INSTITUTO FEDERAL DO ESPÍRITO SANTO

MESTRADO PROFISSIONAL EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO

RODRIGO DE SOUZA LIMA

PREVISÃO DE TEMPERATURAS DENTRO DE UM FORNO DE REAQUECIMENTO DE PLACAS DE AÇO USANDO REDES NEURAIS

SERRA

2024

RODRIGO DE SOUZA LIMA

PREVISÃO DE TEMPERATURAS DENTRO DE UM FORNO DE REAQUECIMENTO DE PLACAS DE AÇO USANDO REDES NEURAIS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Controle e Automação do Instituto Federal do Espírito Santo, como requisito parcial para obtenção do Título de Mestre em Engenharia de Controle e Automação.

Orientadores:

Prof. Dr. Gustavo Maia de Almeida
Prof. Dr. Leonardo Azevedo Scardua

SERRA
2024

Dados Internacionais de Catalogação na Publicação (CIP)

R732p Lima, Rodrigo de Souza
2024 Previsão de temperaturas dentro de um forno de reaquecimento de placas de aço usando redes neurais / Rodrigo de Souza Lima. - 2024.
89 f.; il.; 30 cm

Orientador: Prof. Dr. Gustavo Maia de Almeida; Prof. Dr. Leonardo Azevedo Scardua.

Dissertação (mestrado) - Instituto Federal do Espírito Santo, Programa de Pós-graduação em Engenharia de Controle e Automação, 2024 .

1. Automação. 2. Redes neurais. 3. Fornos de reaquecimento. 4. Siderurgia. 5. Placas metálicas. I. Almeida, Gustavo Maia de. II. Instituto Federal do Espírito Santo. III. Título.

CDD 629.895

Bibliotecário: Valmir Oliveira de Aguiar - CRB6/ES 566

MINISTÉRIO DA EDUCAÇÃO

INSTITUTO FEDERAL DO ESPÍRITO SANTO

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO

RODRIGO DE SOUZA LIMA

"PREVISÃO DE TEMPERATURA DENTRO DE UM FORNO DE REAQUECIMENTO DE PLACAS DE AÇO USANDO REDES NEURAIS"

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Controle e Automação do Instituto Federal do Espírito Santo, como requisito parcial para obtenção de título de Mestre em Engenharia de Controle e Automação.

Aprovado em 21 de Junho de 2024

COMISSÃO EXAMINADORA

Documento assinado digitalmente
gov.br
GUSTAVO MAIA DE ALMEIDA
Data: 25/06/2024 10:13:35-0300
Verifique em https://validar.iti.gov.br

_____

Prof. Dr. Gustavo Maia de Almeida
Instituto Federal do Espírito Santo
Orientador

Documento assinado digitalmente
gov.br
LEONARDO AZEVEDO SCARDUA
Data: 25/06/2024 10:46:30-0300
Verifique em https://validar.iti.gov.br

_____

Prof. Dr. Leonardo Azevedo Scárdua
Instituto Federal do Espírito Santo
Co-Orientador

Documento assinado digitalmente
gov.br
LUIZ ALBERTO PINTO
Data: 25/06/2024 15:17:46-0300
Verifique em https://validar.iti.gov.br

_____

Prof. Dr. Luiz Alberto Pinto
Instituto Federal do Espírito Santo
Membro Interno

Documento assinado digitalmente
gov.br
BRENO TOTTI MAIA
Data: 25/06/2024 16:01:23-0300
Verifique em https://validar.iti.gov.br

_____

Dr. Breno Totti Maia
Lumar Metals
Membro Externo

AGRADECIMENTOS

Agradeço primeiramente a Deus, por ser essencial em minha vida. Ao meu pai Antônio Carlos de Lima e minha mãe Cecília Amélia de Souza Lima. À minha esposa Poliana Carvalho dos Santos e a nossos filhos Gustavo e Antônio. Aos meus irmãos, Robson e Leandro e minhas sobrinhas: Sara, Maria Cecília, Marina e Bruna.

À Poliana Carvalho dos Santos, pessoa com quem amo partilhar a vida. Com você tenho me sentido mais vivo de verdade. Obrigado pelo carinho, paciência e por sua capacidade de me trazer paz durante essa caminhada;

A toda equipe do Programa Propcaut do IFES que me acompanhou, ensinando-me a importância do trabalho em equipe, do comprometimento, da disciplina, e do desenvolvimento constante, destacando o valor da pesquisa acadêmica para a produção de novos conhecimentos, avanço das teorias e tecnologias.

Especialmente aos professores Gustavo Maia de Almeida e Leonardo Azevedo Scardua pela dedicação no processo de orientação, me conduzindo para que eu chegasse até aqui. Obrigado pela oportunidade e pela generosidade de partilhar seu saber.

Por fim, agradeço a todos que estiveram ao meu lado em cada momento desta trajetória, meus amigos, colegas de turma e as equipes de manutenção e operação do fornos de reaquecimento de placas do LTQ da ArcelorMittal Tubarão. Sem o apoio e incentivo de todos vocês, essa conquista não seria possível.

Obrigado!

.

“O homem não é nada além daquilo que a educação faz dele."

(Kant)

RESUMO

Devido à complexidade e aos altos custos financeiros envolvidos nos processos de produção, a indústria siderúrgica pode se beneficiar largamente com aplicações de sistemas inteligentes, capazes de realizar atividades automatizadas. Este trabalho de pesquisa aborda uma descrição do processo de criação de um sistema computacional orientado a dados, com propósito de desenvolvimento de modelos neurais artificiais aplicados no processo de predição de temperaturas em fornos de reaquecimento de placas através de predição recursiva de curto, médio e longo prazo. Modelos computacionais suficientemente precisos podem ser usados em conjunto com técnicas de otimização de controle, como controle preditivo baseado em modelo (MPC) ou como um Gêmeo Digital de um sistema físico real, podendo ser bastante útil para as equipes de manutenção e operação como ferramenta preditiva para detecção de anomalias. Para tal desenvolvimento, as Redes Neurais Artificiais Recorrentes têm sido amplamente estudadas e aplicadas com desígnio de realizar previsões baseadas em conhecimentos passados, por meio de sequências históricas que possuem ligações temporais, caso típico do monitoramento de variáveis de processos industriais. Com finalidade de atendimento ao objetivo proposto, investigou-se o desempenho de modelos neurais com capacidade de predição em etapas futuras, tais como, *Neural Network Recurrent* (RNN), *Long-Short Term Memory* (LSTM) e *Gated Recurrent Unit* (GRU) e Temporal Convolucional Network (TCN). Para medir a precisão das previsões, foram utilizadas as métricas de erro médio absoluto (MAE) e raiz do erro médio quadrático (RMSE). Os testes foram avaliados sob diferentes horizontes de previsão e apontaram que as técnicas aqui empregadas são eficazes, apresentando previsões suficientemente precisas, tornando-se uma opção interessante para a previsão de curto, médio e longo prazo de temperatura em fornos de reaquecimento de placas. Assim, entende-se que essa abordagem pode ser utilizada para melhorar os processos de reaquecimento de placas em fornos industriais, buscando a otimização da produção e redução de custos e impactos ambientais.

Palavras–chave: Redes Neurais; Predição Passo à Frente; Fornos de Reaquecimento de Placas;

ABSTRACT

Due to the complexity and high financial costs involved in production processes, the steel industry can greatly benefit from applications of intelligent systems, capable of performing automated activities. This research paper addresses a description of the process of creating a data-driven computational system for the purpose of developing artificial neural models applied to the process of predicting temperatures in slab reheating furnaces through short, medium, and long-term recursive prediction. Sufficiently accurate computational models can be used in conjunction with control optimization techniques, as model-based predictive control (MPC) or as a Digital Twin of a physical system, which can be especially useful for maintenance and operation teams as a predictive tool for anomaly detection. For such development, Recurrent Artificial Neural Networks have been widely studied and applied with the purpose of making predictions based on past knowledge, by means of historical sequences that have temporal links, a typical case of monitoring industrial process variables. To meet the proposed objective, the performance of neural models with prediction capacity in future steps, such as Recurrent Neural Network (RNN), Long-Short Term Memory (LSTM) and Gated Recurrent Unit (GRU) and Temporal Convolutional Network (TCN), was investigated. To measure the accuracy of the predictions, the metrics of mean absolute error (MAE) and root mean square error (RMSE) were used. The tests were evaluated under different forecast horizons and pointed out that the techniques employed here are effective, presenting sufficiently accurate forecasts, making them an interesting option for short, medium, and long-term temperature forecasting in slab reheating furnaces. Thus, it is understood that this approach can be used to improve the process of slab reheating in industrial furnaces, seeking to optimize production and reduce costs and environmental impacts.

Keywords: Neural Networks; Forward Step Prediction; Slab Reheating Furnaces.

LISTA DE FIGURAS

Figura 1- Produção de aço bruto mundial em milhões de toneladas. 12
Figura 2 - Produção de aço bruto em 2021. 13
Figura 3 - Produção de aço bruto no Brasil. 13
Figura 4 - Fluxo de produção de uma usina siderúrgica integrada. 15
Figura 5 - Etapas do processo Laminação de Tiras a Quente. 16
Figura 6 - Saída de um forno de reaquecimento placas. 17
Figura 7 - Validação de modelos com placa instrumentada. 22
Figura 8 - Proposta de controle *MPC* para zonas On-Off. 23
Figura 9 - Forno tipo empurrador (Pusher). 27
Figura 10 - Forno tipo vigas móveis (Walking Beam). 27
Figura 11 - Ciclo de movimentação das vigas móveis. 28
Figura 12 - Vista do interior de um forno tipo viga móvel. 28
Figura 13 - Evolução da geometria dos fornos de reaquecimento contínuos. 29
Figura 14 - Geometria espacial aplicável na transferência de calor para placa. 31
Figura 15 - Distribuição das zonas de um forno de reaquecimento. 32
Figura 16 - Tipo de queimadores. 34
Figura 17 - Compara em modulação de amplitude e frequência. 35
Figura 18 - Exemplo de hierarquia do controle em fornos de reaquecimento. 36
Figura 19 - Típico de sistema de controle térmico em fornos de reaquecimento. 37
Figura 20 - Modelo não linear de um neurônio, rotulado com k. 38
Figura 21 - Arquitetura MLP com uma camada oculta de neurônios. 41
Figura 22 - Unidade Neural Recorrente. 43
Figura 23 - Rede Neural k com recorrência rk. 44
Figura 24 - Célula LSTM. 45
Figura 25 - Célula GRU. 47
Figura 26 - Exemplo de rede convolucional totalmente conectada. 50
Figura 27 - Exemplo de convolução com e sem dilatação. 50
Figura 28 - Convolução causal dilatada empregada no bloco residual. 51
Figura 29 - Vista Lateral do Forno de Reaquecimento. 53
Figura 30 - Principais componentes de um queimador lateral. 54
Figura 31 - Fluxo Metodológico do trabalho. 56

Figura 32 - Análise dos dados usados na zona 1.....57
Figura 33 - Exemplo do filtro aplicado aos sinais. 58
Figura 34 - Análise de dados discrepantes. 59
Figura 35 - Mapa de correlação entre as variáveis. 60
Figura 36 - Seleção sequencial de variáveis.....61
Figura 37 - Janela deslizantes para treinamento supervisionado.....64
Figura 39 - MAE e RMSE antes e depois da sintonia. 68
Figura 40 - Avaliação da predição da zona 1. 71
Figura 41 - Avaliação do erro de previsão da zona 1. 72

LISTA DE TABELAS

Tabela 1 - Tipos de termopares aplicados em fornos de reaquecimento. 33
Tabela 2 - Dados construtivos do forno em estudo 52
Tabela 3 - Lista de hiperparâmetros e sintonia da zona 01. 67
Tabela 4 - Avaliação das predições dos modelos por MAE e RMSE. 69
Tabela 5 - Quantidade de parâmetros treináveis por modelo. 74

SUMÁRIO

1 INTRODUÇÃO 12
1.1 OBJETIVOS 19
1.2 JUSTIFICATIVA E IMPORTÂNCIA 20
1.3 ORGANIZAÇÃO DO TRABALHO 25
2 REVISÃO BIBLIOGRÁFICA 26
2.1 FORNOS DE REAQUECIMENTO EM SIDERURGIA 26
2.1.1 Classificação dos fornos industriais 26
2.1.2 Geometria e principais componentes 29
2.1.3 Processo de reaquecimento em fornos 30
2.1.3.1 Zonas de aquecimento 31
2.1.3.2 Medição da Temperatura 33
2.1.3.3 Queimadores 33
2.1.3.4 Controle do aquecimento 35
2.2 REDES NEURAIS ARTIFICIAIS 38
2.2.1 Neurônio Artificial 38
2.2.2 Redes Neurais MLP (*Multilayer Perceptron)* 40
2.2.3 Redes Neurais Temporais 42
2.2.3.1 Recorrentes 42
2.2.3.2 LSTM 45
2.2.3.3 GRU 47
2.2.3.4 Convolucional 49
3 MATERIAIS E MÉTODOS 52
3.1 EQUIPAMENTO DE ESTUDO 52
3.2 MODELAGEM DA TEMPERATURA DO FORNO DE REAQUECIMENTO 55
3.2.1 Avaliação da base de dados 56

3.2.2 Filtragem dos sinais 57

3.2.3 Normalização dos dados 58

3.2.4 Análise de *outliers* 59

3.2.5 Seleção das variáveis 59

3.2.6 Preparação dos dados para treino supervisionado 63

3.2.7 Métrica de avalição de desempenho 64

3.2.8 Arquitetura e sintonia dos modelos 66

4 RESULTADOS E DISCUSSÃO 69

4.1 AVALIÇÃO DOS RESULTADOS POR MAE E RMSE 69

4.2 AVALIAÇÃO GRÁFICA DOS RESULTADOS 70

4.3 ANÁLISE DOS PARÂMETROS TREINÁVEIS 74

4.4 ANÁLISE DO PRÉ-PROCESSAMENTO DOS DADOS 75

4.5 ANÁLISE DA SINTONIA DOS MODELOS 75

5 CONCLUSÕES 76

REFERÊNCIAS 78

ANEXO A – Resultados das previsões e avaliação do erro por zona 84

1 INTRODUÇÃO

As usinas siderúrgicas são responsáveis pela produção do aço, que é uma liga metálica formada por ferro e carbono, em que o teor de carbono varia desde 0,008% até 2,11% (CHIAVERINI, 1996). O aço está presente nos principais materiais utilizados no dia a dia, desde talheres e outros utensílios domésticos a meios de transporte e arranha-céus construídos em grandes cidades. Versátil, seguro e 100% reciclável, o aço também é o material mais reutilizado do mundo, sem perder sua qualidade, leveza e durabilidade. Possibilitando a redução do uso de matérias-primas, menor impacto ambiental e produtos cada vez mais confiáveis (AMT, 2022).

No mercado mundial, segundo a WorldSteel Association (2022), a maioria dos países produtores de aço, viram um aumento na produção e no uso de aço em 2021, conforme figura 01, em que a produção mundial atingiu 1.951 milhões de toneladas de aço bruto produzido, mesmo com as restrições do COVID que permaneceram em muitos locais ao redor do mundo.

Figura 1- Produção de aço bruto mundial em milhões de toneladas.

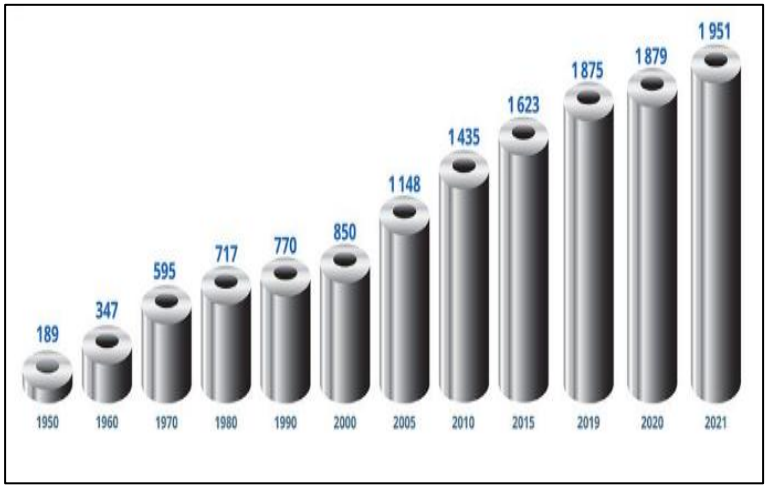

Fonte: WorldSteel Association, 2022.

A produção mundial de aço bruto pode ser vista na figura 2, em que são listados os 20 principais produtores de aço do mundo, de acordo com a produção do último ano. A produção de aço bruto no mundo cresceu 3,7% quando comparamos os números de 2020 com 2021. Neste mesmo período, o Brasil elevou a sua produção em 15,2%,

chegando a uma a produção 36,2 milhões de toneladas de aço, conforme visto na figura 3. Atualmente o Brasil ocupa a 9ª posição no ranking de produtores mundiais e 1° lugar na América Latina, sendo responsável por 52% da produção local (Aço Brasil, 2022).

Figura 2 - Produção de aço bruto em 2021.

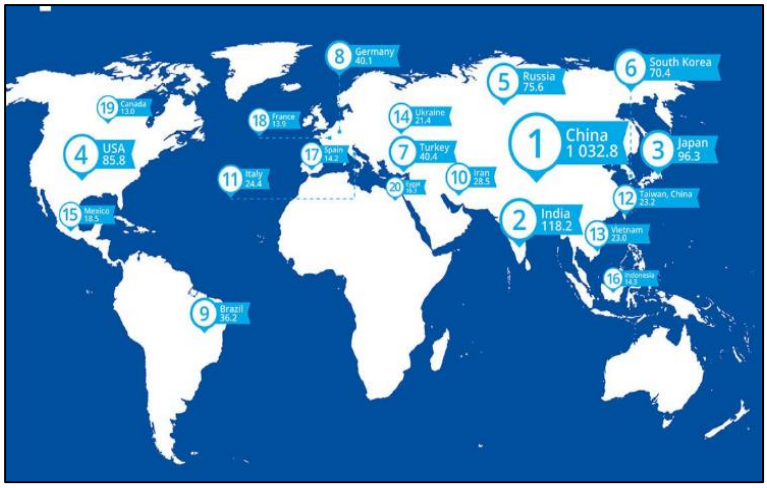

Fonte: WorldSteel Association, 2022.

Figura 3 - Produção de aço bruto no Brasil.

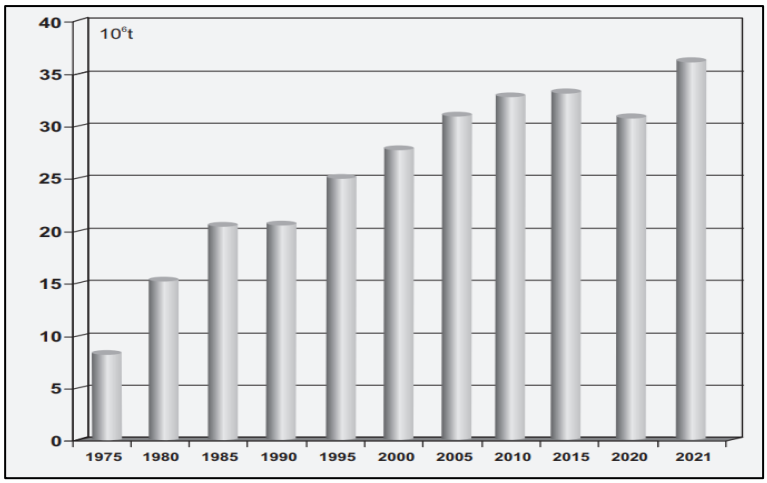

Fonte: Aço Brasil, 2022.

Com base nos dados apresentados é possível observar a tendência de crescimento deste segmento. O parque siderúrgico do Brasil é atualmente representado por 15 empresas privadas, controladas por doze grupos empresariais e operando 31 usinas distribuídas por 10 estados brasileiros (Aço Brasil, 2022).,

A produção do aço pode ser realizada em usinas integradas ou semi-integradas. Na forma integrada a produção passa por quatro fases básicas do processo produtivo: preparação, redução, refino e laminação. Nas usinas semi-integradas a operação passa apenas por duas fases: refino e laminação. Pátria (2020), descreve de forma sucinta as etapas do processo siderúrgico em uma operação regular de produção de aço. O processo produtivo do aço é apresentado na figura 4 e pode ser dividido em quatro etapas, conforme descrito abaixo.

1°. Preparação da carga - Grande parte do minério de ferro (finos) é aglomerada utilizando-se cal e finos de coque. O produto resultante é chamado de sínter. O carvão é processado na coqueria e transforma-se em coque.

2°. Redução - Essas matérias-primas, agora preparadas, são carregadas no alto forno. O oxigênio aquecido a uma temperatura de 1000ºC é soprado pela parte de baixo do alto forno. O carvão, em contato com o oxigênio, produz calor que funde a carga metálica e dá início ao processo de redução do minério de ferro em um metal líquido: o ferro-gusa. O gusa é uma liga de ferro e carbono com um teor de carbono muito elevado.

3°. Refino - Aciarias a oxigênio ou elétricas são utilizadas para transformar o gusa líquido ou sólido e a sucata de ferro e aço em aço líquido. Nessa etapa parte do carbono contido no gusa é removido juntamente com impurezas. A maior parte do aço líquido é solidificada em equipamentos de lingotamento contínuo para produzir semiacabados, lingotes ou blocos.

4°. Laminação - Os semiacabados, lingotes e blocos são processados por equipamentos chamados laminadores e transformados em uma grande variedade de produtos siderúrgicos, cuja nomenclatura depende de sua forma e/ou composição química.

Figura 4 - Fluxo de produção de uma usina siderúrgica integrada.

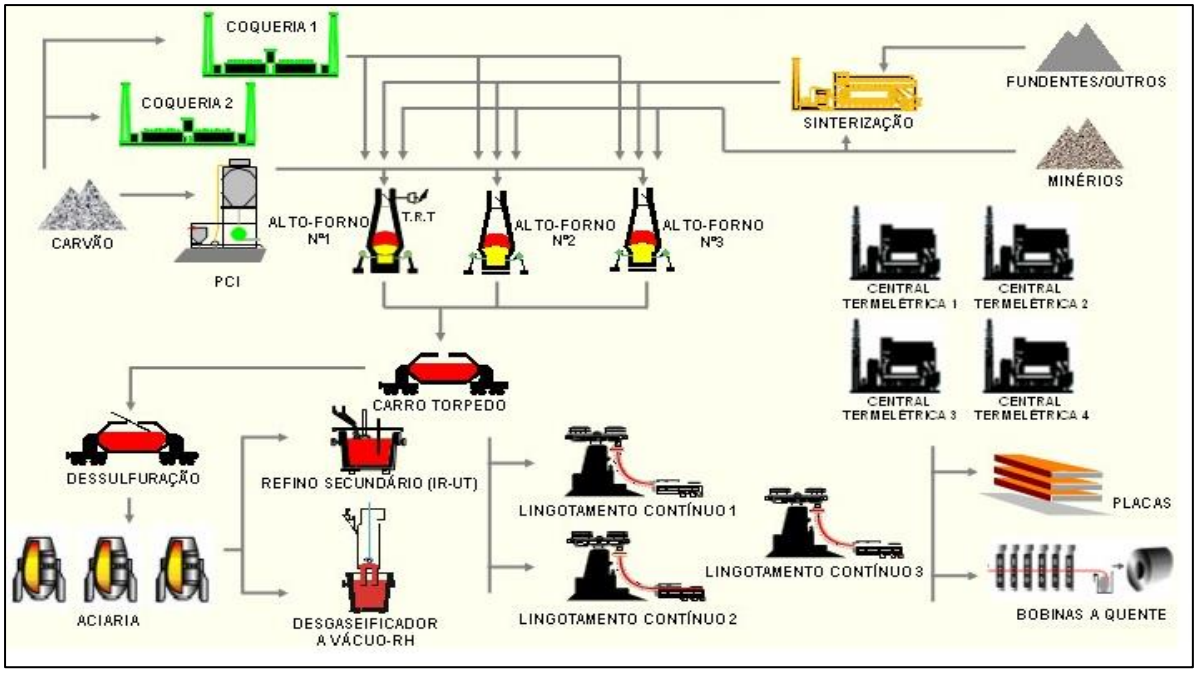

Fonte: AMT, 2022.

A ArcelorMittal Tubarão é uma usina siderúrgica especializada na produção de placas e bobinas de aço, com capacidade de produção anual de 7,5 milhões de toneladas de aço. As placas de aços que são produzidas nas máquinas de lingotamento contínuo, podem ser comercializadas em formato de placas ou serem encaminhadas para o processo de Laminação de Tiras a Quente (LTQ), no qual serão transformadas em bobinas, agregando assim mais valor ao produto, já que aumenta sua aplicabilidade (AMT, 2022).

O processo de Laminação de Tiras a Quente, visto na figura 5, tem início nos fornos de reaquecimento, foco deste trabalho de pesquisa, em que as placas de aço são reaquecidas de forma controlada a temperaturas próximas a 1200°C com o propósito de garantir as propriedades térmica e mecânica, adequadas para seu devido processamento no laminador.

Atingida a temperatura ideal para laminação, as placas passam por um processo de deformação mecânica. Inicialmente, essa deformação ocorre no laminador de bordas e espessura (Laminador de Desbaste), sofrendo uma primeira redução em suas dimensões, tendo sua espessura reduzida por meio de passes sucessivos pelo

laminador desbastador, saindo da forma de placa para a forma de chapa grossa ou esboço. Em seguida, são conduzidas ao laminador final, composto de cadeiras sequenciais de laminação, que reduzirá gradualmente a espessura da chapa grossa de forma a garantir sua espessura final.

Por fim, o material será resfriado e direcionado às bobinadeiras, onde as tiras de aço são enroladas em formato de bobinas, que serão utilizadas como matérias-primas para a produção de laminados frio ou simplesmente processadas para serem utilizadas na fabricação de peças para veículos, estruturas metálicas, tubos, implementos agrícolas, botijões, equipamentos rodoviários e outras aplicações (PÁTRIA, 2020).

Figura 5 - Etapas do processo Laminação de Tiras a Quente.

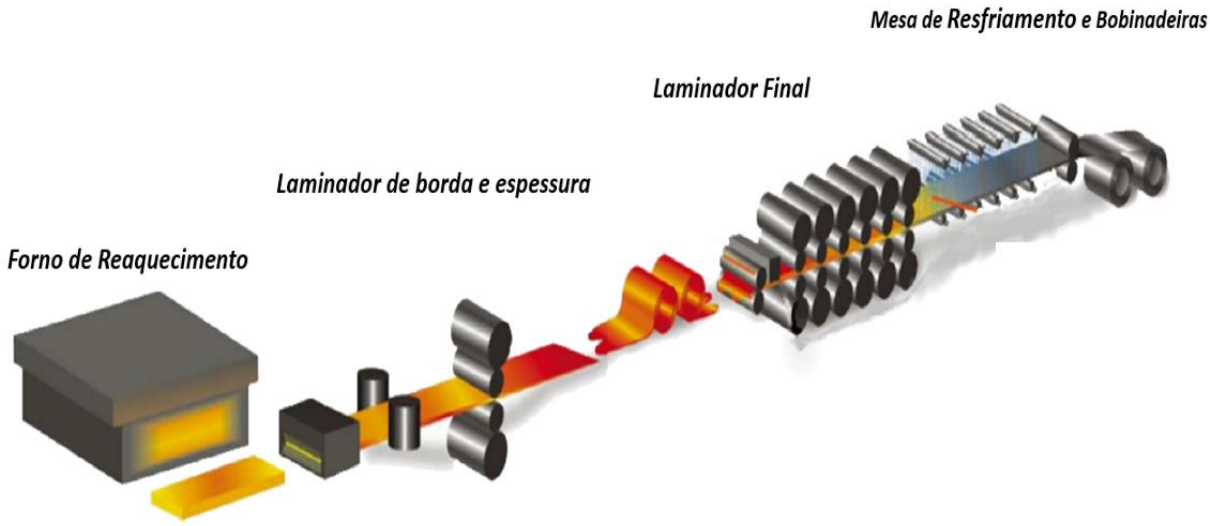

Fonte: Adaptado de AMT, 2022.

Os fornos de reaquecimento são extremamente importantes para o processo de laminação. O calor produzido no interior de um forno, por uma reação química exotérmica, é propagado as placas de aço por condução, convecção e radiação. Sua função principal é realizar o aquecimento da sua carga até que esta esteja suficientemente plástica para permitir a redução mecânica até seção desejada no processo laminação (TRINKS et al., 2004). A figura 6 apresenta a saída de um forno de reaquecimento de placas.

Figura 6 - Saída de um forno de reaquecimento placas.

Fonte: AMT, 2023.

O processo de reaquecimento pode ser considerado complexo e extremamente crítico na produção de chapas grossas ou bobinas a quente. É uma fase importante para obtenção de boas condições de laminação e qualidade superficial do produto. O aquecimento deve ser homogêneo, de forma a obter a maior produtividade, menor consumo energético possível e menores taxas de emissões de poluentes (HU et al., 2018).

Rosado (2020), destaca inúmeros fatores que podem afetar a eficiência térmica de um forno de reaquecimento de placas de aço, sendo eles: a distribuição do fluxo dos gases quentes no interior do forno, tipo de combustível, distribuição das placas, tempo de residência, geometria construtiva do forno, estratégia aplicada ao sistema de controle de aquecimento etc.

Dentro deste contexto, entende-se a necessidade do conhecimento específico da dinâmica térmica presente no processo de reaquecimento de placas, onde este trabalho de pesquisa, visa criar modelos preditivos, por meio de dados reais e técnicas de aprendizado de máquina, especificamente redes neurais de aprendizado profundo, que possam representar o comportamento térmico das zonas de controle de temperatura de um forno, durante o processo de reaquecimento de placas aço para laminação a quente.

A metodologia aplicada neste de trabalho de pesquisa pode ser considerada promissora, devido ao fato de termos uma representação de um sistema real de um equipamento complexo e multivariável em um ambiente computacional, ou seja, um modelo computacional baseado em dados para cada zona de aquecimento do forno de reaquecimento de placas, viabilizado avaliações do sistema de controle do aquecimento da placas ou mesmo o desenvolvimento de um sistema de controle avançado, como o controle preditivo baseado em modelo computacional.

Também, observa-se que esse tipo de tecnologia está alinhada ao conceito de indústria 4.0, englobando os conceitos de controle e automação com inteligência artificial. Com o propósito claro de aumento de produtividade, eficiência do uso de recursos energéticos e sustentabilidade. Assim, entende-se que a previsibilidade do comportamento do sistema térmico do forno de reaquecimento de placas, tem um potencial grandioso e deve ser explorado cada vez mais em estudos de pesquisas.

1.1 OBJETIVOS

OBJETIVO GERAL

Têm-se como objetivo geral deste trabalho a obtenção de modelos computacionais baseados em redes neurais, que possam representar um processo real de um forno de reaquecimento para predição das temperaturas em suas zonas de aquecimento.

OBJETIVOS ESPECÍFICOS

1. Coletar, identificar e selecionar as variáveis do processo que são, capazes de influenciar a dinâmica térmica de um forno de reaquecimento de placas.

2. Criar um banco de dados para treinamento, validação e testes de modelos preditivos baseados em redes neurais.

3. Fazer um trabalho de pesquisa sobre o processo térmico de um forno de reaquecimento de placas e as técnicas atuais de redes neurais artificias para predição temporal.

4. Treinar modelos computacionais para predição da temperatura em sete zonas de aquecimento de um forno de reaquecimento de placas.

5. Realizar testes de capacidade de predição da temperatura e comparar o desempenho por meio de métricas aplicáveis ao problema em questão.

1.2 JUSTIFICATIVA E IMPORTÂNCIA

Em todas as operações de laminação a quente, o forno de reaquecimento é um equipamento determinante na qualidade dos produtos fins: blocos de aço, tarugos ou placas. Portanto, fornos de reaquecimento requerem um controle preciso da temperatura do produto e uniformidade térmica durante todo o período de aquecimento (PIKE,1970). Os fornos de reaquecimento desempenham um papel fundamental no processo de laminação de tiras a quente e de chapas grossas. São neles, que os produtos intermediários, como placas ou tarugos, são reaquecidos até se tornarem suficientemente plásticos para o processamento subsequente (TEIXEIRA et. al., 2007).

Desde a década de 1970, os problemas de modelagem, otimização e controle de forno de reaquecimento tem recebido atenção considerável (Yang e Lu, 1988). Na literatura são apontadas algumas razões principais pelo interesse no estudo em fornos de reaquecimento, pois problema de controle de temperatura em fornos de reaquecimento de placas não é trivial, devido à complexidade do processo de aquecimento e o fato da quantidade significativa de energia que é consumida durante este processo (YANG E LU, 1986). As características não lineares, as altas constantes de tempo, distúrbios e vários outros fatores de incerteza, corroboram com a dificuldade no desenvolvimento de controladores que sejam eficazes para obtenção de desempenho ótimo para esse tipo de sistema (ZHANG et al., 2002).

Nas publicações mais recentes, encontram-se conteúdos que justificam a importância dos estudos sobre fornos de reaquecimento, destacando três pilares fundamentais: econômico, produtivo e ambiental. No aspecto econômico, o forno de reaquecimento é um dos principais consumidores de energia, representando de 15 a 20% do consumo total de energia na indústria siderúrgica (Chen et al., 2018). Sob a perspectiva produtiva, a dinâmica do reaquecimento das placas e a capacidade do forno determinam o ritmo de laminação, fazendo do processo de reaquecimento um fator limitante para o aumento do volume de produção. O pilar ambiental também é significativo e relevante. Em termos de sustentabilidade, as organizações têm direcionado esforços para reduzir o consumo de combustíveis fósseis e minimizar a emissão de gases.

Segundo Niekurzak et al. (2021), um dos problemas associados à laminação a quente é a emissão de poeira e gases poluentes na atmosfera, especialmente óxidos de nitrogênio (NOx), óxidos de enxofre (SOx) e hidrocarbonetos alifáticos. Nesse contexto de sustentabilidade e produtividade, diversos estudos podem ser encontrados na literatura, focando na solução de problemas relacionados aos fornos de reaquecimento de placas, como a abordagem realizada por: Landfahrer et al. (2020) e Khalid et al. (2021). Neste trabalho de pesquisa, o destaque é dado à modelagem do sistema térmico, cujo objetivo é a otimização dos sistemas de controle.

Usualmente, os sistemas de controle térmico em fornos de reaquecimento usam modelos complexos para otimização do aquecimento e esses podem ser diferenciados com base no método aplicado na modelagem. Modelos conhecidos como “caixa branca”, são modelos que adotam as equações fundamentais de fenômenos físicos, de modo que os parâmetros do modelo sejam diretamente atribuíveis às grandezas físicas do sistema real. Em contrapartida, a modelagem “caixa preta” utiliza estruturas genéricas do sistema, como por exemplo a teoria de identificação de sistema ou redes neurais, que geralmente não permite interpretações palpáveis. (KUSTERS et al.,1996).

Normalmente, para validação de modelos em sistema de otimização de processo térmico em fornos, utiliza-se uma placa instrumentada, tecnicamente conhecida como placa de teste. Esta é equipada com sensores de temperatura que são distribuídos ao longo do seu comprimento com inserções distintas.

A placa de teste deve atravessar todo o forno, desde a entrada até a saída, sendo reaquecida durante o processo. As variações temporais das temperaturas da placa e do forno são medidas e registradas, com o objetivo de avaliar a precisão do modelo computacional de aquecimento. A Figura 7 apresenta um exemplo de validação do modelo com base em um sistema utilizando uma placa instrumentada. Em A**,** vemos a placa antes do carregamento, e em B, a placa após passar por todo o forno. Em C, são mostrados os registros de temperatura nas faces inferior, superior e no centro da placa. Finalmente, em D, é exibida a diferença entre os valores medidos e os valores previstos pelos modelos A e B.

Figura 7 - Validação de modelos com placa instrumentada.

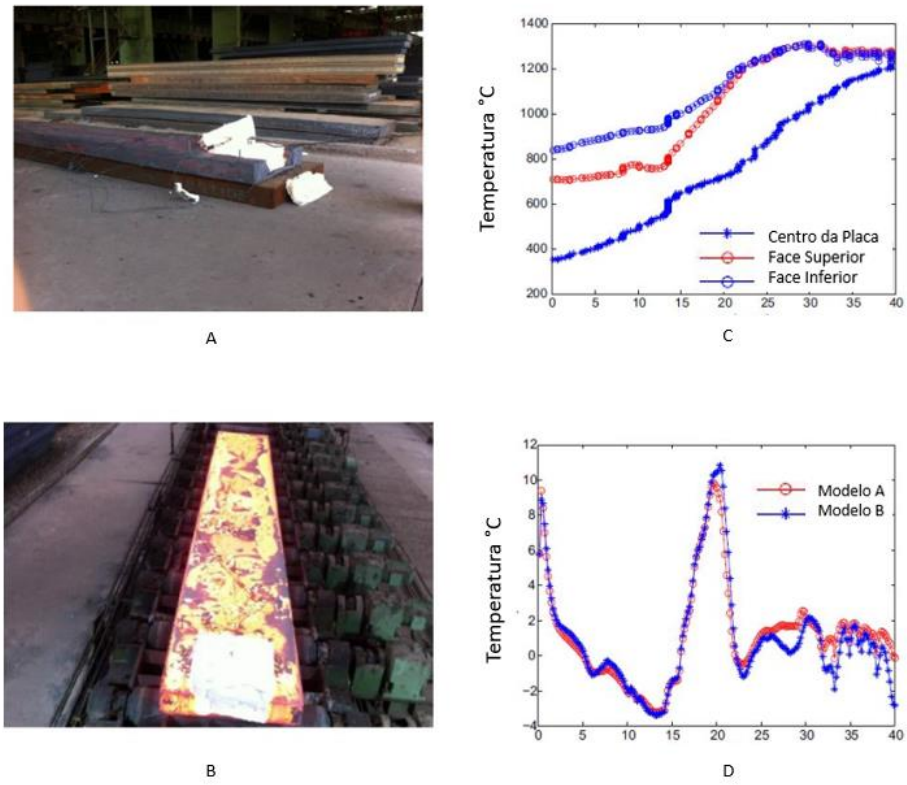

Fonte: Adaptado de Luo et al. 2017.

No entanto, em produção, a temperatura das placas não pode ser medida diretamente e são inferidas por modelos matemáticos de aquecimento. É difícil prever com precisão a temperatura das placas no interior de um forno de reaquecimento. Devido aos seguintes aspectos (LIAO; ZHAI, et. al, 2020).

- Complexidade do parâmetro. Existem muitos tipos de parâmetros de processo em forno, incluindo os parâmetros estruturais de aquecimento, parâmetros de controle, parâmetros térmicos etc., e os parâmetros têm forte acoplamento e influência mútua.
- Histerese de temperatura. O processo de aquecimento é não linear, sendo variável no tempo e retardado.
- Previsão multiobjetivo. O processo de aquecimento das placas em um forno passará por várias zonas de aquecimento, com diferentes objetivos térmicos. E ao mesmo tempo, há compartilhamento de parâmetros entre diferentes zonas de aquecimento.

A previsão precisa da temperatura do forno pode ser útil na solução do problema de otimização de um forno de reaquecimento. A otimização do reaquecimento busca sempre minimizar o consumo de combustível e a quantidade de incrustação na superfície das placas (oxidação), sob a condição de que o aquecimento seja uniforme, atendendo as temperaturas especificadas para laminação.

Segundo Zhai et. al., (2020) o objetivo fundamental da previsão da temperatura em forno de reaquecimento é estabelecer um modelo de aquecimento das placas, capaz de fornecer base de julgamento para a operação, manutenção e o próprio sistema de controle. Se a temperatura do forno pode ser prevista com exatidão, controladores avançados podem ser usados para realização de ajustes no sistema de forma manter a distribuição normal de combustível, minimizando custos, otimizando a eficiência aquecimento, reduzindo emissões de poluentes e aumentando a vida útil do forno. Uma proposta de arquitetura de controle baseado em modelo pode ser vista na figura 8, onde o modelo preditivo baseado em modelo é adicionado ao sistema de controle atual do forno estudado nesta pesquisa.

Figura 8 - Proposta de controle *MPC* para zonas On-Off.

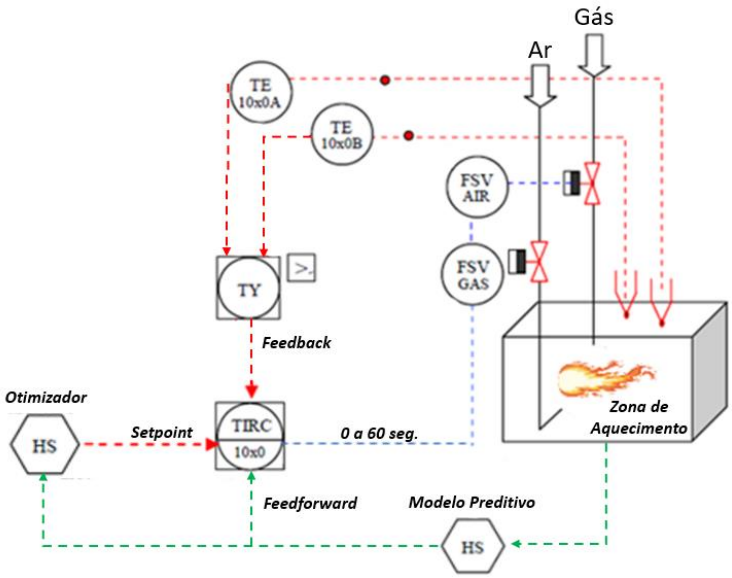

Fonte: Autoria própria, 2023.

Outra justificativa para realização da predição das temperaturas do forno de reaquecimento com dados do processo real, seria possibilidade da criação de um Gêmeo Digital, do inglês *Digital Twin*. Tal aplicação, tornaria o trabalho de pesquisa

em fornos de reaquecimento inovador, possibilitando o desenvolvimento de aplicativos que possam representar o funcionamento real de um forno de reaquecimento de placas. O Gêmeo Digital para Glaessgen et. al., (2019), pode ser considerado uma ferramenta poderosa para realização de testes operacionais off-line sem colocar em risco o processo real, abrindo uma série de oportunidades, como o uso de dados para antecipar a resposta de um mau funcionamento do sistema.

O forno de reaquecimento estudado utiliza queimadores on-off, o que representa um diferencial, já que, nesta aplicação, não há medições contínuas de vazão de ar e gás por queimador. Isso aumenta a complexidade da modelagem térmica das zonas de aquecimento. Queimadores on-off permitem um regime de queima ideal, maximizando o aproveitamento da energia, ao contrário dos fornos convencionais, onde a eficiência dos queimadores é menor quando operam abaixo da vazão projetada (MOREIRA; RAMPINELLI et al., 2019).

O gás siderúrgico utilizado como combustível para o forno em questão é uma mistura de gases oriundos do próprio processo industrial. No caso do gás proveniente da coqueria (COG), a limpeza inclui a remoção de poeira, alcatrão, naftaleno, óleo leve, compostos sulfurosos e o craqueamento de amônia no hidrogênio (ROSADO, 2020). A limpeza do gás nem sempre é efetiva, gerando um efeito danoso ao sistema de combustão. Ao longo do tempo, observa-se uma perda de capacidade de vazão devida as obstruções nas tubulações e componentes da linha de gás. Este problema ocasiona alteração no ponto de operação do queimador e desbalanço da relação Ar/Gás, afetando diretamente a capacidade de entrega de energia térmica as zonas de aquecimento.

A percepção da perda de capacidade de vazão é sempre reativa, pois atualmente não há nenhum sistema dinâmico para detecção. Portanto, é de grande interesse a predição das temperaturas das zonas de controle por modelos computacionais, pois indiretamente podem ser úteis para detecção dessas anomalias no sistema de combustão.

.

1.3 ORGANIZAÇÃO DO TRABALHO

Esta dissertação foi organizada em cinco capítulos conforme descrição baixo:

O capítulo inicial apresenta uma introdução e contextualização sobre o assunto abordado, sua importância e relevância, e apresenta os objetivos traçados para execução do trabalho.

O segundo capítulo apresenta o referencial teórico necessário, incluindo uma revisão bibliográfica sobre a aplicação de redes neurais a problemas similares, especificamente a predição de temperatura em fornos de reaquecimento de placas de aço.

O terceiro capítulo descreve o desenvolvimento do trabalho de pesquisa, incluindo a metodologia utilizada, a construção do banco de dados e o processo de escolha da técnica de predição mais adequada ao problema em questão.

Já o quarto capítulo apresenta a discussão dos resultados encontrados nas diversas etapas de desenvolvimento do trabalho, mostrando a eficiência dos modelos de predição das temperaturas nas zonas de aquecimento e os pontos de melhorias encontrados.

No quinto e último capítulo temos as conclusões e considerações finais e sugestões para trabalhos futuros.

Por fim, as referências utilizadas de trabalhos relacionados que contribuíram para o entendimento e sucesso no trabalho proposto.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo, será apresentada uma visão técnica, com base em estudos científicos, sobre fornos de reaquecimento de placas de aço e sobre redes neurais artificias. O objetivo é preparar o leitor para uma compreensão dos capítulos seguintes e abordar o estado da arte das produções acadêmicas recentes sobre o tema.

2.1 FORNOS DE REAQUECIMENTO EM SIDERURGIA

O primeiro objetivo do forno de reaquecimento é aquecer a carga de aço existente no seu interior, cujos formatos podem ser: tarugos, blocos ou placas, obedecendo a certos requisitos de qualidade, otimizando custos e temperaturas de laminação, atingindo o ponto adequado para a deformação plástica do aço e, portanto, para processamento seguinte no laminador.

2.1.1 Classificação dos fornos industriais

Os fornos de reaquecimento podem ser classificados como contínuos, quando a carga é deslocada no seu interior por ação de empurradores ou vigas móveis que transportam o material a ser aquecido, ou como intermitentes, quando o material é carregado e permanece estacionário sobre a soleira até atingir a temperatura de laminação ou forjamento (TRINKS et al., 2004).

Fornos do tipo intermitentes são usados principalmente para reaquecer materiais de formatos especiais, enquanto os fornos do tipo contínuo são geralmente aplicados para produção em massa, como o Forno Empurrador (figura. 9) e o Forno de Viga Móvel (figura 10), nome dado a caraterística de transporte da carga em seu interior.

Figura 9 - Forno tipo empurrador (Pusher).

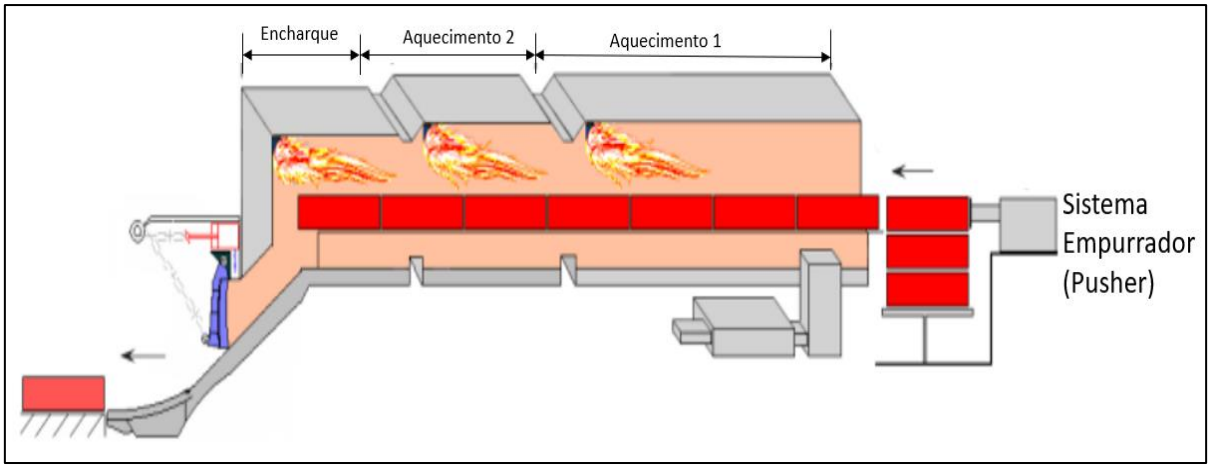

Fonte: Adaptado de Feliu, et. al., (2013).

Figura 10 - Forno tipo vigas móveis (Walking Beam).

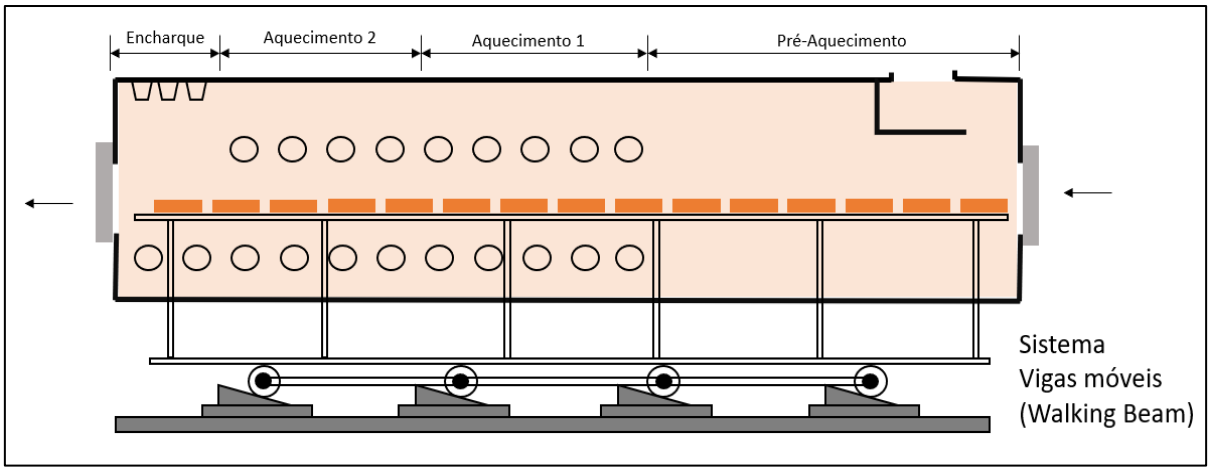

Autor: Autoria própria, 2023.

Nos fornos com tecnologia de vigas móveis, característica do forno do presente estudo, as placas são depositadas nas vigas fixas, no ato do carregamento, e posteriormente içadas e movimentas para frente pelas vigas móveis, as quais se movimentam em um ciclo retangular. As etapas do processo são descritas a seguir e são ilustradas na figura 11. Condição inicial: Vigas fixas e moveis alinhadas.

I. Movimento de elevação, ao fim a carga estará suspensa pelas vigas móveis;

II. Movimento de translação, ao fim a carga estará ainda suspensa, mas avançada;

III. Movimento de descida, a carga que foi avançada será depositada na viga fixa;

IV. Movimento de recuo, viga móvel sem contato com a carga retorna para condição inicial.

Figura 11 - Ciclo de movimentação das vigas móveis.

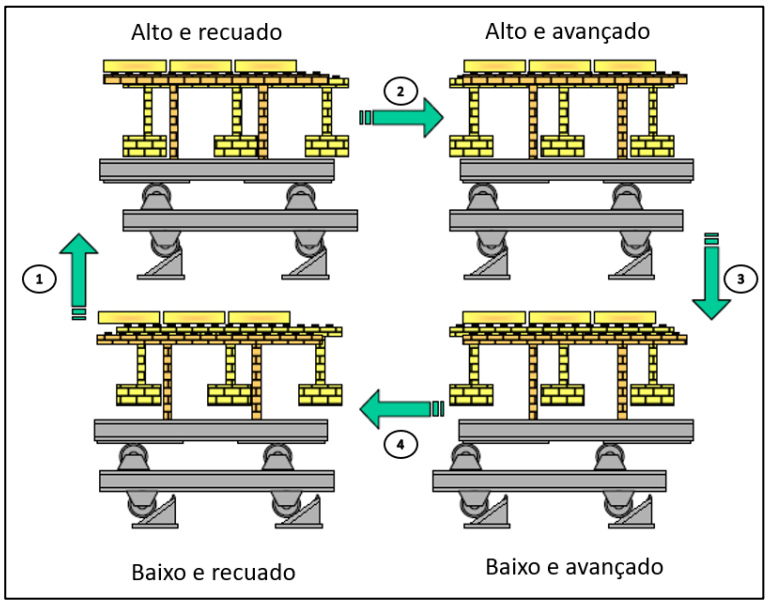

Fonte: AMT, 2022.

A carga é movimentada ao longo do forno, que é dividido por zonas de controle de aquecimento com objetivos térmicos independentes e graduais. Desta forma, assim que as placas passarem por cada zona ao longo do forno, elas serão progressivamente aquecidas até a temperatura de descarga desejada. A figura 12, mostra uma visão lateral do interior de um forno de reaquecimento de placas tipo vigas móveis.

Figura 12 - Vista do interior de um forno tipo viga móvel.

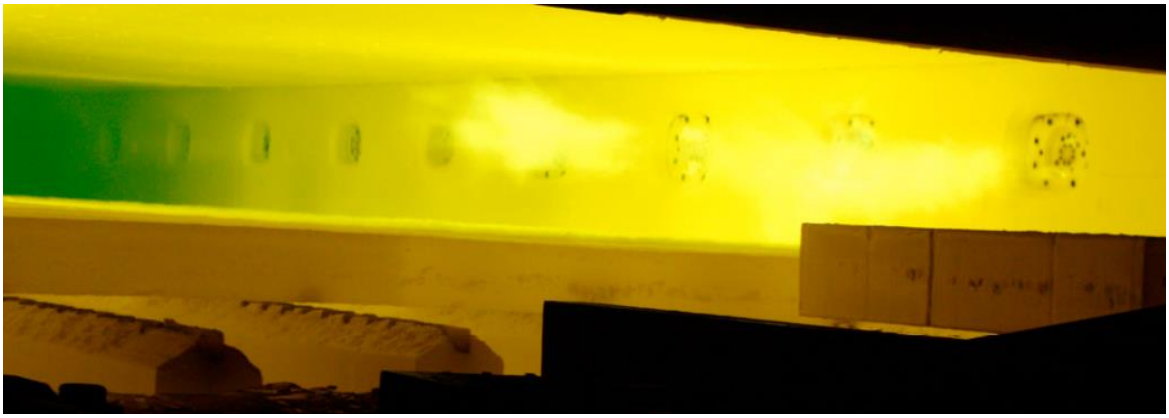

Fonte: Caillat et al., 2019.

2.1.2 Geometria e principais componentes

Várias geometrias de fornos de reaquecimento e disposição dos queimadores têm sido usadas durante as últimas décadas, conforme observado na figura 13. Nos fornos recentes, destaque para os fornos tipo viga móvel, a tendência é alongar a zona de pré-aquecimento para melhor eficiência térmica. Nesta zona sem queimadores, os gases de combustão quentes são usados para pré-aquecer os produtos e, em seguida, a energia residual dos gases é usada para aquecer o ar de combustão (CAILLAT, 2017).

Figura 13 - Evolução da geometria dos fornos de reaquecimento contínuos.

Ano	Comprimento máximo	Descrição	Visão esquemática
1970	~35 m	Forno empurrador, queimadores frontais	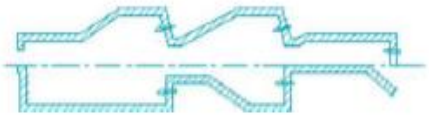
1975 – 1980	~40 m	Forno de viga caminhante, queimadores frontais, laterais e de teto	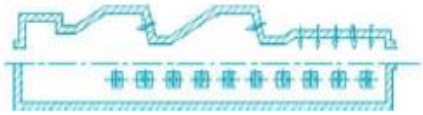
1985 – 1990	50/55 m	Forno de viga caminhante, queimadores frontais e de teto	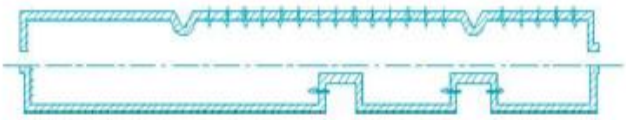
1990 – 1998	50/55 m	Forno de viga caminhante, queimadores frontais e de teto	
Desde 1995	~60 m	Forno de viga caminhante, queimadores laterais	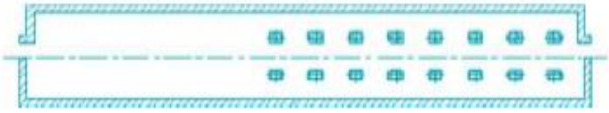

Fonte: Calliat; Marinos (2021).

Segundo o guia de boas práticas de Fornos de Reaquecimento publicado por *The Energy Technology Support Uni*t (ETSU, 1993). Os principais componentes de um forno de consistem em:

- Câmara construída com materiais refratários e isolantes para reter o calor nas altas temperaturas de operação;
- Estrutura para suportar e transportar a carga. Isso pode consistir em materiais metálicos revestidos por isolante refratário que podem ser refrigerados a água;
- Conjunto de queimadores que pode usar combustível sólido, líquido ou gasoso, para elevar e manter a temperatura na câmara;
- Sistema de exaustão para remoção dos gases da combustão da câmara;
- Sistema de refrigeração das partes metálicas internas do forno, exemplo vigas de transporte;
- Sistemas para a introdução e remoção das placas ou tarugos de aço do forno. Os sistemas comuns incluem mesas de rolos, transportadores, máquinas de carregamento de descarregamento e empurradores.
- Sistema de recuperação de calor, normalmente usados para aquecer o ar que será usado na combustão.

2.1.3 Processo de reaquecimento em fornos

Na prática do forno, o calor é transferido por três modos - condução, convecção e radiação. A combustão, como a usada em fornos industriais, vem de processos químicos, conversão de energia química em calor sensível. A transferência de calor por condução é rara em fornos industriais. O calor transferido para carga por meio de condução, ocorre no movimento dos gases quentes sobre a superfície da carga. Já o mecanismo da radiação é predominante.

Em termos simples, o calor é transferido por: radiação da chama, produtos quentes da combustão, paredes e teto do forno. Baseado nas equações regentes de transferência de calor é possível modelar o comportamento térmico do aquecimento das placas de aço, na maioria das vezes, o problema de condução de calor é resolvido por meio do método de diferenças finitas (GORNI, et.al., 2000).

Segundo Steinboeck et. al., (2010), o perfil de temperatura dentro das placas pode ser modelado de forma unidimensional na direção vertical *y.* Modelos matemáticos bidimensionais também são amplamente aplicados, levando em consideração as coordenadas espaciais *y* e *z*. Considerando que as variáveis do modelo são assumidas como invariantes em relação a coordenada x. As coordenadas geométricas de uma placa de aço, aplicáveis a modelagem numérica do processo transferência de calor, podem serem vistas na figura 14.

Figura 14 - Geometria espacial aplicável na transferência de calor para placa.

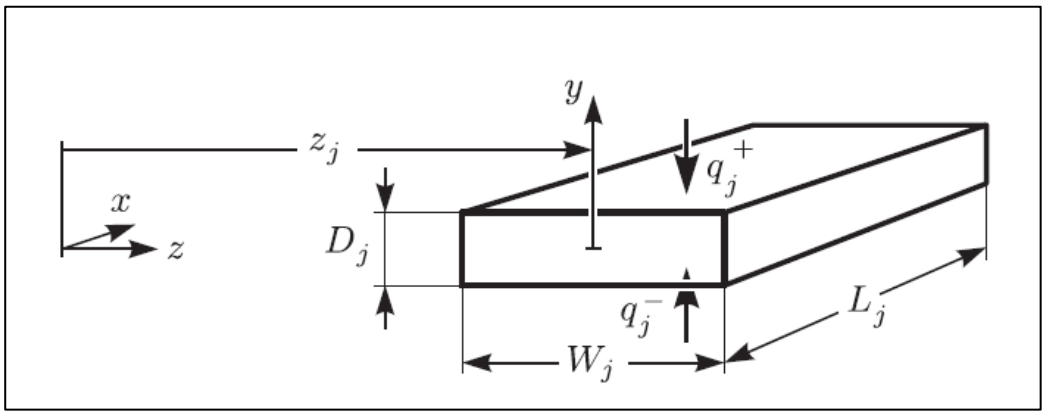

Fonte: Steinboeck et. al., 2010.

Modelos tridimensionais também são aplicados para avaliação do problema de transferência de calor em placas de aço. Jang et. al., (2016) apresentaram um modelo matemático tridimensional de transferência de calor transiente para a previsão da distribuição de temperatura dentro da placa considerando a radiação térmica na câmara de um forno de reaquecimento do tipo viga móvel.

2.1.3.1 Zonas de aquecimento

Os fornos de reaquecimento contínuos, normalmente, possuem três zonas de aquecimento, sendo ainda possível ser subdivididas em zonas superiores e inferiores. A figura 15 exemplifica um formato típico de zonas de aquecimento de um forno tipo vigas caminhantes. A elevação da temperatura ocorre de forma gradual ao longo do forno, onde cada zona de aquecimento tem o seu objetivo térmico. Podemos destacar as principias características das zonas de aquecimento sendo:

- A zona de pré-aquecimento ou zona convectiva, é caracterizada pela ausência de queimadores, onde o aquecimento inicia-se por convecção, devido ao contato da carga com os gases quentes, que fluem contra o sentido da carga, provenientes das zonas posteriores.

- A zona de aquecimento é responsável por elevar a temperatura da carga próxima da temperatura final desejada. Nesta região o material é aquecido principalmente por radiação proveniente das chamas dos queimadores. Em alguns fornos, dependendo da capacidade de produção, essa zona pode ser dívida em aquecimento 01 e 02.

- Na zona de encharque ou homogeneização, o objetivo é garantir que a temperatura da carga seja homogênea em todo seu volume. Assim como na zona de aquecimento, nessa etapa a troca térmica ocorre por convecção e radiação.

Figura 15 - Distribuição das zonas de um forno de reaquecimento.

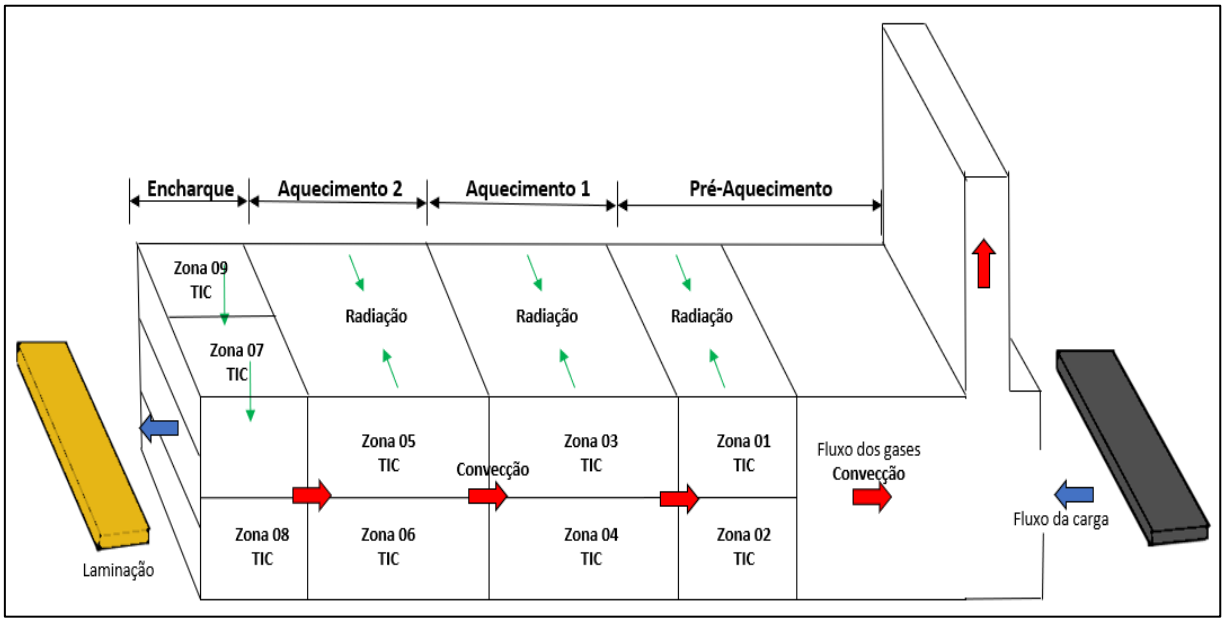

Fonte: Autoria própria, 2023.

2.1.3.2 Medição da Temperatura

Os termopares são mais comumente usados para medição e controle de temperatura. Conhecidos também como sensores termoelétricos, os termopares são constituídos por dois metais distintos, unidos nas suas extremidades. Os termopares respondem rapidamente e são capazes de operar em uma ampla faixa de temperatura com precisão aceitável. São normalmente posicionados no teto do forno ou, em alguns casos, na parede lateral ou soleira, mas longe da influência direta de queimadores, dutos de exaustão e portas. É prática normal usar uma bainha de proteção cerâmica ou metálica para proteger o elemento sensor da atmosfera do forno. Modelos típicos de termopares aplicados em fornos são apresentados na tabela 1.

Tabela 1 - Tipos de termopares aplicados em fornos de reaquecimento.

Tipo	Elemento Sensor	Faixa de medição (°C)
R	$\mathrm{Pt{+}13\%Rh - Pt}$	$0 \sim 1600$
S	$\mathrm{Pt{+}10\%Rh - Pt}$	$0 \sim 1550$
T	$\mathrm{Pt{+}30\%Rh - Pt{+}6\%Rh}$	$100 \sim 1600$
K	$\mathrm{NiCr - NiAl}$	$0 \sim 1100$

Fonte: Adaptado de ETSU, 2000.

2.1.3.3 Queimadores

São equipamentos destinados a promover uma mistura entre o combustível e o ar de combustão, proporcionando uma queima contínua e eficiente da mistura. Em fornos de reaquecimento os queimadores são distribuídos nas laterais e teto, no caso da zona de encharque. Há aplicações onde os queimadores podem ter em sua forma construtiva, mecanismos de ajuste do comprimento da chama, vide figura 16. Os queimadores de chama modulável proporcionam uma melhor distribuição do calor ao longo da largura do forno, permitindo que o sistema de controle de aquecimento possa corrigir a homogeneidade térmica entre topo, centro e base do material a ser aquecido.

Figura 16 - Tipo de queimadores.

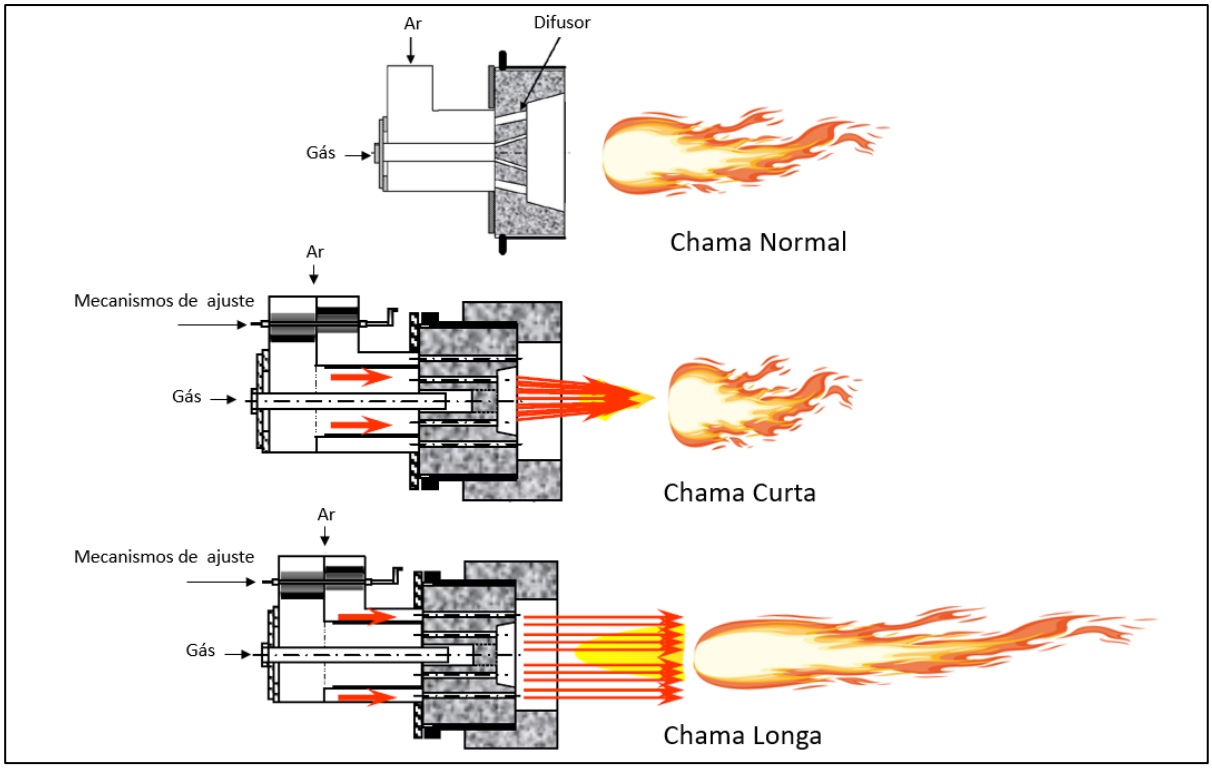

Fonte: Adaptado de AMT,2023.

A função primária de um sistema de controle da combustão é variar o calor de entrada de forma a manter a temperatura desejada. O calor de entrada é ajustado basicamente por dois métodos: amplitude ou frequência modulada (CADENA et al., 2017).

- Controle por modulação da amplitude**:** O método de controle por amplitude modulada, os queimadores são regulados entre alta e baixa chama de uma forma continuamente variável. Neste tipo de controle, o fluxo é variável de forma a ajustar as quantidades de combustível e de ar que irão para o queimador.

- Controle por frequência modulada (Pulso): Na técnica de frequência modulada (chama por pulso), os queimadores são comutados entre dois estados e um ciclo padrão controla os queimadores e consequentemente a entrada de calor para o processo. A demanda de calor de entrada determina o ciclo imposto, que é o tempo em que o queimador estará ligado ou desligado.

A figura 17 exemplifica graficamente os dois procedimentos comumente aplicados no acionamento das válvulas de controle para liberação do ar e gás para um queimador industrial.

Figura 17 - Compara em modulação de amplitude e frequência.

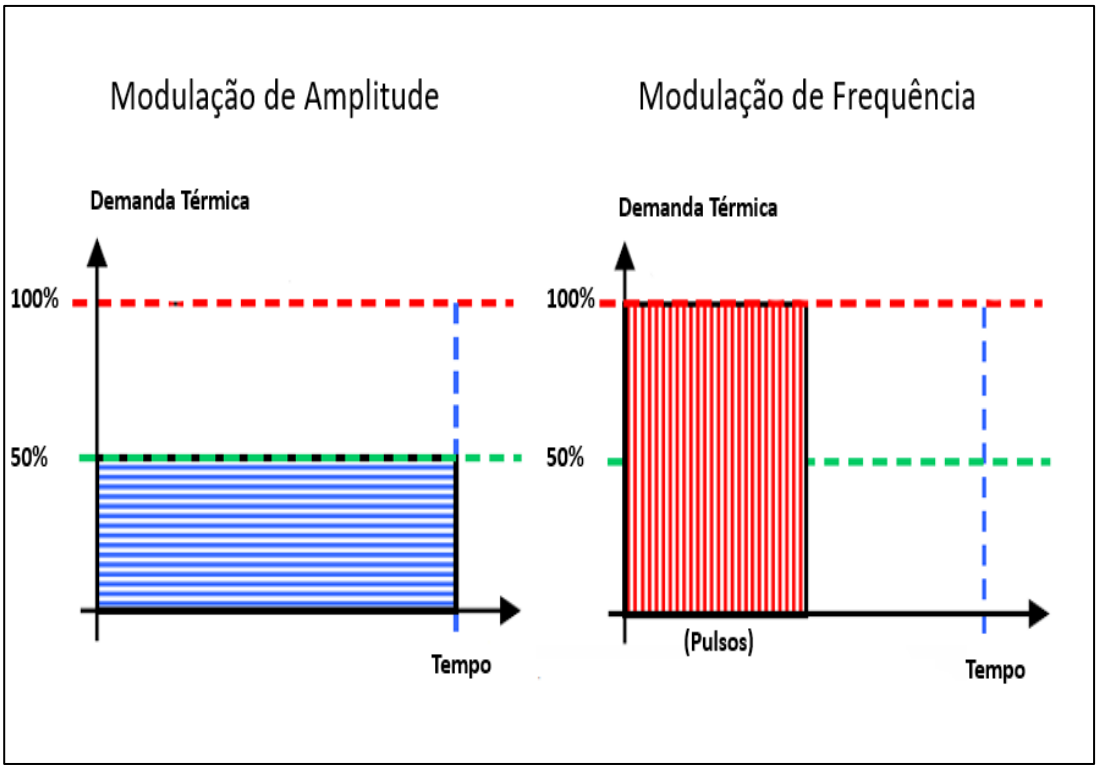

Fonte: Adaptado de AMT, 2023.

2.1.3.4 Controle do aquecimento

A operação de um forno de reaquecimento é conduzida pelo controle da planta, que define a ordem do material a ser aquecido, seu movimento, e seu perfil de temperatura final desejado. Usualmente, o processo de aquecimento é realizado por modelos de otimização, que controlam a potência aplicada em cada zona de aquecimento, objetivando a temperatura de extração visada, a uniformidade de aquecimento exigida, menor consumo específico possível de combustível e perda metálica por oxidação mínima (STEINBOECK et al., 2010).

A apresentação de uma estrutura em níveis de automação aplicado ao processo de controle do aquecimento pode ser vista na figura 18. Basicamente, o sistema de otimização de nível 02 controla os sistemas secundários de nível 01, que estão integrados aos comandos de abertura de queimadores e ritmo do deslocamento das placas no interior do forno. Outros sistemas como gerenciamento e controle da laminação, são aplicados com proposito de gestão e rastreamento.

Figura 18 - Exemplo de hierarquia do controle em fornos de reaquecimento.

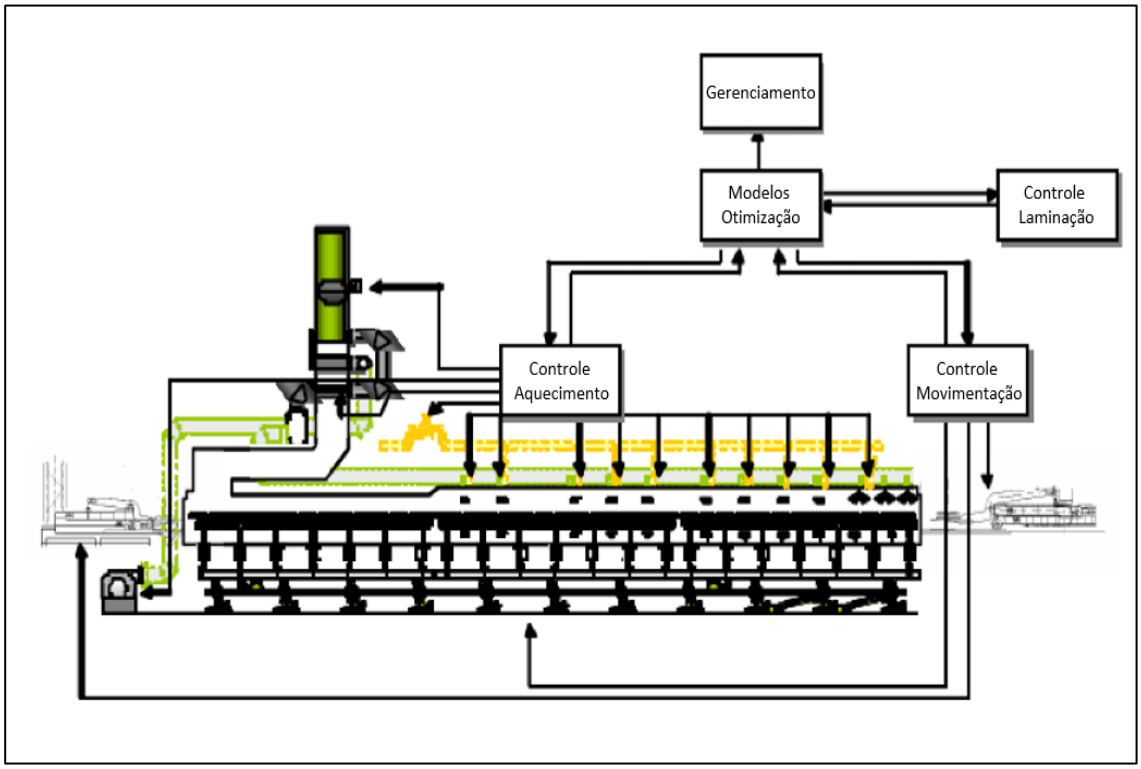

Fonte: Adaptado de AMT, 2009.

Em cada zona de aquecimento do forno, as variações das temperaturas são medidas por sensores do tipo termopares e enviadas ao modelo térmico, que estima a temperatura de cada produto existente dentro do forno, exemplo figura 19. Assim, o sistema de controle é realimentado com a necessidade de aplicação ou não de potência térmica nas zonas de aquecimento. A referência de temperatura desejada para cada placa é chamada de curva de aquecimento e pode variar devido as propriedades metalúrgicas das placas, temperatura de enfornamento, potência disponível etc.

Figura 19 - Típico de sistema de controle térmico em fornos de reaquecimento.

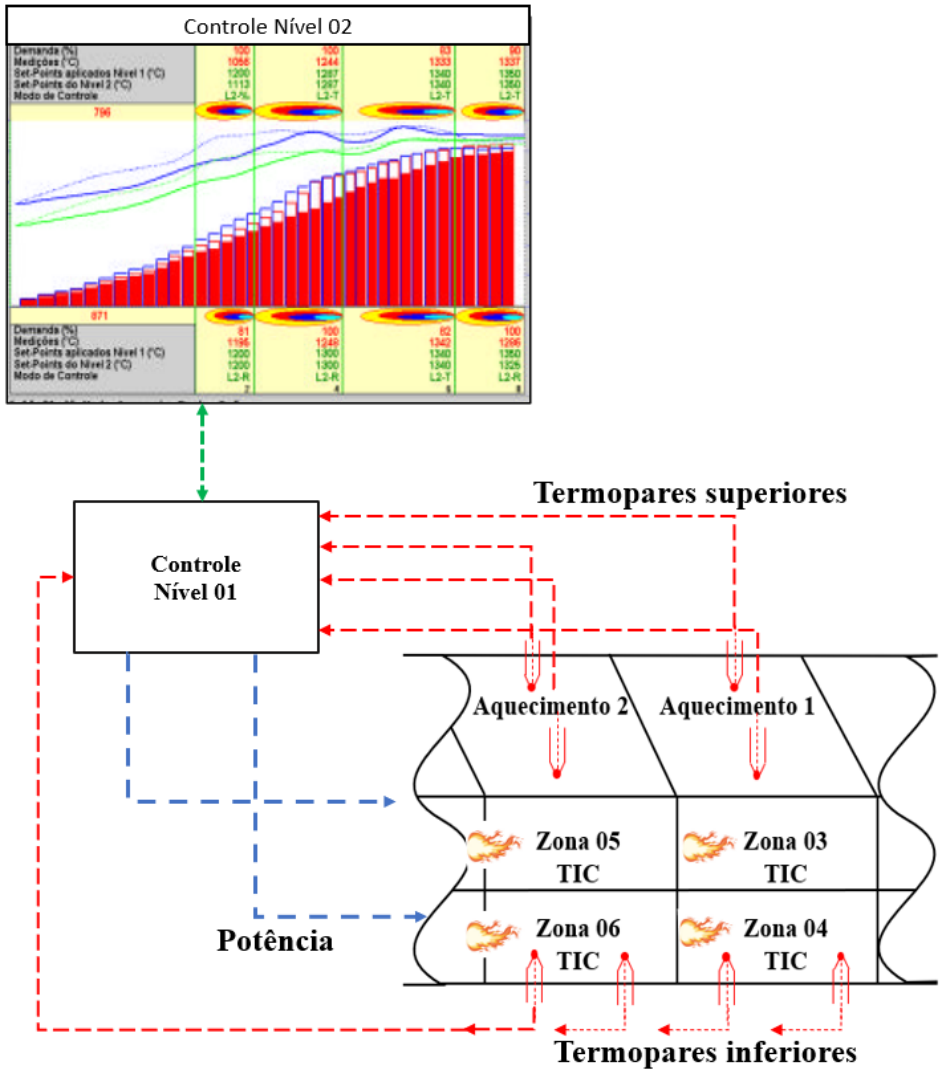

Fonte: Autoria própria, 2023.

2.2 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais podem ser definidas como um modelo computacional inspirado no funcionamento do neurônio biológico. O cérebro humano contém bilhões de estruturas simples de processamento, denominadas de neurônios, onde cada um deles está conectado a centenas de outros. Os neurônios têm três componentes principais: os dendritos, corpo celular e axônio. Os dendritos são os numerosos prolongamentos dos neurônios que atuam como receptores de estímulos em forma de redes de fibras nervosas que transportam sinais elétricos para o corpo celular. O corpo celular efetivamente soma e limita esses sinais de entrada. O axônio é uma única fibra longa que transporta o sinal do corpo celular para outros neurônios. O ponto de contato entre um axônio de uma célula e um dendrito de outra célula é chamada de sinapse. A disposição dos neurônios e as forças das sinapses individuais, é determinada por um processo químico complexo que estabelece a função da rede neural (Hagan et. al., 2014).

2.2.1 Neurônio Artificial

Um neurônio é uma unidade de processamento de informações que é fundamental para a operação de uma rede neural. A rede neural artificial mais simples é chamada de *Perceptron*, sendo constituída de *n* sinais de entrada e somente uma saída, pois este tipo de rede é composto de um único neurônio. A arquitetura do *Perceptron* é apresentada na figura 20.

Figura 20 - Modelo não linear de um neurônio, rotulado com k.

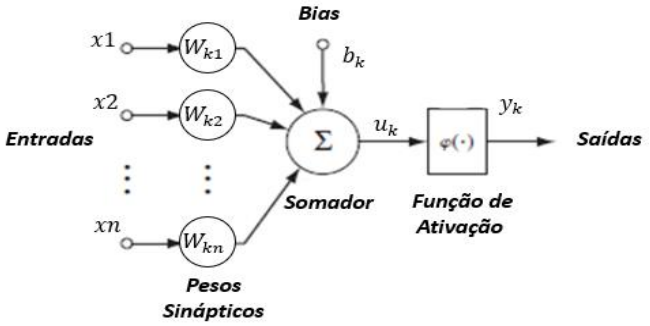

Fonte: Adaptado de Haykin, 2009.

Onde as entradas $\{x_1, x_2, \dots x_n\}$, serão inicialmente ajustadas pelos pesos sinápticos $\{w_{k1}, w_{k2}, \dots w_{kn}\}$ a fim de quantificar a importância de cada uma delas frente aos objetivos funcionais atribuídos ao neurônio, onde o propósito será mapear o comportamento da entrada em relação a saída do referido processo. O valor resultante da composição de todas as entradas já devidamente ponderadas pelos seus respectivos pesos $\{u_k\}$, entrarão em uma função de ativação $\{\varphi\}$, cujo resultado de retorno será a saída $\{y_k\}$. Normalmente, a faixa de amplitude normalizada da saída de um neurônio artificial é escrita como o intervalo unitário fechado $\{0,1\}$, ou, alternativamente, $\{-1,1\}$. O bias $\{b_k\}$, tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação (Haykin, 2009). Em termos matemáticos, o processamento interno realizado pelo *Perceptron* pode ser descrito pelas seguintes expressões:

$$u_k = \sum_{j=1}^{n} w_{kj}.x_j \tag{2.3.1}$$

sendo,

$$y_k = \varphi(u_k + b_k) \tag{2.3.2}$$

A função de ativação denotada por $\varphi(u)$, permite um grau de liberdade extra, podendo dotar um neurônio de comportamento não linear. Mesmo que não seja aplicada função de ativação, o termo $u_k + b_k$, já é um processamento da entrada x_j. As funções de ativação básicas podem ser definidas como:

1. Função limiar, conhecida também como função *Heaviside*, descrita por:

$$\varphi(u) = \begin{cases} 1, & se\ u \geq 0 \\ 0, & se\ u < 0 \end{cases} \tag{2.3.3}$$

2. Função sigmoide. Definida como uma função estritamente crescente que exibe um equilíbrio harmonioso entre comportamento linear e não linear, definida por:

$$\varphi(u) = \frac{1}{1 + e^{-au}} \tag{2.3.4}$$

em que, a é o parâmetro de inclinação da função sigmoide. Uma função sigmoide assume um intervalo contínuo de valores de 0 a 1.

3. Função Tangente Hiperbólica. Às vezes é desejável que a função de ativação adote valores dentro do intervalo contínuo de -1 a 1. Para isso, é aplicado como função a tangente hiperbólica, conforme equação 2.3.5.

$$\varphi(u) = \frac{e^{u} - e^{-u}}{e^{u} + e^{-u}} \tag{2.3.5}$$

A rede perceptron pertence à arquitetura feedforward de camada única, pois o fluxo de informações em sua estrutura reside sempre no sentido da camada de entrada em direção à camada neural de saída, inexistindo-se qualquer tipo de realimentação de valores produzidos pelo seu único neurônio. Embora seja uma rede simples, o perceptron teve o potencial de atrair, quando de sua proposição, diversos pesquisadores que aspiravam investigar essa promissora área de pesquisa para a época, recebendo-se ainda especial atenção da comunidade científica que também trabalhava com inteligência artificial (Silvas. et. al., 2016).

2.2.2 Redes Neurais MLP (*Multilayer Perceptron)*

O estudo das redes neurais artificiais iniciou-se com descoberta do neurônio artificial, porém logo foi percebido que a rede perceptron era incapaz de solucionar problemas que não fossem linearmente separados, tornando esse tipo de rede limitada, por não serem capazes de modelar funções complexas (Silva, et al., 2016). Com os avanços das pesquisas sobre o assunto foi idealizada a estrutura dos perceptron em multicamadas ou *Multilayer Perceptron* (MLP). Uma rede neural artificial multicamada, conhecida também por rede *feedforward,* se distingue pela presença de uma ou mais camadas ocultas, sem laços de realimentação, em que os neurônios de uma camada se conectam a todos os neurônios da camada seguinte, agindo como dados de entrada daquela camada, vide figura 21.

Figura 21 - Arquitetura MLP com uma camada oculta de neurônios.

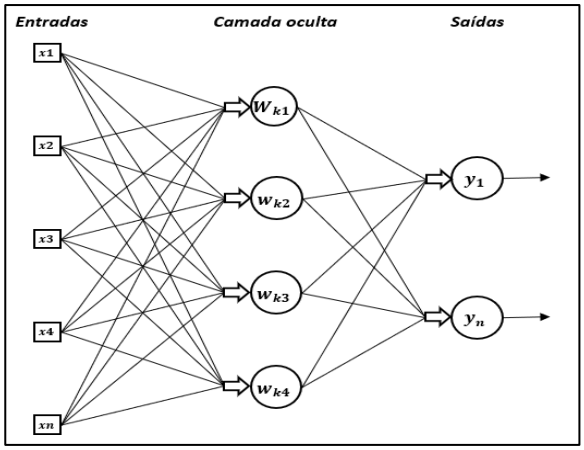

Fonte: Adaptado de Haykin, 2009.

As redes MLP são caracterizadas pelas elevadas possibilidades de aplicações em diversos tipos de problemas relacionados com as mais diferentes áreas do conhecimento, sendo também consideradas uma das arquiteturas mais versáteis quanto à aplicabilidade. Todavia, essa topologia de rede não tem nenhum tipo de ciclo dentro da sua estrutura, por causa da característica de transportar a informação em apenas uma direção, partindo da primeira até última camada (Rojas, 2013).

Processo de aprendizado da rede MLP

O algoritmo de aprendizado supervisionado comumente aplicado em redes neurais é o algoritmo Backpropagation, técnica baseado na retropropagação do erro. O processo de aprendizado de uma rede MLP é efetuado utilizando-se o treinamento supervisionado, isto é, para cada amostra dos dados de treinamento de entrada obtém-se a respectiva saída desejada. Os ajustes dos pesos sinápticos e dos limiares de cada um dos neurônios devem ser realizados de forma que a rede seja capaz de convergir, ou seja, aprender os padrões existentes nos dados apresentado para treinamento e ser generalista, respondendo corretamente a novos padrões apresentados, sendo a capacidade de generalização o principal objeto do treinamento.

No processo de treinamento, uma amostra do conjunto de treinamento é apresentada nas entradas da rede e é propagada camada a camada até a produção das

respectivas saídas (*forward)*. Os erros entre as respostas produzidas pelas saídas da rede em relação as respostas desejadas, são calculados. De posse do erro, aplica-se a fase backpropagation, denominada propagação reversa do erro” (*backward*). Nesta etapa os pesos sinápticos e limiares de todos os neurônios da rede são ajustados. Assim, sucessivas aplicações das fases *forward* e *backward* fazem com que os pesos sinápticos e limiares dos neurônios se ajustem automaticamente em cada iteração.

O processo de aprendizado baseado neste método tem como objetivo a atualização dos pesos sinápticos da rede, que é realizada por meio de funções de perda (*Loss Function*) conjugada com algoritmos de otimização, em que é avaliada a direção do erro e aplicado a quantidade do ajuste numérico necessária aos pesos dos neurônios da rede, buscando a minimização do erro, concedendo assim o aprendizado. Otimizadores como *SGD (Stochastic gradient descente), RMSProp (Root Mean Square Propagation)* e *ADAM*, que são otimizadores amplamente aplicados em sistemas de aprendizado de máquinas (DIEDERIK et. al., 2015).

2.2.3 Redes Neurais Temporais

Redes Neurais Temporais são redes neurais especializadas no processamento de dados sequenciais ou temporais. Ao contrário das redes tradicionais, que tratam entradas e saídas como independentes, as redes neurais recorrentes possuem conexões cíclicas, permitindo que informações de etapas anteriores sejam reutilizadas no processamento subsequente. Isso as torna ideais para tarefas como processamento de linguagem natural, reconhecimento de fala e análise de séries temporais. A seguir serão apresentadas técnicas utilizadas por essas redes neurais.

2.2.3.1 Recorrentes

Uma rede neural recorrente, do inglês *Recurrent Neural Network* (RNN), se distingue de uma rede neural *feedforward* MLP por possuir ao menos um *loop* de *feedback* em sua estrutura, característica que fornece a esse tipo de rede a capacidade de “memorização” de estado. É um tipo de rede neural artificial que usa dados

sequenciais ou dados de séries temporais e são comumente usadas para soluções de problemas ordinais ou temporais.

O princípio básico funcional de uma rede recorrente é descrita como: Para uma dada sequência $\{x = x_1, x_2, \dots x_t\}$ a RNN atualiza seu estado oculto recorrente $\{h_t\}$ por:

$$h_t = \begin{cases} 0, & t = o \\ \emptyset(h_{t-1}, x_t) \end{cases} \quad (2.3.6)$$

Tradicionalmente, a atualização do estado oculto recorrente é implementada como:

$$h_t = g(Wx_t + Uh_{t-1}) \quad (2.3.7)$$

Em que $\{g\}$ é uma função suave e limitada, como uma função sigmoide logística ou tangente hiperbólica. Uma unidade recorrente pode ser vista na figura 22.

Figura 22 - Unidade Neural Recorrente.

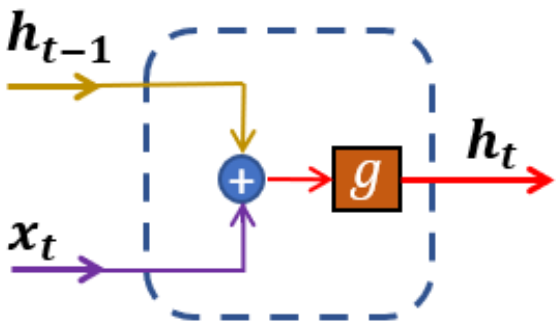

Fonte: Autoria própria, 2023.

Um design comum de redes neurais recorrentes, consiste em um padrão MLP mais *loops* adicionados, conforme visto na figura 23. Podendo explorar os poderosos recursos de mapeamento não linear do MLP e capacidade de memorização advindos dos loops. Isso viabiliza o processamento de aprendizado temporal, aprendendo sequências ou padrões e tornando-a capaz de realizar predições passos à frente.

Figura 23 - Rede Neural k com recorrência r_k.

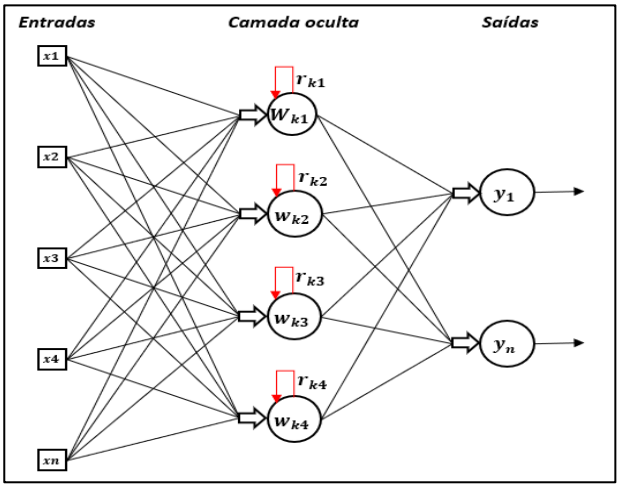

Fonte: Autoria própria, 2023.

O aprendizado das redes neurais recorrentes pode ser alcançado usando os procedimentos do gradiente descendente, semelhantes aos que levam à retropropagação do erro para as redes *feedforward* pura. Porém, Infelizmente, foi observado por Bengio et al. (1994), que é difícil treinar RNN para capturar dependências de longo prazo, devido ao fato de os gradientes tenderem ao desaparecimento (na maioria das vezes) ou explodirem e isso dificulta o método de otimização baseado em gradiente.

O problema de explosão do gradiente, acontece quando o gradiente do erro acumula em valores muito alto, gerando grandes alterações nos pesos sinápticos de modo a gerar a instabilidade. Já o desaparecimento ocorre quando o gradiente assume valores muito pequenos e irrelevantes, inviabilizando a atualização dos pesos nas camadas iniciais da rede, levando uma imprecisão geral. Este problema de gradientes desaparecendo torna difícil o aprendizado de dependências de longo prazo em algoritmos de treinamento baseados em gradiente (Haykin, 2009).

Em Bengio et al. (1994), argumenta-se que para muitas aplicações práticas, é necessário que uma rede recorrente seja capaz de armazenar informações de estado por uma duração arbitrária e fazê-lo na presença de ruído. Uma solução para o problema de dependência de longo prazo foi proposta com a rede neural de aprendizado profundo *"LSTM" (Long-Short Term Memory)*, em que unidades de

memória, chamadas células de estados, foram introduzidas em modelagem recorrente.

2.2.3.2 LSTM

Um desafio que afeta as *RNN's* é que os modelos acabaram sendo muito difíceis de treinar, devido ao problema do gradiente instável discutido anteriormente. Como solução do problema, foi possível incorporar uma ideia conhecida como unidades de memória de longo prazo LSTM em RNN. Esse tipo de rede neural especial foi introduzido por Hochreiter e Schmidhuber em 1997, com o propósito explícito de ajudar o problema do gradiente instável.

A rede de memória de longo prazo, geralmente chamadas apenas de LSTM é um tipo especial de rede recorrente, capaz de aprender ligações de longo prazo. Este tipo de rede recorrente tem a capacidade de armazenar quantidades de informações maiores, referente as entradas passadas, enquanto mantém a relevância de estados recentes.

Para isso, a LSTM faz uso de estados denominados como *cell state* e *hidden state*, que são responsáveis pelo transporte de informações por meio dos neurônios da rede. Basicamente, uma célula da rede LSTM é composta por uma unidade de memória de longo prazo e uma unidade de memória de curto prazo, em que essas "memorias", que são manipuladas por quatro camadas de rede neural que controlam quais informações devem ser memorizadas ou esquecidas. A figura 24 apresenta a arquitetura básica de uma célula LSTM.

Figura 24 - Célula LSTM.

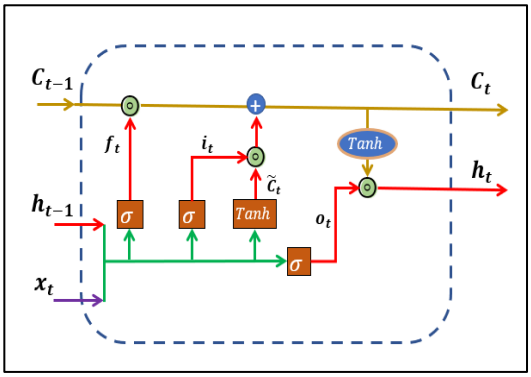

Fonte: Autoria própria, 2023.

Princípio de funcionamento

O ponto central das LSTMs é o estado da célula. A linha horizontal principal C_t que passa pela parte superior do diagrama é conhecida como memória de longo prazo e responsável por transportar o estado da célula, percorrendo toda a cadeia com apenas algumas interações lineares. As entradas das células, $\{x_t\}$ e $\{h_{t-1}\}$, são consideradas aumentadas, devido a concatenação das novas informações $\{x_t\}$ e a saída da célula anterior $\{h_{t-1}\}$. As interações das funções sigmoides e as operações de multiplicação de vetor, elemento a elemento, funcionam como portões, adicionando ou removendo informações ao estado da célula, atuando no *Forget Gate, Input Gate e Output Gate.*

Na parte inicial da célula temos o *Forget Gate* ou portão de esquecimento, em que a saída da rede neural sigmoide $\{f_t\}$ controla quais informações serão adicionadas a memória $\{C_t\}$.

$$f_t = \sigma(W_f.[h_{t-1}, x_t] + b_f) \tag{2.3.8}$$

Já na parte central, aparece a unidade *Input Gate* ou Portão de entrada, porém neste caso em especial a rede neural tangente hiperbólica $\{\widetilde{C_t}\}$, calcula um possível contexto e o *Input Gate* $\{i_t\}$ controla a adição, *Cell Update,* desse novo contexto a unidade de memória. As operações matemáticas $\{\odot\}$ descrevem uma multiplicação de vetores de elemento a elemento.

$$i_t = \sigma(W_i.[h_{t-1}, x_t] + b_i) \tag{2.3.9}$$

$$\widetilde{C_t} = tanh(W_C.[h_{t-1}, x_t] + b_C) \tag{2.3.10}$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \widetilde{C_t} \tag{2.3.11}$$

Por fim, o *Output Gate* $\{o_t\}$, controla as informações que seguem para saída $\{h_t\}$ e próxima entrada celular $\{h_{t-1}\}$.

$$o_t = \sigma(W_o.[h_{t-1}, x_t] + b_o) \tag{2.3.12}$$

Observa-se que a saída $\{h_t\}$ é o produto elemento a elemento do *Output Gate* com $\{C_t\}$, que é limitada por uma função tangente hiperbólica [-1,1], a fim de manter os cálculos controlados.

$$h_t = o_t \odot \tanh(C_t) \tag{2.3.13}$$

2.2.3.3 GRU

Um outro modelo de rede neural de aprendizado profundo *Gated Recurrent Unit* (GRU), assim como as LSTM, foi projetado, para resolver o problema do desaparecimento do gradiente que acontece nas RNN padrão, quando submetidas a dependências de longo tempo. A GRU usa os chamados portão de atualização e portão de reinicialização. Basicamente, são dois vetores que decidem quais informações devem ser passadas para a saída. O que há de especial neles é que podem ser treinados para guardar informações de muito tempo atrás, sem lavá-las no tempo ou remover informações irrelevantes para a previsão (Chung et. al., 2014).

Proposta por Cho et. al. (2014), a GRU faz com que cada unidade recorrente capture de forma adaptativa as dependências de diferentes escalas de tempo. O fluxo da informação é modulado pelos “portões” de forma similar as LSTMs, dentro da unidade celular, porém, sem possuir células de memória separadas. A figura 25 apresenta a arquitetura de uma célula GRU.

Figura 25 - Célula GRU.

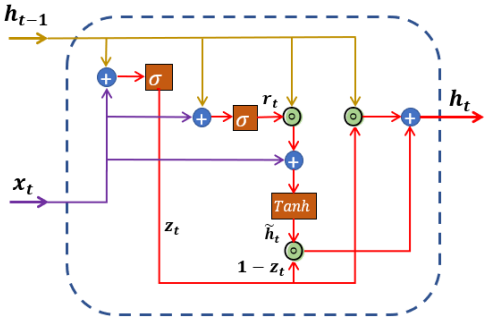

Fonte: Autoria própria, 2023.

As operações matemáticas do funcionamento interno da unidade recorrente GRU é apresentada abaixo. Calculando o portão de controle das atualizações da memória *Update Gate* $\{z_t\}$, temos:

$$z_t = \sigma(W_t x_t + U_t h_{t-1}) \tag{2.3.14}$$

Em que $\{x_t\}$ é a entrada de novas informações da rede e $\{h_{t-1}\}$ é a saída do estado anterior que contém as informações passadas. Ambos são multiplicados pelos seus respectivos pesos $\{W_t\}$ e $\{U_t\}$. O resultado é somado e em seguida é ativado por uma função sigmoide, compactando a saída $\{z_t\}$ entre 0 e 1. O *Update Gate* suporta a unidade celular determinado a quantidade de informações do passado que serão mantidas, eliminando o risco de desaparecimento do gradiente. Calculando o portão de controle de esquecimento (*Reset Gate)* $\{r_t\}$, temos:

$$r_t = \sigma(W_t x_t + U_t h_{t-1}) \tag{2.3.15}$$

A equação é similar a saída $\{z_t\}$ apresentada anteriormente, a diferença ocorre nos pesos $\{W_t\}$ e $\{U_t\}$ e no trabalho realizado dentro da célula. O portão $\{r_t\}$, será usado adiante como um controlador do fluxo de informação do estado anterior que será possível candidato a adição no estado atual.

Uma informação candidata a entrar na memória $\{\tilde{h}_t\}$, será calculada por uma rede neural com função ativação não linear tangente hiperbólica, baseada nas novas entradas $\{x_t\}$ e o portão de esquecimento, que por sua vez permitirá ou não que as informações do estado anterior sejam adicionadas no estado presente.

$$\tilde{h}_t = tanh(W x_t + U(r_t \odot h_{t-1})) \tag{2.16}$$

Por fim, a memória atual será $\{h_t\}$ será atualizada no *Update Memory*, por:

$$h_t = z_t \odot h_{t-1} + (1 - z_t) \odot h_t \tag{2.17}$$

2.2.3.4 Convolucional

As redes temporais convolucionais TCN (*Temporal Convolutional Network*) tem-se mostrado bastante eficiente em aplicações em que se deseja modelar tarefas sequenciais. Esse tipo de rede de aprendizado profunda, emprega circunvoluções e dilatações causais em sua estrutura, portanto, é adequado para dados sequenciais com temporalidade (XU et al., 2021).

Algumas características definem a rede TCN. Os cálculos são executados sem camadas, o que significa que cada passo de tempo é atualizado simultaneamente, em vez de atualizar sequencialmente por quadro. A arquitetura pode pegar uma sequência de qualquer comprimento e mapeá-la para uma sequência de saída do mesmo comprimento. As convoluções são causais, isso significa que não há “vazamento” de informação do futuro para o passado. O funcionamento de uma TCN é baseado em dois princípios: a rede neural usa uma arquitetura totalmente convolucional de uma dimensão (FCN-1D), do inglês *fully convolutional networks*, em que cada camada oculta é de mesmo comprimento que a camada de entrada BAI et. al., 2021. Uma máscara para preenchimentos com zeros é aplicada em cada camada oculta, de forma a manter as camadas subsequentes no mesmo comprimento das anteriores BAI et. al., 2018. Em resumo a rede TCN é a soma de FCN 1D + convoluções causais.

Uma rede totalmente convolucional introduz um estágio decodificador que consiste em um “*upsampling*”. O sinal interpolado é então combinado com o sinal correspondente no codificador que tem a mesma taxa, conforme figura 26. Isso permite a rede produzir uma saída cujas dimensões correspondam às dimensões de entrada. Esta técnica é comumente aplicada em processo de segmentação de imagens.

Figura 26 - Exemplo de rede convolucional totalmente conectada.

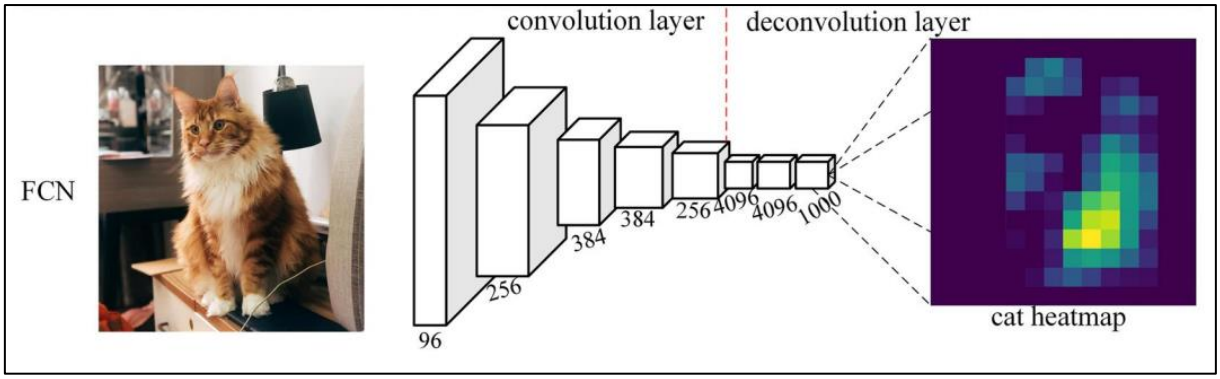

Fonte: Lea et. al., 2020.

A expertise das TCN está na aplicação de convolução dilatada, que é uma convolução em que um filtro é aplicado sobre uma área maior que seu comprimento, pulando valores de entrada com uma certa etapa, garantindo que a rede cubra mais informações com o aumento do tamanho do campo receptivo. A figura 27 apresenta uma comparação entre a convolução causal e convolução causal com dilatação.

Figura 27 - Exemplo de convolução com e sem dilatação.

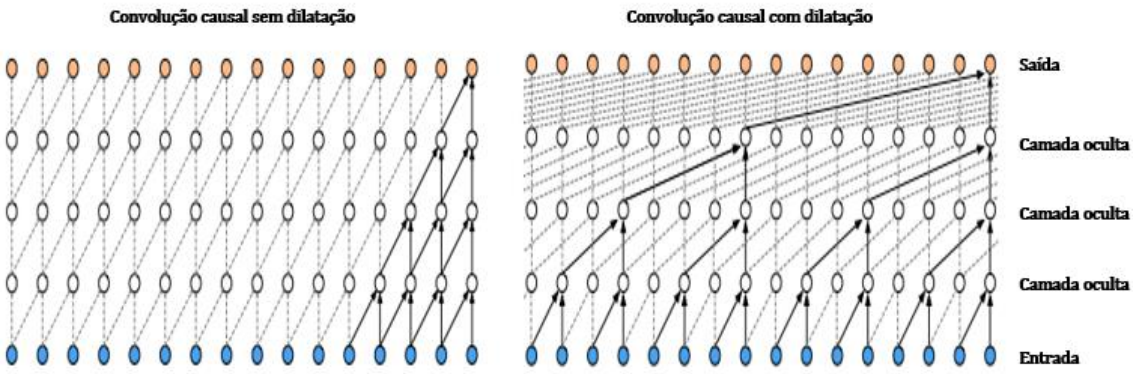

Fonte: Adaptado de Oord et al. 2016

Segundo os trabalhos de Oord, Hashempour et al. 2022, as convoluções dilatadas resultam no crescimento exponencial do campo receptivo com apenas algumas camadas, ou seja, a quantidade de atrasos que a rede consegue ver para prever sua saída, preservando a resolução de entrada em toda rede, bem como a eficiência computacional. Formalmente, para uma sequência unidimensional de entrada $\{x\} \in \mathbb{R}^n$ e um filtro $f: \{0, \dots, k-1\} \rightarrow \mathbb{R}$, o operador $\{F\}$ da convolução dilatada aplicado a sequência {s} pode ser definido como (10):

$$F(s) = (x *_d f)(s) = \sum_{i=0}^{k-1} f(i).x_{s-d.i} \quad (2.18)$$

Onde, d é o fator de dilatação, k é o tamanho do filtro, e $s - d.i$ explica a direção que a convolução será aplicada. Se d for igual a 1 a convolução dilatada se reduz a uma convolução regular. O campo receptivo na TCN está diretamente ligado à profundidade da rede, assim como o tamanho do filtro e o fator de dilatação. Para evitar que a estrutura de rede mais profunda complique o processo de aprendizagem, uma conexão residual é adicionada à saída (HE et al., 2016). Como a entrada e a saída podem ter larguras diferentes, o resíduo conectado usa uma convolução 1x1 para garantir que a operação de adição receba os mesmos tensores (POLLHAMMER et. al. 2017). A figura 28 apresenta um exemplo de bloco residual com convolução dilatada.

Figura 28 - Convolução causal dilatada empregada no bloco residual.

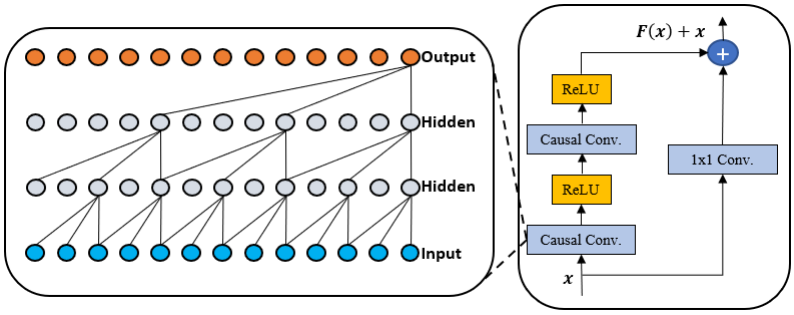

Fonte: Adaptado de XÓ et al., 2021.

A Unidade Linear Retificada (ReLU), é uma função de ativação que retorna 0 se receber qualquer entrada negativa, mas para qualquer valor positivo $\{x\}$ ele retorna esse valor de volta, então pode ser escrito como (3.3.1)

$$ReLU(x) = \max(0, X) \quad (2.19)$$

3 MATERIAIS E MÉTODOS

3.1 EQUIPAMENTO DE ESTUDO

Com capacidade produtiva de 400 toneladas hora e dividido em nove zonas de controle de temperatura sem barreira física, com total de 20 pares de queimadores laterais e 21 de teto, o forno aqui estudado, utiliza como combustível gás industrial, mistura de gases siderúrgicos, com poder calorifico controlado. Como comburente é usado o ar atmosférico, que é reaquecido em sistema de recuperação de calor. O transporte das placas no interior do forno é por meio de vigas caminhantes, nome que caracteriza o modelo do forno, forno tipo *Walking Beam*. Informações básicas do forno em questão pode sem observadas na tabela 2.

Tabela 2 - Dados construtivos do forno em estudo

ITEM	Zonas de Controle de Aquecimento								
	Z1	Z2	Z3	Z4	Z5	Z6	Z7	Z8	Z9
Zona	Pré-aquecimento		Aquecimento 1		Aquecimento 2		Encharque		
Comprimento	7,59 m		9,51 m		12,17 m		5,85 m		
Queimadores	4	4	6	6	8	8	10	4	11
Posição da zona	Inferior	Superior	Inferior	Superior	Inferior	Superior	Teto	Inferior	Teto
Controle On-Off	x	x	X	x	x	x		x	
Controle Proporcional							x		x

Fonte: Adaptado de AMT, 2022.

O forno possui três zonas de aquecimento, aqui representadas por “Z”, subdivididas em superiores e inferiores vide figura 29. O calor é transferido para carga por meio de condução e radiação, em que o mecanismo da radiação é predominante. Cada zona possui seu controlador de temperatura dedicado e a elevação da temperatura ocorre de forma gradual ao longo do forno e cada zona de aquecimento tem o seu próprio objetivo térmico.

Figura 29 - Vista Lateral do Forno de Reaquecimento.

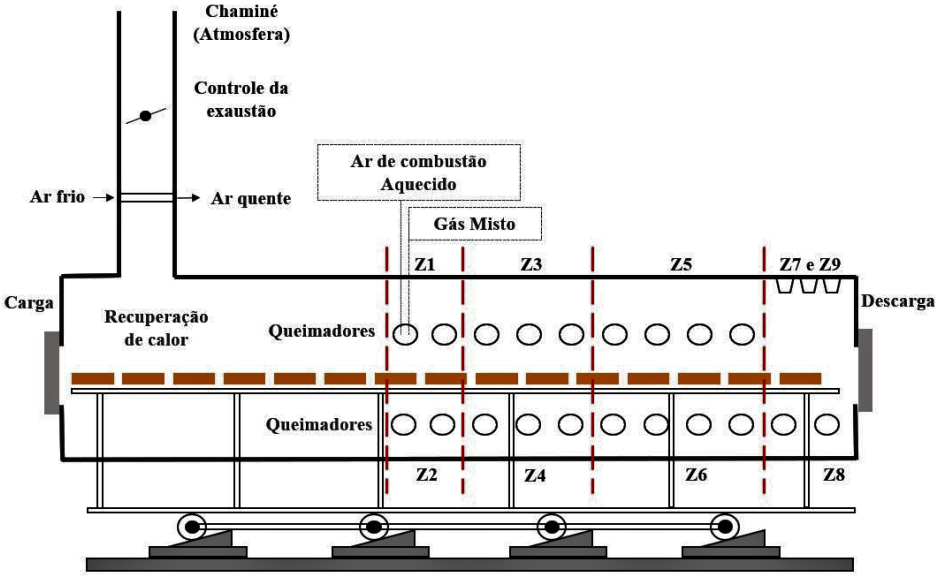

Fonte: Autoria própria, 2023.

Em cada zona de aquecimento, as variações das temperaturas são medidas por sensores do tipo termopares e enviadas ao modelo térmico, que estima a temperatura de cada produto existente dentro do forno. Assim, o modelo otimizado de controle é realimentado com a demanda de aplicação de energia térmica.

Os queimadores são acionados individualmente por meio de válvula de controle *On/Off*. O *setup* para cada queimador é enviado em base de tempo, e uma técnica de frequência modulada, chama por pulso, é aplicada, de modo que os queimadores são comutados entre os dois estados, desligado ou ligado, com base em um ciclo de trabalho determinado, que controla a entrada de calor para o processo. A demanda de calor de entrada determina o ciclo imposto, que é o tempo em que o queimador estará ligado ou desligado. Uma informação de suma importância é a determinação do tempo total de ciclo, pois, tempos curtos aumentam a ciclagem das válvulas acarretando problemas mecânicos nas partes móveis das válvulas e componentes. Contrapartida tempos elevados podem provocar atrasos no sistema de controle. O forno aqui abordado usa com tempo total de ciclo um valor parametrizável entre 60 e 120 segundos.

Este forno, possui uma estratégia de controle térmico peculiar, chamada de controle por microzona, pois dentro da própria zona de controle, o sistema entende a região

de influência de cada queimador instalado como uma zona de controle. O benefício desse sistema é a otimização de potência, visto que pode haver placas com propriedades metalúrgicas distintas ou mesmo diferentes temperaturas de enfornamento. Assim, a dinâmica térmica torna-se diferente para as placas vizinhas.

A calibração periódica dos queimadores é necessária face a não existir medições contínuas de vazão de ar e gás em cada queimador. O objetivo da calibração é identificar se a relação ar/gás em cada queimador está coerente com a proporção estequiométrica. Esse processo é realizado de forma manual, por meio dos ajustes das vazões, que são medidas individualmente nas linhas de Ar e Gás de cada queimador e reguladas através das válvulas manuais existente nos condutos dos fluidos para cada queimador. Com as vazões ajustadas dentro da relação estequiométrica, obtém-se a máxima performance na combustão. Os principais componentes existes nas linhas e ar e gás, podem ser vistos na figura 30. No total, são 20 pares de queimadores totalizando 80 válvulas manuais e 80 válvulas *on-off*.

Figura 30 - Principais componentes de um queimador lateral.

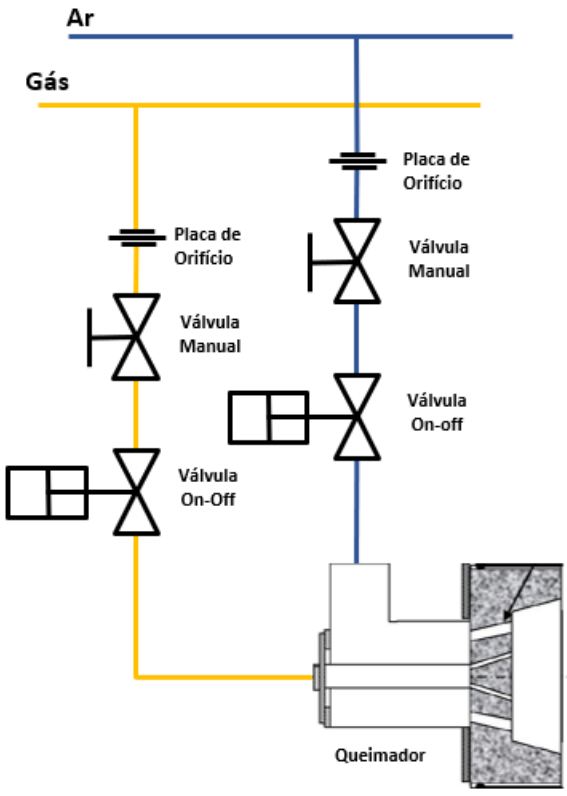

Fonte: Autoria própria, 2023.

Para este tipo de forno, a estabilidade das pressões nas linhas principais de ar e gás é fundamental para o funcionamento ótimo de cada queimador. No sentido de atender a essa necessidade, são usados dois controladores de pressão feedforward, que atuam nas válvulas principais de ar e gás de forma antecipada de acordo com a demanda térmica aplicada. Outro sistema de controle muito importante é o controlador de pressão interna do forno, que é usado com o objetivo de manter a pressão do forno levemente positiva, impedindo que haja entrada de ar externo pelas portas do forno.

Observa-se que o sistema de combustão de um forno de reaquecimento contínuo, pode ser considerado complexo devido à gama de controles e variáveis existentes, que por sua vez possuem forte acoplamento. Uma série de parâmetros também é aplicada, como: taxas de relação excesso de ar, poder calorífico do gás, ritmo de deslocamento das placas, temperatura do enfornamento etc.

A seguir será apresentado o método aplicado para construção dos modelos térmicos, com dados reais do processo de operação de um forno de reaquecimento de placas de aço, por meio de técnicas baseadas em redes neurais de aprendizado profundo.

3.2 MODELAGEM DA TEMPERATURA DO FORNO DE REAQUECIMENTO

Para construir o modelo de previsão, os dados foram coletados de um forno de reaquecimento de placas, após sua manutenção, em que foi realizada a limpeza das tubulações gás, das placas de orifício, das válvulas e bem como a calibração dos queimadores. Foram modeladas todas as zonas de controle *on-off*. Os conjuntos de dados foram coletados individualmente para cada zona de controle de temperatura.

As informações do sistema para construção do banco de dados, treinamentos e testes dos modelos foram coletadas entre 13/08/2022 e 14/08/2022 por meio do software *IbaAnalyzer* com tempo de amostragem de 1 segundo, suficiente para permitir a captura da dinâmica operacional do forno. A base de dados bruta capturada do forno aqui em questão, possui com 64 variáveis do processo com 86.400 amostras para cada variável. A seleção inicial dessas variáveis foi baseada no conhecimento tácito do processo e no comportamento operacional do forno.
A figura 31 representa um overview de todo o fluxo metodológico usado do início ao

fim do processo. A seguir será detalhado os processos de análise e tratamento dos dados, bem como o método aplicado nas seleções das variáveis mais representativas para construção de cada modelo. Entende-se que está etapa do processo tem fundamental importância na construção dos modelos, pois tal análise solidifica o processo de aprendizado dos modelos computacionais e ajudam na redução da carga de dados.

Figura 31 - Fluxo Metodológico do trabalho.

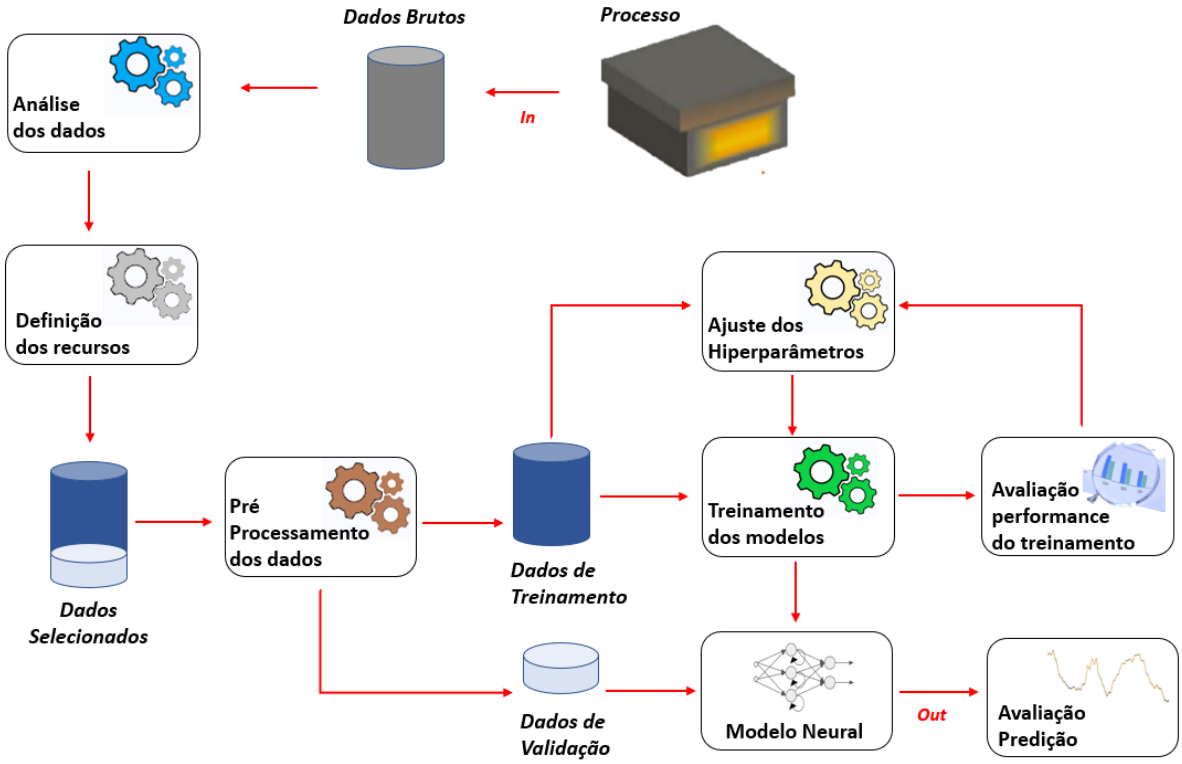

Fonte: Autoria própria, 2023.

3.2.1 Avaliação da base de dados

A avaliação inicial da base de dados ainda bruta, baseou-se em um processo simples de verificação da consistência dos dados, analisando por meio de códigos da biblioteca Pandas em linguagem Python, os tipos de dados, a verificação de ausências de dados e contagem. O resultado dessa avaliação, especificamente para zona de aquecimento 1, é apresentado na figura 32.

Figura 32 - Análise dos dados usados na zona 1.

Visão geral

TARGET	Potência	Vazão gás	Vazão ar	Válvula exaustão	Vazão exaustão	o2 chaminé	Pressão de chegada	Pressão interna	co chaminé	ZONA2	ZONA3	ZONA4	ZONA5	ZONA6	ZONA8	1A	1B	1C	1D
891.281	10.5623	3715.11	23470.6	2.39565	8.86302	11.9501	1369.25	-0.408238	60.5917	1123.12	1167.40	1170.29	1203.30	1264.88	1232.82	0	0	1	0
891.144	11.3190	3709.69	23474.6	2.38103	10.99140	11.9501	1376.72	-0.390866	60.5917	1122.99	1167.27	1170.16	1203.17	1264.88	1232.57	0	0	1	0
890.870	11.8865	3691.38	23491.5	2.39903	11.00930	12.1607	1385.04	-0.362747	60.6479	1122.73	1167.02	1169.90	1203.05	1264.75	1232.32	0	0	1	0
890.732	12.0958	3675.49	23507.3	2.40522	11.04820	12.1607	1398.70	-0.319318	60.6479	1122.47	1166.76	1169.78	1202.92	1264.63	1232.19	0	0	1	0
890.595	12.3525	3670.21	23528.7	2.39339	11.06940	12.3643	1403.72	-0.289972	60.7491	1122.34	1166.51	1169.65	1202.79	1264.37	1232.06	0	0	1	0

Dados ausentes

TARGET	0
Potência	0
Vazão gás	0
Vazão ar	0
Válvula exaustão	0
Vazão exaustão	0
o2 chaminé	0
Pressão de chegada	0
Pressão interna	0
co chaminé	0
ZONA2	0
ZONA3	0
ZONA4	0
ZONA5	0
ZONA6	0
ZONA8	0
1A	0
1B	0
1C	0
1D	0

Tipo de dados

TARGET	float64
Potência	float64
Vazão gás	float64
Vazão ar	float64
Válvula exaustão	float64
Vazão exaustão	float64
o2 chaminé	float64
Pressão de chegada	float64
Pressão interna	float64
co chaminé	float64
ZONA2	float64
ZONA3	float64
ZONA4	float64
ZONA5	float64
ZONA6	float64
ZONA8	float64
1A	int64
1B	int64
1C	int64
1D	int64

Contagem dos dados

TARGET	86400
Potência	86400
Vazão gás	86400
Vazão ar	86400
Válvula exaustão	86400
Vazão exaustão	86400
o2 chaminé	86400
Pressão de chegada	86400
Pressão interna	86400
co chaminé	86400
ZONA2	86400
ZONA3	86400
ZONA4	86400
ZONA5	86400
ZONA6	86400
ZONA8	86400
1A	86400
1B	86400
1C	86400
1D	86400

Fonte: Autoria própria, 2023

.

3.2.2 Filtragem dos sinais

Para suavizar as variações abruptas dos sinais um filtro Butterworth foi usado. Como um filtro passa-baixa, um filtro Butterworth permite a passagem de frequências mais baixas enquanto atenua progressivamente as frequências mais altas. Para suavizar as variações bruscas dos sinais, foi utilizado um filtro Butterworth.

O filtro Butterworth de segunda ordem concebido tem uma frequência de corte de 2 Hz e foi aplicado com uma frequência de amostragem de 30 Hz. Oferece uma transição suave e eficaz para remover frequências indesejadas acima de 2 Hz, mantendo o conteúdo de baixa frequência sem distorção significativa, com uma atenuação gradual dos componentes de frequência mais elevada, o que o torna uma consideração em aplicações sensíveis ao tempo. No gráfico de magnitude, Fig. 10, as frequências abaixo de 2 Hz são transmitidas com pouca ou nenhuma atenuação. À medida que a frequência se aproxima de 2 Hz, a magnitude começa a diminuir, atingindo -3 dB no ponto de corte. Após 2 Hz, o filtro começa a atenuar as frequências mais fortemente. Esta suavidade na transição da banda passante para a banda de rejeição é uma caraterística do filtro Butterworth, que dá prioridade a uma resposta sem ondulações. O gráfico de fase mostra uma mudança de fase mais significativa

em torno da frequência de corte, o que é de se esperar em filtros digitais. A Fig. 11 mostra o resultado do filtro aplicado aos caudais de ar e de gás.

Traduzido com a versão gratuita do tradutor - DeepL.com

A figura 33 exemplifica o processo de filtragem.

.

Figura 33 - Exemplo do filtro aplicado aos sinais.

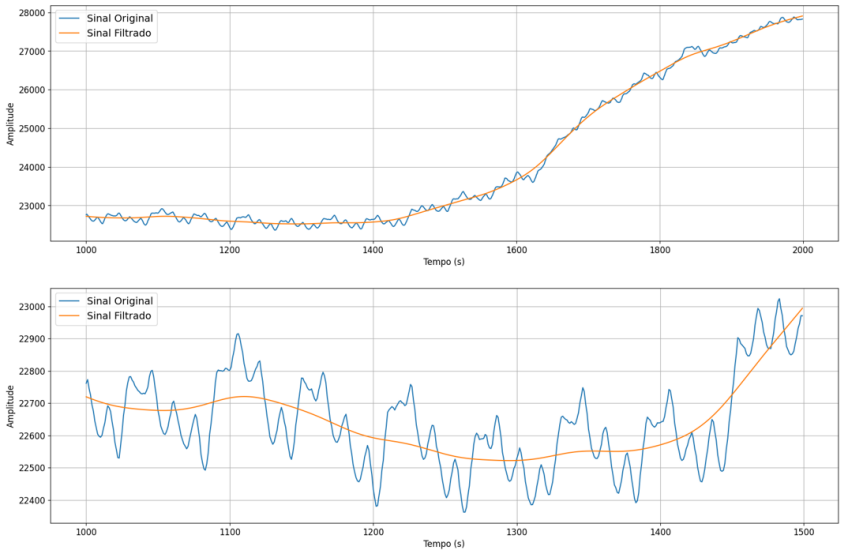

Fonte: Autoria própria, 2023.

3.2.3 Normalização dos dados

Para obtenção de alto desempenho no aprendizado de máquinas os dados devem ser pré-processados para normalização (SHI et al. 2022). Aqui, todos os dados foram sujeitados ao pré-processamento, uma vez que os valores das variáveis escolhidas estão em faixas diferentes. Existem várias técnicas de normalizações bem conhecidas como *Simple Feature Scaling*, *Min-Max*, *Z-score etc.* A estratégia de pré-processamento foi a mesma para as variáveis de entrada e saída do sistema de combustão, e consistiu na normalização padrão z, ou "*standardization*", que centraliza os dados na média zero com um desvio padrão de 1, conforme equação (3.2.1).

$$z = \frac{X - \mu}{\sigma} \tag{3.2.14}$$

Onde, X são os dados a serem observados, μ é a média e σ o desvio padrão.

3.2.4 Análise de *outliers*

Os outliers podem ser considerados como dados discrepantes em relação a um conjunto de dados e tal discrepância podem trazer distorções na fundamentação dos modelos. Para deteção desses tipos de dados, optou-se por usar o gráfico de boxplot para auxiliar na análise, conforme figura 34.

Figura 34 - Análise de dados discrepantes.

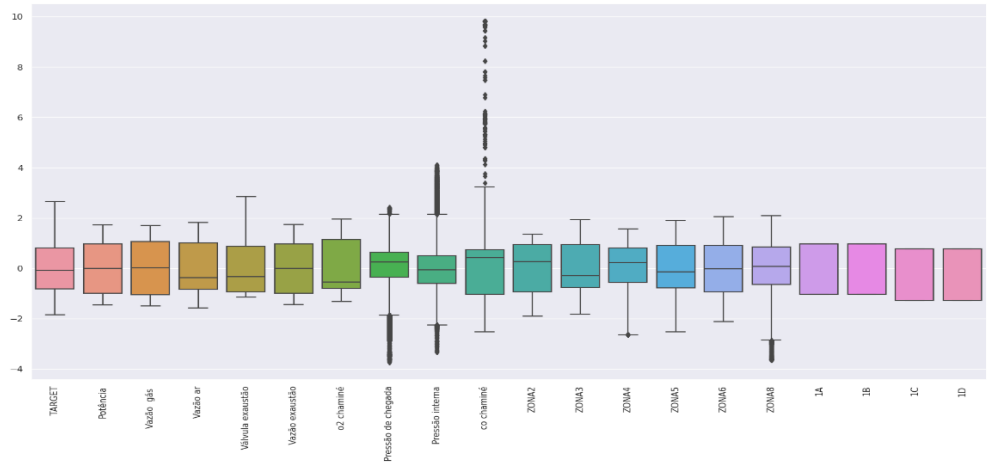

Fonte: Autoria própria, 2023.

Este tipo de análise é normalmente aplicado para visualizar se há dados afastados do centro de distribuição, da média e da variância. Foi possível identificar e remover, por meio dessa técnica, a presença de dados discrepantes nas variáveis: pressão de chegada, pressão interna, co chaminé e temperatura zona 8.

3.2.5 Seleção das variáveis

Selecionar as variáveis ou características específicas é uma etapa fundamental no pré-processamento de dados para previsão, podemos limitar os requisitos de armazenamento e aumentar a velocidade dos algoritmos. Isso implica em escolher um conjunto de variáveis relevantes e informativos de entre muitas variáveis ambientais ruidosas que podem influenciar o resultado desejado dos modelos computacionais. A seguir é apresentando brevemente alguns métodos, como:

- *Filters:* Os métodos de filtro são baseados nas propriedades estatísticas dos variáveis, como correlação, variância e testes qui-quadrado, para avaliar a importância dos variáveis em relação à variável alvo. As variáveis com as comissões mais elevadas são então escolhidas para serem incluídos no modelo.
- *Wrappe*r: Que usam um algoritmo de aprendizado para avaliar o desempenho de diferentes subconjuntos de variáveis na tarefa de previsão. Alguns exemplos de métodos *wrapper* são a seleção progressiva, a eliminação regressiva e a eliminação recursiva de variáveis.
- *Embedded*: Incorporados que combinam as vantagens dos métodos de filtro e de invólucro. Eles realizam a seleção de variáveis como parte do processo de aprendizado, incorporando um termo de regularização ou uma função de penalidade que reduz a complexidade do modelo. Alguns exemplos de métodos incorporados são a regressão Lasso e Ridge, além de algoritmos baseados em árvores de decisão.
- *Hybrids*: Que são uma combinação de métodos de filtro e de agrupamento. Eles usam um método de filtro para reduzir a dimensionalidade dos dados e, em seguida, aplicam um método de agrupamento para encontrar o melhor subconjunto de variáveis do conjunto reduzido.

Nesta pesquisa, realizamos teste como os métodos *Filters* e *Wrapper*. Inicialmente, pelo método *Filters*, usamos a correlação de Pearson como referência. Esta técnica é usada para medir se as variáveis estão relacionadas de maneira linear. A métrica da linearidade entre os variáveis é exposta em um número que vai de -1 a 1. Quanto mais próximo dos extremos maior é a força da correlação. Valores próximos de zero inferem uma correlação é fraca. A intepretação da correlação de Pearson, usualmente é representada por intervalos que a classifica como correlação muito fraca, fraca, moderada, forte ou muito forte. Aqui, optou-se por selecionar os variáveis com força de correlação maior que 75% com o *Target,* conforme figura 35.

Figura 35 - Mapa de correlação entre as variáveis.

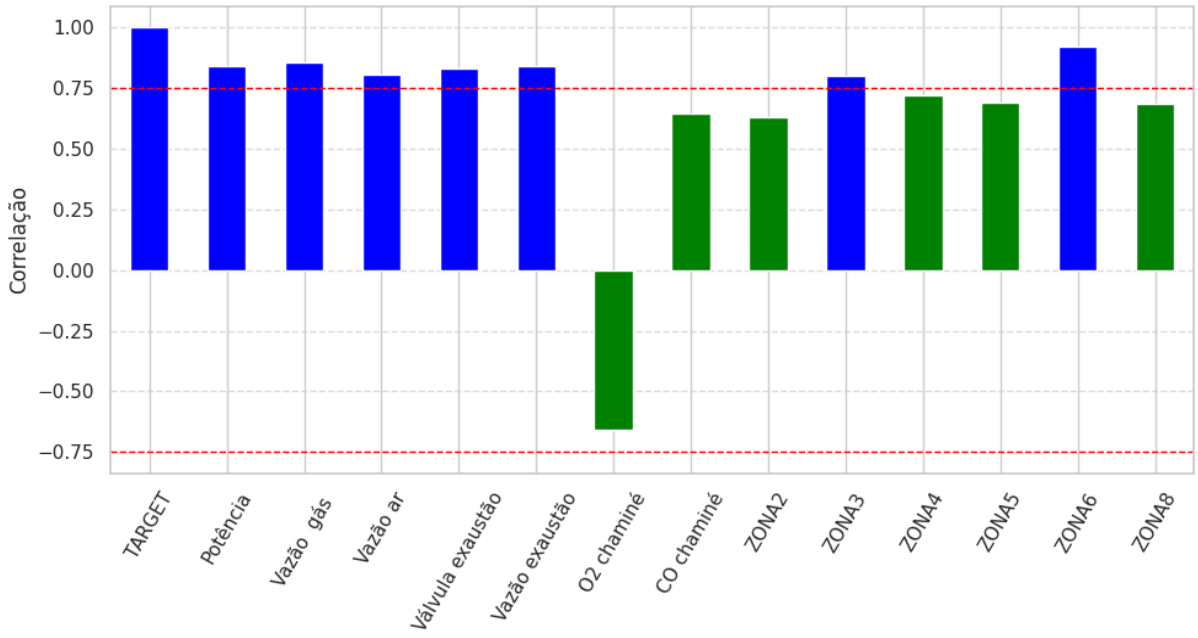

Fonte: Autoria própria, 2023.

Pelo método *Wrapper*, optou-se por usar a seleção sequencial de variáveis para frente (*Forward-SFS*). Onde, a seleção acontece por um método iterativo, no qual inicia-se sem nenhum recurso no modelo, e a cada iteração, é adicionado uma nova variável e avaliado a performance do modelo até que a adição de uma nova variável não melhore o desempenho do modelo. Seguindo a avaliação do dataset usado na modelagem da zona de aquecimento 1, foi aplicado o método baseando-se em um modelo de regressão linear e o resultado pode ser observado no gráfico da figura 36.

Figura 36 - Seleção sequencial de variáveis.

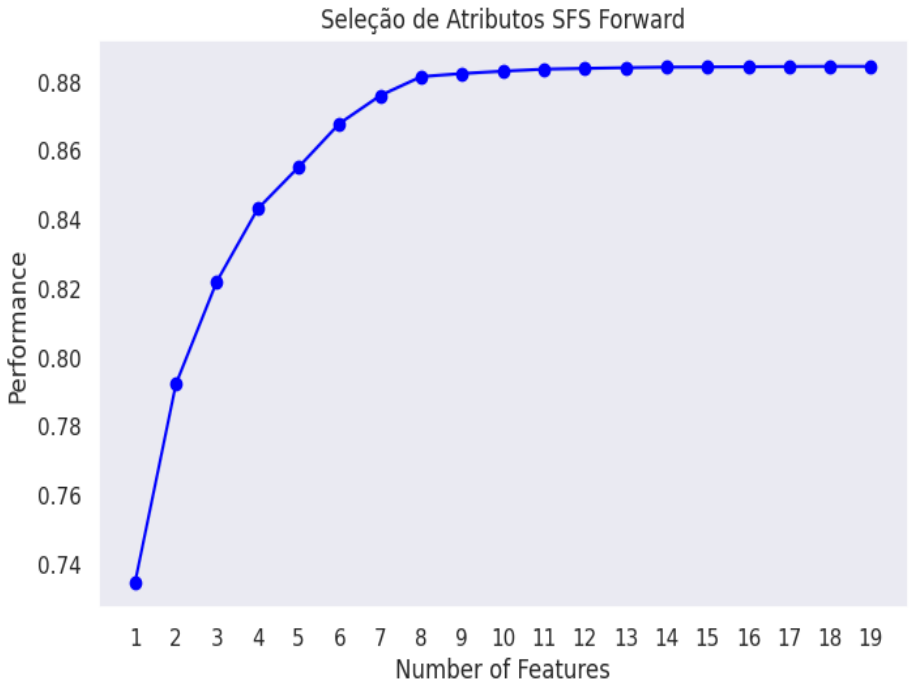

Fonte: Autoria própria, 2023.

Analisando o gráfico, em que o eixo das abscissas representa o número de variáveis adicionado ao modelo e o eixo das ordenadas traz a performance do modelo, calculada pelo coeficiente de determinação R^2, onde é dividida a soma dos quadrados dos resíduos do modelo de regressão (SS_{res}) pela soma total dos quadrados dos erros do modelo médio SS_{tot} e, em seguida, subtraindo-o de 1. R^2 é dado por (3.2.2). Valores mais próximos a 1 indicam boa relação entre os valores e reais e os valores preditos.

$$R^2 = \frac{SS_{res}}{SS_{tot}} = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \hat{y}_i)^2} \tag{3.2.2}$$

Assim, é possível obter uma curva relacionando a performance com o número de variáveis. É notório que, após um determinado ponto a performance do modelo estabiliza o seu desempenho.

Os dois métodos apresentaram resultados similar, onde a principais variáveis selecionadas para modelagem da zona 1 foram: Potência, vazão de gás, vazão de ar, válvula de exaustão, vazão da exaustão, temperaturas das zonas 3 e 6.

3.2.6 Preparação dos dados para treino supervisionado

Por meio de dados históricos, modelos baseados em redes neurais de aprendizado profundo podem desenvolver uma relação funcional entre os variáveis de entrada e os valores futuros da variável objetivo. O modelo resultante pode fornecer previsões sobre a variável objetivo em pontos de tempo no futuro. O aprendizado dos modelos se baseia na relação funcional entre a série temporal e pode ser expressa matematicamente pela equação (3.2.3). Sendo x_t o vetor de característica de entrada observado no tempo e $\hat{y}_{t+k}$ é a predição em um ponto de tempo futuro.

$$\hat{y}_{t+k} = f_k\,(x_{k-w}, \dots, x_{t-1,}\, y_{k-w}, \dots, y_{t-1}) \tag{3.2.3}$$

Onde $\hat{y}_{t+k}$ e previsão da variável objetivo para o tempo $t + k$. k é o período no futuro para o qual a variável alvo deve ser prevista. Já $y_{k-w}, \dots, y_{t-1}$ são os valores alvo observado desde o tempo $t - w$ a $t - 1$; $x_{k-w}, \dots, x_{t-1}$ são os vetores de caraterísticas de m entradas, observadas a partir do tempo $t - w$ a $t - 1$. f_k é a função treinada pelos modelos de aprendizado profundo.

Para o treinamento supervisionado de modelos de predição temporal faz-se necessário a preparação previa da base de dados que contém a série histórica. A entrada no modelo deve ter um comprimento uniforme (Shi et al 2022.). Usualmente, aplica-se uma janela de tempo deslizante de tamanho fixo, vide figura 37. As predições de dados futuros podem ser de um passo à frente ou vários passos à frente. A sequência temporal apresentada na equação 3.2.4, exemplifica uma janela “look-back” de tamanho m tempos passados com predição de n passos à frente e predição.

$$x(t-m) \dots\, x(t-2), x(t-1), x(t) \rightarrow\, \hat{y}\,(t+n) \tag{3.2.4}$$

Figura 37 - Janela deslizantes para treinamento supervisionado.

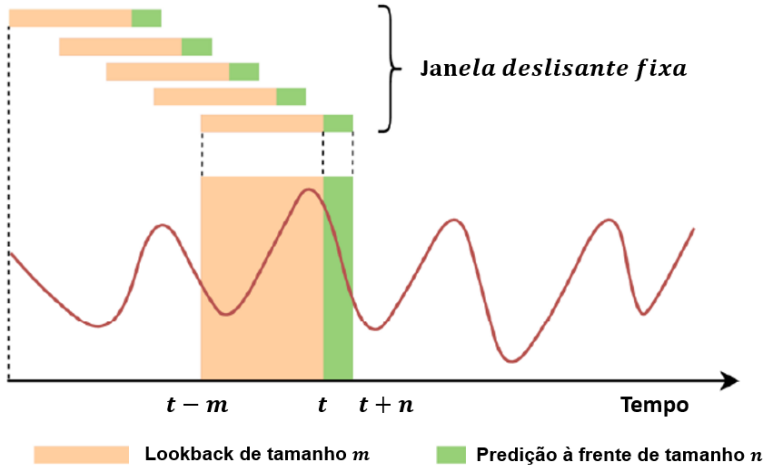

Fonte: Adaptado de Shi et al 2022.

Na literatura existe várias formas de realização de predições passos à frente sendo as principais destacas em (TAIBE,2012; BONTEMPAI,2013): De forma resumida, apresenta-se a seguir algumas estratégias: previsão direta em várias etapas, em que o modelo será treinado para prever um ponto fixo no futuro. Estratégia recursiva, que envolve o uso de um modelo de uma etapa várias vezes, na qual a previsão para a etapa de tempo anterior é usada como uma entrada para fazer uma previsão na próxima etapa de tempo. Estratégias híbridas direto-recursivas, que combina a predição direta e recursiva é pode oferecer os benefícios de ambos os métodos. E por último, a estratégia de saída múltipla, que envolve o desenvolvimento de um modelo capaz de prever toda a sequência de previsão de uma só vez.

Cada método possui a sua aplicabilidade com os benefícios e limitações, que podem variar entre o erro máximo aceitável quanto a carga computacional e complexidade exigida para treino e execução do modelo. Aqui, optou-se por aplicar o método de predição recursiva, devido ao baixo custo computacional empregado nesta estratégia.

3.2.7 Métrica de avalição de desempenho

Em previsão de séries temporais, modelos estatísticos ou aprendizado de máquina tentam antecipar os próximos valores de uma série ao longo do tempo. No caso deste estudo, focou-se na previsão de um ou mais passos à frente, ou seja, tentamos prever

os próximos valores da série. Geralmente, essa previsão não será exata e haverá uma diferença entre o valor previsto e o valor real, resultando em um erro de previsão e existem algumas medidas para essa comparação, que serão discutidas a seguir.

Para medir os índices de desempenho, normalmente, analisam-se os erros que ele apresenta, ou seja, realiza-se a comparação da saída real com o valor previsto pelo modelo no mesmo instante de tempo, no caso de series temporais. Tanto a raiz quadrada média do erro (*RMSE*) quanto o erro médio absoluto (*MAE*) são regularmente empregados como critérios de avaliação de desempenho em predições de series (CHAI, et al., 2014). Sendo essas métricas usadas aqui como parâmetro avaliativo do desempenho dos modelos de predição, no qual valores próximos a zero indicam um desempenho ótimo do modelo.

O erro médio absoluto, MAE é calculado a partir da média dos erros absolutos, ou seja, utilizamos o módulo de cada erro para evitar a subestimação, isso porque, o valor é menos afetado por pontos especialmente extremos (*outliers*). Como dito anteriormente, cada erro pode ser interpretado como a diferença entre o valor real e o valor previsto. Calcula-se o MAE por (3.2.5).

$$MAE = \frac{1}{n_{ts}} \sum_{i=0}^{n_{ts}} |yi^{\{ts\}} - \hat{y}_i| \tag{3.2.5}$$

A raiz quadrada do erro médio, RMSE é frequentemente usada em séries temporais por ser mais sensível a erros maiores, devido ao processo de quadratura que a produziu. O cálculo da RMSE é dado pela equação (3.2.6).

$$RMSE = \sqrt{\frac{1}{n_{ts}} \sum_{i=0}^{n_{ts}} (\hat{y}_{i-} yi^{\{ts\}})^2} \tag{3.2.6}$$

onde $\hat{y}_i$ é o $i\text{-}ésimo$ valor previsto e $yi^{\{ts\}}$ é o $i\text{-}ésimo$ valor verdadeiro.

Além da análise do erro médio visto anteriormente, intendesse necessário avaliar o erro de previsão para cada horizonte predito na série temporal. Considerando que as variações de temperatura em cada zona de aquecimento são medidas por termopares do tipo S, com uma tolerância de $\pm 1°C$ conforme norma NBR 12771, e que o erro máximo aceitável para o sistema de controle é de 0,5% do fundo de escala do instrumento, estabelece os limites de $\pm 7°C$ como faixa aceitável para os modelos de previsão. Assim, pela equação (3.2.7) podemos calcular o erro de previsão para cada passo à frente e compará-lo com os limites aceitáveis. Onde, ε é o erro de previsão, y o valor real e $\hat{y}$ o valor predito no horizonte n. Este procedimento nos permite monitorar o desempenho dos modelos para cada ponto predito, trazendo uma visão um controle eficaz do sistema de aquecimento.

$$\varepsilon = y - \hat{y}_n \tag{3.2.7}$$

3.2.8 Arquitetura e sintonia dos modelos

Existem decisões importantes relacionadas às camadas ocultas em redes neurais: quantas camadas ocultas usar e quantos neurônios cada uma dessas camadas deve ter. Geralmente, uma ou duas camadas ocultas são suficientes para resolver a maioria dos problemas práticos. Redes com duas camadas ocultas podem representar funções com diferentes formatos, mas não há razão teórica para usar mais de duas camadas. Na prática, uma camada oculta costuma ser adequada para muitos casos (HEATON, 2008),

Nesta pesquisa foram usados quatro tipos de redes neurais, sendo três recorrentes RNN, LSTM, GRU e uma Convolucional, a TCN. As arquiteturas das redes foram mantidas de forma semelhante em números de camadas. Sendo uma camada de entrada $[i]$, uma oculta $[h]$ e uma densa $[d]$ de saída. Essa definição também foi embasada em testes realizados com a rede neural de camadas de célula simples, a RNN. Que apresentou resultados satisfatórios com esta configuração. Todos os modelos foram desenvolvidos no ambiente do Google Colaboratory por meio das bibliotecas Keras. Os outros hiperparâmetros foram ajustados por um otimizador e serão detalhados a seguir.

A tarefa de ajuste dos hiperparâmetros, como taxa de aprendizado, número de neurônios, e épocas de treinamento, pode ser considerada morosa quando feita manualmente (KAPLUNOVICH,2020). Neste trabalho, aplicou-se o algoritmo de autoajuste *Keras Tuner*, para definir as melhores configurações dos modelos propostos para cada zona, com base em uma lista de parâmetros, na qual automaticamente são testadas as melhores combinações, buscando o melhor desempenho para o problema. A tabela 3 apresenta a lista de parâmetros usada para sintonia de cada modelo e os resultados da sintonia da zona 01 para cada modelo.

Tabela 3 - Lista de hiperparâmetros e sintonia da zona 01.

Hiperparâmetros	Lista	Zona 01			
		RNN	LSTM	GRU	TCN
Neurônio camada de entrada	**2 a 12**	**10**	**7**	**3**	**3**
Função de ativação camada de entrada	**Sigmoid, Tanh, ReLU**	**ReLU**	**Tanh**	**Tanh**	**ReLU**
Ativação recorrente camada de entrada	**Sigmoid, Tanh, ReLU**	**-**	**ReLU**	**Sigmoid**	**-**
Kernel camada de entrada	**32, 64**	**-**	**-**	**-**	**64**
Bloco residual camada de entrada	**1, 2, 3**	**-**	**-**	**-**	**1**
Neurônio camada oculta	**2 a 12**	**12**	**3**	**10**	**4**
Função de ativação camada oculta	**Sigmoid, Tanh, ReLU**	**ReLU**	**ReLU**	**Tanh**	**ReLU**
Ativação recorrente camada oculta	**Sigmoid, Tanh, ReLU**	**-**	**Sigmoid**	**ReLU**	**-**
Kernel da camada oculta	**32, 64**	**-**	**-**	**-**	**32**
Bloco residual camada oculta	**1, 2, 3**	**-**	**-**	**-**	**2**
Taxa de aprendizado	**0.01, 0.03, 0.06 e 0.09**	**0.01**	**0.03**	**0.01**	**0.06**
Épocas de treinamento	**25, 50, 100, 125 e 150**	**100**	**150**	**50**	**125**
Tamanho dos lotes	**32, 64, 128, 252 e 512**	**64**	**32**	**64**	**128**
Métrica função perda	**MAE, MSE**	**MSE**	**MSE**	**MSE**	**MSE**

Fonte: Autoria própria, 2023.

Considerando as diferenças intrínsecas de configuração entre as redes neurais exploradas neste estudo, é importante destacar que existem parâmetros exclusivos para cada modelo. Esse processo foi aplicado individualmente a cada zona, considerando o conjunto de dados específico. Para exemplificar os resultados a figura 39 apresenta a avalição da zona 1. Observa-se uma melhora significativa no desempenho dos modelos quando analisamos as métricas de erro absoluto médio (MAE) e erro quadrático médio (RMSE) antes e depois dos ajustes. Essa etapa é crucial para o sucesso do processo de modelagem, pois garantir baixos erros nas previsões iniciais é fundamental para que as previsões futuras atendam aos requisitos especificados no projeto.

Figura 38 - MAE e RMSE antes e depois da sintonia.

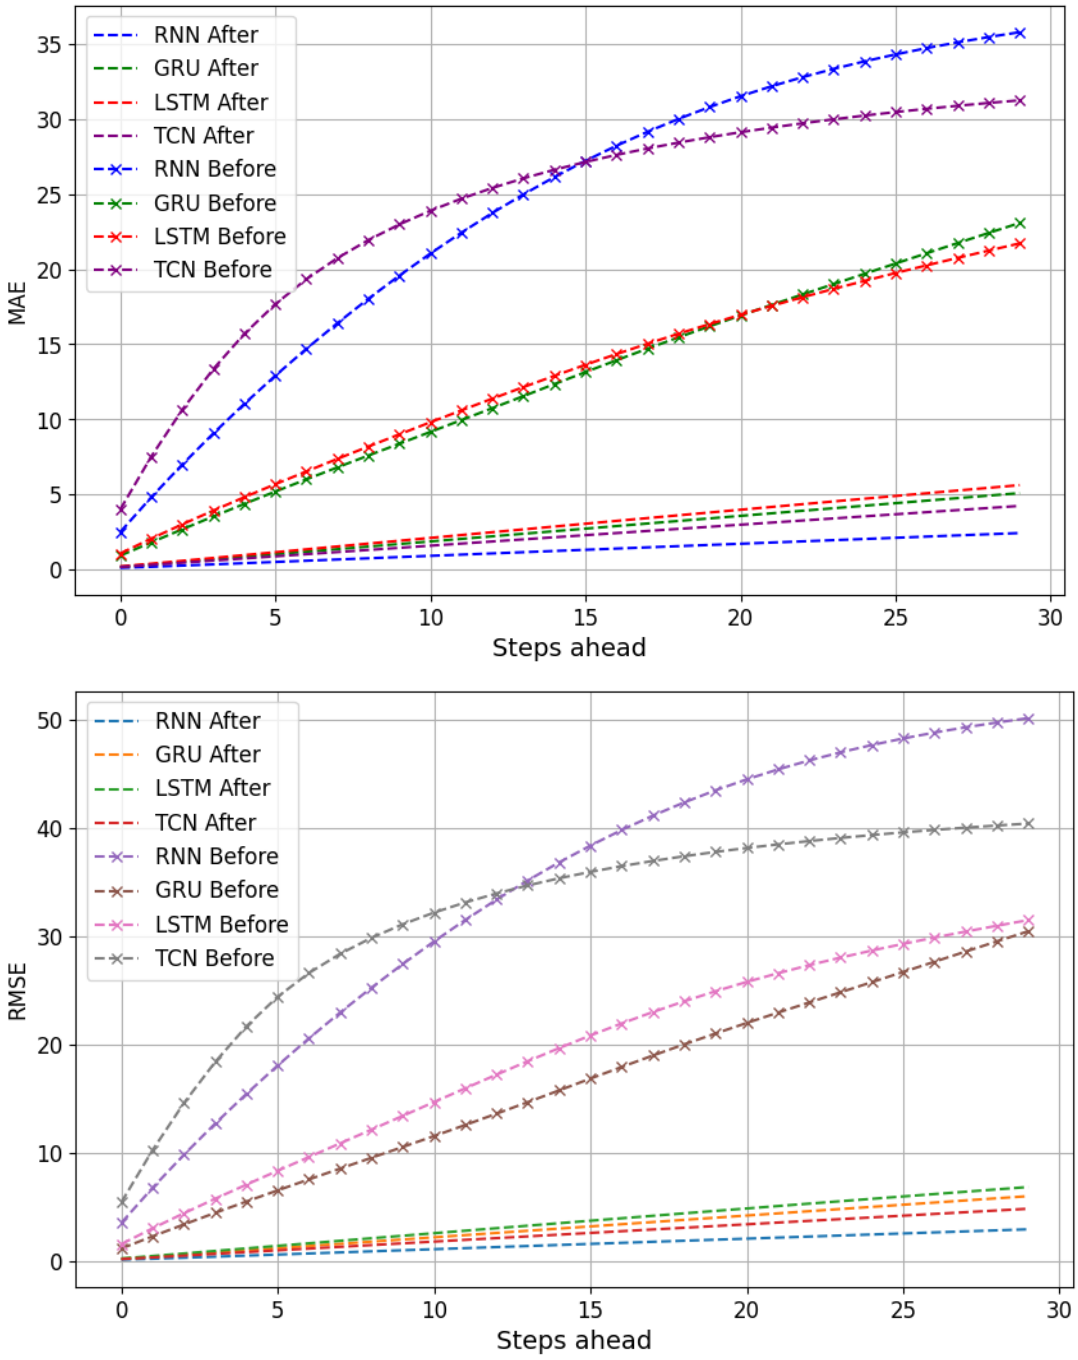

Fonte: Autoria própria, 2023.

No próximo seção, capítulo 4, será apresentado os resultados das setes zonas de controle *on-off* do forno de reaquecimento de placas, que foram analisados de forma criteriosa com foco na precisão das predições, atendimento aos requisitos de tolerância e a capacidade computacional exigida para cada modelo.

4 RESULTADOS E DISCUSSÃO

Nesta seção serão apresentados os resultados de previsão obtidos e avaliados por meio de métricas aplicáveis para tal. Separou-se por avaliação por resultados numéricos, resultados gráficos, análise de parâmetros treináveis.

4.1 AVALIÇÃO DOS RESULTADOS POR MAE E RMSE

Os resultados a seguir, são referentes as sete zonas de aquecimento com predições em horizontes de t+1, t+15 e t+30. A forma de avaliação dos modelos foi abordada pelas métricas MAE e RMSE, calculadas com base em todo o dataset de validação. Inicialmente, apresentamos na tabela 4 os resultados das métricas calculadas para cada zona de aquecimento denominadas como (z). Em negrito, são destacados os melhores resultados.

Tabela 4 - Avaliação das predições dos modelos por MAE e RMSE.

Modelo	Z	1 s		15 s		30 s		Z	1 s		15 s		30 s	
		MAE	RMSE	MAE	RMSE	MAE	RMSE		MAE	RMSE	MAE	RMSE	MAE	RMSE
RNN	1	**0,095**	**0,116**	**1,255**	**1,517**	**2,336**	**2,85**	2	0,207	0,283	2,07	2,63	3,76	4,752
GRU		0,083	0,101	1,77	2,149	3,328	4,034		**0,190**	**0,268**	**2,024**	**2,53**	**3,608**	**4,465**
LSTM		0,136	0,168	1,713	2,107	3,225	3,994		0,264	0,353	3,209	4,012	5,644	7,119
TCN		0,13	0,157	2,045	2,486	3,811	4,623		0,315	0,368	4,432	5,197	6,246	7,779
RNN	3	**0,100**	**0,127**	1,307	1,598	2,46	3,039	4	0,137	0,169	1,246	1,506	2,245	2,719
GRU		0,191	0,267	2,877	3,36	5,237	6,083		0,143	0,174	1,512	1,955	2,796	3,78
LSTM		0,161	0,209	**0,914**	**1,268**	**1,896**	**2,61**		0,197	0,248	2,53	3,205	4,512	5,673
TCN		0,114	0,202	0,404	1,089	0,961	2,206		**0,11**	**0,138**	**0,935**	**1,071**	**1,75**	**2,003**
RNN	5	0,121	0,144	1,191	1,619	1,956	4,752	6	0,078	0,090	1,270	1,540	2,487	3,039
GRU		0,118	0,14	1,089	1,345	1,801	2,241		**0,076**	**0,091**	**1,028**	**1,278**	**1,969**	**2,461**
LSTM		0,156	0,196	1,905	3,051	3,038	4,4		0,138	0,179	2,033	2,599	3,661	4,589
TCN		**0,082**	**0,099**	**0,565**	**0,768**	**1,023**	**1,285**		0,114	0,125	1,803	1,914	3,367	3,578
RNN	8	0,203	0,243	2,07	2,63	3,76	4,752							
GRU		0,297	0,99	0,898	1,576	1,558	2,755							
LSTM		0,283	0,798	0,711	1,289	1,393	2,541							
TCN		**0,213**	**0,704**	**0,664**	**1,036**	**1,446**	**2,601**							

Fonte: Autoria própria, 2023.

Ao dissertar sobre os resultados quantitativos destaca-se as pequenas variações de desempenho entre as diferentes zonas de controle e modelos, tornando a identificação da melhor performance não tão trivial. Como os modelos neurais em geral iniciam o treinamento com valores aleatórios pode haver alterações nesses resultados caso haja novos treinamentos.

No entanto, em termos gerais, afirma-se, baseado nos dados, que os resultados de Erro Médio Absoluto (MAE) e Raiz do Erro Médio Quadrático (RMSE) foram satisfatórios para as previsões objetivadas, pois os erros médios de previsão se mantiveram dentro dos limites estabelecidos de $\pm 7°C$, que representam o valor de tolerância aceitável para as malhas de controle de temperatura estudadas, equivalendo a 0,5% da escala total dos instrumentos de *feedback* de controle. Definição baseada no erro máximo aceitável para o sistema de controle conforme abordagem da seção 3.2.7.

4.2 AVALIAÇÃO GRÁFICA DOS RESULTADOS

Observa-se que o erro médio MAE e RMSE desempenha um papel crucial na avaliação desse tipo de problema. Valores baixos indicam um bom desempenho dos modelos, mas, por ser uma média, podem não revelar faixas especificas ou pontuais de baixo desempenho no horizonte de previsão. Ao considerar a aplicação desses modelos em projetos como sistemas de controle baseados em modelos, é imperativo não se limitar apenas à análise dos erros médios.

Para complementar a interpretação dos resultados, realizou-se uma análise das séries preditas para cada horizonte em cada ponto amostrado, avaliando: valor mínimo e máximo do erro, adotado aqui como $\pm 7°C$. Também é abordado uma análise qualitativa por gráficos de tendência da série predita, observando o comportamento da predição de cada modelo. Portanto, uma avaliação dinâmica das variações para cada ponto previsto é essencial para compreender a eficácia real dos modelos em diferentes horizontes de previsão. Para isso, foram gerados gráficos de previsão contemplando os resultados de cada modelo e o valor real, denominado *Target*, conforme representados na figura 40, que retrata os resultados da zona de pré-aquecimento 1.

Essa representação visual possibilita ponderações e *insights* sobre o desempenho, observa-se que variável objetivo percorre amplitudes diferentes de temperatura com faixa total de 900°C a 1230°C. Na faixa de 7.000 a 15.000 segundos tem-se a elevação da temperatura da zona, onde poderemos avaliar o desempenho dos modelos quando submetidos a rampa.

Figura 39 - Avaliação da predição da zona 1.

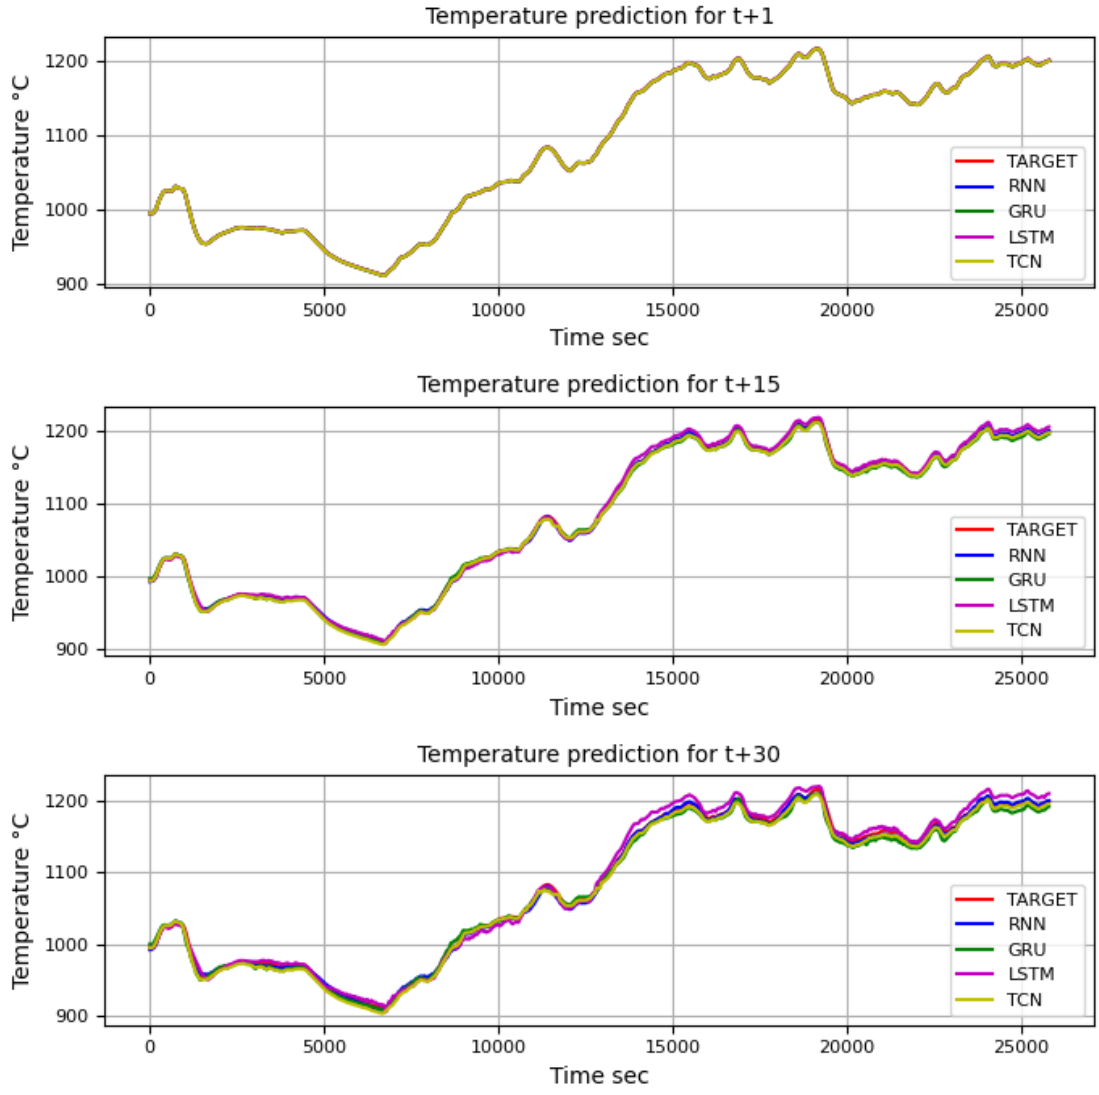

Fonte: Autoria própria, 2023.

Ao avaliar os resultados da zona de aquecimento 1, denominada zona 1, percebe-se que os modelos seguem a tendência da variável objetivo na maioria dos casos e não se observa ruídos nas previsões, destacando uma melhora nos resultados quando comparado ao trabalho apresentado por Lima et. al., 2023.

No entanto, em pontos específicos, há um deslocamento entre as predições e a variável objetivo. Na faixa de temperatura de 900°C a 1.000°C observa-se que modelos performaram de forma satisfatória em todos os horizontes. Já na elevação da temperatura após os 1.100°C o modelo LSTM desloca significativamente do *target,* principalmente no horizonte t+30. Na fixa onde a temperatura está a 1.200°C, nota-se uma dispersão dos modelos em relação a variável objetivo. Para concretização dessa análise iremos avaliar agora o gráfico do erro de previsão, conforme figura 41. Essa análise permite uma avaliação do erro ao logo de toda a série.

Figura 40 - Avaliação do erro de previsão da zona 1.

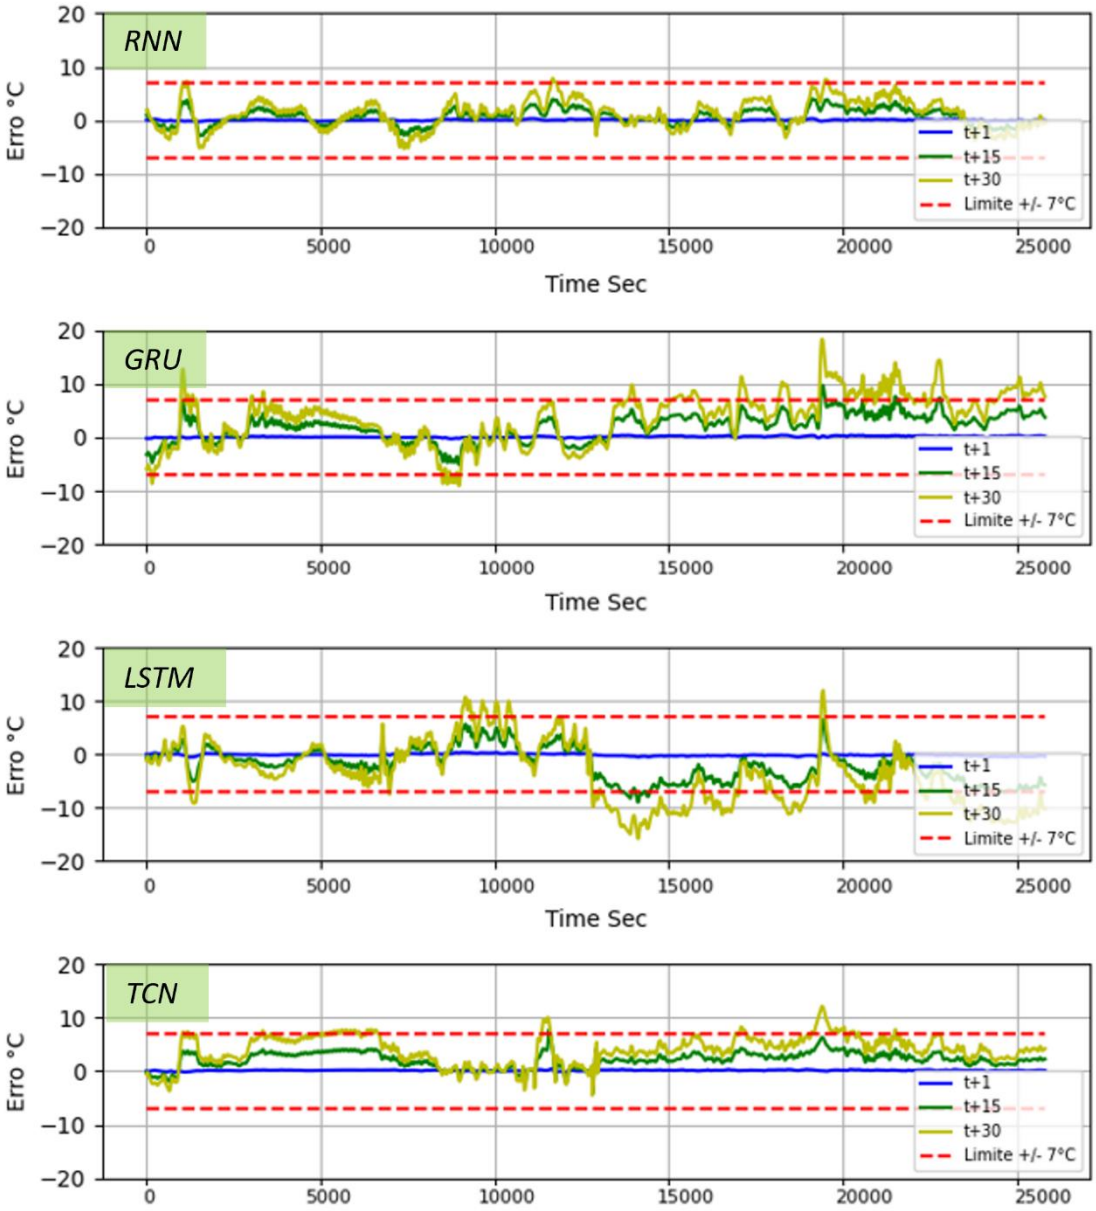

Fonte: Autoria própria, 2023.

Por meio desta análise gráfica é possível obter uma compreensão mais aprofundada desse problema, permitindo-nos descrever sobre as possíveis causas e propor soluções de resolução. Exemplificando, percebe-se que o ponto analisado anteriormente sobre o modelo LSTM, previsão t+30 durante a elevação de temperatura, é visivelmente destacado no gráfico do erro, onde o erro aparece de forma negativa, mostrando que modelo fez previsões maiores que o valor real. Nesta faixa o erro foi significativamente grande ultrapassando os limites aceitáveis conforme definição do projeto.

Para esta zona, destaca-se que apenas o modelo RNN conseguiu se manter dentro dos limites estabelecidos como ótimos. O modelo GRU apresentou um aumento mais acentuado do erro ao final da série, saindo da faixa aceitável. O modelo LSTM não performou bem quando comparado aos demais. E já o model teve um desempenho satisfatório, com erros um pouco maiores em faixas pontuais.

Ao analisarmos as demais zonas observa-se que não há uma predominância de modelos, como as características da zonas e *datasets* são diferentes os resultados de performance dos modelos acabam sendo diversos. Exemplo, os modelo TCN obteve resultados surpreendentes nas previsões das temperaturas das zona 4, 5, 6 e 8, pois previsões foram precisas com erros muito pequenos e com pouca variabilidade. Já os modelos GRU e LSTM, apesar de apresentarem bons resultados, tiveram algumas dificuldades em lidar com as transições temperatura. Este problema é evidência nos resultados das previsões das zona 5. Os modelos RNN, ganham um destaque especial, pois são modelos menos complexos quando comparados aos outras aqui apresentado, e as suas previsões foram efetivas e na maioria das vezes dentro dos limites estabelecidos como critério de desempenho.

Generalizando, a avaliação dos resultados mostra que os modelos foram bem precisos para as previsões de um passo à frente. Para as previsões com horizonte t+15, os resultados se deterioram, mas permanecem dentro dos limites aceitáveis. Já para as previsões de t+30, o desafio foi um pouco maior, pois o método de previsão recursiva acumula erros de previsão, ou seja, quanto maior o horizonte, maior o erro acumulado, assim, para algumas zonas em pontos específicos este quesito não foi atendido.

Em linhas gerais, os resultados foram satisfatórios, abrindo oportunidades para aplicação dos modelos na previsão das temperaturas das zonas de aquecimento em fornos de reaquecimento de placas com sistema de controle *on-off.*

4.3 ANÁLISE DOS PARÂMETROS TREINÁVEIS

Os modelos utilizados para prever temperaturas são fundamentados no conceito de redes neurais, porém cada modelo possui uma arquitetura operacional distinta. O modelo RNN, por exemplo, apresenta uma única recorrência em cada unidade neural, enquanto a GRU conta com três portões neurais treináveis em sua unidade. Já a LSTM possui um portão adicional em relação à GRU, totalizando quatro portões neurais treináveis em suas unidades, os quais regulam o fluxo de memorização de informações relevantes de longo prazo. Por outro lado, a rede TCN se baseia no conceito de convolução unidimensional, onde seus parâmetros treináveis dependem do tamanho do filtro da convolução e do número de unidades. Esta discrepância fica evidente ao avaliar a complexidade e a quantidade de parâmetros treináveis em cada modelo. A Tabela 5 fornece uma comparação simples entre os modelos neurais utilizados nesta pesquisa para previsão temporal, permitindo a observação da quantidade de parâmetros treináveis conforme a estrutura de rede proposta.

Tabela 5 - Quantidade de parâmetros treináveis por modelo.

Modelos	RNN	GRU	LSTM	TCN
Parâmetros	457	1986	2491	6241
Comparação	1,00	4,35	5,45	13,66

Fonte: Autoria própria, 2023.

A rede TCN tem aproximadamente quatorze vezes mais parâmetros do que o modelo RNN e utilizou mais recurso computacional para realização do treinamento, sendo necessário uso de uma unidade de processamento gráfico GPU para seu treinamento. Essa avaliação é importante devido à necessidade computacional exigida para processar o algoritmo referente a cada modelo. Por exemplo, ao compararmos os resultados da TCN com o modelo simples RNN para o problema de predição de temperatura em fornos de reaquecimento, seria injustificável a aplicação de um

modelo TCN, visto que a sua exigência computacional é 13,66 vezes superior a RNN simples.

4.4 ANÁLISE DO PRÉ-PROCESSAMENTO DOS DADOS

É muito importante ressaltar essa etapa do trabalho onde as técnicas aplicadas na fase de pré-processamento dos sinais foram de suma importância para convergência no processo de treinamento dos modelos e a estabilidade das previsões. Os sinais de dinâmica rápida como as vazões, concentração química dos gases etc. foram filtrados, e este procedimento ajudou na retirada dos ruídos, que são indesejáveis durante o processo de treinamento. A análise exploratória dos dados, remoção dos *outliers,* bem como técnicas de seleção das variáveis corroboram com os bons resultados vistos, confirmando a importância dessas análises aplicadas no processo de criação de modelos computacionais A qualidade dos dados reflete diretamente na qualidade dos modelos. No caso das seleção das *features* mais representativa para cada zona de aquecimento, naturalmente é feita considerando as condições operacionais e a dinâmica intrínseca do processo. Entretanto, os fornos de reaquecimentos de placas possuem dinâmica complexas com forte acoplamento entre as malhas de controle tornado esse processo não tão intuitivo e o uso de métodos específicos beneficiou a tomada de decisão, pois os acoplamentos entre as malhas de controle de cada zona foram devidamente detectados durante o processo de seleção de variáveis.

4.5 ANÁLISE DA SINTONIA DOS MODELOS

Não menos importante, o processo de ajuste automático dos hiperparâmetros de cada modelo, elaborado com base em um pipeline, mostrou-se fundamental tanto para o desempenho das previsões quanto para a otimização do tempo dedicado à parametrização, dado o grande número de modelos treinados. Também se observa o benefício desse método na seleção apropriada do número de neurônios e outros hiperparâmetros que estão diretamente ligados à necessidade de aumentar os recursos computacionais. É digno de nota uma modificação realizada nas funções de ativação das redes RNN, GRU e LSTM, onde a aplicação da função ReLU resultou em melhorias nos modelos.

5 CONCLUSÕES

Este trabalho descreveu a criação modelos computacionais baseados em rede neurais de aprendizado profundo, aplicados na predição da temperatura interna de um de um forno real de reaquecimento de placas de aço que usa queimadores pulsantes em seu sistema de controle térmico. A abordagem consistiu na construção de 21 modelos para previsão das temperaturas de 7 zonas de aquecimento. A precisão da previsão de cada modelo foi testada para três diferentes horizontes, pois um dos objetivos da criação desses modelos é empregá-los juntamente com técnicas avançadas de controle e otimização.

A importância da qualidade e tratamento do banco de dados foi fundamental para o sucesso do trabalho, pois cada conjunto de dados foi devidamente analisado como o objetivo de proporcionar o aprendizado dos modelos, bem como a redução da quantidade de dados, que tem total influência na capacidade de processamento computacional. Os resultados mostram uma capacidade grandiosa desses modelos para prever com precisão as temperaturas para horizontes de previsão curtos, médios e longos. Importante destacar que os modelos devem ser parametrizados e retreinados buscando o desempenho ótimo a um passo à frente, ou seja, a curto prazo, pois à medida que avançamos para previsões de médios ou longos horizontes, temos a degradação da predição.

Conforme apresentados nos resultados, mesmo com princípios operacionais distintos, os modelos RNN, GRU, LSTM e TCN obtiveram performance surpreendente para uma aplicação de curto prazo, mesmo sem uma avaliação criteriosa dos hiperparâmetros. Os resultados das predições de médio e longo prazo sofrem algumas penalizações pontuais e devem ser novamente analisados após os ajustes dos modelos. Assim, o teste de performance comparativa entre os modelos, pode ser mais efetivo. É valido ressaltar a diferença entre os modelos, quando analisamos os parâmetros treináveis, pois uma rede neural recorrente simples, RNN, foi capaz de predizer as temperaturas com uma quantidade de parâmetros infinitamente menor, quando comparamos com outros modelos mais elaborados com a GRU, LSTM e TCN.

Este trabalho descreve uma abordagem abrangente e promissora na previsão da

temperatura interna de um forno de reaquecimento de placas de aço, utilizando modelos baseados em redes neurais de aprendizado profundo. Algumas sugestões de trabalhos futuro são apresentadas a seguir:

- Refinamento dos modelos para especificação de médio e longo prazo: Dado que as variações de médio e longo prazo incluem algumas penalizações, é importante investigar e ajustar os modelos específicos para lidar com esses horizontes de previsão. Isso pode envolver estratégias como regularização, arquiteturas específicas ou técnicas de pré-processamento de dados.
- Comparação de desempenho entre os modelos: Realizar uma análise mais detalhada e comparativa do desempenho de diferentes modelos, especialmente em termos de eficiência computacional e capacidade de generalização, isso pode fornecer insights valiosos para a seleção do modelo mais adequado para diferentes cenários de aplicação.
- Exploração de técnicas de otimização e controle: Integrar os modelos de previsão desenvolvidos com técnicas avançadas de controle e otimização para melhorar o desempenho geral do sistema de controle térmico do forno. Isso pode incluir abordagens como controle preditivo baseado em modelo (MPC) ou técnicas de otimização multiobjetivo.
- Considerações sobre a escalabilidade e eficiência computacional: Avaliar a escalabilidade dos modelos para lidar com conjuntos de dados maiores e garantir que os requisitos computacionais sejam viáveis em ambientes de produção em larga escala.

REFERÊNCIAS

AÇO BRASIL. **Mini anuário – A Siderurgia em Números 2022.** https://acobrasil.org.br/site/wpcontent/uploads/2022/05/AcoBrasil_Mini_anuario_2022.pdf. Acesso em: 18 Nov. 2022.

BAI, Shaojie; KOLTER, J. Zico; KOLTUN, Vladlen. **An empirical evaluation of generic convolutional and recurrent networks for sequence modeling**. arXiv preprint arXiv:1803.01271, 2018.

BENGIO, Yoshua; SIMARD, Patrice; FRASCONI, Paolo. **Learning long-term dependencies with gradient descent is difficult**. IEEE transactions on neural networks, v. 5, n. 2, p. 157-166, 1994.

BONTEMPI, Gianluca; BEN TAIEB, Souhaib; LE BORGNE, Yann-Aël. Machine learning strategies for time series forecasting. Business Intelligence: Second European Summer School, eBISS 2012, Brussels, Belgium, July 15-21, 2012, Tutorial Lectures 2, p. 62-77, 2013.

CAILLAT, Sébastien. Burners in the steel industry: utilization of by-product combustion gases in reheating furnaces and annealing lines. **Energy Procedia**, v. 120, p. 20-27, 2017.

CARHUAVILCA, L. Agüero et al. A Comparison of GPC and Fuzzy Smith Predictor for Temperature Control of Steel Slab Reheating Furnace. In: **2021 IEEE XXVIII International Conference on Electronics, Electrical Engineering and Computing (INTERCON)**. IEEE, 2021. P. 1-4.

CHEN, Demin et al. Variations on billet gas consumption intensity of reheating furnace in different production states. Applied Thermal Engineering, v. 129, p. 1058-1067, 2018.

CHIAVERINI, VICENTE. Aços e ferros fundidos. 7 edição. **São Paulo: Editora Associação Brasileira de Metalurgia e Materiais–ABM**, 2005.

CHUNG, Junyoung et al. **Empirical evaluation of gated recurrent neural networks on sequence modeling**. arXiv preprint arXiv:1412.3555, 2014.

CHURCHLAND, Patricia Smith; SEJNOWSKI, Terrence Joseph. **The computational brain**. MIT press, 1994.

FELIU-BATLLE, V. et al. Fractional order temperature control of a steel slab reheating furnace robust to delay changes. In: Proceedings of 5th IFAC Workshop on Fractional Differentiation and its Applications, Nanjing, China. 2012.

GLAESSGEN, Edward; STARGEL, David. The digital twin paradigm for future NASA and US Air Force vehicles. In: **53rd AIAA/ASME/ASCE/AHS/ASC structures, structural dynamics, and materials conference 20th AIAA/ASME/AHS adaptive structures conference 14th AIAA**. 2012. P. 1818.

H.E. Pike, S.J. Citron, **Optimization studies of a slab reheating furnace**, Automatica, Volume 6, Issue 1, 1970, Pages 41-50, ISSN 0005-1098, https://doi.org/10.1016/0005-1098(70)90073-7.

HAYKIN, S. (2009). **Neural Networks and Learning Machines**. 3rd edition, Pearson Education, Inc., New Jersey.

HE, Kaiming et al. **Deep residual learning for image recognition**. CVPR. 2016. arXiv preprint arXiv:1512.03385, 2016.

HEATON, Jeff. Introdução às redes neurais com Java. Heaton Research, Inc., 2008.

HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. **Long short-term memory**. Neural computation, v. 9, n. 8, p. 1735-1780, 1997.

HU, Yukun et al. Model-based multi-objective optimization of reheating furnace

operations using genetic algorithm. **Energy Procedia**, v. 142, p. 2143-2151, 2017.

JANG, Jung Hyun et al. Investigation of the slab heating characteristics in a reheating furnace with the formation and growth of scale on the slab surface. **International Journal of Heat and Mass Transfer**, v. 53, n. 19-20, p. 4326-4332, 2010.

KHALID, Yusra et al. Combustão de enriquecimento de oxigênio para reduzir o consumo de energia fóssil e as emissões na produção de aço laminado a quente. Journal of Cleaner Production, v. 320, p. 128714, 2021.

KAPLUNOVICH, Alex; YESHA, Yelena. Automatic tuning of hyperparameters for neural networks in serverless cloud. In: 2020 IEEE International Conference on Big Data (Big Data). IEEE, 2020. P. 2751.

KINGMA, Diederik P.; BA, Jimmy. Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980, 2014.

LANDFAHRER, M. et al. Modelo numérico incorporando diferentes oxidantes em um forno de reaquecimento alimentado com gás natural. Fuel, v. 268, p. 117185, 2020

LEA, Colin et al. **Temporal convolutional networks for action segmentation and detection**. In: proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017. P. 156-165.

LIAO, Ying-Xin; SHE, Jin-Hua; WU, Min. **Integrated hybrid-PSO and fuzzy-NN decoupling control for temperature of reheating furnace.** IEEE transactions on industrial electronics, v. 56, n. 7, p. 2704-2714, 2009.

LIMA, Rodrigo de Souza; SCÁRDUA, Leonardo Azevedo; DE ALMEIDA, Gustavo Maia. Previsão de temperaturas dentro de um forno de reaquecimento de placas de aço usando Deep Learning. In: 2023 15ª Conferência Internacional IEEE sobre Aplicações Industriais (INDUSCON). IEEE, 2023. p. 655-662.

LIU, Xiang et al. Numerical simulation of heat transfer and scale formation in a reheat

furnace. **Steel research international**, v. 90, n. 4, p. 1800385, 2019.

LUO, Xiaochuan; YANG, Zhi. A new approach for estimation of total heat exchange factor in reheating furnace by solving an inverse heat conduction problem. **International Journal of Heat and Mass Transfer**, v. 112, p. 1062-1071, 2017.

MOREIRA, Ângelo Campos, Moreira Lara de Assis, Botelho Alexander de Oliveira. **Novas tecnologias aplicadas ao forno de reaquecimento de placas do LTQ da CST.** Associação Brasileira de Metalurgia e Materiais; São Paulo, SP, Brasil; 2004**.**

NIEKURZAK, Mariusz; MIKULIK, Jerzy. **Modeling of Energy Consumption and Reduction of Pollutant Emissions in a Walking Beam Furnace Using the Expert Method—Case Study**. Energies, v. 14, n. 23, p. 8099, 2021.
NIELSEN, Michael A. **Neural Networks and Deep Learning.** San Francisco: Determination Press, 2015.

OORD, Aaron van den et al. Wavenet: **A generative model for raw audio**. arXiv preprint arXiv:1609.03499, 2016.

PÁTRIA, Henrique. Aços Planos: produção, redução, refino e produtos finais. Siderurgia Brasil, Grips Editora, Ano 21, Nº 141, p. (27-31), Outubro, 2020.

POLLHAMMER, Werner et al. Modeling of a walking beam furnace using CFD–methods. **Energy Procedia**, v. 120, p. 477-483, 2017.

RAMPINELLI, Vinicius L. C.; Moreira, Lara A.; Novais, Eduardo J. **Energy efficiency increasing in slab reheating furnace of a steel plant**. Technical contribution to the 11th International Rolling Conference, part of the ABM Week 2019, October 1st -3 rd, 2019, São Paulo, SP, Brazil.

ROJAS, Raúl. **Neural networks: a systematic introduction**. Springer Science & Business Media, 2013.

ROSADO, Diego J. Mariños et al. Energetic analysis of reheating furnaces in the combustion of coke oven gas, Linz-Donawitz gas and blast furnace gas in the steel industry. **Applied Thermal Engineering**, v. 169, p. 114905, 2020.

SRIVASTAVA, Nitish et al**. Dropout: a simple way to prevent neural networks from overfitting**. The journal of machine learning research, v. 15, n. 1, p. 1929-1958, 2014.

SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes neurais artificiais para engenharia e ciências aplicadas**. 2°edição. São Paulo: Artliber, 2010.

STEINBOECK, A. et al. A mathematical model of a slab reheating furnace with radiative heat transfer and non-participating gaseous media. **International Journal of Heat and Mass Transfer**, v. 53, n. 25-26, p. 5933-5946, 2010.

STEINBOECK, Andreas; WILD, Daniel; KUGI, Andreas. Feedback tracking control of continuous reheating furnaces. **IFAC Proceedings Volumes**, v. 44, n. 1, p. 11744-11749, 2011.

TAIEB, Souhaib Ben et al. Recursive and direct multi-step forecasting: the best of both worlds. Department of Econometrics and Business Statistics, Monash Univ., 2012.

TEIXEIRA, Bruno Otávio Soares; JOTA, Fábio Gonçalves; TEIXEIRA, Marcos Henrique. Modelagem, controle e otimização do processo dos fornos de reaquecimento de placas. Sba: Controle & Automação Sociedade Brasileira de Automatica, v. 18, p. 67-93, 2007.

TRINKS, W.; MAWHINNEY, M.; SHANNON, R.; REED, R.; GARVEY, J. **Industrial Furnaces**. 6. Ed. New York: John Wiley & Sons, 2004.

TUBARÃO, ArcelorMittal. **Diagnóstico de processo dos fornos de reaquecimento de placas**. Manual Operacional, Revisão 1, ArcelorMittal Tubarão, Serra, 2008.

TUBARÃO, ArcelorMittal. **Produtos e Soluções**. Disponível em: <

https://brasil.arcelormittal.com/produtos-solucoes>. Acesso em 30 de julho de 2022.

TUBARÃO, ArcelorMittal. **Produtos e Soluções**. Disponível em: < https://brasil.arcelormittal.com/produtos-solucoes>. Acesso em 25 de setembro de 2022.

WORLDSTEEL, Association. **Crude steel production and 2021 global crude steel production totals.** Disponível em: (https://worldsteel.org/media-centre/press-releases/2022/december-2021-crude-steel-production-and-2021-global-totals/). Acesso em: 28 jan. 2022.

YANG, Yong-yao; LU, Yong-zai. **Development of a computer control model for slab reheating furnaces**. **Computers in Industry**, v. 7, n. 2, p. 145-154, 1986.

YANG, Y., and Lu, Y. **Dynamic model-based optimization control for reheating furnaces**, Computers in Industry 10: 11–20, 1988.

ZHAI N, Zhou X. **Temperature Prediction of Heating Furnace Based on Deep Transfer Learning**. Sensors (Basel). 2020 Aug 19;20(17):4676. doi: 10.3390/s20174676. PMID: 32825025; PMCID: PMC7506676.

ZHANG, Bin et al. The modeling and control of a reheating furnace. In: **Proceedings of the 2002 American Control Conference (IEEE Cat. No. CH37301)**. IEEE, 2002. p. 3823-3828.

ZHAO, JUN ET AL. INDUSTRIAL REHEATING FURNACES: A REVIEW OF ENERGY EFFICIENCY ASSESSMENTS, WASTE HEAT RECOVERY POTENTIALS, HEATING PROCESS CHARACTERISTICS AND PERSPECTIVES FOR STEEL INDUSTRY. **PROCESS SAFETY AND ENVIRONMENTAL PROTECTION**, V. 147, P. 1209-1228, 2021.

ANEXO A – Resultados das previsões e avaliação do erro por zona

- Zona 2: Predição.

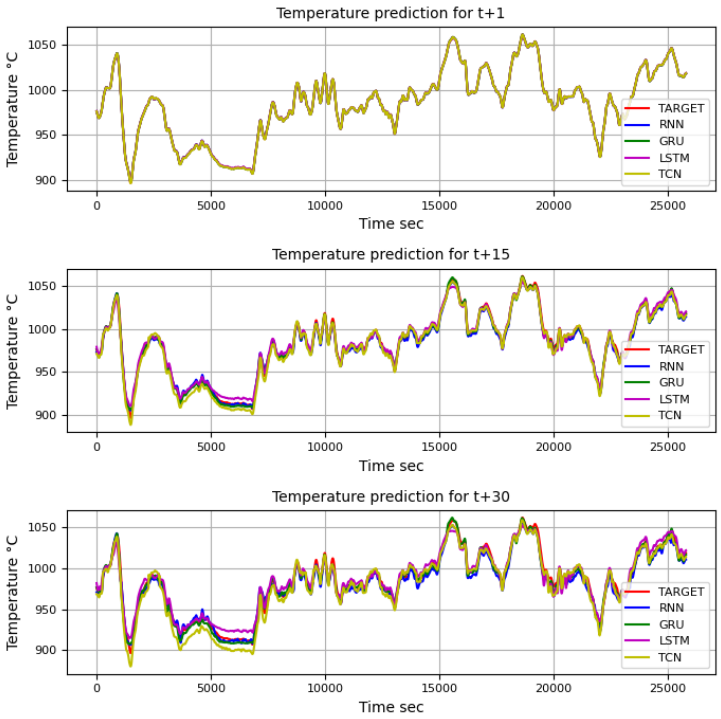

- Zona 02 – Erro RNN, GRU, LSTM e TCN

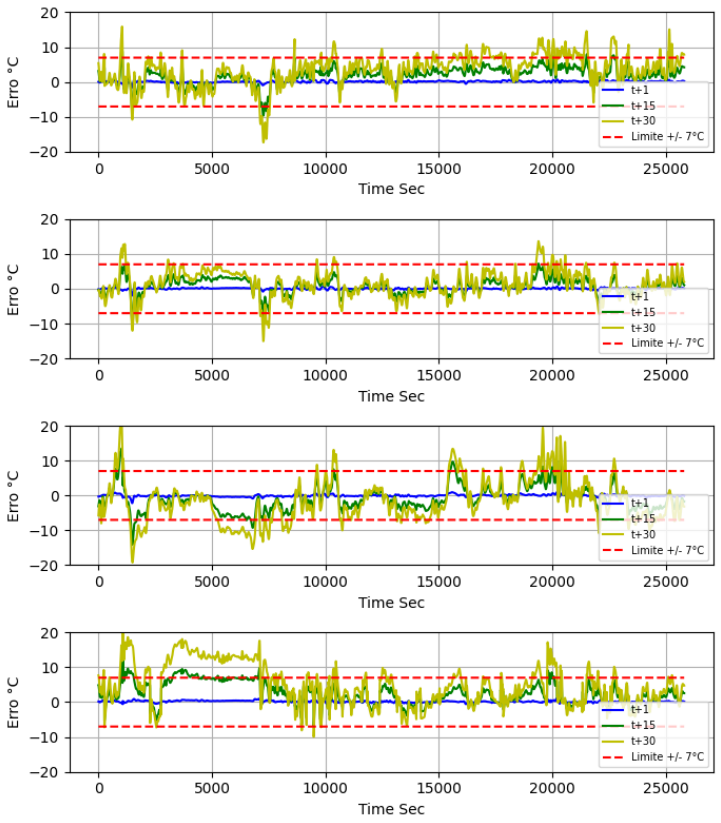

- Zona 03 – Predição.

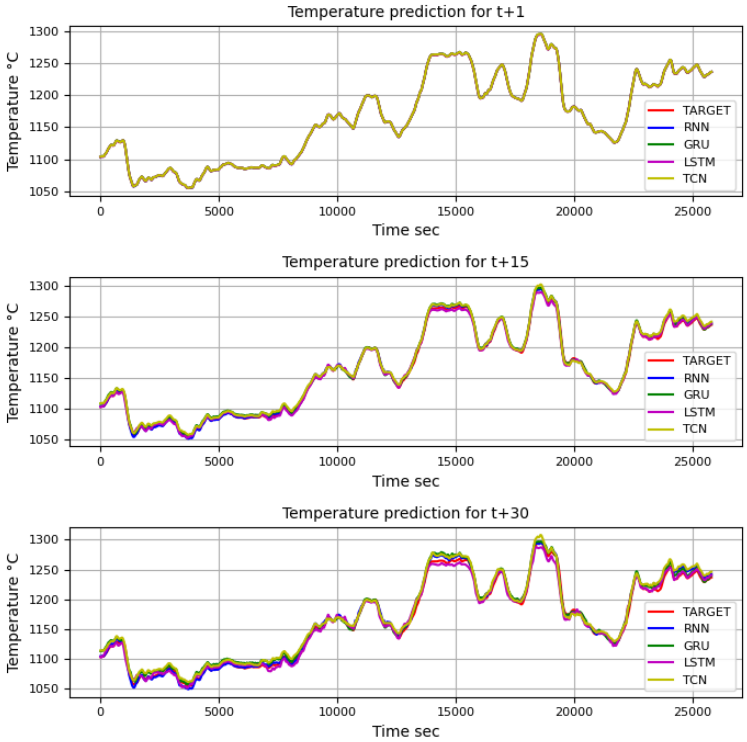

- Zona 03 – Erro RNN, GRU, LSTM e TCN.

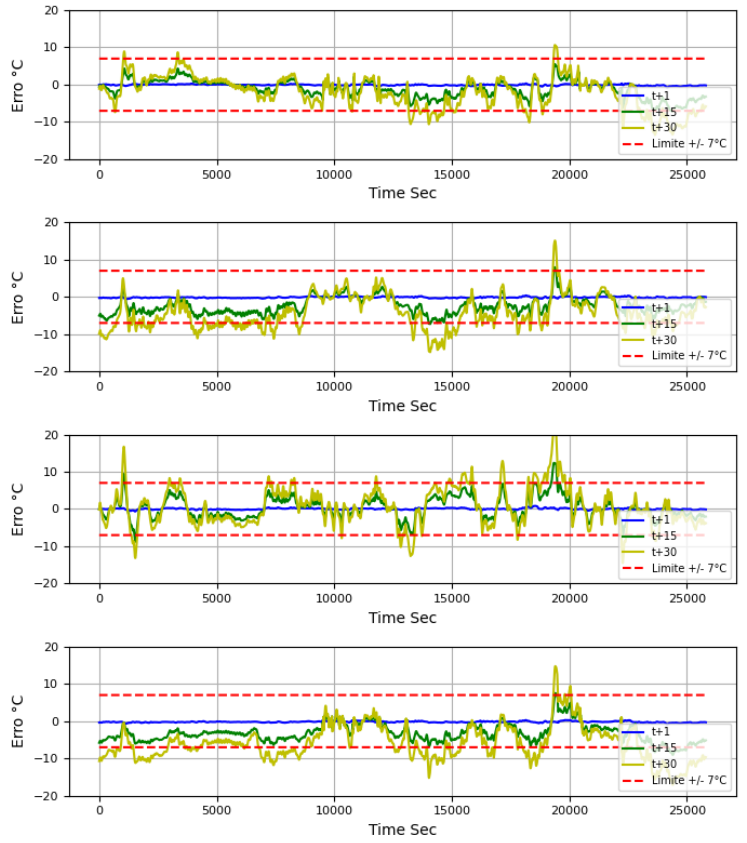

- Zona 04 – Predição.

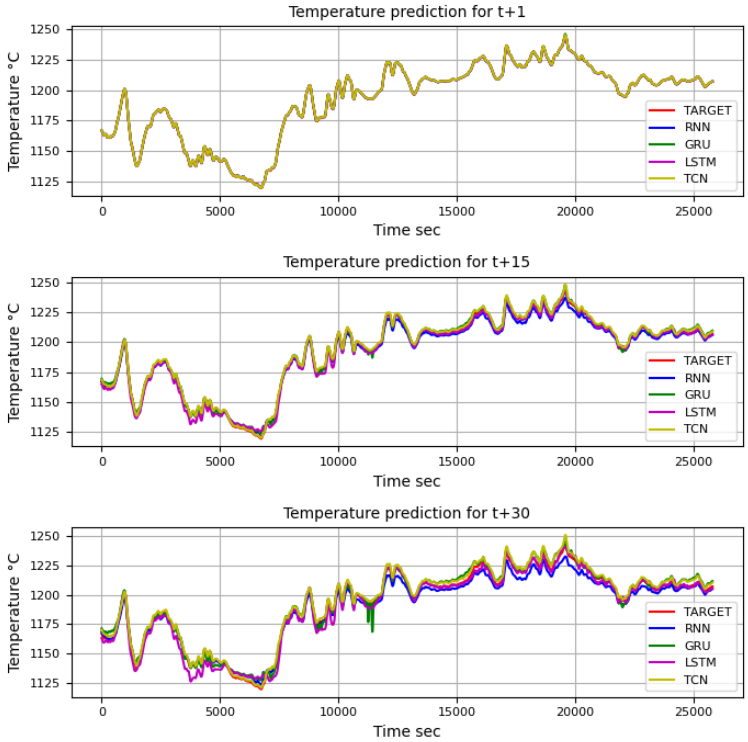

- Zona 04 – Erro RNN, GRU, LSTM e TCN.

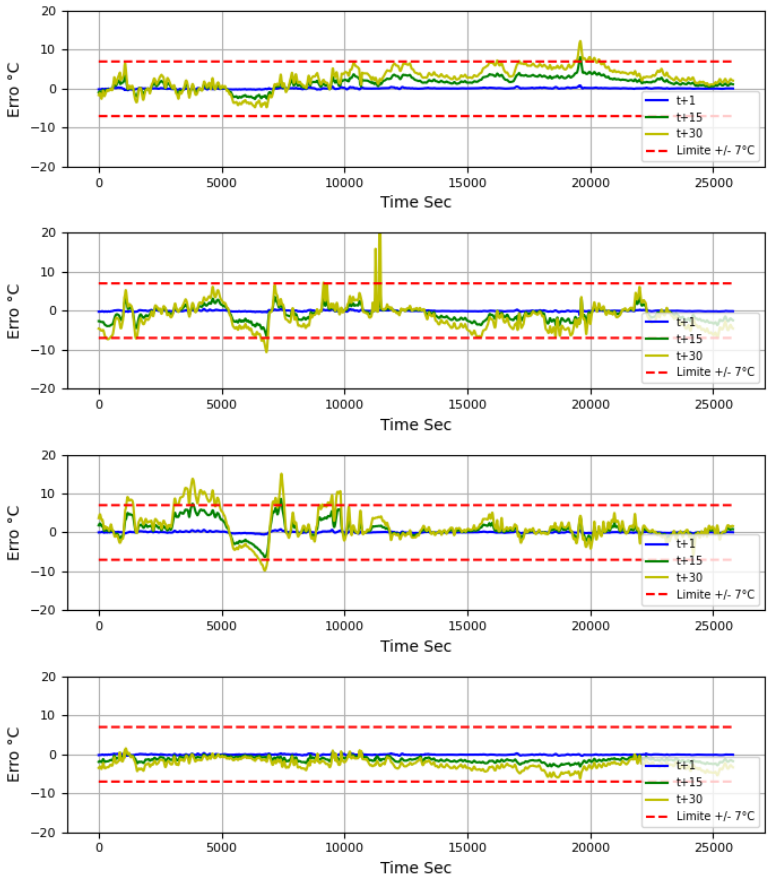

- Zona 05 – Predição.

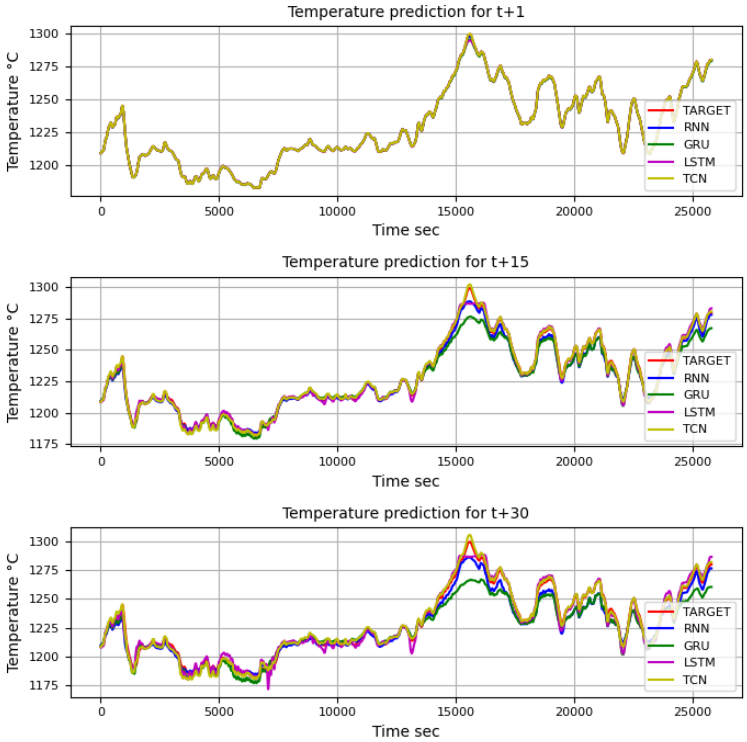

- Zona 05 – Erro RNN, GRU, LSTM e TCN.

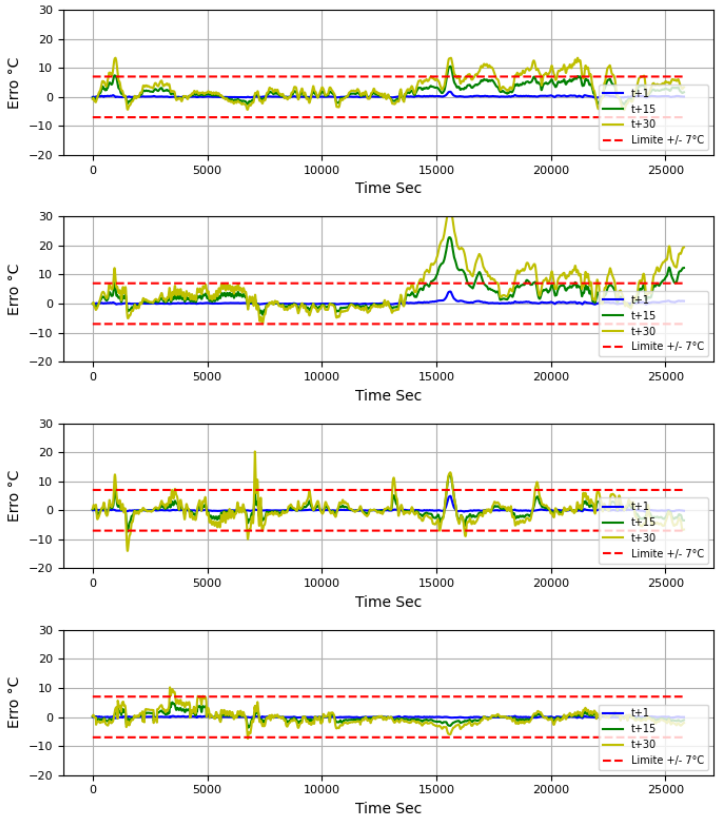

- Zona 06 - Predição

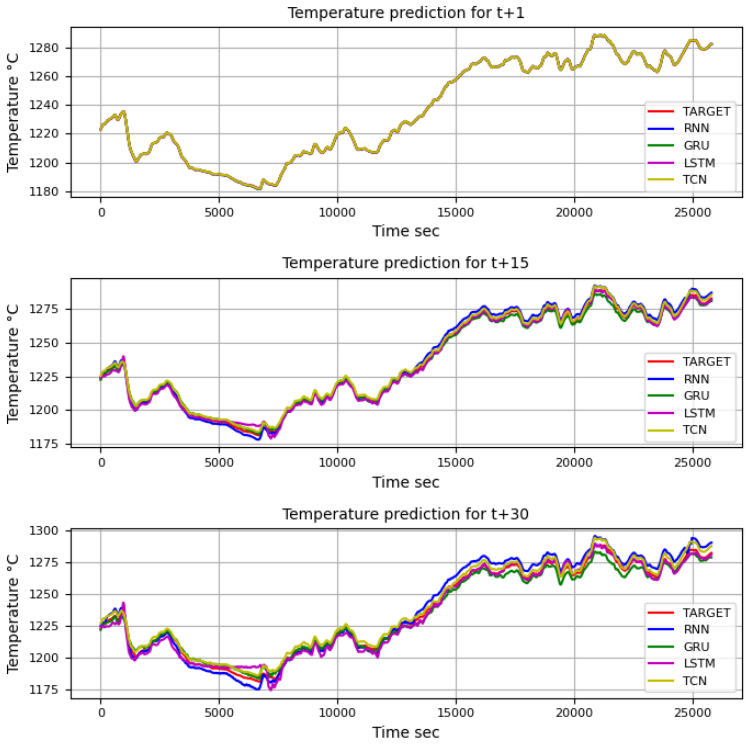

- Zona 06 – Erro RNN, GRU, LSTM e TCN.

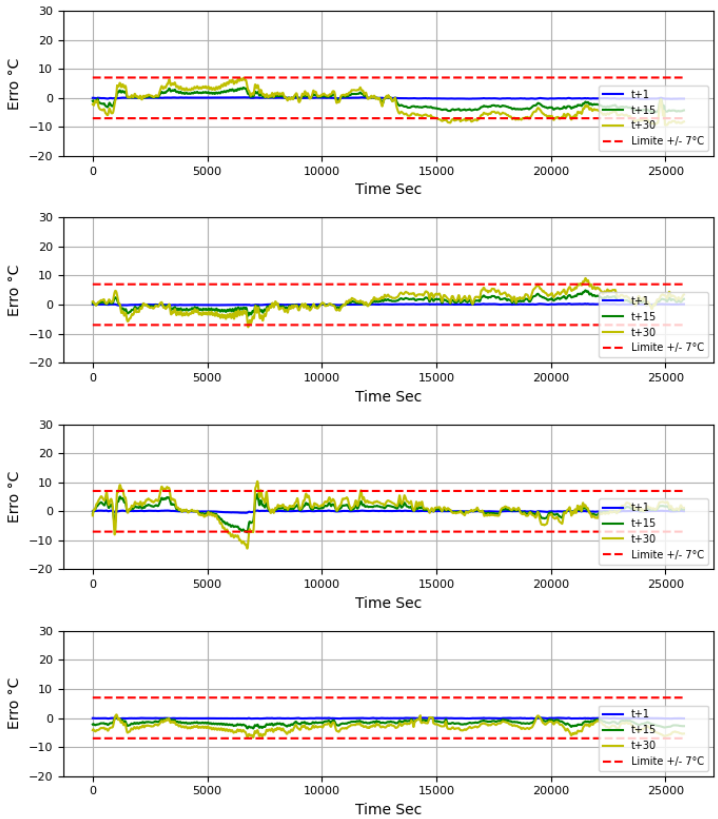

- Zona 08 – Predição.

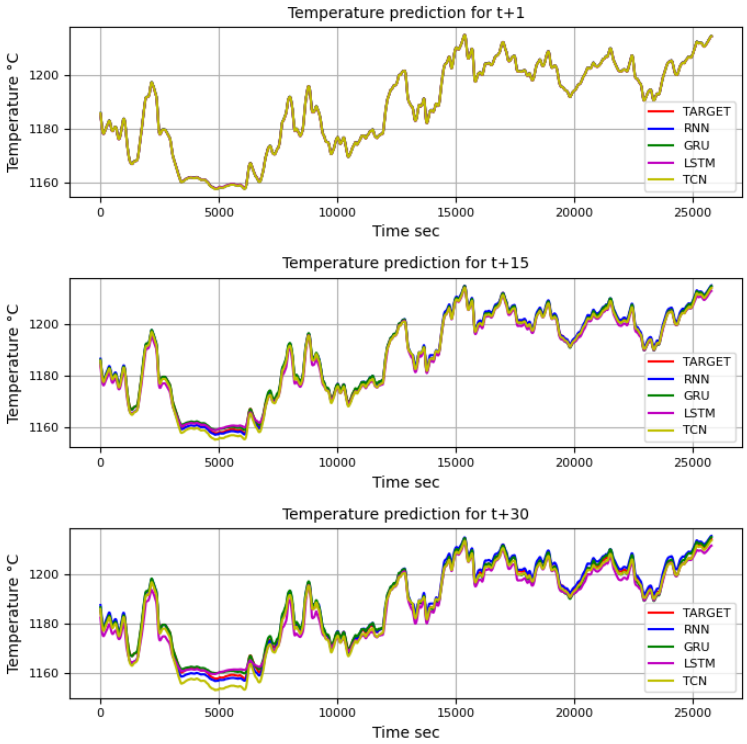
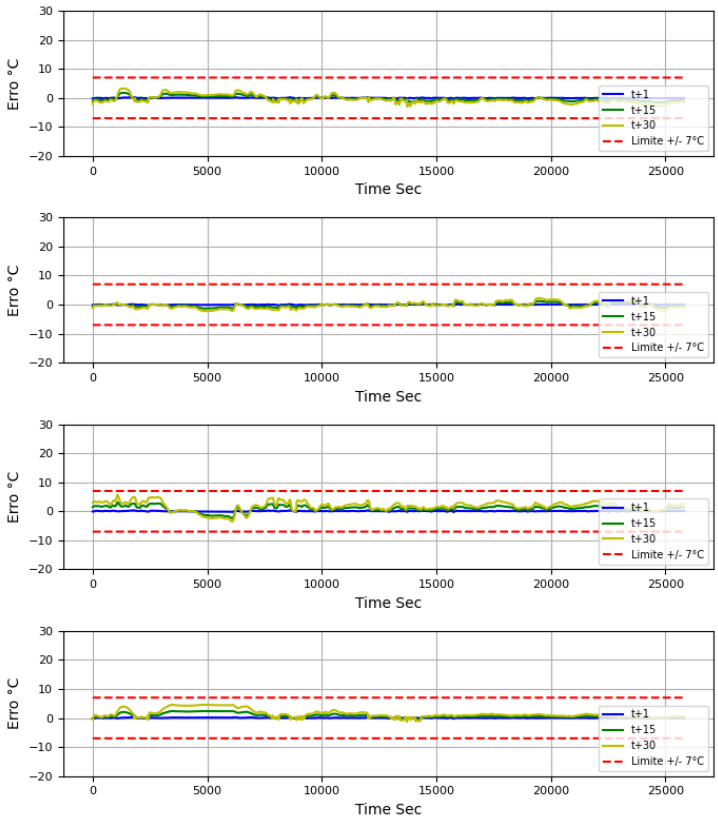
- Zona 08 – Erro RNN, GRU, LSTM e TCN.