



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



DIANE OTÍLIA LIMA FONTES

**DESENVOLVIMENTO DE SOFT SENSOR PARA PREDIÇÃO DO ESTADO
TÉRMICO DO FERRO GUSA EM ALTO-FORNO USANDO FUZZY C-MÉDIAS E
MODELO EXÓGENO AUTO-REGRESSIVO NÃO LINEAR**

**CAMPINA GRANDE - PB
AGOSTO DE 2020**

DIANE OTÍLIA LIMA FONTES

**DESENVOLVIMENTO DE SOFT SENSOR PARA PREDIÇÃO DO ESTADO
TÉRMICO DO FERRO GUSA EM ALTO-FORNO USANDO FUZZY C-MÉDIAS
E MODELO EXÓGENO AUTO-REGRESSIVO NÃO LINEAR**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Química da Universidade Federal de Campina Grande, como requisito para obtenção do título de Mestre em Engenharia Química, sob a orientação do Professor Dr. Luis Gonzaga Sales Vasconcelos.

CAMPINA GRANDE – PB

AGOSTO DE 2020

F682d

Fontes, Diane Otília Lima.

Desenvolvimento de soft sensor para predição do estado térmico do ferro gusa em alto-forno usando fuzzy c-médias e modelo exógeno auto-regressivo não linear / Diane Otília Lima Fontes. - Grande, 2020.
85f. : il. Color.

Dissertação (Mestrado em Engenharia Química) - Universidade Federal de Campina Grande, Centro de Ciência e Tecnologia, 2020.

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

Referências.

1. Estado Térmico. 2. Alto Forno. 3. Soft Sensor. 4. FCM. 5. NARX.
I. Vasconcelos, Luis Gonzaga Sales. II. Título.

CDU 66-97(043)

DIANE OTÍLIA LIMA FONTES

**DESENVOLVIMENTO DE SOFT SENSOR PARA PREDIÇÃO DO ESTADO
TÉRMICO DO FERRO GUSA EM ALTO-FORNO USANDO FUZZY C-MÉDIAS E
MODELO EXÓGENO AUTO-REGRESSIVO NÃO LINEAR**

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

Dissertação aprovada em: 28 / agosto / 2020

BANCA EXAMINADORA

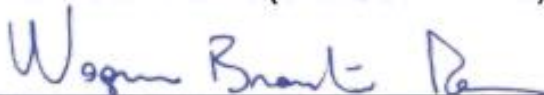


Prof. Dr. Luis Gonzaga Sales Vasconcelos
Orientador (UAEQ/CCT/UFCG)

ROMILDO PEREIRA
BRITO:41912675404

Digitally signed by ROMILDO
PEREIRA BRITO:41912675404
Date: 2020.09.02 19:36:55
+03'00'

Prof. Romildo Pereira Brito
Examinador Interno (UAEQ/CCT/UFCG)



Prof. Wagner Brandão Ramos
Examinador Interno (UAEQ/CCT/UFCG)



Prof. Arioston Araújo De Moraes Junior
Examinador Externo (DEQ/CT/UFPB)

Aos meus pais Everton (in memoriam) e Rosineide, minha fonte de amor e proteção, o combustível necessário para eu chegar até aqui.

AGRADECIMENTOS

Aos meus pais, Everton (*in memoriam*) e Rosineide, por serem pais dedicados ao meu desenvolvimento educacional/profissional por me proporcionar suporte, amor, infinitas doses de paciência, cuidados, além de serem fonte de inspiração para as minhas realizações e conquistas.

Ao meu irmão Raí, por acreditar em mim e ser meu companheiro em jornadas acadêmicas e de vida. Ao meu irmão Djalma, pelo carinho.

Aos amigos Aline, Arthur, David, Everton, Ítala, Jéssica, Mariane, Paloma, Rafaela, Ranny e Vitória que se tornaram família por acompanhar de perto essa jornada, amenizando o peso das tarefas e multiplicando as coisas boas.

A minha família pelo carinho e preocupação em todas as minhas realizações.

Ao Prof. Dr. Luis Gonzaga Sales Vasconcelos pelo tempo dedicado a supervisão, orientação, apoio e confiança durante a realização desse trabalho.

Ao Prof. Dr. Romildo Pereira Brito, ao Prof. Dr. Wagner Brandão Ramos e ao Prof. Dr. Arioston Araújo De Moraes Junior, por aceitarem o convite para avaliar e contribuir com mais essa experiência acadêmica.

Ao Laboratório de Referência em Controle e Automação (LARCA) pela infraestrutura fornecida e a equipe de trabalho pelo acolhimento durante a realização das atividades.

A todos que aqui não foram citados, mas que de alguma forma contribuíram para que eu chegasse até aqui.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES).

“É bom ter um objetivo nas jornadas que empreendemos; mas, no fim das contas, o que importa é a jornada em si.”

Ursula K. Le Guin

FONTES, Diane Otília Lima. **Desenvolvimento de soft sensor para predição do estado térmico do ferro gusa em alto-forno usando FCM e NARX**. 2020. 85 p. Dissertação (Mestrado em Engenharia Química). Universidade Federal de Campina Grande – UFCG. Campina Grande, PB.

RESUMO

A temperatura e a composição de silício no ferro gusa são parâmetros essenciais para o controle térmico do alto-forno. Entretanto, a estrutura física do alto-forno não permite métodos diretos e online para detectar esses parâmetros. Neste estudo, foi proposto um algoritmo híbrido usando *fuzzy c*-médias (FCM) e modelo exógeno auto-regressivo não linear (NARX) para construir um soft sensor capaz de prever a temperatura do gusa e o teor de silício em um intervalo de amostragem regular. O FCM é uma técnica de modelagem de dados para gerar subconjuntos similares entre si e dissimilares entre os outros subconjuntos. Sua importância se dá pelo fato de descobrir agrupamentos naturais dos dados observados, neste caso, determinar grupos de condições operacionais. O modelo neural NARX visa gerar um modelo de predição dos indicadores. O algoritmo proposto foi avaliado a partir da sua eficiência em um processo industrial de fabricação de ferro gusa em um alto-forno. Os resultados obtidos demonstraram que construir um soft sensor com modelos FCM-NARX apresenta um alto desempenho, tendo um coeficiente de determinação para a predição para a temperatura e teor de silício no gusa de 99,7% e 99,6%, respectivamente.

Palavras-chave: Alto-forno, Estado térmico, Soft sensor, FCM, NARX.

FONTES, Diane Otília Lima. **Development of soft sensor for prediction of the thermal state of hot metal in blast furnace using FCM and NARX**. 2020. 85 p. Dissertation (Master's degree in Chemical Engineering). Federal University of Campina Grande – UFCG. Campina Grande, PB.

ABSTRACT

The temperature and silicon content of hot metal are essential parameters for the thermal control of a blast furnace. However, the physical structure of the blast furnace prevents direct and online methods from accurately predicting these parameters. In this study, it was proposed a new algorithm based on fuzzy c-means (FCM) and exogenous nonlinear autoregressive model (NARX) to develop a soft sensor for predicting the temperature and silicon content of hot metal. FCM is a data modeling technique that works by clustering similar data objects while separating dissimilar ones. FCM is highly effective in the identification of natural groupings in the observed data; in this case, determination of groups of operational conditions. The NARX neural network presents a model for the accurate prediction of temperature and silicon content of hot metal. The proposed algorithm was evaluated based on its efficiency in simulating the industrial process for manufacturing hot metal in a blast furnace. The results showed that a soft sensor based on FCM-NARX models presents a high performance, with a determination coefficient for the prediction of temperature and silicon content in hot metal of 99.7% and 99.6%, respectively.

Keywords: Blast furnace, Thermal state, Soft sensor, FCM, NARX.

LISTA DE FIGURAS

Figura 1-1 – Ranking de produção de aço bruto em 2018 em milhões de toneladas.	17
Figura 2-1 – Sistemas que compõe uma unidade de Alto-forno.....	21
Figura 2-2 – Esquema de funcionamento do alto forno.....	23
Figura 2-3 – Zonas internas do Alto-Forno.....	24
Figura 2-4 – Divisão, reações e perfil de térmico do alto forno.....	26
Figura 4-1 – Ramos da Inteligência Artificial.	36
Figura 4-2 – Categorias de aprendizado de máquina com algoritmos comumente adotados.....	37
Figura 4-3 – Esquema simplificado de neurônios biológicos.....	41
Figura 4-4 – Modelo não linear de um neurônio.	42
Figura 4-5 – Representação da rede neural (a) feedforward de camada única, (b) feedforward multicamadas e (c) recorrente.....	44
Figura 4-6 – A estrutura de uma rede NARX.....	46
Figura 5-1 – Curva do Método do Cotovelo.....	56
Figura 5-2 – Representação das fases do algoritmo de retropropagação.....	61
Figura 5-3 – Fluxograma da construção do soft sensor.	63
Figura 6-1 – Interpolação de dados para (a) temperatura do gusa e (b) teor de silício.	66
Figura 6-2 – Identificação de outliers na medição da redução direta.	67
Figura 6-3 – Seleção dos clusters.	70
Figura 6-4 – Função objetivo do FCM variando com o número de clusters.	71
Figura 6-5 – Resultado da regressão para (a) temperatura do gusa e (b) teor de silício utilizando o modelo FCM-NARX.....	74
Figura 6-6 – Resultado da predição para (a) temperatura do gusa e (b) teor de silício utilizando o modelo FCM-NARX.....	74

LISTA DE TABELAS

Tabela 5-1 - Variáveis de processo selecionadas a partir da experiência industrial.	54
Tabela 6-1 – Seleção de variáveis de processo utilizadas como entrada do modelo.	68
Tabela 6-2 – Coordenadas dos centros de cada cluster.....	72
Tabela 6-3 – Resumo da otimização dos parâmetros da rede neural.....	73
Tabela 6-4 – Resumo dos parâmetros de desempenho das predições.....	73

LISTA DE SIGLAS

AM	Aprendizado de Máquina
DAM	Desvio Absoluto da Média
FCM	Fuzzy C-Means
MAPE	Mean Absolute Percentage Error
MMA	Média Móvel Aritmética
NARX	Modelo Exógeno Auto-regressivo Não-linear
PCHIP	Interpolação Cúbica Segmentada de Hermite
PCI	Pulverized Coal Injection
PLS	Partial Least Squares
RMSE	Root Mean Square Error
RNA	Redes Neurais Artificiais
SVR	Support Vector Regression

LISTA DE SÍMBOLOS

Símbolo	Significado	Unidade
C	Número de clusters	—
H	Funções Hermite	—
J	Função objetivo do FCM	—
P	Probabilidade	—
b	Bias	—
d	Derivada da função	—
g	Centro do cluster	—
m	Fator <i>fuzzy</i>	—
p	Função monotônica	—
u	entradas exógenas originárias	—
v	Saída do combinador linear	—
x	Sinal de entrada (variáveis do processo)	—
y	Sinal de saída	—

Letras Gregas

φ	Função de ativação	—
μ	Grau de pertencimento	—

Subscrito

c	Número de cluster
i	Número de amostras
k	Número de neurônios
n	Número de amostras
q	Número de atrasos

SUMÁRIO

1. INTRODUÇÃO	16
1.1. OBJETIVO GERAL.....	18
1.2. OBJETIVOS ESPECÍFICOS	18
1.3. ORGANIZAÇÃO DA DISSERTAÇÃO.....	19
2. ALTO-FORNO E A PRODUÇÃO DO FERRO GUSA.....	21
2.1. MATÉRIAS-PRIMAS	22
2.2. PRINCÍPIO DE FUNCIONAMENTO	22
2.3. ZONAS FÍSICAS E PRINCIPAIS REAÇÕES.....	23
2.4. OPERAÇÃO DO ALTO-FORNO.....	26
3. DESCRIÇÃO DO PROBLEMA	30
3.1. ESTUDO DE CASO.....	30
3.2. REVISÃO BIBLIOGRÁFICA	31
4. INTELIGÊNCIA ARTIFICIAL	35
4.1. APRENDIZADO DE MÁQUINA	35
4.1.1. <i>Fuzzy C-Médias</i>	38
4.1.2. Redes Neurais Artificiais	40
5. MODELAGEM DO ALTO-FORNO.....	49
5.1. AMBIENTE DE SIMULAÇÃO	49
5.2. PREPARAÇÃO DOS DADOS	50
5.2.1. Interpolação de Dados	50
5.3. PRÉ-PROCESSAMENTO DE DADOS.....	52
5.3.1. Substituição de Dados Ausentes.....	52
5.3.2. Substituição de <i>Outliers</i>	52
5.4. SELEÇÃO DE VARIÁVEIS	53
5.5. ESCOLHA DOS <i>CLUSTERS</i>	55
5.6. MODELO NARX.....	56
5.6.1. Otimização Bayesiana.....	57
5.6.2. Treinamento da Rede.....	59
5.7. CRITÉRIO DE AVALIAÇÃO	61

5.8. RESUMO DO ALGORITMO	62
6. RESULTADOS E DISCUSSÕES	65
6.1. DESENVOLVIMENTO DO SOFT SENSOR	65
7. CONCLUSÃO	77
REFERÊNCIAS	78
ANEXOS.....	85
ANEXO A – TRABALHO PUBLICADO	85

CAPÍTULO 1

INTRODUÇÃO

1. INTRODUÇÃO

A indústria siderúrgica é uma das indústrias mais importantes do mundo moderno, permanecendo no centro do desenvolvimento global. A maioria dos produtos usados é feita ou fabricada com aço. Por ser versátil e proporcionar alto desempenho em suas utilizações, o aço é um material continuamente aprimorado para atender às novas demandas do mercado. (ZHOU et al., 2017).

Há dois tipos principais de matérias-primas para produzir o aço: ferro gusa, ou simplesmente gusa, e sucata de aço. Para cada uma dessas matérias-primas há uma rota de produção associada. As usinas integradas produzem aço a partir do minério de ferro, usando o carvão (mineral ou vegetal) como agente redutor nos altos-fornos, para obtenção do ferro metálico. Já as usinas semi-integradas não incluem a etapa de redução e usam sucata de aço e ferro gusa para alimentar as aciarias elétricas (CAMERON et al., 2020; YANG; RAIPALA; HOLAPPA, 2014)

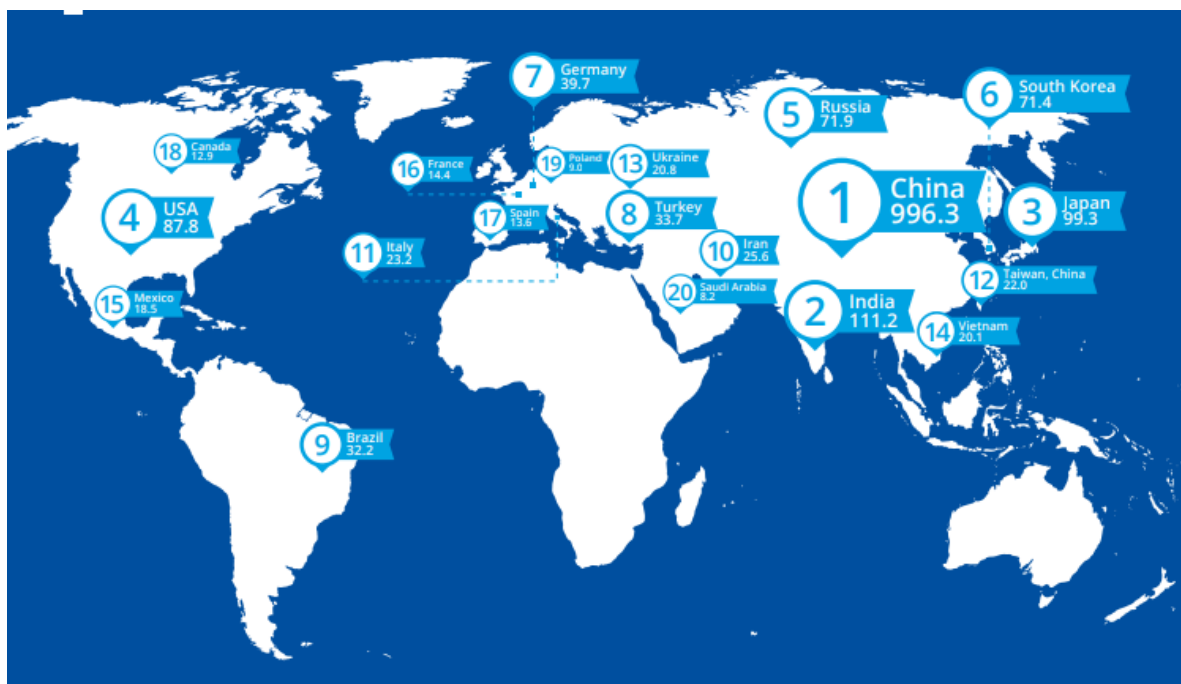
A produção mundial de aço bruto atingiu pouco mais de 1.869 milhões de toneladas em 2019. O Brasil ocupa a nona posição no ranking dos países produtores de aço bruto no mundo, correspondendo a aproximadamente 32,2 milhões de toneladas. Na Figura 1-1 é mostrado o ranking dos 20 maiores produtores mundiais de aço bruto. Estima-se que cerca de 70,7% dessa produção foi obtida via rota integrada a partir de alto-forno, enquanto que o percentual remanescente utilizou rota semi-integrada com o forno elétrico a arco (WORLD STEEL ASSOCIATION, 2020).

Energia térmica e energia elétrica são intensivamente utilizadas nos processos siderúrgicos. Apesar da energia térmica envolver quase todos os processos, sua maior utilização se dá nas unidades integradas, que englobam os processos de sinterização, coqueificação e redução. O alto-forno desempenha o papel de fundir e reduzir o minério de ferro, sendo a operação de maior consumo de energia. Essa energia corresponde, principalmente, à energia térmica do agente termo redutor e à injeção de finos de material carbonoso (BERNASOWSKI; KLIMCZYK; STACHURA, 2019; HASHIMOTO et al., 2019).

O alto-forno é um reator contínuo de grande dimensão, baseado no princípio de fluxo contracorrente, no qual há troca de calor à medida que acontecem as reações. Também é caracterizado por sua grande dimensão e de alta produtividade. Seu objetivo é produzir continuamente ferro gusa de alta qualidade e baixo custo de produção. Operar e controlar precisamente o alto-forno é uma tarefa desafiadora

devido aos ambientes operacionais adversos, tal como alta temperatura e alta pressão, inúmeras reações físico-químicas complexas, além de transferência de calor não uniforme e fluxos de fluido multifásicos dentro do forno (ZHANG; KANO; MATSUZAKI, 2019a; ZHOU et al., 2015a).

Figura 1-1 – Ranking de produção de aço bruto em 2018 em milhões de toneladas.



Fonte: World Steel in Figures 2020.¹

A temperatura e a composição de silício no ferro gusa são parâmetros essenciais para o controle térmico do alto forno. A temperatura do gusa reflete o estado térmico, o consumo de energia e a qualidade; a composição de silício no gusa indica o estado termoquímico do ferro gusa. Por se tratar de um reator vertical grande de alta temperatura e fechado, não há método para detectar diretamente esses índices no cadinho do alto-forno, isto é, os instrumentos regulares atuais não têm a capacidade de fornecer medições online para a qualidade do ferro gusa. Devido a essas dificuldades na medição, na maioria dos altos-fornos o controle térmico ainda é corretivo, ou seja, uma ação é tomada a partir da observação de um desvio na faixa de temperatura ou composição do gusa. Portanto, o controle térmico geralmente

¹ Disponível em: <<https://www.worldsteel.org/en/dam/jcr:e1f8ca82-b51f-4b10-9edf-5498780a9059/World%20Steel%20in%20Figures%202020%20infographic.pdf>>. Acessado em: 10 jun. 2020.

depende da experiência do operador e a resposta ao problema pode ser lenta (GASPARINI et al., 2017; IFFAT et al., 2018; ZHOU et al., 2017).

A competitividade industrial no mercado mundial torna a busca por redução de gastos operacionais uma tarefa primordial. Portanto, a gestão eficiente do processo deve contar com o acesso a indicadores importantes durante a operação para tomar de decisões estratégicas assertivas. Para esse fim, torna-se fundamental o desenvolvimento de um modelo capaz de prever em tempo real o estado térmico do alto-forno (ZHANG; KANO; MATSUZAKI, 2019b).

As metodologias para análise de processos, geralmente, são divididas em dois grandes grupos: modelos fenomenológicos e modelos orientados a dados. A abordagem fenomenológica tem como base as equações fundamentais e constitutivas para descrever o comportamento do sistema. A utilização dessa abordagem é limitada quando se trata um sistema muito complexo pela dificuldade da obtenção dos parâmetros necessários para descrever o processo e o conjunto de ações restritas de controle que permitem realizar experimentos na instalação, visto que a operação do alto-forno envolve a interação entre as fases gás-sólido, gás-líquido, sólido-sólido e sólido-líquido acompanhado de alta temperatura, alta pressão, escoamento multifásico, entre outros fatores. Por outro lado, os modelos orientados a dados vem se mostrando promissores ao ser diretamente derivados dos dados do processo (ZHANG; KANO; MATSUZAKI, 2019b; ZHOU et al., 2015b)

1.1. OBJETIVO GERAL

Utilizar os dados históricos do processo de produção do ferro gusa em alto-forno para construir um *soft sensor* baseado em um algoritmo híbrido usando *fuzzy c-médias* (FCM) e modelo exógeno auto-regressivo não linear (NARX) para prever a temperatura do gusa e o teor de silício de modo que seja possível utilizá-lo no controle e assegurar o funcionamento estável do alto-forno.

1.2. OBJETIVOS ESPECÍFICOS

- Obter os dados históricos do processo;
- Realizar a preparação e pré-processamento dos dados históricos;
- Selecionar variáveis influentes no estado térmico do alto-forno;

- Realizar o estudo de clusters para a temperatura e teor de silício no gusa;
- Desenvolver o modelo NARX a partir do estudo de clusters para temperatura e teor de silício no gusa;
- Simular e analisar os resultados do modelo na operação do alto forno.

1.3. ORGANIZAÇÃO DA DISSERTAÇÃO

Esse trabalho está estruturado de forma a facilitar a compreensão dos temas envolvidos. Deste modo, no Capítulo 2 é apresentada a fundamentação teórica em relação ao alto-forno e a produção do ferro gusa. São descritos os aspectos físicos do alto-forno, uma visão geral do processo produtivo do ferro gusa e detalhes sobre a operabilidade do equipamento.

O estudo de caso do alto-forno, o apontamento da sua principal limitação e uma breve descrição dos trabalhos realizados na área são apresentados no Capítulo 3. No Capítulo 4 são abordadas as ferramentas da Inteligência Artificial utilizadas para a modelagem e previsão da temperatura e do teor de silício no ferro gusa.

O Capítulo 5 mostra o detalhamento da metodologia empregada para o desenvolvimento do soft sensor. Enquanto no Capítulo 6 são apresentados os resultados decorrentes realizada metodologia proposta, além da análise e a discussão desses resultados. Por fim, no Capítulo 7 são mostradas as conclusões deste estudo.



CAPÍTULO 2


**ALTO-FORNO E A PRODUÇÃO DO
FERRO GUSA**

2. ALTO-FORNO E A PRODUÇÃO DO FERRO GUSA

Considerado o reator mais complexo da metalurgia, o alto-forno é o primeiro passo para a produção de aço a partir do minério de ferro. Esse reator é formado por segmentos de cilindros e troncos de cone e de grande dimensão, podendo alcançar altura e diâmetro de 40 e 15 metros, respectivamente (BAMBAUER et al., 2018).

Uma unidade de alto-forno típica é formada por vários sistemas, cada um com sua respectiva função, como visto na Figura 2-1. A unidade consiste principalmente do alto-forno, um sistema de alimentação de minério e coque, um sistema de ar quente, um sistema de injeção de carvão pulverizado, um sistema de tratamento de gás de alto-forno e um sistema de vazamento do gusa (ZHOU et al., 2015a).

Figura 2-1 – Sistemas que compõe uma unidade de Alto-forno.



Adaptado de: ZHOU et al., 2015b.

As principais partes do alto-forno são: topo, garganta, cuba, ventre, rampa e cadinho. O equipamento de carregamento está localizado no topo, assim como as tomadas do gás do alto-forno. Abaixo do topo está a garganta, uma pequena parte cilíndrica. A próxima parte compreende a maior porção volumétrica do equipamento,

a cuba, região na qual ocorrem as principais reações gás/sólido de redução. O ventre liga a cuba à rampa. A rampa é a parte cônica contraída que se une ao cinto ventaneiras. Na parte inferior está o cadinho. Essas divisões podem ser visualizadas na Figura 2-1 (YANG; RAIPALA; HOLAPPA, 2014).

2.1. MATÉRIAS-PRIMAS

O alto-forno é alimentado continuamente com carga de ferro, fundentes e coque. A carga de ferro consiste em sinter, pelotas e/ou minério granulado. Os óxidos de ferro são principalmente a hematita (Fe_2O_3), magnetita (Fe_3O_4) e wustita (FeO) em aglomerados e em materiais de ganga. Os fundentes são geralmente calcários, que além de auxiliar na fundição da carga também são utilizados para equilibrar a produção de escória e sua composição química. O coque é a fonte básica de energia e atua como redutor de carbono. Outras fontes de agentes redutores são carvão pulverizado, hidrocarbonetos, resíduos de plástico ou até biomassa, que são injetadas pelas ventaneiras. O ar de sopro preaquecido ou ar enriquecido com oxigênio (1200–1300 °C) fornece uma quantidade importante de calor ao processo (YANG; RAIPALA; HOLAPPA, 2014).

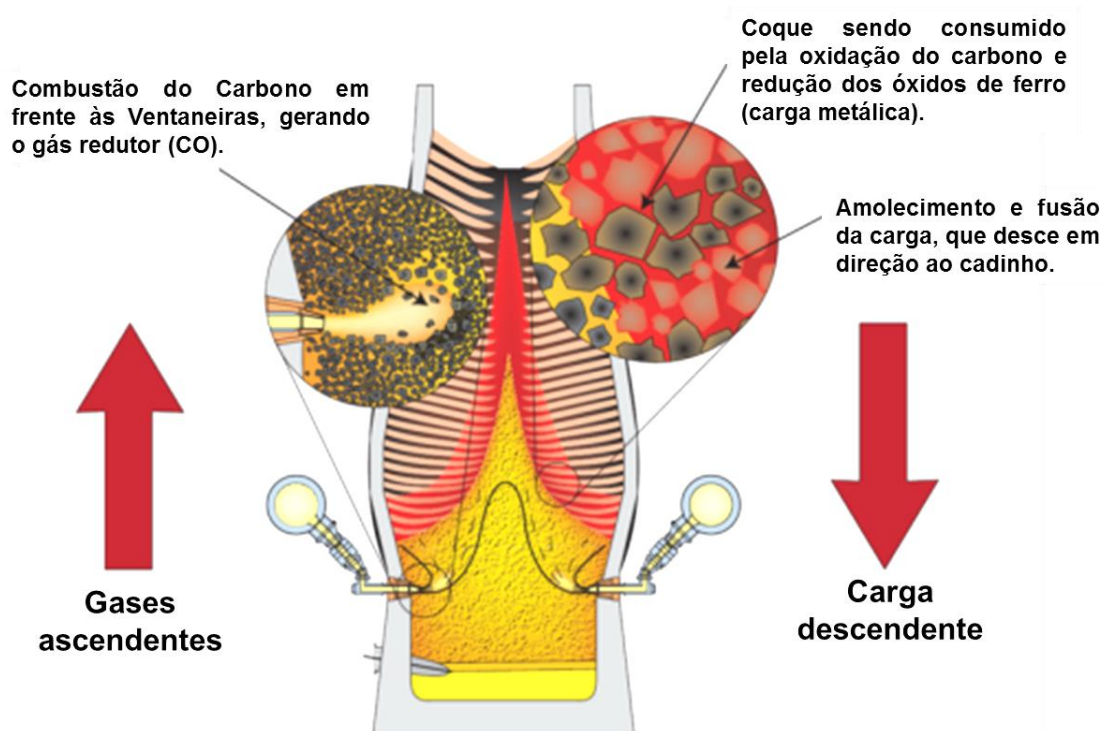
2.2. PRINCÍPIO DE FUNCIONAMENTO

A principal função do alto-forno é produzir continuamente ferro gusa de alta qualidade e baixo custo de produção; os subprodutos são escória, gás de alto-forno e poeiras. O processo inicia com o carregamento em camadas alternadas de coque e carga na parte superior do alto-forno. A carga desce sob a influência da gravidade. Já na parte inferior, o ar quente e de alta pressão é soprado através das ventaneiras, aliado à injeção de combustível (CAMERON et al., 2020). O princípio de funcionamento do alto-forno é ilustrado na Figura 2-2.

O gás gerado pela reação de combustão do ar soprado com o coque e o carvão pulverizado transfere calor ao atravessar a carga que desce do topo em sentido contrário. A carga do topo é consumida por reações de combustão, redução direta, redução indireta, transferência de silício e transformações físicas, como fusão, produzindo o ferro gusa e a escória que gotejam até o cadinho (ZHOU et al., 2015b; ZHOU; GUO; CHAI, 2018).

Geralmente, as matérias primas alimentadas no topo levam em torno de 6 a 8 horas para chegarem ao cadinho, enquanto o ar quente soprado nas ventaneiras leva de 1 a 5 segundos para chegar ao topo. O curto tempo de permanência do gás indica que os sólidos devem ser muito reativos para atingir a utilização máxima de carbono, especialmente na parte inferior do forno. (ASCEND et al., 2020).

Figura 2-2 – Esquema de funcionamento do alto forno.




Adaptado de: GEERDES; TOXOPEUS; VLIET, 2009.

2.3.ZONAS FÍSICAS E PRINCIPAIS REAÇÕES

A fabricação de ferro no alto-forno é um processo de transferência de calor e de massa, por isso o forno pode ser dividido em diferentes zonas de acordo com o estado físico-químico da alimentação e a temperatura. Para analisar o estado físico-químico do forno, tem-se as reações de redução do minério ocorrendo de forma sequencial, nas quais gradualmente diminuem o grau de oxidação do ferro até que este atinja a condição de ferro metálico. Já a geração dos gases redutores ocorre através das reações de combustão e gaseificação. Como mostrada na Figura 2-3,

têm-se as seguintes zonas: granular, coesa, de coque ativo ou de gotejamento, de combustão e do cadinho. (YANG; RAIPALA; HOLAPPA, 2014).

Figura 2-3 – Zonas internas do Alto-Forno.



Fonte: GASPARINI, 2016.

Na zona granular, o minério e o coque carregados na parte superior do forno deslizam gradualmente como partículas discretas em suas camadas separadas à medida que os materiais carregados são consumidos na parte inferior do forno. Enquanto isso, o minério é aquecido e são reduzidos os óxidos de ferro de maior valência (hematita e magnetita) (MATSUZAKI et al., 2005)

A região em que a carga metálica inicia o seu processo de amolecimento e fusão enquanto a camada de coque permanece sólida é conhecida como zona coesa. Como a porosidade dos grãos de minério fundidos é baixa, a permeabilidade da zona de coesão também é baixa. Essa massa é pouco permeável e a subida do gás só pode acontecer pelas camadas de coque restantes. A gaseificação de coque com CO_2 se torna significativa devido ao aumento das taxas de reação na faixa de temperatura

entre 1000 e 1300 °C (GEERDES; TOXOPEUS; VLIET, 2015; YANG; RAIPALA; HOLAPPA, 2014).

A zona de gotejamento trata-se da zona onde o metal e a escória, já líquidos, escoam através de um empilhamento de coque em direção ao interior do forno. As partículas de coque desempenham um papel ativo na redução adicional dos óxidos de ferro restantes e no aumento do conteúdo de carbono do ferro através da dissolução do carbono do coque no ferro. Em vista disso, essa zona é dividida em duas subzonas: a zona de coque ativo, que compreende a porção do coque que flui em direção às ventaneiras para ser queimado, e o homem morto, a qual é composta pela porção de coque não direcionado às ventaneiras, que é consumido substancialmente pela incorporação de carbono ao gusa (GASPARINI, 2016; MATSUZAKI et al., 2005)

Na zona de combustão, devido à alta velocidade do ar de sopro quente injetado no forno, forma-se um bolsão de ar (raceway). Nessa região semivazia, as partículas de coque circulam enquanto são gaseificadas e queimadas, gerando gás redutor e energia para o processo. A região na qual o ferro gusa e a escória se acumulam, próximo ao furo por onde se drena o gusa, é chamada de zona do cadinho (GASPARINI, 2016; GEERDES; TOXOPEUS; VLIET, 2015).

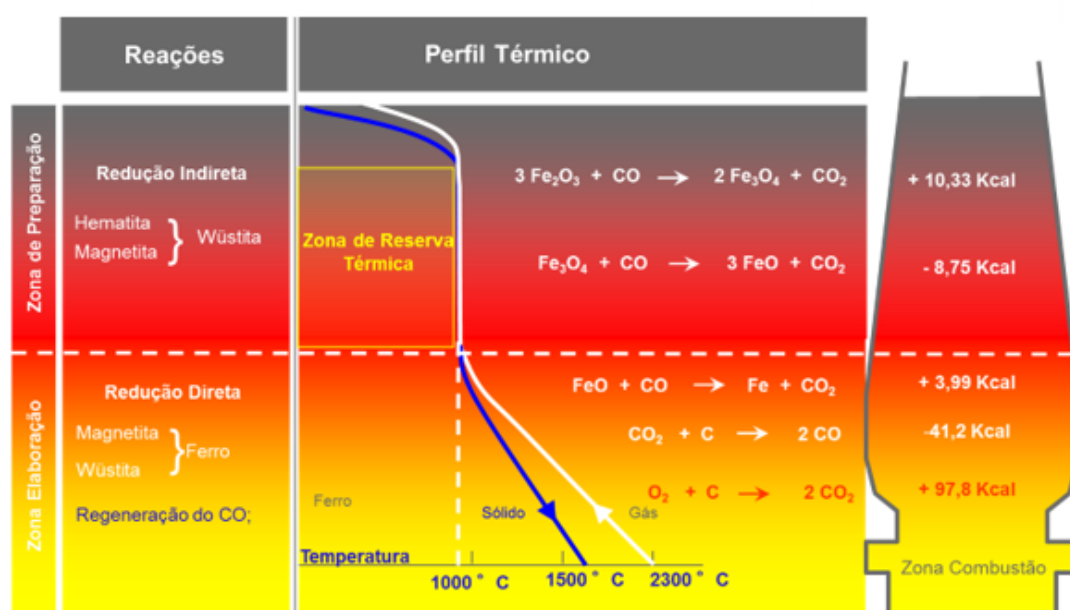
O perfil de temperaturas também assume uma forma característica. Do ponto de vista do regime de trocas térmicas no alto forno aliado às condições físico-químicas impostas pelas reações químicas com o carbono, pode-se fazer uma divisão do alto forno em duas zonas bem distintas: zona de preparação, onde o carbono não reage (constituindo-se um material inerte), e a zona de elaboração, onde o carbono reage com outros componentes. As zonas térmicas e as principais reações que acontecem em cada zona são mostradas na Figura 2-4 (GASPARINI, 2016).

A zona de preparação se localiza em temperaturas inferiores à temperatura na qual a reação muito endotérmica conhecida por reação de Boudouard ($CO_2 + C \rightarrow 2CO$) ocorre entre 130 - 950 °C. Os principais fenômenos que acontecem com a carga nessa região são a secagem, pré-aquecimento e redução indireta pelos gases ascendentes, responsáveis por aquecer a carga rapidamente até cerca de 1000°C. À medida que essa troca térmica acontece, a diferença de temperatura entre o sólido e o gás reduz até um valor desprezível. Quando a troca térmica cessa, os sólidos e gases conservam-se em uma determinada altura no forno e temperaturas bem

próximas, em torno de 950°C, constituindo-se uma coluna isotérmica, para efeitos práticos. Essa zona corresponde à zona de reserva térmica (DAVID, 2013).

Na zona de elaboração, os gases entram na temperatura de chama, através da zona de combustão, e saem na temperatura em que a reação de Boudouard ocorre. O carbono nessa zona reage com o CO₂, incorpora ao gusa e é queimado na zona de combustão, gerando os gases redutores a altas temperaturas (DAVID, 2013).

Figura 2-4 – Divisão, reações e perfil de térmico do alto forno.



Adaptado de: GEERDES; TOXOPEUS; VLIET, 2009.

2.4. OPERAÇÃO DO ALTO-FORNO

O bom funcionamento do alto forno é alcançado quando há uma alta produção com baixo consumo de combustível. Isso acontece quando os gases ascendentes são aproveitados ao máximo, ou seja, quando os gases deixam o alto forno com o teor de CO₂ o mais alto e a temperatura a mais baixa possível. Para isto, é importante que a permeabilidade da carga em toda a seção do forno seja uniforme, o que só é viável quando a carga tem uma boa granulometria. Se houver formação de caminhos preferenciais na periferia do revestimento ou no eixo do forno, tanto o calor sensível como a ação redutora não serão utilizados com eficiência. O minério de ferro deve ter boa redutibilidade e elevado teor em ferro, para se obter baixo consumo de coque (NAZARENO; SILVA, 2011).

A fim de atingir esse objetivo, monitorar e controlar em tempo real todo o processo de fabricação de gusa no alto-forno é fundamental. Apesar do grande número de instrumentos avançados ter sido usado para monitorar fenômenos e medir dados operacionais, o alto-forno ainda é considerado uma caixa preta. De fato, durante esse processo, ocorrem reações químicas sofisticadas, transferência de calor e de massa e fluxo de fluido multifásico simultaneamente em sua operação. Além disso, a análise do sistema é ainda mais complicada pelos efeitos de interação das fases gás-sólido, gás-líquido, sólido-sólido e sólido-líquido acompanhada de alta temperatura e alta pressão. Em consequência desses fatores, vários fenômenos que ocorrem no interior do alto-forno ainda não são perfeitamente explicados. Por isso, a maioria dos altos-fornos em operação ainda depende, em muitos pontos, da experiência dos operadores (ANDERSSON; ANDERSSON; JÖNSSON, 2004; ZHANG; KANO; MATSUZAKI, 2019b; ZHOU et al., 2015b).

O controle térmico adequado do processo reflete diretamente na melhora da qualidade do produto final e a eficiência do processo, ou seja, operação estável do forno aliada a redução do consumo total de energia (combustível). Os principais parâmetros para indicar os fenômenos causadores da variação do nível térmico são a temperatura do ferro gusa e o teor de silício no gusa. Normalmente, a faixa de operação da temperatura do gusa é entre 1480 a 1530 °C. A temperatura muito alta do gusa indica o elevado consumo de combustíveis, pode gerar falhas na operação, causar enormes aumentos na perda de produtividade e no custo de manutenção do equipamento. Ao contrário, quando a temperatura é muito baixa, pode ocorrer o entupimento dos furos do gusa e gerar um aumento no custo de produção dos processos siderúrgicos subsequentes (DINIZ, 2018; GASPARINI et al., 2017; ZHOU et al., 2017).

Já o teor de silício é um indicador sensível do estado térmico do forno devido às análises de consistência do processos realizados a partir de suas características termoquímicas. Alto teor de silício significa um maior volume de escória, tornando mais fácil a remoção de impurezas como o fósforo e o enxofre. Entretanto, o teor excessivo de silício tornará o gusa rígido e quebradiço, devido a sua ação grafitizante, e até levará a um menor rendimento do gusa. Além disso, o alto teor de silício resultará em uma redução de SiO₂ na escória, influenciando assim a velocidade de formação da escória, estendendo o tempo de conversão e intensificando a corrosão no revestimento do forno. Do ponto de vista energético, um elevado teor de silício

significa um aquecimento do estado no forno, enquanto um baixo teor de silício indica um resfriamento do estado no forno. Geralmente, o conteúdo de silício deve ser controlado em $0,4\% \pm 0,7\%$ (ABD ELMOMEN, 2017; DAI et al., 2019; DINIZ, 2018; GEERDES; TOXOPEUS; VLIET, 2015; ZHANG; KANO; MATSUZAKI, 2019b).

CAPÍTULO 3

DESCRIÇÃO DO PROBLEMA

3. DESCRIÇÃO DO PROBLEMA

3.1. ESTUDO DE CASO

Por se tratar de um reator vertical grande de alta temperatura e fechado, não há método para detectar diretamente a temperatura do gusa e o teor de silício no cadinho do alto-forno, isto é, os instrumentos regulares atuais não têm a capacidade de fornecer medições online para a qualidade do ferro gusa. A obtenção dessas medições acontece durante o vazamento do ferro gusa em cada corrida (IFFAT et al., 2018; ZHOU; GUO; CHAI, 2018).

Ao longo do processo de vazamento, o ferro gusa no interior do cadinho flui através do furo do gusa para o canal de corrida e é transportado para a aciaria após a separação da escória e do gusa. Normalmente, o alto-forno é vazado de 8 a 14 vezes por dia pelo furo do gusa, tendo uma duração média de vazamento de 90 a 180 minutos. O fim da corrida é indicado pelo início da saída de gás do interior do forno através furo (GEERDES; TOXOPEUS; VLIET, 2015).

A medição da temperatura do ferro gusa é realizada no canal de corrida após a separação da escória, dado o ambiente severo e de alta temperatura durante o vazamento. Essa medição pode ser realizada de forma direta ou indireta (PAN et al., 2018). Já o teor de silício é determinado pela análise laboratorial de amostras no ferro gusa obtidas no canal de corrida em cada carregamento. A logística e a realização dessas análises costuma levar entre 2 e 3 horas (DINIZ, 2018).

A junção de todos esses fatores colabora para a irregularidade do tempo de amostragem da temperatura e teor de silício. Deste modo, considerando a dinâmica atual do processo de coleta/análise das amostras de ferro-gusa, as atualizações no sistema de novas medições ocorrem a cada 3 horas no mínimo. Devido esse tempo para obter as medições, na maioria dos altos-fornos o controle térmico ainda é corretivo, ou seja, uma ação é tomada a partir da observação de um desvio na faixa de temperatura ou composição do gusa. Assim, o controle térmico geralmente depende da experiência do operador e a resposta ao problema pode ser lenta.

A operação estável do forno aliada a redução do consumo total de energia é reflexo do controle térmico adequado, tendo como consequência também a melhora da qualidade do produto final e a eficiência do processo. A gestão eficiente do processo deve contar com o acesso a indicadores importantes durante a operação para tomar de decisões estratégicas assertivas. Com este propósito, torna-se fundamental o desenvolvimento de um *soft sensor*, técnica na qual uma variável que não pode ser medida diretamente é relacionada por um modelo adequado a várias outras variáveis de processo que são passíveis de medições online. Essa técnica é capaz de prever em tempo real o estado térmico do alto-forno.

3.2. REVISÃO BIBLIOGRÁFICA

Os modelos baseados em dados são chamados de modelo caixa preta porque o modelo em si não tem conhecimento sobre o processo e é baseado em observações empíricas do processo. No que diz respeito a modelos e algoritmos orientados a dados, vários estudos apresentam diferentes soluções para a previsão do estado térmico do alto-forno. Pandit, Clum e Wu (1975) foram os primeiros a aplicar sistematicamente os métodos de análise linear de séries temporais para prever parâmetros de qualidade do alto-forno. Um modelo auto-regressivo com entradas exógenas de primeira ordem foi desenvolvido utilizando 200 amostras para prever o teor de enxofre, teor de silício, temperatura do ferro gusa a partir do volume de sopro e relação coque/minério. Analisando os resultados, os autores verificaram que as variáveis apresentavam interdependências consideráveis. A partir de então, os autores propuseram um esquema de previsão e controle das variáveis características do ferro gusa.

Chao et al. (1986) propuseram um modelo exógeno adaptativo auto-regressivo para predição de teor de silício de gusa. Östermark e Saxén (1996) usaram o modelo auto-regressivo vetorial exógeno de média móvel para prever o conteúdo e a temperatura do silício de ferro gusa. Nurkkala et al. (2011) empregaram vários modelos auto-regressivos para prever o teor de silício no ferro gusa. Porém, esses métodos de modelagem auto-regressivos geralmente sustentam o problema de propagação de erros que leva à baixa precisão de estimativa, porque eles usam os valores previamente estimados em vez dos valores observados como entradas.

De fato, a modelagem orientada a dados para a produção de ferro em alto-forno vem fazendo progresso, onde um grande número de modelos e algoritmos foi proposto e usado. Além dos exemplos já citados, a regressão de mínimos quadrados parciais (PLS) é o método de modelagem mais popular e tem sido amplamente utilizado no processo de fabricação de ferro de alto forno (BHATTACHARYA, 2005; LIN et al., 2011). No entanto, a técnica dos mínimos quadrados parciais não possui a capacidade de lidar com a não linearidade do processo e a dinâmica variável no tempo dos processos industriais. Os métodos de regressão baseados em kernel são um tipo de técnicas preditivas não lineares. A regressão de vetores de suporte é um dos métodos de aprendizado de máquina que mapeia os dados de entrada em um espaço de recurso de alta dimensão por meio de uma função do kernel e, em seguida, executa regressão linear no espaço de recurso. Gao, Jian e Luo (2012), Jian e Gao (2013) e Gao e Xia (2012) utilizaram a regressão SVR para prever a o teor de silício no ferro gusa (GAO; JIAN; LUO, 2012; JIAN; GAO, 2013; JIAN; GAO; XIA, 2012).

Zhang, Kano e Matsuzaki (2019b) fizeram um estudo comparando diferente modelagem baseado em dados para prever a temperatura do ferro gusa. Seus resultados apontaram para uma alta performance utilizando redes neurais artificiais. As primeiras implementações de redes neurais na previsão de parâmetros do alto-forno ocorreram no final do século XX. Por exemplo, Bulsari, Saxén, H. e Saxén, B. (1992) usaram as redes *feedforward* de camadas múltiplas para prever o teor de silício do ferro-gusa. Diversos modelos de redes neurais artificiais também foram testados por Singh, Sridhar e Deo (1996) para prever o teor de silício do ferro-gusa. Radhakrishnan e Mohamed (2000) construíram um sistema especializado para controlar a qualidade do ferro gusa utilizando também uma modelo com redes neurais, além de outros trabalhos (CHEN, 2001; HONGWU et al., 2015; JIMÉNEZ et al., 2004).

Neste estudo, um algoritmo híbrido é proposto usando *fuzzy c-médias* (FCM) e modelo exógeno auto-regressivo não linear (NARX) para construir um *soft sensor* capaz de prever a temperatura do gusa e o teor de silício. O FCM é uma técnica de modelagem de dados que se baseia em gerar grupos de subconjuntos nos quais os elementos pertencentes a um mesmo subconjunto apresentam maior semelhança entre si que os elementos pertencentes a qualquer outro subconjunto. Sua importância se dá pelo fato de descobrir agrupamentos natural dos dados observados (CHEN; HONDA, 2020; SADA AKI; ICHIHASHI; HONDA, 2008).

As redes neurais artificiais têm se destacado devido a facilidade de implementação com poucos parâmetros para ajustar, apresentar boa adaptação a sistemas não lineares, alta tolerância a dados ruidosos, além de algoritmos de rede neural serem inerentemente paralelos, uma vez que a paralelização pode ser usada para acelerar o processo computacional (HAN; KAMBER; PEI, 2011; HAYKIN, 2009).

CAPÍTULO 4

INTELIGÊNCIA ARTIFICIAL

4. INTELIGÊNCIA ARTIFICIAL

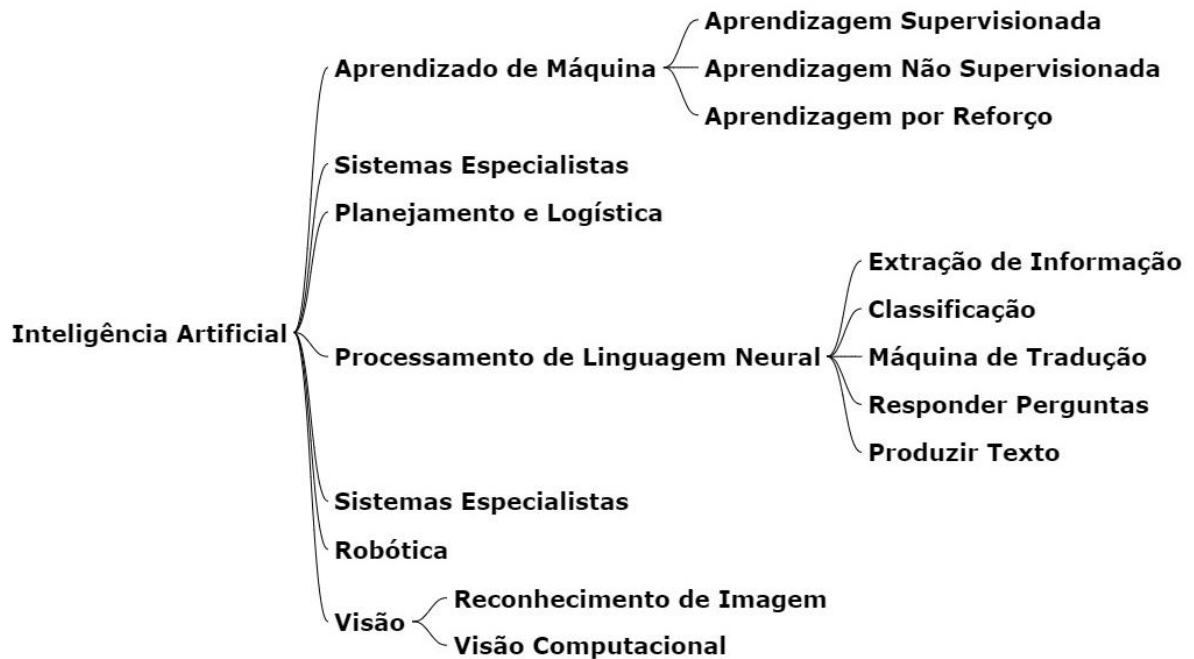
O campo da Inteligência Artificial (IA) teve sua origem em 1956 numa conferência em que John McCarthy cunhou o conceito de IA, definindo-o como "a ciência e a engenharia de fabricação de máquinas inteligentes" (RUSSELL; NORVIN, 2016). Esse conceito vem sendo atualizado e melhorado desde então:

Inteligência artificial é a capacidade de uma máquina para executar tarefas cognitivas que associamos à mente humana. Isso inclui possibilidades de percepção e capacidade de argumentar, aprender de forma independente e, assim, encontrar soluções para problemas de forma independente. (KREUTZER; SIRRENBORG, 2019)

A inteligência Artificial foi desenvolvida a partir de ideias, pontos de vista e técnicas decorrente de várias áreas do conhecimento científico como a Filosofia, Matemática, Economia, Neurociência, Psicologia, Engenharia da Computação, Teoria de Controle e Linguística (RUSSELL; NORVIN, 2016). Assim, os problemas abordados pela investigação em IA têm características particulares de acordo com cada área. Para tanto, a Figura 4-1 exemplifica as principais ramificações da inteligência artificial.

4.1. APRENDIZADO DE MÁQUINA

O aprendizado de máquina (AM) é uma subdivisão relevante da inteligência artificial por lidar com o estudo, o design e o desenvolvimento de algoritmos que podem aprender com os dados. De fato, AM refere-se à capacidade dos computadores aprenderem sem serem explicitamente programados e assim automatizar soluções para problemas complexos difíceis de programar usando os métodos de programação convencionais. Os modelos baseados em aprendizado de máquina podem ser preditivos ou descritivos para obter conhecimento dos dados (KUBAT, 2017; SALEHI; BURGUEÑO, 2018).

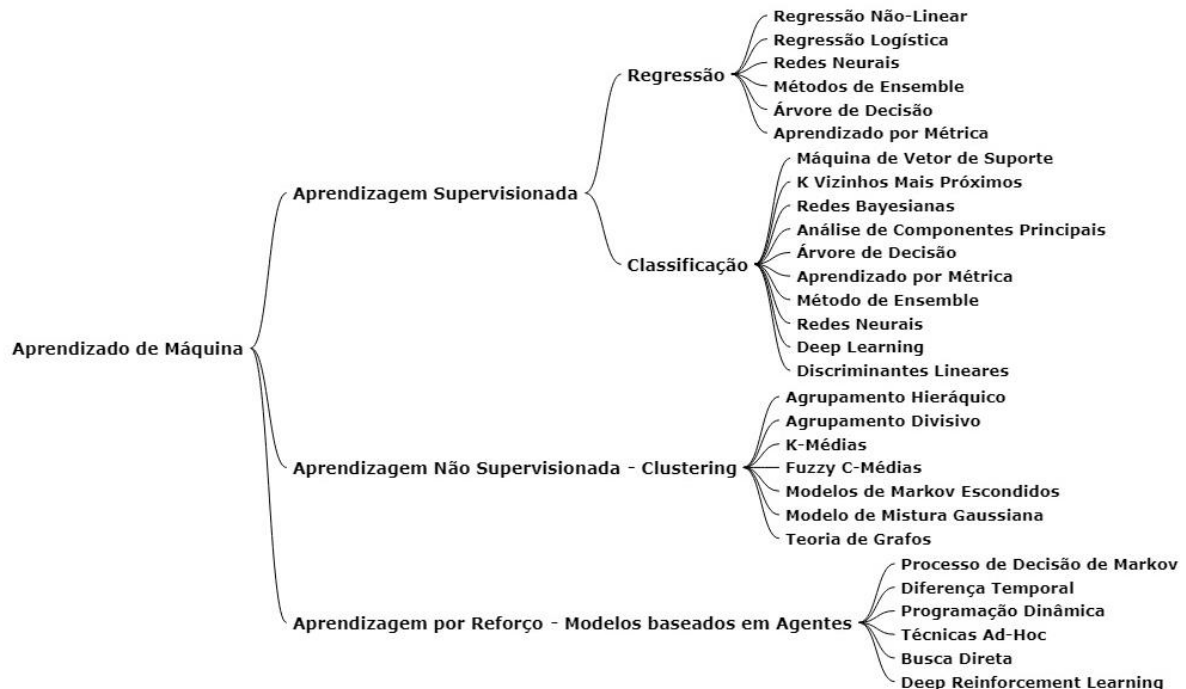
Figura 4-1 – Ramos da Inteligência Artificial.

Adaptado de: VILLANUEVA, 2018.

Dependendo dos recursos do conjunto de dados de treinamento, o aprendizado de máquina pode ser classificado como aprendizado supervisionado, não supervisionado ou por reforço (CARCILLO et al., 2019). Em resumo, a Figura 4-2 mostra as categorias de aprendizado de máquina junto de alguns dos algoritmos comumente adotado para cada categoria.

Nos algoritmos de aprendizado supervisionado, as amostras rotuladas ou conhecidas são usadas para produzir um modelo para prever o valor de uma amostra desconhecida ou estimar uma resposta futura. A sua principal característica é a existência de um professor que fornece um rótulo de custo ou categoria para cada padrão em um conjunto de dados de treinamento, buscando assim diminuir o custo agregado para esses padrões. O objetivo deste modelo é conectar ou combinar os recursos extraídos com os rótulos de cada amostra. Existem duas técnicas principais de aprendizado supervisionado: regressão e classificação. Se o objetivo do modelo de AM é prever variáveis-alvo contínuas, a tarefa é considerada uma regressão. Entretanto, se o objetivo é prever variáveis-alvo discretas, a tarefa é conhecida como classificação (HASSANIEN, 2019; SALEHI; BURGUEÑO, 2018).

Figura 4-2 – Categorias de aprendizado de máquina com algoritmos comumente adotados.



Adaptado de: SALEHI; BURGUEÑO, 2018.

Em outros casos, os rótulos para dados não estão disponíveis e não há professor explícito. Assim, a máquina recebe um conjunto de dados e não recebe a resposta certa. Dada a enorme quantidade de dados, a máquina pode identificar tendências de similaridade. O algoritmo identificará informações valiosas para processamento e análise adicionais, como visualizar os dados em um espaço de baixa dimensão, descobrir padrões interessantes usando a análise de *cluster*, ou detectar *outliers*. O aprendizado não supervisionado está se tornando cada vez mais importante na era do Big Data, permitindo explorar a grande quantidade de dados não rotulados disponíveis (KUBAT, 2017; SALEHI; BURGUEÑO, 2018; TSIHRINTZIS; SOTIROPOULOS; JAIN, 2019).

A inspiração da aprendizado por reforço surge do processo natural de aprendizagem que envolve a interação com o meio ambiente e como sistemas biológicos aprendem. Para tanto, não é fornecida nenhuma informação sobre o sinal de categoria desejado ou objetivos explícitos, deste modo os algoritmos de reforço

são forçados a aprender a partir de objetivos ideais por tentativa e erro. Esse aprendizado permite que um agente defina o comportamento ideal dentro de um contexto específico. Os agentes recebem uma recompensa numérica como um sinal de reforço que codifica o sucesso do resultado de uma ação. O objetivo do agente é aprender a selecionar ações que maximizem a recompensa acumulada ao longo do tempo. Em outras palavras, trata-se de mapear situações para ações, a fim de maximizar algumas recompensas (HASSANIEN, 2019; SALEHI; BURGUEÑO, 2018).

O modelo de aprendizado inteligente utilizado nesse trabalho combina as técnicas de aprendizado de máquina não supervisionadas e supervisionadas para selecionar o material de aprendizado através dos algoritmos *fuzzy c-médias* e Redes Neurais Artificiais (RNA), mais detalhados a seguir.

4.1.1. Fuzzy C-Médias

O *clustering*, ou agrupamento em português, ganhou importância dentro do aprendizado máquina por descobrir agrupamentos natural dos dados observados. Frequentemente, a análise de *cluster* é a primeira ferramenta utilizada na análise de dados com o objetivo de resumir as informações estruturais dos conjuntos de dados. Entender os tipos de problema e qual técnica utilizar é essencial na inteligência artificial; um esquema auxiliar para essa diferenciação é apresentado na Figura 4-2. A distinção a ser feita é entre problemas de aprendizado supervisionados e aqueles que não supervisionados. O primeiro trabalha com dados rotulados, portanto são problemas de classificação, enquanto o segundo caso são problemas de *clustering* por tratar de dados sem rótulos (CHEN; HONDA, 2020; NASRAOUI; BEN N'CIR, 2019).

Clustering é uma técnica de modelagem de dados que se baseia em gerar grupos de subconjuntos nos quais os elementos pertencentes a um mesmo subconjunto apresentam maior semelhança entre si que os elementos pertencentes a qualquer outro subconjunto, ou seja, o objetivo é obter a similaridade dentro de *clusters* e dissimilaridade entre *clusters*. Dissimilaridade está ligada ao conceito de distância. Isso quer dizer que os objetos são colocados em um espaço topológico e a proximidade é medida usando uma diferença entre dois objetos a serem agrupados (CHEN; HONDA, 2020; SADAANKI; ICHIHASHI; HONDA, 2008).

Os métodos de agrupamento são projetados com diferentes abordagens. Entre elas tem-se: hierárquica, particional, probabilística e baseada em densidade. Devido à sua simplicidade, os métodos de agrupamento particional têm sido amplamente utilizados em diversas aplicações. Os métodos de *cluster* de particionamento tentam organizar os dados em um determinado número C de *clusters*, otimizando uma função objetivo que captura uma estrutura local e global de agrupamento. A maioria dos métodos de particionamento começa com uma atribuição inicial e, em seguida, usa um procedimento de relocação iterativa que move pontos de dados de um *cluster* para outro para otimizar a função objetivo (NASRAOUI; BEN N'CIR, 2019)

No *fuzzy c*-médias, um objeto pode pertencer a vários *clusters* em diferentes graus. Esse algoritmo consegue extrair informações em conjuntos de dados complexos onde existem *clusters* sobrepostos ao fazer a associação de pontos a diferentes *clusters* na faixa de pertencimento que pode variar de 0 a 1 (AGGARWAL, 2014; CHEN; HONDA, 2020)

Para entender o algoritmo, supõe-se que existem n objetos onde objeto i ($i = 1, \dots, n$) é caracterizado pela observação p -dimensional numérica $x_i = (x_{i1}, \dots, x_{ip})^T$. FCM é um método que particiona os objetos em um determinado número de agrupamento c ($2 \leq c \leq C$) otimizando uma função objetivo. Do ponto de vista da otimização matemática, o FCM é reduzido à minimização da Equação (4-1) sujeito as restrições das Equação (4-2) a (4-4), mostradas a seguir (CHEN; HONDA, 2020).

$$J_{fcm} = \sum_{i=1}^n \sum_{c=1}^C \mu_{ci}^m \|x_i - g_c\|^2 \quad (4-1)$$

$$\sum_{c=1}^C \mu_{ci} = 1, \quad 1 \leq i \leq n \quad (4-2)$$

$$u_{ci} \geq 0, \quad 2 \leq c \leq C, 1 \leq i \leq n \quad (4-3)$$

$$\sum_{i=1}^N \mu_{ci} > 0, \quad 2 \leq c \leq C \quad (4-4)$$

Onde m é o fator *fuzzy*, μ_{ci} é o pertencimento da n -ésima amostra no c -ésimo cluster e g_c é centro do cluster, ou centroide.

O algoritmo começa com a inicialização aleatória do grau de pertencimento u_{ci} de cada amostra. Em seguida, o centro do cluster é calculado a partir da Equação (4-5). O próximo passo consiste em atualizar o grau de pertencimento u_{ci} utilizando a Equação (4-6).

$$b_c = \frac{\sum_{i=1}^n \mu_{ci}^m x_i}{\sum_{i=1}^n u_{ci}^m} \quad (4-5)$$

$$u_{ci} = \left(\sum_{l=1}^c \left(\frac{\|x_i - g_c\|^2}{\|x_i - g_l\|^2} \right)^{\frac{1}{1-m}} \right)^{-1} \quad (4-6)$$

Por fim é realizada a minimização da função objetivo descrita pela Equação (4-1). Esse processo continua até a convergência dos centroides. O algoritmo FCM é sensível a *outliers* e as soluções finais obtidas corresponderão ao mínimo local da função objetivo (PALUMBO; MONTANARI; VICHI, 2017).


4.1.2. Redes Neurais Artificiais

Inspirados em observações feitas no estudo de sistemas biológicos, não necessariamente baseadas na biologia real, as redes neurais artificiais são uma construção matemática que une um grande número de elementos simples, chamados neurônios, nos quais possuem capacidade de armazenar o conhecimento obtido através de experiências e adaptar-se perante as alterações do ambiente por um processo de aprendizagem (PRIDDY; KELLER, 2005).

As redes neurais foram criadas com a ideia de que elas imitam o cérebro humano. A partir de uma melhor compreensão do cérebro, atualmente, sabe-se que a rede neural não está nada perto de como o cérebro funciona. Apesar disso, algumas das ideias principais por trás da rede neural foram derivadas de um entendimento básico do funcionamento do cérebro partindo de uma simplificação do neurônio. Assim, os três componentes principais considerados do neurônio são: os dendritos, o corpo celular e o axônio (KUBAT, 2017).

Os dendritos são redes receptivas em forma de árvore de fibras nervosas que transportam sinais elétricos para o corpo celular. O corpo da célula efetivamente soma e limita esses sinais recebidos. O axônio é uma única fibra longa que transmite o sinal do corpo celular para outros neurônios. Neurônios são conectados entre si através de sinapses. É o arranjo dos neurônios e as forças das sinapses individuais, determinadas por um processo químico complexo, que estabelece a função da rede neural (HAGAN et al., 2014; HAYKIN, 2009). O esquema simplificado de neurônios biológicos é mostrado na Figura 4-3.

Figura 4-3 – Esquema simplificado de neurônios biológicos.



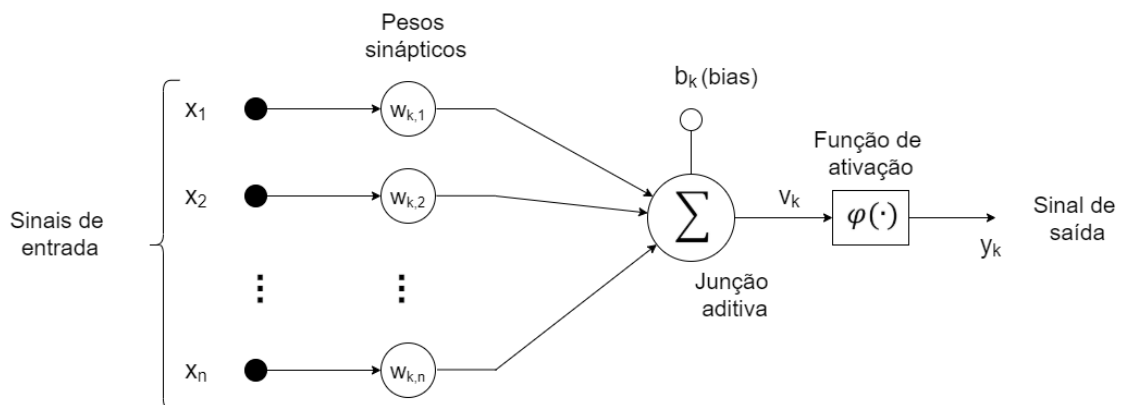
Adaptado de: HAGAN et al., 2014.

Ao comparar as redes neurais biológicas e artificiais, dois pontos de semelhança podem ser destacados. Primeiro, os componentes de ambas as redes são dispositivos computacionais simples, nos quais são altamente interconectados. Segundo, as conexões entre neurônios determinam a função da rede. O desafio principal é determinar as conexões apropriadas para resolver problemas específicos (HAGAN et al., 2014).

O diagrama de blocos da Figura 4-4 mostra o modelo de um neurônio artificial. O modelo neural também é composto por três elementos básicos. O primeiro elemento é formado pelo conjunto de sinapses (ou elos de conexão), cada um dos quais é caracterizado por um peso. Especificamente, um sinal x_j na entrada da sinapse n

conectado ao neurônio k é multiplicado pelo peso sináptico $w_{k,n}$, onde o primeiro subscrito refere-se ao neurônio em questão, enquanto o segundo identifica a sinapse em que o peso se refere. O segundo elemento é um somador, ou combinador linear, para somar os sinais de entrada, ponderado pelos respectivos pesos sinápticos do neurônio. Por fim, uma função de ativação para limitar a amplitude da saída do neurônio (HAYKIN, 2009).

Figura 4-4 – Modelo não linear de um neurônio.



Adaptado de: HAYKIN, 2009.

Em termos matemáticos, um neurônio k pode ser descrito através das Equações (4-7 e (4-8, onde v_k é a saída do combinador linear, b_k é o bias correspondente ao neurônio k , $\varphi(\cdot)$ é a função de ativação e y_k é o sinal de saída.

$$v_k = \sum_{j=1}^n w_{k,j} x_j \quad (4-7)$$

$$y_k = \varphi(v_k + b_k) \quad (4-8)$$

A função de ativação, ou transferência, mais comum é a função sigmoide ou logística, presente na Equação (4-9, por possui boas propriedades matemáticas como monotonicidade, continuidade e diferenciabilidade, que são fundamentais ao treinar uma rede neural com gradiente descendente. Outras funções que podem ser destacada são a tangente hiperbólica e a ReLu (PRIDDY; KELLER, 2005).

$$y_k = \frac{1}{1 + e^{-(v_k + b_k)}} \quad (4-9)$$

Um neurônio tem a função de realizar um processamento simples. Neurônios interconectados geram uma rede neural artificial com capacidade de realizar operações bem mais complexas que apenas um neurônio. O número de neurônios é um dos hiperparâmetros que determinam a qualidade do ajuste. Ao usar uma rede com muito poucos neurônios, o ajuste para a função será de ordem inferior ao ideal. No caso contrário, o uso de muitos neurônios permitirá à rede aprender os recursos específicos, ou seja, perdendo a capacidade de generalização (HAGAN et al., 2014).

A maneira pela qual os neurônios de uma rede neural são estruturados está intimamente ligada ao algoritmo de aprendizado usado para treinar a rede. Em geral, pode-se identificar três classes fundamentalmente distintas de arquiteturas de rede: *feedforward* de camada única, *feedforward* multicamadas e recorrentes (HAYKIN, 2009; RUSSELL; NORVIN, 2016).

Uma rede de alimentação direta, ou *feedforward*, tem conexões apenas em uma direção, assim como mostra a Figura 4-5 (a) e (b), onde cada nó recebe entrada de nós anterior e entrega saída para nós, sem a presença de loops. Uma rede *feedforward* representa uma função de sua entrada atual, portanto não possui outro estado interno além dos pesos. Uma rede *feedforward* de camada única, Figura 4-5 (a), tem os neurônios organizados numa forma mais simples de rede de camadas. Na primeira camada estão os nós de entrada e, na segunda, estão os neurônios. A rede de camada única refere-se apenas à camada dos neurônios (HAYKIN, 2009).

A segunda classe trata de uma rede neural *feedforward* com a presença de uma ou mais camadas ocultas. Entende-se por camada oculta a parte da rede neural que não é vista diretamente na entrada ou na saída da rede. Ao adicionar uma ou mais camadas ocultas, a rede é ativada para extrair estatísticas de ordem superior de sua entrada. Em um sentido bastante flexível, a rede adquire uma perspectiva global, apesar de sua conectividade local, devido ao conjunto extra de conexões sinápticas e à dimensão extra das interações neurais. A arquitetura de uma rede *feedforward* multicamadas com uma camada oculta pode ser vista na Figura 4-5 (b) (HAYKIN, 2009).

Apesar de não interagirem com o ambiente externo, as camadas ocultas exercem grande influência no funcionamento da rede. O número de camadas ocultas

pode melhorar o desempenho da rede neural ao aumentar a capacidade de aprendizado e a precisão com que ela delimita regiões de decisão. Entretanto, aumentar demais as camadas ocultas pode ter um efeito negativo, pois cada vez que o erro médio durante o treinamento é utilizado para atualizar os pesos das sinapses da camada imediatamente anterior, ele se torna menos útil ou preciso (HAGAN et al., 2014; HAYKIN, 2009).

Já uma rede recorrente, apresentada na Figura 4-5 (c), por sua vez, é alimentada também por suas próprias saídas. Isso significa que os níveis de ativação do sistema dinâmico em forma de rede podem atingir um estado estável ou exibir oscilações ou mesmo comportamento caótico. Além disso, a resposta da rede a uma determinada entrada depende do seu estado inicial, que pode depender de entradas anteriores. Portanto, redes recorrentes podem suportar memórias de curto prazo (RUSSELL; NORVIN, 2016).


O processo de modificar os pesos em um neurônio ou rede para executar corretamente um mapeamento de entrada-saída desejado é denominado algoritmo aprendizado da rede neural. Os métodos para definir os pesos sinápticos são o supervisionado, não supervisionado e aprendizagem por reforço, citados anteriormente. (HAYKIN, 2009; MACIEL; BALLINI, 2008).

Neste caso, trata-se de aprendizado supervisionado no qual utiliza um agente externo para indicar à rede a resposta desejada para o padrão de entrada. O agente externo ajusta os parâmetros da rede através do erro dado pela diferença entre os valores esperados e os valores obtidos. A taxa de aprendizado entra nesse processo como reguladora da taxa que altera os pesos sinápticos da rede. Este ajuste é feito até que o erro seja minimizado, passando a não existir mais ou atingindo um valor considerado satisfatório. A partir deste momento, diz-se que a rede adquiriu conhecimento e apresenta-se treinada (HAGAN et al., 2014).

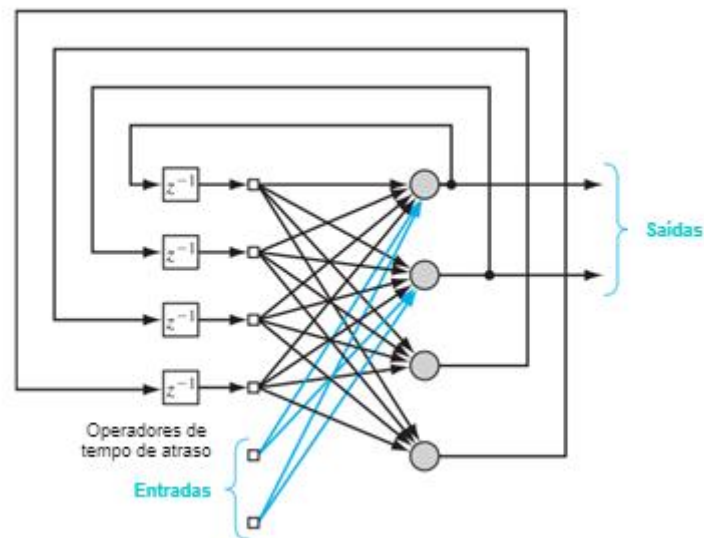
Figura 4-5 – Representação da rede neural (a) *feedforward* de camada única, (b) *feedforward* multicamadas e (c) recorrente.

(a)

(b)



(c)



Adaptado de: HAYKIN, 2009.

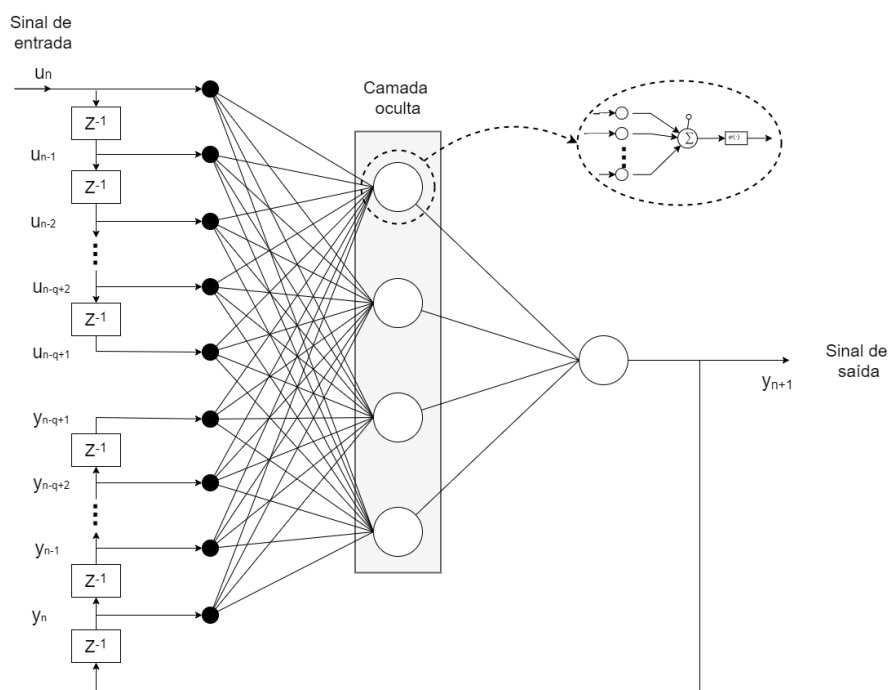
No geral, uma rede neural artificial pode ser descrita como mapeando um espaço de entrada para um espaço de saída, análogo ao conceito de uma função matemática. A utilização de RNA pode detectar as relações funcionais subjacentes dentro de um conjunto de dados e executar tarefas como reconhecimento de padrões, classificação, avaliação, modelagem, previsão e controle. As principais vantagens em utilizar as redes neurais para previsão estão relacionadas a capacidade de executar modelagem não linear sobre os relacionamentos entre variáveis de entrada e saída sem um conhecimento a priori sobre essas variáveis. Por serem aproximações de funções universais, as RNA podem generalizar, ou seja, podem inferir corretamente

sobre uma nova amostra depois de aprender os dados apresentados (MACIEL; BALLINI, 2008).

4.1.2.1. NARX

O modelo NARX é um tipo especial de rede neural dinâmica recorrente que descreve o processo modelado com base em variáveis de entrada/saída atrasadas. A Figura 4-6 mostra a estrutura de uma rede NARX. A memória incorporada das redes NARX fornece caminhos mais curtos para propagar idealmente as informações e retropropagar o sinal de erro, reduzindo as dependências de longo prazo do modelo (GUZMAN; PAZ; TAGERT, 2017).

Figura 4-6 – A estrutura de uma rede NARX.



Adaptado de: HAYKIN, 2009.

O valor atual da entrada do modelo é indicado por x_n e o valor correspondente da saída do modelo é indicado por y_{n+1} ; isto é, a saída está à frente da entrada em uma unidade de tempo. Portanto, a entrada da rede corresponde a valores presentes e passados da entrada, ou seja, $x_n, x_{n-1}, \dots, x_{n-q+1}$, que representam entradas

exógenas originárias de fora da rede. Assim como valores atrasados da saída, ou seja, $y_n, y_{n-1}, \dots, y_{n-q+1}$, nos quais a saída do modelo y_{n+1} é a regredida. A Equação (4-10), mostrada a seguir, é a equação geral que descreve os modelos NARX (HAYKIN, 2009).

$$y_{n+1} = F(y_n, \dots, y_{n-q+1}, x_n, \dots, x_{n-q+1}) \quad (4-10)$$

Onde F é uma função não linear de seus argumentos e q indica o número de atrasos.

CAPÍTULO 5

MODELAGEM DO ALTO-FORNO

5. MODELAGEM DO ALTO-FORNO

Os dados do mundo real tendem a ser incompletos, apresentar ruídos e inconsistências. Este capítulo apresenta uma revisão dos métodos de transformação e análise de dados, incluindo técnicas e formas de preparação e pré-processamento de dados para um melhor desempenho dos modelos a serem utilizados. Também serão discutidas técnicas e práticas para a extração do conhecimento através da análise de clusters e modelo NARX.

A realização dos procedimentos de cálculo deve ser executada em um ambiente adequado. Em vista disso, primeiramente é definido o software utilizado. Em seguida, são apresentados os métodos e a modelagem utilizadas.

5.1. AMBIENTE DE SIMULAÇÃO

As simulações foram realizadas no ambiente de programação MATLAB®, software comercial da MathWorks®. O MATLAB® é uma ferramenta voltada para o cálculo numérico que pode ser utilizada para diversas finalidades, incluindo a realização de cálculos de engenharia, execução de modelagem de sistemas, simulações, otimizações e análise de dados.

O estudo de características relevantes de processos industriais, além de modelagem e simulação, é facilitado utilizando o MATLAB® por existir uma série de funções matemáticas já implementadas que podem ser utilizadas em uma rotina construída pelo usuário. Estas funções são agrupadas de acordo com a área de interesse em toolboxes. As toolboxes em destaque por se tratar, nesse estudo, de um algoritmo baseado em dados são: Statistics and Machine Learning Toolbox, Deep Learning Toolbox e Optimization Toolbox.

O algoritmo descrito pelas etapas de desenvolvimento do soft sensor são organizados em forma de rotinas de cálculos, nas quais há a liberdade para determinar a sequência e os critérios utilizados na construção do código. As rotinas possibilitam análises cuidadosas de parâmetros dos cálculos a partir de resultados apresentados em formas de tabelas e gráficos.

5.2. PREPARAÇÃO DOS DADOS

As técnicas e práticas utilizadas na preparação de uma base de dados são os primeiros procedimentos para garantir a consistência dos dados. No caso do alto-forno, as medições da temperatura do gusa e do teor de silício no gusa são realizadas no fim de cada corrida. Sabendo que cada corrida tem uma duração variável, o tempo de amostragem desses dois indicadores é irregular e não uniforme.

O tempo de amostragem selecionado para o soft sensor se baseia em um período de amostragem no qual pode ser observado mudança significativa na dinâmica do alto-forno, assim como possibilitar a tomada de decisão para mudança de parâmetros operacionais. A fim de obter um intervalo uniforme para as medições de temperatura e teor de silício no gusa, utilizou-se a interpolação cúbica segmentada de Hermite (PCHIP) descrita na seção 5.2.1.

5.2.1. Interpolação de Dados

O objetivo do PCHIP é produzir interpoladores que preservem propriedades como monotonicidade ou convexidade presentes nos dados. O algoritmo de interpolação satisfaz as condições de interpolação de Hermite, isso é, a função é determinada por seus valores e valores de sua primeira derivada nos pontos de interpolação (EL-SALLABI; QARAQE; SERPEDIN, 2013).

Considerando que $\pi: a = x_1 < x_2 < \dots < x_n = b$ seja a partição do intervalo $I = [a, b]$. Seja y_i um determinado conjunto de valores de dados monotônicos nos pontos de partição $i = 1, 2, \dots, n$; isto é, assumindo que $y_i \leq y_{i+1}$ ou $y_i \geq y_{i+1}$ para $i = 1, 2, \dots, n - 1$. O objetivo é construir em π uma função cúbica por partes $p(x)$ como mostrada na Equação (5-1) a seguir (FRITSCH; CARLSON, 1980):

$$p(x_i) = y_i, \quad i = 1, 2, \dots, n \quad (5-1)$$

Em que $p(x_i)$ é uma função monotônica.

Em cada subintervalo $I_i = [x_i, x_{i+1}]$, $p(x)$ é um polinômio cúbico que pode ser representado pela Equação (5-2):

$$p(x) = f_i H_1(x) + f_{i+1} H_2(x) + d_i H_3(x) + d_{i+1} H_4(x) \quad (5-2)$$

Onde $d_j = p'(x_j)$, $j = i, i + 1$, e $H_k(x)$ são as funções básicas Hermite cúbicas usuais para o intervalo I_i : $H_1(x) = \phi((x_{i+1} - x)/h_i)$, $H_2(x) = \phi((x - x_i)/h_i)$, $H_3 = -h_i \psi((x_{i+1} - x)/h_i)$, $H_4 = h_i \psi((x - x_i)/h_i)$, em que $h_i = x_{i+1} - x_i$, $\phi(t) = 3t^2 - 2t^3$ e $\psi(t) = t^3 - t^2$ (FRITSCH; CARLSON, 1980).

O intuito desta implementação é manipular a inclinação d_j para que os valores da função não extrapolem os dados fornecidos. Considere que $\delta_i = (y_{i+1} - y_i)/h_i$. Três casos diferentes analisados são (SIM; WEE; LIM, 2008):

- **Caso I:** o valor x_i é um máximo ou mínimo local discreto se δ_i e δ_{i-1} tiverem sinais opostos ou se um deles tiver um valor zero. Neste caso, a inclinação da função é definida como zero, $d_i = 0$.
- **Caso II:** a inclinação dos intervalos é a média harmônica das duas inclinações discretas se δ_i e δ_{i-1} , dada pela Equação (5-3), tiverem o mesmo sinal e os dois intervalos tiverem o mesmo comprimento.

$$\frac{1}{d_i} = \frac{1}{2} \left(\frac{1}{\delta_{i-1}} + \frac{1}{\delta_i} \right) \quad (5-3)$$

- **Caso III:** quando os dois intervalos têm comprimentos diferentes e δ_i e δ_{i-1} têm o mesmo sinal, a inclinação do interpolante Hermite é uma média harmônica ponderada, como mostra na Equação (5-4). Seu peso pode ser determinado pelos comprimentos dos dois intervalos.

$$\frac{w_1 + w_2}{d_i} = \frac{w_1}{\delta_{i-1}} + \frac{w_2}{\delta_i} \quad (5-4)$$

$$\text{E } w_1 = 2h_i + h_{i-1} \text{ e } w_2 = h_i + 2h_{i-1}.$$

5.3. PRÉ-PROCESSAMENTO DE DADOS

O pré-processamento dos dados visa detectar e remover anomalias presentes com o objetivo de aumentar e melhorar a sua qualidade. Esse procedimento também é conhecido como limpeza dos dados que envolve uma verificação da consistência das informações, a correção de possíveis erros e o preenchimento ou a eliminação de valores nulos e redundantes. Normalmente, o pré-processamento requer um conhecimento especializado dos dados, uma vez que é necessário detectar e corrigir anomalia do sistema.

5.3.1. Substituição de Dados Ausentes

Os dados ausentes são amostras ou conjuntos de amostras, em que uma ou mais variáveis têm um valor que não reflete o estado real da quantidade física medida. No contexto industrial, os valores ausentes são comumente causados por falha de um sensor de medição ou manutenção (GE et al., 2017). As variáveis afetadas geralmente têm valores como $\pm \infty$, 0 ou outro valor constante. A média móvel (MM) de ordem M, representada pela Equação (5-5), foi utilizada para substituir os dados ausentes e assim recuperar a informação.

$$\bar{x}_t = \frac{1}{M} \sum_{j=-k}^k x_{t+k} \quad (5-5)$$

Onde $M = 2k + 1$. Ou seja, o dado ausente no momento t é estimado pela média dos valores das séries de medidas dentro de k períodos de t. A ordem da média móvel foi definida como 5; determina a suavidade da estimativa.

5.3.2. Substituição de *Outliers*

Outliers são observações realizadas por sensores que se desviam dos intervalos típicos de operação ou até dos intervalos significativos de valores medidos. Pode-se distinguir entre dois tipos de *outliers*: os valores extremos óbvios são os que violam as limitações físicas ou tecnológicas. Por exemplo, a pressão absoluta não

pode atingir valores negativos ou o sensor de fluxo pode não fornecer valores que excedam as limitações tecnológicas do sensor. Já o segundo tipo, os *outliers* não óbvios, são valores discrepantes que não violam nenhuma limitação, mas ainda estão fora dos intervalos típicos e não refletem os estados variáveis corretamente. Os *outliers* podem ser causados por erros de análise ou outros tipos de erros sistemáticos (KADLEC; GABRYS; STRANDT, 2009).

Parâmetros estatísticos podem ser usados para identificar e substituir ou remover os *outliers* nos dados. Neste trabalho, os *outliers* foram identificados utilizando o desvio absoluto da mediana (DAM) representada pela Equação (5-6). O método detecta como *outliers* os elementos com mais de três DAM dimensionados da mediana. Os *outliers* detectados foram substituídos utilizando a interpolação cúbica segmentada de Hermite (PCHIP).

$$DAM = \text{mediana}(|x_i - \text{mediana}(x)|), \quad 1 \leq i \leq n \quad (5-6)$$

5.4. SELEÇÃO DE VARIÁVEIS

No alto-forno, centenas de variáveis de processo são monitoradas e armazenadas. Entretanto, não são todas as variáveis que têm influência direta na temperatura do gusa e no teor de silício. A seleção de um conjunto apropriado dessas variáveis é uma tarefa fundamental, mas nada trivial. Incluir muitas variáveis no modelo dificultará o treinamento e o uso. Por outro lado, se for deixado de fora quaisquer variáveis importantes, a precisão do modelo será fraca. Além disso, no conjunto selecionado deve conter variáveis controladas diretamente pelos operadores da planta para fins de controle em uma aplicação prática.

O primeiro passo para selecionar as variáveis exige explorar a experiência dos operadores da planta devido a familiaridade com o processo e os padrões de operação do equipamento. Assim, a primeira lista de variáveis mostradas na foi construída com as indicações dos especialistas de alto-forno.

Em seguida, foi utilizado parâmetros estatísticos para avaliar como essas variáveis se relacionam. Para isso, a covariância entre as demais variáveis e a temperatura do gusa e o teor de silício, dado pela Equação (5-7). A covariância indica a independência entre duas variáveis, ou seja, variáveis independentes têm

covariância zero. Portanto, é preferível a variáveis de maior covariância com os indicadores propostos.

$$cov(x, y) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \quad (5-7)$$

Onde x representa a variável de entrada, \bar{x} a sua média, y é variável de saída e sua média.

Tabela 5-1 - Variáveis de processo selecionadas a partir da experiência industrial.

Notação	Variáveis	Unidade
x_1	Taxa de injeção de carvão pulverizado (PCI Rate)	<i>kg/ton</i>
x_2	Taxa de Coque	<i>kg/ton</i>
x_3	Taxa de Sínter	<i>kg/ton</i>
x_4	Taxa de Minério	<i>kg/ton</i>
x_5	Taxa de Pelotas	<i>kg/ton</i>
x_6	Relação Minério/Coque	–
x_7	Velocidade de Produção de Gusa	<i>ton/min</i>
x_8	Volume do ar soprado pelas ventaneiras (Volume de Sopros)	<i>Nm³/min</i>
x_9	Umidade do ar soprado pelas ventaneiras (Umidade de Sopros)	<i>g/Nm³</i>
x_{10}	Temperatura do ar soprado pelas ventaneiras (Temperatura de Sopros)	<i>°C</i>
x_{11}	Pressão no Topo	<i>kg/cm²</i>
x_{12}	Taxa (de Enriquecimento) de O ₂	%
x_{13}	Taxa de Vapor	<i>ton/h</i>
x_{14}	Temperatura Teórica de Chama	<i>°C</i>
x_{15}	Redução Direta	%
x_{16}	Teor de H ₂ no Topo	%
x_{17}	Teor de N ₂ no Topo	%

x_{18}	Teor de CO no Topo	%
x_{19}	Teor de CO ₂ no Topo	%
x_{20}	Eficiência do gás H ₂	%
x_{21}	Eficiência do gás CO	%
x_{22}	Perdas Térmicas pelo Stave	10 ⁴ Kcal/h
x_{23}	Índice de Permeabilidade 1	–
x_{24}	Índice de Permeabilidade 2	–
x_{25}	Índice de Permeabilidade 3	kg/cm ² /(Nm ³ /min)

Outro fator analisado foi o coeficiente de regressão entre as variáveis selecionadas. Esse coeficiente, representado pela Equação (5-8), descreve um grau de colinearidade entre duas variáveis. Neste caso, o coeficiente indica variáveis redundantes para o modelo. Esse índice pode variar entre -1 a 1 indicando o grau de relação linear entre duas variáveis. Quando o coeficiente de regressão é 0, não existe relação linear. No entanto, se for 1 ou -1, existe uma relação linear positiva ou negativa perfeita, ou seja, uma das variáveis apresenta informação repetida.

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (5-8)$$

5.5. ESCOLHA DOS CLUSTERS

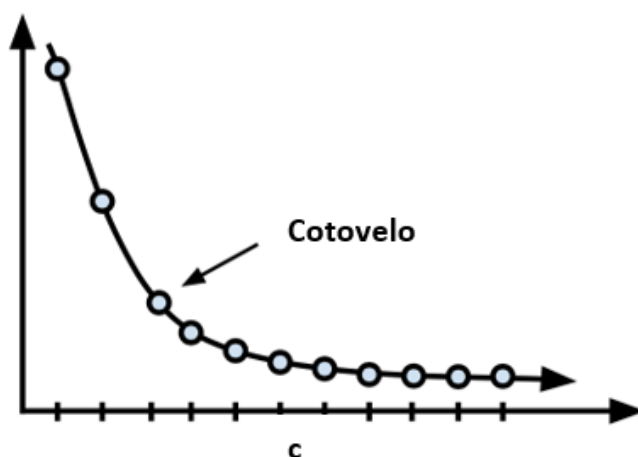
A análise de *clusters* requer determinar quais variáveis serão utilizadas e o número de *clusters*. No processo de fabricação de ferro, os indicadores de operação, temperatura do gusa e teor de silício, são usadas para representar o estado térmico do alto forno. O conjunto representado pelo estado térmico indica regiões de condições operacionais. Portanto, a escolha adequada do número de *clusters* delimita essas regiões.

Determinar o número de *clusters* não é uma tarefa trivial, visto que esse é um método de aprendizagem não supervisionado em que há uma técnica bem

estabelecida para obter esse resultado. Neste trabalho, o método do cotovelo foi aplicado para selecionar o número de centros.

O algoritmo consiste em identificar o cotovelo na curva gerada a partir do cálculo da função objetivo FCM dado pela Equação (4-1) variando o número de *clusters* em um determinado intervalo. A representação dessa curva é mostrada na Figura 5-1 – Curva do Método do Cotovelo. Selecionar o cotovelo da curva representa uma boa escolha no número de *clusters*, uma vez que aumentar o número de *clusters* além deste ponto não gera nenhuma redução significativa no valor geral da função objetivo (KUBAT, 2017).

Figura 5-1 – Curva do Método do Cotovelo.



5.6. MODELO NARX

Treinar uma rede neural significa encontrar os melhores pesos sinápticos para realizar a tarefa de predição de novas amostras. Para definir a topologia de uma rede neural existem vários hiperparâmetros que precisam ser especificados. Os hiperparâmetros são variáveis que, de alguma forma, governam o espaço do modelo ou o procedimento de ajuste do mesmo, visando assim a redução do seu erro de generalização. Essas variáveis são definidas antes do treinamento da rede, como por exemplo o número de camadas ocultas, o número de neurônio por camadas, taxa de aprendizagem e função de ativação. A definição desses hiperparâmetros é um processo empírico (JÚNIOR, 2018).

Se por um lado, os hiperparâmetros possibilitam a obtenção de modelos com melhores desempenho de predição, por outro, paga-se um preço pelo esforço inerente à estimação dos valores ótimos. Estimar os hiperparâmetros ótimos possui desafios que estão ligados ao tipo de algoritmo de aprendizado utilizado, à função de custo empregada, aos conjuntos de dados de treinamento e teste, dentre outros. A depender desses fatores e dos recursos computacionais disponíveis, cada avaliação pode levar um tempo que varia desde minutos a vários dias (JÚNIOR, 2018).

Algumas características das RNAs na busca por definir a topologia ótima da rede devem ser ressaltadas, como o condicionamento entre hiperparâmetros. Neste caso, refere-se ao hiperparâmetro que governa o número de camadas, e a posterior definição do número de neurônios em cada camada, sendo dada por hiperparâmetros distintos. Além disso, essa busca abrange variáveis de natureza distintas como hiperparâmetros contínuos (taxa de aprendizado), discretos (número de neurônios e de camadas de uma rede neural) e categóricos (tipo de função de ativação) (HAGAN et al., 2014).

Através da otimização de hiperparâmetros é possível identificar a melhor configuração para alcançar um melhor desempenho do modelo. Existem alguns métodos rotineiramente usados: ajuste manual, busca em grade, pesquisa aleatória, algoritmos evolutivos e otimização bayesiana. Dentre essas, a otimização bayesiana tem se destacado por descobrir com eficiência os extremos globais de uma função de caixa preta no espaço de hiperparâmetros definidos (FRAZIER, 2018).

5.6.1. Otimização Bayesiana

A otimização bayesiana é uma abordagem baseada em modelo probabilístico para encontrar o mínimo de qualquer função que retorne uma métrica de valor real. Este método é particularmente útil quando o custo de avaliação da função é alto, quando não se tem acesso as derivadas da função e/ou quando o problema não é convexo (JÚNIOR, 2018).

O algoritmo de otimização bayesiano tenta minimizar uma função objetiva escalar $f(x)$ para x em um domínio limitado. A função pode ser determinística ou estocástica, o que significa que pode retornar resultados diferentes quando avaliada no mesmo ponto x . Os componentes de x podem ser reais contínuos, números inteiros

ou categóricos, significando um conjunto discreto de nomes (BROCHU; CORA; FREITAS, 2010).

A abordagem bayesiana permite a determinação de probabilidades a priori, que resulta de informações passadas de uma entidade, sem o conhecimento de qualquer outro evento, e probabilidades a posteriori, que é a probabilidade condicionada a algum outro evento sabido. Em contraste com a pesquisa aleatória ou busca em grade, mantêm o controle dos resultados de avaliações a priori que se usa para formar um modelo probabilístico de mapeamento de hiperparâmetros para uma probabilidade de pontuação na função objetivo, como mostra a Equação (5-9) (FRAZIER, 2018).

$$P(A|B) = \frac{P(B|A)}{P(A)} P(B) \quad \text{ou} \quad (5-9)$$

$$posteriori = \frac{\text{verosimilhança}}{\text{evidência}} \text{priori}$$

Onde A e B são eventos e $P(A|B)$ é a probabilidade condicional.

Na literatura, esse modelo é chamado de "substituto" para a função objetivo e é representado como $P(A|B)$. O substituto é muito mais fácil de otimizar do que a função objetivo e os métodos bayesianos funcionam encontrando o próximo conjunto de hiperparâmetros para avaliar a função objetivo real, selecionando os hiperparâmetros que apresentam melhor desempenho na função substituta (FRAZIER, 2018).

A otimização bayesiana mantém internamente um modelo de processo gaussiano da função objetivo e usa avaliações da função objetivo para treinar o modelo. Uma inovação na otimização bayesiana é o uso de uma função de aquisição, que o algoritmo usa para determinar o próximo ponto a ser avaliado. A função de aquisição pode equilibrar a amostragem em pontos que possuem funções objetivas com baixo modelo e explorar áreas que ainda não foram bem modeladas (BROCHU; CORA; FREITAS, 2010).

Segundo Brochu, Cora e Freitas (2010), os passos seguidos na rotina de otimização são:

- **Passo 1:** Inicializar o processo fazendo uma amostragem do espaço do hiperparamétrico aleatoriamente e obter o resultado dessas observações.
- **Passo 2:** Criar um modelo probabilístico (modelo substituto) para aproximar a função verdadeira com base nos valores de hiper parâmetro determinados e nos valores de saída associados (observações). Nesse caso, ajusta-se um processo gaussiano aos dados observados da etapa 1, usando a média do processo gaussiano como a função mais provável para modelar a função de caixa preta.
- **Passo 3:** Usar a localização máxima da função de aquisição para descobrir onde amostrar em seguida no espaço do hiperparâmetro. As funções de aquisição jogam com o *trade-off* de explorar um máximo conhecido e explorar locais incertos no espaço do hiperparâmetro. Diferentes funções de aquisição adotam abordagens diferentes para definir exploração.
- **Passo 4:** Fazer uma observação da função da caixa preta, considerando os pontos de hiperparâmetro recém-amostrados. Adicionar observações ao conjunto de dados observados.

Esse processo (etapas 2 a 4) se repete até que um número máximo de iterações seja alcançado. Após realizar esse processo, a otimização bayesiana efetivamente pesquisa o espaço dos hiperparâmetros enquanto se encontra nos ótimos globais (BROCHU; CORA; FREITAS, 2010).

5.6.2. Treinamento da Rede

Ao treinar redes multicamadas, a primeira prática, geralmente, é dividir os dados em três subconjuntos. O primeiro subconjunto é o conjunto de treinamento, o erro desse subconjunto é usado para calcular o gradiente e atualizar os pesos e desvios da rede. O segundo subconjunto é o conjunto de validação. O erro no conjunto de validação é monitorado durante o processo de treinamento. Esse erro normalmente diminui durante a fase inicial do treinamento, assim como o erro do conjunto de treinamento. No entanto, quando a rede começa a ajustar demais os dados, o erro no

conjunto de validação geralmente começa a aumentar. Os pesos e desvios de rede são salvos no mínimo do erro do conjunto de validação (BEALE; HAGAN; DEMUTH, 2018).

O terceiro subconjunto refere-se aos dados de teste. O erro do conjunto de testes não é usado durante o treinamento, mas é usado para comparar diferentes modelos. Também é útil plotar o erro do conjunto de testes durante o processo de treinamento. Se o erro no conjunto de testes atingir um mínimo com um número de iteração significativamente diferente do erro do conjunto de validação, isso pode indicar uma divisão incorreta do conjunto de dados (BEALE; HAGAN; DEMUTH, 2018).

O processo de treinamento de uma rede neural envolve o ajuste dos valores dos pesos e desvios da rede para otimizar o desempenho da rede, conforme definido pela função de desempenho da rede. Comumente a função utilizada é o erro quadrático médio (MSE) dado pela Equação (5-10).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5-10)$$

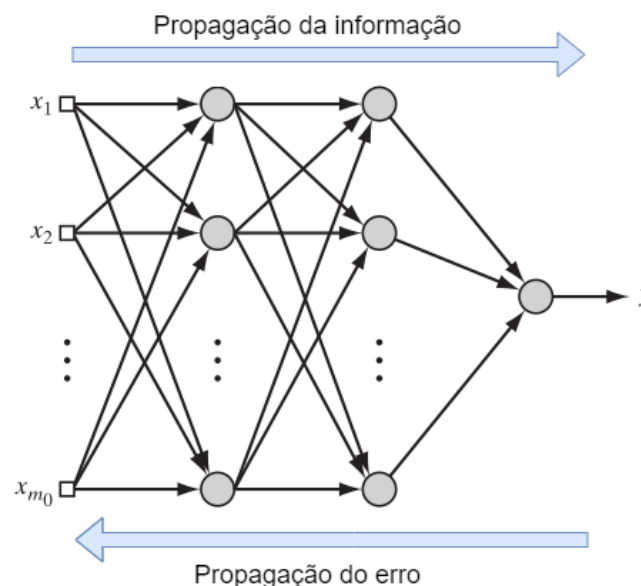
Qualquer algoritmo de otimização numérico padrão pode ser usado para otimizar a função de desempenho, mas existem alguns importantes que mostraram excelente desempenho para o treinamento de redes neurais. Esses métodos de otimização usam o gradiente do desempenho da rede em relação aos pesos da rede, ou o jacobiano dos erros da rede em relação aos pesos. O gradiente e o jacobiano são calculados usando uma técnica chamada algoritmo de retropropagação, que envolve a realização de cálculos para trás através da rede (BEALE; HAGAN; DEMUTH, 2018).

O Algoritmo retropropagação ocorre em duas fases. Para cada fase, o sinal percorrendo as camadas da rede é processado em um sentido distinto. O comportamento das fases é apresentado na Figura 5-2. Na primeira fase, a propagação do sinal tem o sentido para frente, onde o sinal de entrada é propagado das entradas até a saída da rede e, a partir da resposta da rede, calcula-se o erro entre o valor medido e o predito. Por outro lado, durante a etapa de retropropagação, o sinal desse erro é propagado para trás. Este sinal é o responsável pelo ajuste dos

pesos entre as conexões da rede, fazendo com que os pesos sinápticos das camadas intermediárias sejam atualizados de forma que a saída da rede se aproxime estatisticamente da resposta desejada (DINIZ, 2018).

Cada vez que uma rede neural é treinada, pode resultar em uma solução diferente devido a diferentes valores iniciais de peso e viés e diferentes divisões de dados em conjuntos de treinamento, validação e teste. Como resultado, redes neurais diferentes treinadas no mesmo problema podem fornecer saídas diferentes para a mesma entrada. Para garantir que uma rede neural de boa precisão seja encontrada, deve-se treinar a rede várias vezes (BEALE; HAGAN; DEMUTH, 2018).

Figura 5-2 – Representação das fases do algoritmo de retropropagação.



Fonte: Adaptado de Diniz (2018).

5.7. CRITÉRIO DE AVALIAÇÃO

Além dos parâmetros que definem a topologia de uma rede neural artificial, também é necessário especificar critérios para parada do treinamento e verificação da capacidade de generalização. Para examinar o desempenho preditivo de cada modelo, foram utilizados os critérios do erro quadrático médio da raiz (RMSE, em inglês), Erro absoluto médio percentual (MAPE, em inglês) e do coeficiente de determinação (R^2). O RMSE é um parâmetro amplamente usado das diferenças entre os valores preditos por um modelo e os valores reais observados. É uma medida de

confiabilidade e eficiência para conjuntos de dados reais e previstos, definido pela Equação (5-11). Quando o valor do RMSE é reduzido, significa que o erro é minimizado e o sistema oferece um desempenho mais eficiente (TUNÇKAYA; KOKLUKAYA, 2016).

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (5-11)$$

O MAPE mede o erro em porcentagem como mostra a Equação (5-12). Assim como o RMSE, o MAPE é uma medida de avaliação do ajuste, entretanto seu uso se deve, em grande parte, à sua facilidade de interpretação, pelo fato de ser expresso em termos percentuais.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (5-12)$$

O coeficiente de determinação descreve a proporção da variação nos dados medidos explicada pelo modelo e R^2 varia de 0 a 1, com valores mais altos indicando menor variação de erro. O coeficiente de determinação é dado pela Equação (5-13) (TUNÇKAYA; KOKLUKAYA, 2016).


$$R^2 = \left(\frac{N \sum_{i=1}^N y_i \hat{y}_i - \sum_{i=1}^N y_i \sum_{i=1}^N \hat{y}_i}{\sqrt{N \sum_{i=1}^N y_i^2 - (\sum_{i=1}^N y_i)^2} \sqrt{N \sum_{i=1}^N \hat{y}_i^2 - (\sum_{i=1}^N \hat{y}_i)^2}} \right)^2 \quad (5-13)$$

5.8. RESUMO DO ALGORITMO

Anteriormente, os métodos utilizados para a modelagem do alto-forno foram apresentados em detalhes. Em resumo, a sequência dos passos utilizados na construção do *soft sensor* para estimar a temperatura do gusa e teor de silício no gusa são descritos abaixo e mostrado na Figura 5-3.

- **Passo 1:** Coletar os dados do processo.
- **Passo 2:** Realizar a interpolação PCHIP para obter os dados no mesmo intervalo amostral.
- **Passo 3:** Substituir os dados faltosos e outliers.
- **Passo 4:** Selecionar as variáveis significativas para a construção do modelo.
- **Passo 5:** Aplicar FCM ao estado térmico do alto-forno (temperatura do gusa e teor de silício) para dividir os dados a partir das condições operacionais.
- **Passo 6:** Treinar um modelo NARX para cada grupo determinado pelo FCM.

Figura 5-3 – Fluxograma da construção do soft sensor.



CAPÍTULO 6

RESULTADOS E DISCUSSÕES


6. RESULTADOS E DISCUSSÕES

Este trabalho busca desenvolver um *soft sensor* para predição da temperatura e composição do silício no gusa. Para modelar o alto-forno utilizou-se do histórico de dados de 6 meses de operação de um processo industrial de produção de ferro gusa em alto-forno, resultando em um total de 6500 amostras. O conjunto de dados contém as variáveis em questão e os demais parâmetros que influenciam de forma significativa em seus valores. A apresentação dos resultados segue a metodologia proposta no Capítulo 5.

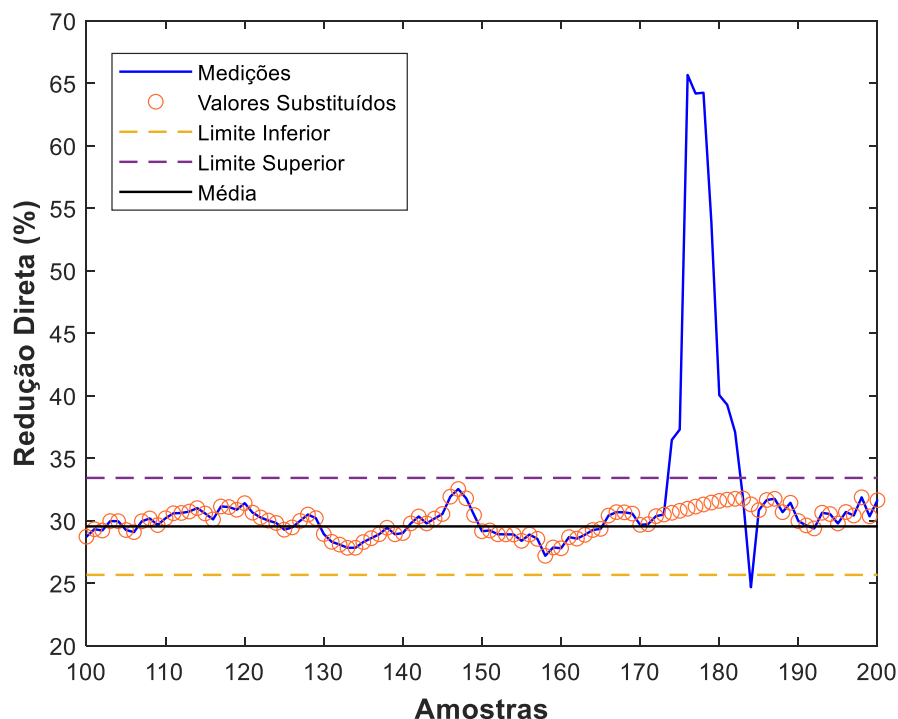
6.1. DESENVOLVIMENTO DO SOFT SENSOR

A operação estável do alto-forno é um processo de alta complexidade, por isso conta sistemas avançados de monitoramento do processo. A partir do monitoramento, pode-se obter o histórico do alto-forno em diferentes tempos amostrais. Esse trabalho utilizou o intervalo de amostragem de 30 minutos. A escolha desse intervalo se dá por ser um tempo no qual pode ser observado mudança significativa na dinâmica do alto-forno, assim como possibilitar a tomada de decisão para mudança de parâmetros operacionais.

Entretanto, as medições de temperatura do gusa e teor de silício ocorrem no fim de cada corrida do alto forno sem um intervalo definido. Ou seja, o número de medições da temperatura e composição do gusa são diferentes das demais medições do processo. A fim de obter os dados com o mesmo intervalo temporal e, portanto, mesmo número de amostras realizou-se a interpolação cúbica segmentada para fornecer uma função de aproximação para as duas variáveis. O resultado é apresentado na Figura 6-1, a partir do qual é possível obter a aproximação das medições no intervalo de 30 minutos.

Figura 6-1 – Interpolação de dados para (a) temperatura do gusa e (b) teor de silício.

O pré-processamento dos dados conseguiu detectar 0,052% de dados faltosos e 1,6% de *outliers* em todo o histórico de dados. Na Figura 6-2 é possível observar o caso da redução direta, como a identificação do *outlier* foi feita. No gráfico, a linha que indica a média dos dados é a preta e as linhas tracejadas representam o limite superior e inferior. O *outlier* é identificado quando uma medição ultrapassa um dos limites, como pode ser observado no intervalo entre as amostras 170 e 190. A substituição dos valores é feita utilizando a função PCHIP e é representada no gráfico pelo marcador circular.

Figura 6-2 – Identificação de outliers na medição da redução direta.

Assim, com uma base de dados consistente, iniciou-se o processo para determinar as variáveis que possuem influência direta na temperatura e composição do silício no ferro gusa. Dentre as centenas de variáveis de processo que são monitoradas e armazenadas, uma seleção prévia foi realizada pelos operadores do alto-forno que se encontra na Tabela 5-1. Parâmetros estatísticos foram aplicados a fim de refinar ainda mais essa seleção, uma vez que é possível avaliar como as variáveis se relacionam entre si para distinguir quais são as variáveis independentes e com influência no processo, ou seja, garantir que não está sendo utilizada informação irrelevante e repetida no modelo.

Ao utilizar o estudo da covariância e correlação, as variáveis são analisadas em pares. A covariância relaciona cada variável com as respostas esperadas (temperatura e teor de silício no gusa, uma de cada vez) e indica a independência entre variáveis, ou seja, variáveis independentes têm covariância zero. Portanto, são preferíveis as variáveis de maior covariância com os indicadores propostos. Já a correlação é calculada entre as variáveis indica quais são as variáveis redundantes para o modelo. Quando o coeficiente de regressão é zero, não existe relação linear

que é o resultado preferível para essa análise. Os resultados dos dois parâmetros foram analisados simultaneamente para determinar a seleção final.

O modelo foi construído com 11 variáveis de processo selecionadas como variáveis de entrada exógenas, conforme listado na Tabela 6-1. Em relação ao controle da carga, a taxa de coque representa a taxa de consumo desse agente redutor que é a fonte básica de energia do processo. A injeção auxiliar de combustível representada pela variável PCI rate é utilizada com o objetivo de substituir parte do coque que é carregado no topo do alto-forno. Além do coque ser o combustível principal, sua importância também é fundamental na permeabilização da carga. Portanto, a combinação da taxa de coque e o PCI rate produzem modificações sensíveis no processo tais como alteração das posições das isothermas no interior do alto-forno.

Tabela 6-1 – Seleção de variáveis de processo utilizadas como entrada do modelo.

Variáveis	Unidade
Taxa de injeção de carvão pulverizado (PCI Rate)	<i>kg/ton</i>
Taxa de Coque	<i>kg/ton</i>
Volume do ar soprado pelas ventaneiras (Volume de Sopro)	<i>Nm³/min</i>
Umidade do ar soprado pelas ventaneiras (Umidade de Sopro)	<i>g/Nm³</i>
Temperatura do ar soprado pelas ventaneiras (Temperatura de Sopro)	<i>°C</i>
Taxa (de Enriquecimento) de O ₂	<i>%</i>
Taxa de Vapor	<i>ton/h</i>
Temperatura Teórica de Chama	<i>°C</i>
Redução Direta	<i>%</i>
Perdas Térmicas pelo Stave	<i>10⁴ Kcal/h</i>
Índice de Permeabilidade 3	<i>kg/cm²/(Nm³/min)</i>

O ar quente soprado no alto-forno é a segunda maior fonte de energia para o processo, depois dos combustíveis carbonosos. A temperatura, umidade e volume do sopro são variáveis operacionais com uma dinâmica mais rápida, cerca de 2 a 3 horas para ser observado as modificações no comportamento do forno. Quanto maior for a temperatura do ar soprado, maior será o calor que entrará no processo (zona de elaboração) e, como consequência, menor será a necessidade de carbono por tonelada de gusa. Entretanto, essa temperatura deve estar dentro dos limites operacionais e de segurança do alto-forno e dos regeneradores.

Assim como a temperatura, a umidade de sopro é outro parâmetro operacional usado com frequência no controle térmico do alto-forno pela facilidade de alteração da mesma e rapidez de resposta do processo. A umidade do sopro também é muito usada para melhorar a permeabilidade da carga. Já um volume de gases muito grande pode levar a problemas de permeabilidade. Assim, a temperatura de sopro deve ser a mais alta possível e a carga permeável para suportar o aumento do volume dos gases sem problemas no escoamento gasoso.

A taxa de vapor é a quantidade de água em forma de vapor que ingressa ao alto-forno pelas ventaneiras. O vapor injetado influencia no consumo de coque e temperatura do gusa. Enquanto a injeção de oxigênio (taxa de enriquecimento de O_2), interfere no volume dos gases, deslocamento da zona coesiva e diminuição da incorporação de silício ao gusa. No entanto, é importante lembrar também que, com o aumento da umidade do ar de sopro, as injeções de O_2 podem elevar a Temperatura de chama e, conseqüentemente, gerar maior quantidade de SiO .

As variáveis para indicar o estado térmico do alto-forno são: redução direta, perdas térmicas pelo Stave e o índice térmico H_0 . A Redução Direta representa o consumo de energia necessário para que o óxido de ferro seja diretamente reduzido a ferro metálico através da reação com o carbono proveniente dos combustíveis sólidos. Já o Índice Térmico H_0 refere-se ao balanço térmico no interior do forno, calculado a partir das reações de combustão nas ventaneiras junto ao calor sensível proveniente do sopro e da perda térmica de calor ocorrida por meio das reações endotérmicas, como a redução direta, decomposição da água, reações com hidrogênio e perdas por calcinação.

Além disso, o modelo depende de pelo menos um loop de *feedback*. Assim, a retroalimentação da temperatura e o teor de silício do ferro gusa tem 4 atrasos cada.

O atraso foi selecionado considerando a não estacionariedade das séries de dados e a dinâmica da produção de aço. O número total de variáveis de entrada passou a 19 após adicionar as variáveis exógenas e de atraso de tempo.

Após definir as variáveis do modelo, os dados do processo foram divididos em clusters. Primeiramente, as variáveis a partir das quais foram derivados os grupos precisam ser selecionadas. A ideia por trás dos clusters surgiu ao observar o estado térmico do alto-forno através das medições de temperatura do gusa e teor de silício, onde cada par de medição representa a condição operacional. Cada ponto neste espaço de estado não representa um estado estacionário. O gráfico da temperatura do gusa versus o teor de silício representa todas as condições operacionais do forno. Ao dividir o processo em grupos, como mostra a Figura 6-3, foi possível observar condições operacionais similares do alto-forno. Ou seja, foi possível distinguir subgrupo com características semelhantes de operação nas quais contribuíram para gerar modelos mais específicos para cada região operacional representada na Figura 6-3 por cada cluster. Além disso, cada ponto no espaço de estados é uma posição do estado em um ciclo limite; isto é, o FCM indica que a transição entre clusters é um fenômeno transitório no processo de simulação.

O número de grupos foi determinado pela análise do resultado da minimização da função objetivo do FCM, tendo como base a Figura 6-4. O aumento do número de clusters pode ajudar a reduzir a soma da variação dentro de cada cluster. Isso ocorre porque ter mais clusters permite capturar grupos de dados mais refinados que são mais parecidos entre si. No entanto, o efeito de reduzir a soma das variações dentro de cada cluster leva a um alto número de clusters, porém dividir um cluster coeso em dois fornece apenas uma redução insignificativa. Uma forma de determinar o número de clusters utilizando o método do cotovelo, ou seja, usar o ponto de viragem da função objetivo em relação ao número de clusters. Como mostrado na Figura 6-4, o ponto de virada corresponde a 8 clusters. Conseqüentemente, o número de clusters escolhido foi 8.

Figura 6-3 – Seleção dos clusters.

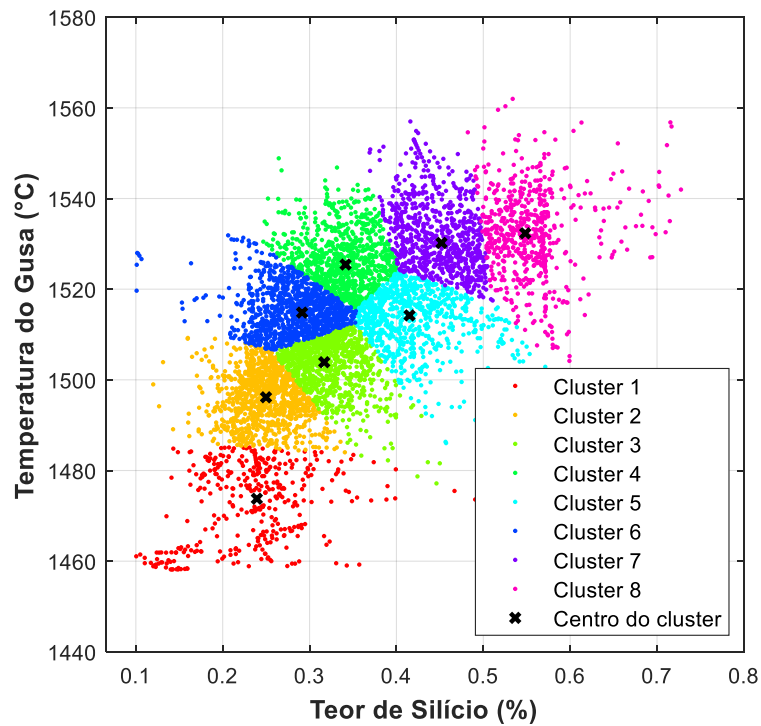
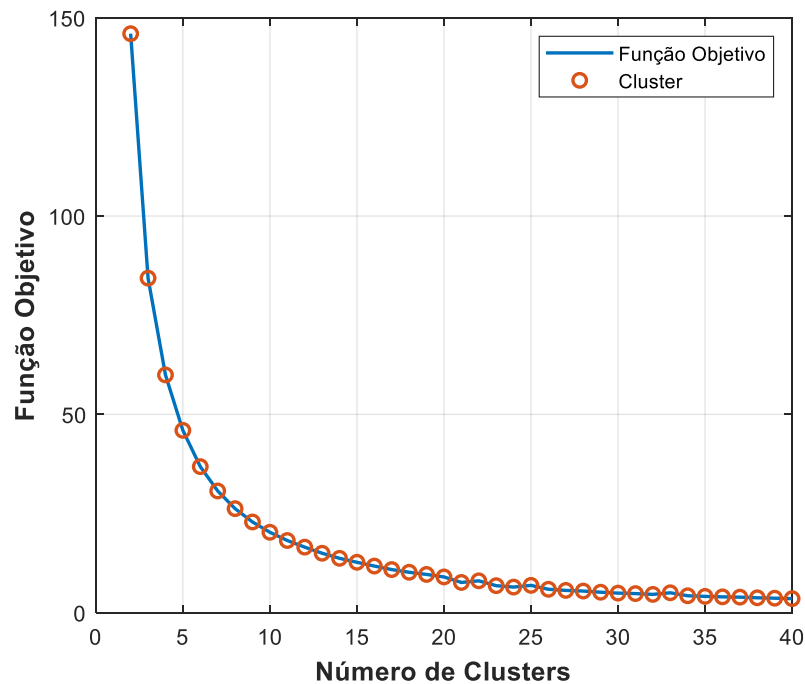


Figura 6-4 – Função objetivo do FCM variando com o número de clusters.



As coordenadas dos centros e o número de amostras de cada cluster são mostrados na Tabela 6-2. Essas coordenadas identificam cada *cluster*, assim como também são os pontos utilizados para a determinar a qual cluster pertence novas

amostras inseridas no modelo a partir do cálculo da distância entre o centroide e a nova amostra. Dentre as condições identificadas, os *clusters* que apresentam as condições ideais de operação são os *clusters* 4 e 5, pois se encontram mais bem posicionados nos entre 1480 e 1520 °C e 0,3 e 0,5% de silício.

Tabela 6-2 – Coordenadas dos centros de cada *cluster*.

Identificação	Número de amostras	Temperatura do gusa	Teor de silício no gusa
Cluster 1	430	1473,774	0,2393
Cluster 2	986	1496,153	0,2498
Cluster 3	898	1503,892	0,3168
Cluster 4	1081	1525,437	0,3414
Cluster 5	858	1514,212	0,4150
Cluster 6	1059	1514,831	0,2913
Cluster 7	787	1530,214	0,4518
Cluster 8	623	1532,333	0,5482

A arquitetura da rede neural foi determinada a partir da otimização bayesiana dos seus hiperparâmetros, entre eles o número de camadas ocultas variando entre 1 e 4 camadas, o número de neurônios para cada camada de 10 a 40 neurônios e a taxa de aprendizagem no intervalo de 0,001 a 1. A otimização busca o menor valor para raiz do erro médio quadrático entre a variável medida e a variável predita para um dos clusters; o resultado foi replicado para os outros grupos. O resultado da otimização é apresentado na Tabela 6-3.

Um modelo NARX foi criado para cada cluster com a configuração de 1 camada oculta contendo 17 neurônios e taxa de aprendizagem de 0,0393. O treinamento do modelo iniciou com a divisão das amostras entre treinamento, validação e teste na proporção de 70, 15 e 15%, respectivamente. O processo de treinamento em si foi repetido 10 vezes para cada modelo e selecionado o que apresentou os menores índices de erros. A Tabela 6-4 mostra os resultados da previsão da temperatura do gusa e teor de silício para cada rede do cluster e o modelo formado por todos os clusters (FCM-NARX). O desempenho das previsões em comparação com as medições foi avaliado pelos critérios da MAPE, RMSE e coeficiente de correlação,

além da visualização gráfica. Os resultados da Tabela 6-4 demonstram que o modelo proposto se adequa ao processo de fabricação do aço uma vez que os erros são baixos e o coeficiente de correlação é alto.

Tabela 6-3 – Resumo da otimização dos parâmetros da rede neural.

Hiperparâmetros	Intervalo de variação	Parâmetro otimizado
Número de Camadas	1 – 3	1
Número de Neurônios	10 – 40	17
Taxa de Aprendizagem	0,001 – 1	0,0393
Função Objetivo	–	3,625

Tabela 6-4 – Resumo dos parâmetros de desempenho das predições.

Modelo	Teor de Silício			Temperatura do Gusa		
	MAPE	RMSE	R ²	MAPE	RMSE	R ²
Rede 1	1,223	0,008	0,981	0,052	1,200	0,988
Rede 2	1,475	0,008	0,934	0,045	1,033	0,961
Rede 3	1,252	0,007	0,957	0,033	0,737	0,984
Rede 4	1,290	0,005	0,979	0,035	0,844	0,967
Rede 5	1,701	0,007	0,997	0,058	1,415	0,973
Rede 6	1,052	0,009	0,953	0,038	0,846	0,992
Rede 7	1,139	0,008	0,944	0,036	0,976	0,983
Rede 8	1,152	0,005	0,978	0,030	0,703	0,983
FCM-NARX	1,268	0,007	0,996	0,039	0,955	0,997

Outra forma de avaliar o modelo é através dos gráficos da Figura 6-5, em que a distribuição dos dados mais de perto na direção diagonal indica a predição obtendo o valores similares aos medidos. Já valores dispersos em torno da diagonal apontam um desajuste. Esses mesmos resultados podem ser observados na Figura 6-6 em que os dados preditos estão quase todos sobrepostos na distribuição das medições no número das amostras. Portanto, todas as análises realizadas demonstram que a

metodologia proposta gera um modelo preciso para a temperatura do gusa e o teor de silício.

Figura 6-5 – Resultado da regressão para (a) temperatura do gusa e (b) teor de silício utilizando o modelo FCM-NARX.

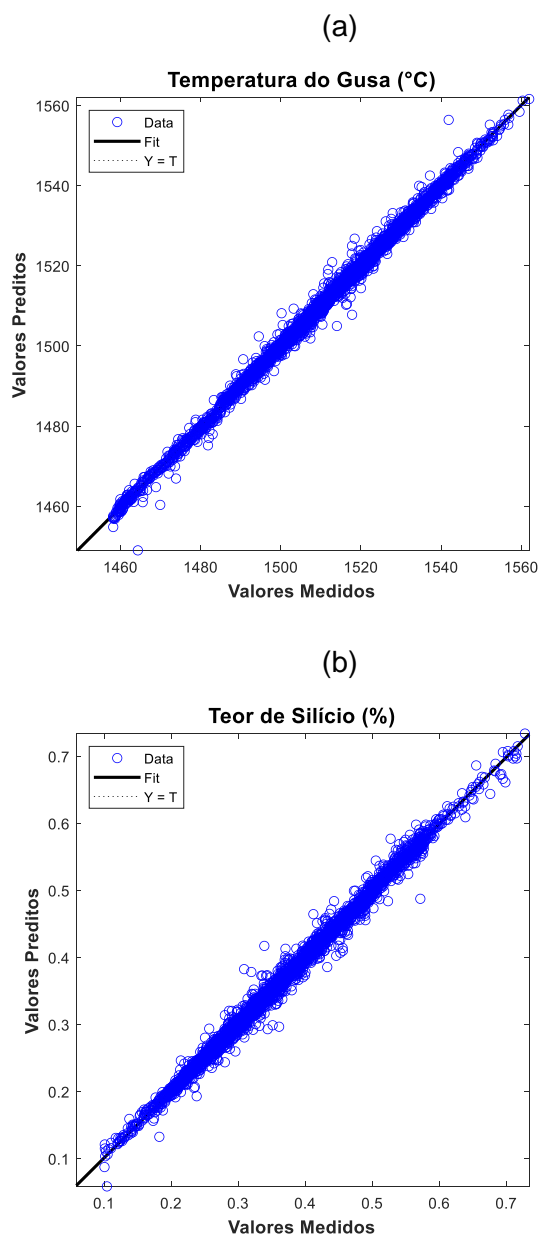

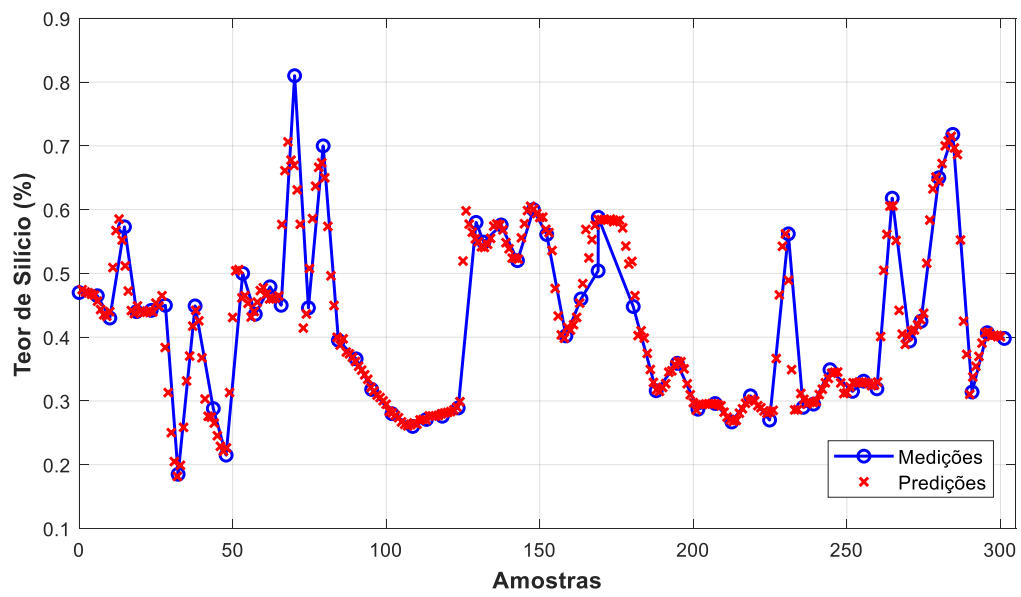


Figura 6-6 – Resultado da predição para (a) temperatura do gusa e (b) teor de silício utilizando o modelo FCM-NARX.

(a)



(b)



CONCLUSÃO

7. CONCLUSÃO

Este trabalho apresentou uma nova metodologia para a previsão de temperatura e teor de silício no gusa do processo de fabricação de ferro gusa, utilizando um *soft sensor* baseado em uma combinação de FCM-NARX. Os dados reais de produção foram empregados para treinar e validar o algoritmo proposto.

A preparação e o pré-processamento dos dados contribuíram para um modelo mais confiável devido a substituição de medições não representativas do processo. Na preparação dos dados foi realizado a interpolação PCHIP para obter uma aproximação e amostragem a cada 30 minutos da temperatura e teor de silício no ferro gusa. Além disso, no pré-processamento foram identificados e substituídos 0,052% de dados faltosos e 1,6% de *outliers* no conjunto do histórico de dados.

A seleção das variáveis foi necessária para determinar quais variáveis do processo afetam o desempenho de operação do alto-forno e o estado térmico. Dentre essas foram selecionadas variáveis manipuláveis e controladas, além de índices de operação.

O estudo dos *clusters* mostrou que a operação do alto-forno pode ser dividida em 8 condições operacionais distintas. Os *clusters* foram determinados a partir dos parâmetros para indicar os fenômenos causadores da variação do nível térmico que são a temperatura e o teor de silício no ferro gusa.

Para cada condição operacional (ou cluster) foi desenvolvido um modelo de rede neural NARX utilizando as variáveis selecionadas e dando como resposta a temperatura e o teor de silício no ferro gusa. O conjunto desses modelos forma o modelo global que atua em todas as condições operacionais do alto-forno.

O *soft sensor* proposto foi testado em dados operacionais e essa simulação forneceu predições dos indicadores do estado térmico do alto-forno, representado pela temperatura e teor do gusa, em intervalos de 30 minutos. O coeficiente de determinação para da temperatura e teor de silício no gusa foram de 99,7% e 99,6%, respectivamente. Esses resultados demonstram que o *soft sensor* proposto pode prever os indicadores com precisão e atender às necessidades de produção do ferro gusa.

REFERÊNCIAS

ABD ELMOMEN, S. Influence of Slag Composition and Temperature on Silicon Distribution between Slag and Hot Metal in the Egyptian Blast Furnace No.III. **Journal of Petroleum and Mining Engineering**, v. 19, n. 1, p. 26–32, 2017.

AGGARWAL, C. C. **Data Classification: Algorithms and Applications**. 1st. ed. New York: Chapman and Hall/CRC, 2014.

ANDERSSON, A. J.; ANDERSSON, A. M. T.; JÖNSSON, P. G. Variation in hot metal and slag composition during tapping of blast furnace. **Ironmaking and Steelmaking**, v. 31, n. 3, p. 216–226, 2004.

ASCEND, G. et al. Inside the Blast Furnace. In: **Blast Furnace Ironmaking**. [s.l.] Elsevier, 2020. p. 19–30.

BAMBAUER, F. et al. Transient DEM-CFD simulation of solid and fluid flow in a three dimensional blast furnace model. **Powder Technology**, v. 334, p. 53–64, 2018.

BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B. **Deep Learning Toolbox™ User's Guide**. [s.l.: s.n.].

BERNASOWSKI, M.; KLIMCZYK, A.; STACHURA, R. Support algorithm for blast furnace operation with optimal fuel consumption. **Journal of Mining and Metallurgy, Section B: Metallurgy**, v. 55, n. 1, p. 31–38, 2019.

BHATTACHARYA, T. Prediction of Silicon Content in Blast Furnace Hot Metal Using Partial Least Squares (PLS). **ISIJ International**, v. 45, n. 12, p. 1943–1945, 2005.

BROCHU, E.; CORA, V. M.; FREITAS, N. DE. A Tutorial on Bayesian Optimization of Expensive Cost Functions , with Application to Active User Modeling and Hierarchical Reinforcement Learning. 2010.

CAMERON, I. et al. The Iron Blast Furnace Process. In: **Blast Furnace Ironmaking**. [s.l.] Elsevier, 2020. p. 1–18.

CARCILLO, F. et al. Combining unsupervised and supervised learning in credit card fraud detection. **Information Sciences**, 2019.

CHAO, Y.; SU, C.; HUANG, H. The adaptive autoregressive models for the system dynamics and prediction of blast furnace. **Chemical Engineering Communications**, v. 44, n. 1-6, p. 309-330, 1986.

CHEN, J. Predictive system for blast furnaces by integrating a neural network with qualitative analysis. **Engineering Applications of Artificial Intelligence**, v. 14, n. 1, p. 77–85, 2001.

CHEN, T.-C. T.; HONDA, K. **Fuzzy Collaborative Forecasting and Clustering**. Cham: Springer International Publishing, 2020.

DAI, Y. et al. Effect of slag-remaining operation on dephosphorization based on single-slag converter steelmaking technology. **Metallurgical Research and Technology**, v. 116, n. 5, 2019.

DAVID, S. F. **Análise da influência dos fatores operacionais dos altos fornos sobre o teor do silício e enxofre no ferro gusa por meio de redes neurais artificiais**. Dissertação (Mestrado)—[s.l.] Instituto Federal do Espírito Santo, Programa de Pós-graduação em Engenharia Metalúrgica e de Materiais, Vitória, 2013.

DINIZ, A. P. M. **Modelos de previsão do conteúdo de silício no ferro- gusa usando redes neurais artificiais**. Dissertação (Mestrado)—[s.l.] Universidade Federal do Espírito Santo, Programa de Pós- Graduação em Engenharia Elétrica, Vitória, 2018.

EL-SALLABI, N. M. H.; QARAQE, K.; SERPEDIN, E. Comparison of Different 1-D Interpolation Algorithms for Estimation of Shadow Fading. **2013 7th IEEE GCC Conference and Exhibition (GCC)**, Doha, p. 372–377, 2013.

FRAZIER, P. I. Bayesian Optimization. In **INFORMS Tutorials in Operations Research**, n. October, 2018.

FRITSCH, F. N.; CARLSON, R. E. Monotone Piecewise Cubic Interpolation. **SIAM Journal on Numerical Analysis**, v. 17, n. 2, p. 238–246, 1980.

GAO, C.; JIAN, L.; LUO, S. Modeling of the thermal state change of blast furnace hearth with support vector machines. **IEEE Transactions on Industrial Electronics**, v. 59, n. 2, p. 1134–1145, 2012.

GASPARINI, V. M. **Desenvolvimento de um Modelo de Controle de Processo para Altos-Fornos a Coque Aplicado a Altos-Fornos Industriais**. Tese (Doutorado)—[s.l.] Universidade Federal de Minas Gerais, Programa de Pós-Graduação em Engenharia Metalúrgica, Materiais e de Minas, Belo Horizonte, 2016.

GASPARINI, V. M. et al. Thermo-chemical model for blast furnace process control with the prediction of carbon consumption. **Journal of Materials Research and Technology**, v. 6, n. 3, p. 220–225, 2017.

GE, Z. et al. Data Mining and Analytics in the Process Industry: The Role of Machine Learning. **IEEE Access**, v. 5, p. 20590–20616, 2017.

GEERDES, M.; TOXOPEUS, H.; VLIET, C. VAN DER. **Modern Blast Furnace Ironmaking**. Amsterdam: IOS Press BV, 2015.

GUZMAN, S. M.; PAZ, J. O.; TAGERT, M. L. M. The Use of NARX Neural Networks to Forecast Daily Groundwater Levels. **Water Resources Management**, v. 31, n. 5, p. 1591–1603, 2017.

HAGAN, M. et al. **Neural Network Design**. 2nd. ed. [s.l: s.n.].

HAN, J.; KAMBER, M.; PEI, J. **Data Mining: Concepts and Techniques**. 3rd. ed. Waltham: Morgan Kaufmann Publishers, 2011.

HASHIMOTO, Y. et al. Transient model-based operation guidance on blast furnace. **Control Engineering Practice**, v. 82, n. July 2018, p. 130–141, 2019.

HASSANIEN, A. E. **Machine Learning Paradigms: Theory and Application**. Cham: Springer, 2019.

HAYKIN, S. **Neural Networks and Learning Machines**. 3rd. ed. Upper Saddle River: Prentice-Hall, 2009.

HONGWU, W. et al. Prediction of Hot Metal Silicon Content in Blast Furnace based on EMD and DNN. **2015 34th Chinese Control Conference (CCC)**, p. 8214–8218, 2015.

IFFAT, U. et al. New digital services for manufacturing industry using analytics: The case of blast furnace thermal regulation. **Proceeding - 2018 20th IEEE International**

Conference on Business Informatics, CBI 2018, v. 2, p. 89–91, 2018.

JIAN, L.; GAO, C. Binary Coding SVMs for the Multiclass Problem of Blast Furnace System. **IEEE Transactions on Industrial Electronics**, v. 60, n. 9, p. 3846–3856, 2013.

JIAN, L.; GAO, C.; XIA, Z. Constructing Multiple Kernel Learning Framework for Blast Furnace Automation. **IEEE TRANSACTIONS ON AUTOMATION SCIENCE AND ENGINEERING**, v. 9, n. 4, p. 763–777, 2012.

JIMÉNEZ, J. et al. Blast Furnace Hot Metal Temperature Prediction through Neural Networks-Based Models. **ISIJ International**, v. 44, n. 3, p. 573–580, 2004.

JÚNIOR, W. J. DE A. **Métodos de Otimização Hiperparamétrica: Um Estudo Comparativo Utilizando Árvores de Decisão e Florestas Aleatórias na Classificação Binária**. Dissertação (Mestrado)—[s.l.] Universidade Federal de Minas Gerais, Pós-Graduação em Engenharia Elétrica da Escola de Engenharia, Belo Horizonte, 2018.

KADLEC, P.; GABRYS, B.; STRANDT, S. Data-driven Soft Sensors in the process industry. **Computers and Chemical Engineering**, v. 33, n. 4, p. 795–814, 2009.

KREUTZER, R. T.; SIRRENBURG, M. **Understanding Artificial Intelligence**. 1st ed. ed. Cham: Springer International Publishing, 2019.

KUBAT, M. **An Introduction to Machine Learning**. Cham: Springer, 2017.

LIN, S. H. I. et al. ScienceDirect Model of Hot Metal Silicon Content in Blast Furnace Based on Principal Component Analysis Application and Partial Least Square. **Journal of Iron and Steel Research International**, v. 18, n. 10, p. 13–16, 2011.

MACIEL, L. S.; BALLINI, R. Design a Neural Network for Time Series Financial Forecasting: Accuracy and Robustness Analysis. **Universidade Estadual de Campinas (UNICAMP)**, n. 2008, p. 1–21, 2008.

MATSUZAKI, S. et al. **Development of visual evaluation and numerical analysis system of blast furnace**. [s.l.] IFAC, 2005. v. 16

NASRAOUI, O.; BEN N' CIR, C.-E. **Clustering Methods for Big Data Analytics**. Cham: Springer, 2019.

NAZARENO, J.; SILVA, S. **Siderurgia**. Belém: Instituto Federal de Educação, Ciência e Tecnologia do Pará, 2011.

NURKKALA, A.; PETTERSSON, F.; SAXÉN, H. Nonlinear Modeling Method Applied to Prediction of Hot Metal Silicon in the Ironmaking Blast Furnace. **Industrial & Engineering Chemistry Research**, v. 50, n. 15, p. 9236-9248, 2011.

ÖSTERMARK, R.; SAXÉN, H. VARMAX-modelling of blast furnace process variables. **European Journal of Operational Research**, v. 90, n. 1, p. 85-101, 1996.

PALUMBO, F.; MONTANARI, A.; VICHI, M. **Data Science**. Cham: Springer International Publishing, 2017.

PAN, D. et al. Temperature Measurement Method for Blast Furnace Molten Iron Based on Infrared Thermography and Temperature Reduction Model. **Sensors**, v. 18, n. 11, p. 3792, 2018.

PANDIT, S. M; CLUM, J. A.; WU, S. M. Modeling, prediction and control of blast furnace operation from observed data by multivariate time series. **Ironmaking Conference, 34th, Toronto**, p. 403–416, 1975.

PRIDDY, K. L.; KELLER, P. E. **Artificial Neural Networks: An Introduction**. Bellingham: SPIE, 2005.

RUSSELL, S.; NORVIN, P. **Artificial Intelligence A Modern Approach**. 3rd Editio ed. Harlow: Pearson, 2016.

SADAAKI, M.; ICHIHASHI, H.; HONDA, K. **Algorithms for Fuzzy Clustering**. Heidelberg: Springer, 2008.

SALEHI, H.; BURGUEÑO, R. Emerging artificial intelligence methods in structural engineering. **Engineering Structures**, v. 171, n. May, p. 170–189, 2018.

SIM, K. S.; WEE, M. Y.; LIM, W. K. Image Signal-to-Noise Ratio Estimation Using Shape-Preserving Piecewise Cubic Hermite Autoregressive Moving Average Model.

Microscopy Research and Technique, v. 720, n. April, p. 710–720, 2008.

TSIHRINTZIS, G. A.; SOTIROPOULOS, D. N.; JAIN, L. C. **Machine Learning Paradigms Advances in Data Analytics**. 1st Editio ed. Cham: Springer, 2019.

TUNÇKAYA, Y.; KOKLUKAYA, E. Comparative performance evaluation of blast furnace flame temperature prediction using artificial intelligence and statistical methods. **Turkish Journal of Electrical Engineering & Computer Sciences**, p. 1163–1175, 2016.

WORLD STEEL ASSOCIATION. **World Steel Fact Sheet: Energy**. Disponível em: <www.worldsteel.org>. Acesso em: 22 jan. 2020.

YANG, Y.; RAIPALA, K.; HOLAPPA, L. Ironmaking. In: **Treatise on Process Metallurgy**. [s.l.] Elsevier, 2014. v. 3p. 2–88.

ZHANG, X.; KANO, M.; MATSUZAKI, S. A comparative study of deep and shallow predictive techniques for hot metal temperature prediction in blast furnace ironmaking. **Computers and Chemical Engineering**, v. 130, p. 106575, 2019a.

ZHANG, X.; KANO, M.; MATSUZAKI, S. Ensemble pattern trees for predicting hot metal temperature in blast furnace. **Computers and Chemical Engineering**, v. 121, p. 442–449, 2019b.

ZHOU, P. et al. Data-Driven Dynamic Modeling for Prediction of Molten Iron Silicon Content Using ELM with Self-Feedback. **Mathematical Problems in Engineering**, v. 2015, 2015a.

ZHOU, P. et al. Multivariable dynamic modeling for molten iron quality using online sequential random vector functional-link networks with self-feedback connections. **Information Sciences**, v. 325, p. 237–255, 2015b.

ZHOU, P. et al. Data-Driven Nonlinear Subspace Modeling for Prediction and Control of Molten Iron Quality Indices in Blast Furnace Ironmaking. **IEEE Transactions on Control Systems Technology**, v. 25, n. 5, p. 1761–1774, 2017.

ZHOU, P.; GUO, D.; CHAI, T. Data-driven predictive control of molten iron quality in blast furnace ironmaking using multi-output LS-SVR based inverse system

identification. **Neurocomputing**, v. 308, p. 101–110, 2018.

ANEXOS**ANEXO A – TRABALHO PUBLICADO**

FONTES, D. O. L.; VASCONCELOS, L. G. S.; BRITO, R. P. Blast furnace hot metal temperature and silicon content prediction using soft sensor based on fuzzy C-means and exogenous nonlinear autoregressive models. **Computers and Chemical Engineering**, v. 141, 2020.