-objective optimization of reheating furnace operations using genetic algorithm, **Energy Procedia**, United Kingdom v.142, p. 2143–2151, 2017.