

UNIVERSIDADE FEDERAL DE MINAS GERAIS
Escola de Engenharia
Programa de Pós-graduação em Engenharia Elétrica

Lourival Fernandes Nogueira Neto

OTIMIZAÇÃO ENERGÉTICA EM SISTEMAS MULTICOMBUSTÍVEIS

Belo Horizonte
2025

Lourival Fernandes Nogueira Neto

OTIMIZAÇÃO ENERGÉTICA EM SISTEMAS MULTICOMBUSTÍVEIS

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

Orientador: Prof. Dr. Lucas de Souza Batista

Belo Horizonte
2025

N778o	Nogueira Neto, Lourival Fernandes. Otimização energética em sistemas multicomcombustíveis [recurso eletrônico] / Lourival Fernandes Nogueira Neto. - 2025. 1 recurso online (102 f. : il., color.) : pdf. Orientador: Lucas de Souza Batista. Dissertação (mestrado) - Universidade Federal de Minas Gerais, Escola de Engenharia. Inclui bibliografia. 1. Engenharia elétrica - Teses. 2. Eficiência energética - Teses. 3. Otimização multiobjetivo - Teses. 4. Sustentabilidade - Teses. 5. Siderurgia - Teses. I. Batista, Lucas de Souza. II. Universidade Federal de Minas Gerais. Escola de Engenharia. III. Título. CDU: 621.3(043)
-------	--

Ficha catalográfica elaborada pelo bibliotecário Reginaldo César Vital dos Santos CRB/6 2165
Biblioteca Prof. Mário Werneck, Escola de Engenharia da UFMG



UNIVERSIDADE FEDERAL DE MINAS GERAIS
Escola de Engenharia
COLEGIADO DO CURSO DE PÓS-GRADUAÇÃO EM Engenharia Elétrica

FOLHA DE APROVAÇÃO

"Otimização Energética em Sistemas Multicombustíveis"

Lourival Fernandes Nogueira Neto

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Mestre em Engenharia Elétrica.

Aprovada em 24 de novembro de 2025.

Por:

Prof. Dr. Lucas de Souza Batista
DEE (UFMG) - Orientador

Prof. Dr. Rodney Rezende Saldanha
DEE (UFMG)

Prof. Dr. André Costa Batista
DEE (UFMG)



Documento assinado eletronicamente por **Lucas de Souza Batista, Professor do Magistério Superior**, em 24/11/2025, às 16:29, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **André Costa Batista, Professor(a)**, em 24/11/2025, às 16:33, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

Documento assinado eletronicamente por **Rodney Rezende Saldanha, Membro de**



comissão, em 28/11/2025, às 11:06, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4754066** e o código CRC **E87106B9**.

Referência: Processo nº 23072.270822/2025-74

SEI nº 4754066

Dedicado à família e amigos.

“Os mais fortes de todos os guerreiros são estes dois: tempo e paciência.”

Leon Tolstói

RESUMO

Este trabalho aborda a otimização energética de um sistema multicomcombustível, baseado em paradigmas ambientais e econômicos. Para tratar este sistema, propõe-se uma modelagem híbrida (linear/não-linear) multiobjetivo e otimização via algoritmo metaheurístico, recorrendo à estratégia de enxame de partículas na perspectiva quântica. Com o intuito de dar suporte à tomada de decisão, desenvolveu-se também uma estratégia dedicada de auxílio à decisão multicritério, considerando atributos comerciais específicos do problema siderúrgico, baseada no método PROMETHEE. A ferramenta proposta é aplicada a três cenários do estudo de caso. Em geral, permitiu-se notar a adoção de soluções não triviais, que, em comparação com a solução inicial, reflete em ganho de performance, redução de emissões e aumento de produção, com consequente retorno financeiro pela produção extra de energia elétrica. A ferramenta global proposta se mostrou de grande valia para a identificação de soluções de menor impacto ambiental, configurando-se como essencial para empresas que queiram ser mais eficientes e competitivas no mercado.

Palavras-chave: otimização multiobjetivo; sistemas multicomcombustíveis; QPSO; PROMETHEE II; siderurgia; eficiência energética; sustentabilidade industrial.

ABSTRACT

This work addresses the energy optimization of a multi-fuel system based on environmental and economic paradigms. To address this system, a hybrid (linear/non-linear) multi-objective modeling and optimization via heuristic search is proposed, using the particle swarm strategy from a quantum perspective. In order to support decision-making, a dedicated multi-criteria decision support strategy was also developed, considering specific commercial attributes of the steel industry problem, based on the PROMETHEE method. The tool is applied in three case study scenarios. In general, it allowed for the adoption of non-trivial solutions, which, compared to the initial solution, reflect performance gains, reduced emissions, and increased production, with a consequent financial return from the extra production of electricity. The proposed global tool proved to be of great value for identifying solutions with less environmental impact, making it essential for companies that want to be more efficient and competitive in the market.

Keywords: multi-objective optimization; multi-fuel systems; QPSO; PROMETHEE II; steelmaking; energy efficiency; industrial sustainability.

LISTA DE FIGURAS

1.1	Usina Termoeletrica de Igarapé: CEMIG. <i>Fonte: Google Photos: Paulo Rodrigues.</i>	18
3.1	Fluxos no setor siderúrgico <i>Fonte: Adaptado de CARVALHO (2021).</i>	33
3.2	Hélices da turbina a vapor de grande porte <i>Fonte: Pexe (2021).</i>	35
3.3	Desenho esquemático e nomenclatura de caldeira aquatubular. <i>Fonte: de Souza (2020).</i>	36
3.4	Diagrama de Representação do Estudo de Caso. <i>Fonte: Elaborado pelo autor.</i>	36
3.5	Bateria de Coque <i>Fonte: Villaça (2023).</i>	39
3.6	Dinâmica das fases de coqueificação <i>Fonte: Merrick (1983).</i>	40
3.7	Representação Alto-Forno, segundo GEERDES et al. (2015)	42
3.8	Representação do processo da Aciaria, segundo Voraberger et al. (2022)	44
3.9	Diagrama de correlação entre entradas e saída.	48
3.10	Representação do diagrama de Bode, à esquerda sistema de primeira ordem, e à direita sistema de segunda ordem com diferentes fatores de amortecimento; adaptado de Serpa (2007).	49
3.11	Entrada Degrau unitário deslocado no tempo (Serpa, 2007).	50
3.12	Entrada Delta de Dirac (Serpa, 2007).	50
3.13	Representações de blocos interconectados (Aguirre, 2007).	52
3.14	Exemplo de aplicação do modelo Hammerstein-Wiener (Center, 2025).	52
3.15	Visão explodida de um neurônio em uma rede, <i>Fonte: Própria.</i>	54
3.16	Definição do hiperplano pelo SVR, <i>Fonte: Hakbilen (2022)</i>	54
3.17	Representação de uma <i>Random Forest</i> , Adaptado de: Kulkarni (2023)	55
3.18	Problema de otimização multiobjetivo. Representação do espaço de projetos. <i>Fonte: Autoria própria.</i>	56
3.19	Problema de otimização multiobjetivo. Representação do espaço de objetivos. <i>Fonte: Autoria própria.</i>	57
3.20	Problema de otimização multiobjetivo. Representação no espaço de objetivos: Avaliação do cone de dominância Pareto. <i>Fonte: Autoria própria.</i>	58
4.1	Diagrama macro da metodologia	61
4.2	Avaliação da coleta de dados brutos provenientes do monitoramento de vazão de óleo nas caldeiras do estudo de caso. <i>Fonte: Autoria própria.</i>	63
4.3	Comparação entre média móvel simples e média móvel de Hull. <i>Fonte: Autoria própria.</i>	64
4.4	Avaliação e tratamento de sinais Sinais coletados da caldeira 03 do estudo de caso, durante parada para manutenção. <i>Fonte: Autoria própria.</i>	64
4.5	Diagrama de criação do modelo de identificação	70

4.6	Visão geral da metodologia proposta	75
5.1	Avaliação e tratamento de sinais Vazão de vapor da Caldeira 01 do estudo de caso. Fonte: Autoria própria.	77
5.2	Avaliação e tratamento de sinais: Conjunto de treinamento Vazão de vapor da Caldeira 01 do estudo de caso. Fonte: Autoria própria.	78
5.3	Avaliação do modelo de identificação da produção de vapor. Fonte: Autoria própria.	79
5.4	Avaliação de consistência do algoritmo em 10 execuções	80
5.5	Relação entre Energia e Vapor Produzido - Fronteira Pareto Estimada. Fonte: Autoria própria.	82
5.6	Análise dos cones de dominância - Fronteira Pareto Estimada. Fonte: Autoria própria.	83
5.7	Avaliação da performance das soluções propostas - Pseudo Pareto Ótima. Fonte: Autoria própria.	83
5.8	Avaliação PROMETHEE II Fonte: Autoria Própria	85
5.9	Avaliação PROMETHEE II - Fluxo líquido Fonte: Autoria Própria	85
5.10	Avaliação comparativa - distribuição de recursos Fonte: Autoria Própria	87
5.11	Avaliação comparativa - performance das caldeiras Fonte: Autoria Própria	87
5.12	Avaliação comparativa - produção de vapor Fonte: Autoria Própria	88
5.13	Retrato de produção do mês coletado Fonte: Autoria Própria	88
5.14	Análise comparativa de produção de vapor - Simulação de três caldeiras em operação Fonte: Autoria Própria	89
5.15	Análise comparativa de consumo de energia - Simulação de três caldeiras em operação Fonte: Autoria Própria	90
5.16	Análise comparativa de produção de vapor - Simulação todas as caldeiras em operação Fonte: Autoria Própria	91
5.17	Análise comparativa de consumo de energia - Simulação todas as caldeiras em operação Fonte: Autoria Própria	91

LISTA DE TABELAS

2.1	Comparativo de Artigos Correlacionados.	31
3.1	Composição química do G_{CO} no estudo de caso.	41
3.2	Composição química do G_{AF} no estudo de caso.	43
3.3	Composição química do G_{AC} no estudo de caso.	45
3.4	Composição química do GN no estudo de caso.	46
3.5	Resumo dos recursos energéticos	47
4.1	Parâmetros da instância do problema, $Base_{1,\beta}$ e $Base_{2,\beta}$	68
4.2	Atributos e Pesos usados no PROMETHEE	74
5.1	Erros médios de representação registrados ao longo da simulação	78
5.2	Fluxos de Combustível por Caldeira (em unidades de vazão)	81
5.3	Vetor de energia admitida - limites de operação	81
5.4	Valores de ϵ para o problema de otimização	81
5.5	Fluxos de Combustível por Caldeira (em unidades de vazão) - Alternativa 02. .	86
5.6	Resultados do Processo de Otimização - avaliação das soluções	92

LISTA DE ABREVIATURAS

ABM	Associação Brasileira de Metalurgia, Materiais e Mineração
AHP	<i>Analytic Hierarchy Process</i> (Processo Analítico Hierárquico)
ANEEL	Agência Nacional de Energia Elétrica
ARMAX	<i>AutoRegressive Moving Average with eXogenous input</i>
ARX	<i>AutoRegressive with eXogenous input</i>
BTX	Benzeno, Tolueno e Xileno
Cald.	Caldeiras
CEMIG	Companhia Energética de Minas Gerais
CHP	<i>Combined Heat and Power</i> (Cogeração de Calor e Energia)
CO	Monóxido de Carbono
CO₂	Dióxido de Carbono
Comb.	Combustíveis
COP30	30ª Conferência das Nações Unidas sobre Mudança do Clima
CTE	Central Termoelétrica
ELECTRE	<i>ELimination Et Choix Traduisant la REalité</i>
ESG	<i>Environmental, Social and Governance</i> (Ambiental, Social e Governança)
FEA	Forno Elétrico a Arco
FGVces	Centro de Estudos em Sustentabilidade da Fundação Getúlio Vargas
Flare	Queima de combustível para alívio de pressão (sem recuperação energética)
G_{AC}	Gás de Aciaria
G_{AF}	Gás de Alto-Forno
G_{CO}	Gás de Coqueria
gbest	<i>Global Best</i> (Melhor posição global do exame)
GEE	Gases de Efeito Estufa
GHG	<i>Greenhouse Gases</i> (Protocolo de Gases de Efeito Estufa)

GN	Gás Natural
H₂	Hidrogênio
HEUR	Heurísticas
HMA	<i>Hull Moving Average</i> (Média Móvel de Hull)
LD	Linz-Donawitz (Processo de produção de aço via convertedor a oxigênio)
LP	<i>Linear Programming</i> (Programação Linear)
LSTM	<i>Long Short-Term Memory</i> (Rede Neural de Memória de Longo Prazo)
MAE	<i>Mean Absolute Error</i> (Erro Absoluto Médio)
MES	<i>Multi-Energy Systems</i> (Sistemas Multi-Energéticos)
ML	<i>Machine Learning</i> (Aprendizado de Máquina)
MSE	<i>Mean Squared Error</i> (Erro Quadrático Médio)
NARMAX	<i>Nonlinear AutoRegressive Moving Average with eXogenous variables</i>
NARX	<i>Nonlinear AutoRegressive with eXogenous input</i>
NLP	<i>Nonlinear Programming</i> (Programação Não Linear)
Nm³	Metro Cúbico Normal
NO_x	Óxidos de Nitrogênio
pbest	<i>Personal Best</i> (Melhor posição pessoal da partícula)
PCI	Poder Calorífico Inferior
PCS	Poder Calorífico Superior
PL	Programação Linear
PLIM	Programação Linear Inteira Mista
PM	Programação Matemática
PNL	Programação Não Linear
PNLIM	Programação Não Linear Inteira Mista
PPGEE	Programa de Pós-Graduação em Engenharia Elétrica
PROMETHEE	<i>Preference Ranking Organization Method for Enrichment Evaluation</i>
PSO	<i>Particle Swarm Optimization</i> (Otimização por Enxame de Partículas)
QPSO	<i>Quantum-behaved Particle Swarm Optimization</i>
RBF	<i>Radial Basis Function</i> (Função de Base Radial)
ReLU	<i>Rectified Linear Unit</i> (Unidade Linear Retificada)
SMA	<i>Simple Moving Average</i> (Média Móvel Simples)
SO₂	Dióxido de Enxofre
SVM	<i>Support Vector Machine</i> (Máquina de Vetores de Suporte)

SVR	<i>Support Vector Regression</i> (Máquina de Vetores de Suporte para Regressão)
UFMG	Universidade Federal de Minas Gerais

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Sistemas a combustão: aliados do desenvolvimento ou inimigos do meio ambiente?	17
1.2	Motivação e Relevância do Trabalho	19
1.3	Objetivos	20
1.4	Contribuições do Trabalho	21
1.5	Organização do texto	21
2	REVISÃO BIBLIOGRÁFICA	23
3	FUNDAMENTAÇÃO TEÓRICA	33
3.1	Siderurgia	33
3.2	Central Termoeletrica	34
3.2.1	Estudo de Caso	35
3.2.2	Formulação Matemática	37
3.3	Recursos Energéticos	38
3.3.1	Gás de Coqueria	38
3.3.2	Gás de Alto-Forno	42
3.3.3	Gás de Aciaria	44
3.3.4	Gás Natural	46
3.3.5	Óleos	47
3.4	Representação do Sistema	48
3.4.1	Métodos Clássicos de Identificação	48
3.4.2	Métodos Heurísticos de Identificação	52
3.5	Otimização	56
3.5.1	Otimização Multiobjetivo	56
3.5.2	Tomada de Decisão	59
4	METODOLOGIA	61
4.1	Coleta de Dados	61
4.2	Elaboração do Problema de Otimização	65
4.2.1	Definições Matemáticas Prévias	65
4.2.2	Formulação Fundamental	66
4.2.3	Variáveis de Decisão	66

4.2.4	Função Objetivo	66
4.2.5	Definição das restrições	67
4.2.6	Método de Agregação ϵ -Restrito	68
4.3	Criação do Modelo de Identificação	69
4.4	Ferramenta Otimizadora	71
4.5	Tomada de Decisão Assistida	73
5	RESULTADOS E DISCUSSÕES	76
5.1	Modelo de Identificação	77
5.2	Fronteira Pareto Estimada	78
5.2.1	Avaliação pontual : uma aplicação prática	81
5.3	Seleção da Solução Interesse	84
5.4	Simulação Horária	88
5.4.1	Três Caldeiras em Funcionamento	89
5.4.2	Operação Convencional	90
6	CONCLUSÕES	93
	Bibliografia	96

Capítulo 1

INTRODUÇÃO

Este capítulo aborda uma breve contextualização do tema trabalhado e ilustra o cenário de estudo. Ao final, detalham-se os objetivos, a relevância do trabalho e as contribuições identificadas.

1.1 Sistemas a combustão: aliados do desenvolvimento ou inimigos do meio ambiente?

Desde o início das observações climáticas, percebe-se que os impactos negativos no ambiente das ações antrópicas alcançaram um patamar agravante; por exemplo, observou-se recentemente em *Copernicus* (observatório europeu) que o mês de outubro de 2023 quebrou uma série de recordes climáticos. Não são à toa as movimentações em torno do comitê de crise na Conferência do Clima da Organização das Nações Unidas (COP) ([Peixoto, 2024](#)), e a postura a que muitas empresas estão aderindo, como o pilar estratégico *Environmental*, da tríade Ambiental, Social e Governança, cuja sigla em inglês é ESG ([PactoGlobal.org, 2000](#)).

A primeira grande revolução industrial se deu, basicamente, pela introdução das máquinas a vapor, que se mostraram essenciais para o desenvolvimento humano. De forma geral, a transformação do poder da queima de combustível em energia cinética, potencial e elétrica favoreceu processos industriais, locomoção e, claro, qualidade de vida ([Branco, 2024](#)).

No Brasil, apesar de envolver uma matriz energética composta predominantemente por hidroelétricas ([Tavares, 2023](#)), o uso de termoeletricas é estratégico para o sistema nacional, mantendo o atendimento à demanda energética em momentos em que as demais fontes não são suficientes, vide Figura 1.1. Destaca-se que, apesar de ser mais caro, a dependência dos combustíveis fósseis em geradores hospitalares também é uma realidade, justificada pela necessidade da redundância para segurança e manutenção dos serviços ([Paletta et al., 2013](#)).



FIGURA 1.1: Usina Termoeletrica de Igarapé: CEMIG.

Fonte: Google Photos: Paulo Rodrigues.

Pode-se citar ainda o setor industrial, farmacêutico, alimentício, ramo de papel e celulose, bem como siderúrgico, que também necessitam de termoeletricas para seus processos internos (Knöttner and Hofmann, 2024). Em uma usina siderúrgica integrada, por exemplo, há uma demanda de ar soprado para a redução do minério de ferro em gusa. Esse ar soprado, geralmente, deriva-se de grandes máquinas conhecidas como turbo-sopradores, que podem ser elétricos ou acionados via vapor superaquecido, obtido por meio da queima de combustíveis em caldeiras. Por se tratar de um processo ininterrupto e com possibilidade de reutilização de coprodutos como material combustível, há uma preferência pelo uso de caldeiras.

Nesse contexto, observa-se um *trade-off* entre a disponibilidade do sistema elétrico e os impactos ambientais. No que se refere ao sistema elétrico brasileiro, a Bandeira Tarifária foi implementada em 2015 pela Agência Nacional de Energia Elétrica (ANEEL), configurando uma espécie de indicador utilizado pelas concessionárias a fim de apontar o quanto é mais custoso recorrer ao sistema termoeletrico para o atendimento à demanda. Pode ser entendida como uma tentativa de moderar o consumo nas condições desfavoráveis de geração, uma vez que se trata de uma penalização financeira. Do outro lado, as usinas cujos processos necessitam da redundância operacional e disponibilidade ininterrupta de energia, pagam mais caro pela aquisição de combustíveis. Porém, é notório que essa estratégia monetária não é suficiente para garantir uma

menor pegada ambiental.

Mesmo com tantos avanços tecnológicos desde o século XVIII, é inegável que ainda há grande dependência da combustão nos dias de hoje. Entretanto, nota-se uma mudança em ascensão frente ao uso de recursos fósseis finitos e à preocupação com o meio ambiente. A União Europeia, por exemplo, já está considerando a comercialização de produtos que poluem menos (consilium.europa.eu, 2025) e, para tanto, as fábricas já estão providenciando os investimentos necessários. Mas nesse contexto existem dois cenários que valem a pena explicitar. Há condições favoráveis para um investimento *greenfield*, que se refere a um projeto que é iniciado do zero, sem qualquer restrição ou dependência de estruturas ou sistemas preexistentes, de maneira que se pode conceber um sistema totalmente eletrificado por fontes renováveis e hidrogênio verde. E existem também os sistemas legados, em que não há possibilidade a curto/médio prazo de uma conversão tecnológica significativa; porém, é possível otimizar com base nas restrições existentes (*brownfield*) e permitir uma operação menos prejudicial ao meio ambiente até que se viabilize a comutação tecnológica de direito e trate a obsolescência.

De fato, o desenvolvimento da sociedade provém da grande revolução favorecida pelas máquinas a vapor. Contudo, é inegável que o uso demasiado dos recursos é inadequado para manter a vida no planeta. Portanto, faz-se necessário adotar um modelo de desenvolvimento sustentável, garantindo a evolução da humanidade e a manutenção do meio ambiente. E é nesse cenário em que as estratégias de modelagem de processos e a filosofia de otimização podem ser utilizadas, não apenas para competitividade de mercado, mas também como técnicas aliadas ao desenvolvimento sustentável.

1.2 Motivação e Relevância do Trabalho

No patamar em que a humanidade se encontra, é inconcebível falar de lucratividade e desenvolvimento sem levar em consideração o meio ambiente. A motivação deste trabalho, portanto, é contribuir cientificamente para o desenvolvimento sustentável, alinhado ao objetivo de reforçar os compromissos climáticos assumidos internacionalmente, como defendido pela 30ª Conferência das Nações Unidas sobre Mudança do Clima (COP30) (gov.br, 2025).

Para tanto, neste trabalho, considera-se um estudo de caso em um complexo termoeletrico de uma siderúrgica integrada, com foco em melhoria de performance e redução da pegada ambiental no estilo *brownfield*, tendo em vista o desejo de constituir uma operação mais adequada às diretrizes ambientais, em detrimento das dificuldades relacionadas ao alto nível de investimentos, bem como restrições operacionais.

Neste trabalho, o intuito principal é propor uma perspectiva que vai além dos ganhos financeiros, adotando uma estratégia de otimização multiobjetivo seguida por uma abordagem de auxílio à

tomada de decisão multicritério, considerando as emissões de dióxido de carbono, os impactos da escolha do regime de trabalho à vida útil das máquinas, além de outros atributos relevantes ao problema de queima de combustíveis do ramo siderúrgico.

Considerando a característica do problema de lidar com a análise do processo, criando um modelo genérico e otimizando o balanço energético, o mesmo pode ser aplicado a outros ramos industriais e suas finalidades. Por exemplo, os setores farmacêutico, alimentício e de celulose, apesar de possuírem fins distintos, apresentam semelhanças com o modelo de cogeração e flexibilidade (Knöttner and Hofmann, 2024).

1.3 Objetivos

Frente ao cenário atual, e a então dependência por combustíveis não renováveis e poluentes, fato que será desafiador de alterar por completo em curto prazo, o presente trabalho propõe a otimização do uso desses recursos, com o objetivo de, no pilar de sustentabilidade, contribuir para extração da maior eficiência possível das máquinas envolvidas e reduzir as emissões de gases de efeito estufa (GEE), aliado aos pilares do Programa Brasileiro GHG *protocol* de desenvolvimento sustentável (FGVces, 2024).

Para tanto, listam-se os seguintes objetivos específicos:

- Conceber um modelo matemático que represente o problema multicomcombustível e o desempenho de conversão calorífica;
- Caracterizar condições de factibilidade que não violem as limitações operacionais;
- Formalizar indicadores/ critérios de avaliação que contribuam para a análise do sistema e sirvam como parâmetros auxiliares à solução, como por exemplo:
 - Análise do impacto da solução na condição das máquinas;
 - Análise da emissão de Gases de Efeito Estufa;
 - Eficiência energética da proposta;
 - Balanço financeiro.
- Definir uma estratégia de otimização condizente com o cenário e com o problema de otimização multiobjetivo, e estimar a fronteira Pareto;
- Desenvolver uma ferramenta de apoio à tomada de decisão, considerando critérios associados e atributos operacionais.

1.4 Contribuições do Trabalho

As principais contribuições identificadas neste estudo incluem:

- Definição de um modelo de identificação adaptativo para captura da dinâmica do sistema com base na instrumentação da planta;
- Design de uma ferramenta de otimização multiobjetivo para o problema, possibilitando a estimação de soluções ótimas para o modelo; e
- Desenvolvimento de uma estratégia dedicada de suporte à decisão multicritério, alimentada por atributos específicos do problema.

Com base nas particularidades avaliadas e na flexibilidade da solução proposta, a ferramenta pode se configurar como relevante para o meio ambiente, bem como para as empresas em geral, que podem reduzir as emissões, garantindo a equivalência produtiva e lucrando com o auxílio à tomada de decisões proposta.

Ao final do capítulo de revisão, capítulo 02, essas contribuições são retomadas, evidenciando a originalidade com base na literatura revisada.

1.5 Organização do texto

Conforme exposto, o Capítulo 01 tem como finalidade trazer uma introdução ao tema, bem como discutir a motivação da pesquisa. Além do mais, definem-se os objetivos e contribuições do trabalho realizado.

No Capítulo 02 faz-se uma revisão bibliográfica abrangente dos trabalhos relacionados com o tema. Lê-se, de maneira breve, sobre otimização em sistemas multicomcombustíveis e motores de combustão interna, bem como os estudos de otimização realizados no setor energético. Logo em seguida, discorre-se sobre as pesquisas voltadas para o ramo siderúrgico. Nesse capítulo, expõem-se informações importantes para a contextualização de como o tema é tratado na academia. Fez-se, ao final, uma comparação pareada das principais publicações, a fim de elucidar o diferencial proposto pelo presente trabalho.

Já no Capítulo 03, faz-se uma exposição da fundamentação teórica, com tópicos que permeiam a solução proposta. Nesse capítulo, define-se, também, questões importantes para o entendimento do estudo de caso.

No Capítulo 04, a metodologia é definida, estabelecendo as ferramentas utilizadas e as devidas parametrizações. Posteriormente, no Capítulo 05, os resultados obtidos em 3 diferentes experimentos são expostos e discutidos.

Por fim, no Capítulo 06, regatam-se os tópicos expostos ao longo do trabalho. É realizada uma validação do atendimento aos objetivos iniciais e expõem-se os desafios futuros.

Capítulo 2

REVISÃO BIBLIOGRÁFICA

Nesta seção, abordam-se alguns aspectos revisados na literatura, evidenciando como a otimização está presente no cotidiano e as oportunidades de atuação.

A pesquisa operacional estende sua aplicabilidade para além das linhas de produção, sendo fundamental no setor de mobilidade, onde motores são otimizados como sistemas de conversão de energia. As investigações nessa área são diversas, abrangendo desde a minimização de emissões em motores multicomcombustíveis (Mishra et al., 2022), a otimização da regeneração de filtros de partículas para uso de biocombustíveis (Walter et al., 2023), e o ajuste de parâmetros de injeção e compressão para misturas alternativas (Krishnamoorthi and Malayalamurthi, 2017). A abrangência dessa otimização transcende o componente individual, alcançando decisões logísticas em larga escala, como a seleção ideal de motores e combustíveis para frotas de navios, visando minimizar os custos totais de investimento e operação (Wu et al., 2023).

De forma análoga, o setor energético utiliza a otimização para aprimorar desde a geração até o consumo final, buscando melhor performance e menor impacto ambiental (Mancarella, 2013). Uma questão central nesse domínio é a escolha da abordagem de modelagem: enquanto os modelos mono-objetivo são eficientes para minimizar custos, eles são limitados. Por isso, as abordagens multiobjetivo ganham destaque por permitirem uma análise mais completa dos trade-offs entre metas conflitantes, como custos e emissões, utilizando métodos como o ϵ – *restrito* para mapear a fronteira de Pareto e identificar soluções de compromisso equilibradas (Fazlollahi et al., 2012, Dorotić et al., 2019).

Para lidar com a alta complexidade dos problemas energéticos, que são frequentemente não lineares e não convexos, a aplicação de meta-heurísticas tornou-se popular. Algoritmos inspirados na natureza são amplamente usados para resolver o despacho econômico de energia em larga escala, embora o benefício ambiental seja muitas vezes uma consequência indireta da busca pela eficiência econômica, e não um objetivo primário (Chen, 2020, Gerardo Castañón, 2024, Dinu

Călin Secui, 2024, Suresh and Sivanagaraju, 2015, Chen and Li, 2022, Arman Goudarzi, 2022). Essas metodologias são aplicadas em subsetores como os Sistemas de Cogeração de Calor e Energia (CHP) e a gestão térmica, onde se otimiza desde a sinergia entre vetores energéticos (Basu, 2011) e a operação integrada com o conforto de edifícios (Ghilardi et al., 2021), até a eficiência de caldeiras domésticas (Tsoumalis et al., 2021) e a mistura de combustíveis em termoelétricas (Varganova A.V., 2019).

A fronteira da pesquisa avança com modelos mais sofisticados que abordam incertezas e múltiplos critérios de forma explícita. Isso inclui modelos estocásticos para lidar com a variabilidade da demanda (Majidi et al., 2019), otimização fuzzy para equilibrar objetivos conflitantes em geração distribuída (Wei Jen Lok, 2020), e otimizações multiestágio que capturam o trade-off entre custos de operação e investimento (Knöttner and Hofmann, 2024). A perspectiva se expande ainda mais para o planejamento estratégico, com modelos para fornecimento descentralizado (Goderbauer et al., 2016), projeto de microrredes de baixo carbono (Nasiri et al., 2023), desenvolvimento de novos indicadores de eficiência (Bartnicki et al., 2023) e o uso de métodos de decisão multicritério para priorizar projetos de sustentabilidade (Kshanh and Tanaka, 2024).

É importante destacar outro setor industrial de base, com grandes oportunidades de otimização, a siderurgia. Apesar de tardio, Quader et al. (2015) avaliam as tecnologias emergentes para o setor, com o foco em eficiência energética e ambiental. O nome “aço verde” se destaca como um produto com menor impacto ambiental e, certamente, adota, ao longo da produção, técnicas como a otimização de transferência térmica, uso de coprodutos e reaproveitamento de material sucateado, garantindo um produto que recorreu a menos energia e baixas emissões.

Em Kim et al. (2003) é proposto um modelo de Programação Linear Inteira Mista (PLIM) para a otimização multiperíodo em toda a planta do sistema de fornecimento de gases subprodutos no processo de fabricação de ferro e aço. Essa abordagem busca otimizar os níveis dos gasômetros e a distribuição de gás para os consumidores, com os objetivos de reduzir a necessidade de queima de combustível do tipo *Flare*, que é um dos controles de nível do gasômetro, utilizado quando o mesmo excede a capacidade de armazenamento seguro; no entanto, que não gera valor direto para o sistema, resultando no que os autores chamaram de “emissões desfavoráveis”. Destaca-se que o *Flare* é contabilizado no sistema de otimização como uma penalização, da mesma forma como tratam o consumo de óleo e o número de comutações de queimadores. Variáveis inteiras e contínuas são utilizadas na determinação da mudança ótima de carga de combustível de acordo com os tipos de combustível. O problema é estruturado como multiobjetivo, sendo um deles maximizar a produção de energia elétrica na usina com compra mínima de óleo, e o outro minimizar a flutuação do nível do gasômetro. Contudo, o conjunto, em geral, é resolvido como um problema mono-objetivo pela agregação de custos e benefícios em uma única função de custo a ser minimizada.

Ainda na indústria de ferro e aço, os autores [Kong et al. \(2010\)](#), bem como [QI et al. \(2010\)](#), concordam que os gases subprodutos configuram um tópico importante para a competitividade no mercado. Destacam que a produção e o consumo desses subprodutos energéticos devem ser iguais, a fim de manter a operação segura. No entanto, este consumo pode ter um foco além da seguridade da usina, e, portanto, os autores propõem um olhar para a redução do custo de operação, por meio de uma otimização da distribuição de gases subprodutos. Eles recorreram à programação linear inteira mista (PLIM) para otimização multiperíodo dos combustíveis, trabalhando simultaneamente com a distribuição de gases e com o sistema de cogeração, favorecendo a conversão de energia térmica em elétrica. Apesar de demonstrarem múltiplos objetivos, formularam como um problema de minimização de custo total, que incorpora benefícios e penalidades em uma só equação, ou seja, a redução do custo total.

O trabalho de [Kong \(2015\)](#) problematiza o uso dos gases subprodutos da siderurgia e, além de foco em performance, o autor demonstra preocupação com o custo ambiental ao trabalhar com estimativas de produção de poluentes derivados da utilização desses combustíveis. Nota-se que foi utilizado o sistema mono-objetivo para solução do problema não linear implementado, cujo objetivo é a minimização dos custos de operação, que contemplam os custos de aquisição de combustível, custo de água utilizada, penalidades por flutuação do nível dos gasômetros, os custos ambientais, dentre outros.

Em respeito ao cálculo do custo ambiental, vale destacar a ponderação realizada pelo autor sobre a quantização dos óxidos de nitrogênio (NO_x), dióxido de carbono (CO_2) e do dióxido de enxofre (SO_2). Ele afirma que a produção de NO_x ocorre em condições estritas e, nesse caso, pode-se considerar que o consumo dos gases coprodutos não emite NO_x , ficando tal emissão exclusiva da combustão de óleo. O autor alega também que a eficiência de dessulfurização dos purificadores de enxofre chega a 95% no setor de ferro e aço, de maneira em que pode-se assumir o CO_2 como o balizador do custo ambiental.

No setor siderúrgico, a iniciativa de [Zhao et al. \(2015\)](#) demonstra o uso estratégico e otimizado dos coprodutos industriais como combustível circular, dentro da própria usina. Esse artigo propõe um modelo de programação linear inteira mista para otimizar a gestão de gases subprodutos, visando a minimização dos custos operacionais e o uso eficiente da energia. Constitui-se um problema multiobjetivo, em que os autores optaram pela escolha da solução equidistante às regiões marginais que representam as condições desfavoráveis para operação. Configurou-se assim um consumo otimizado dos gases, mantendo os gasômetros em níveis estáveis e as caldeiras em regimes de operação factíveis. Quanto ao aspecto ambiental, não há um cálculo direto focado na descarbonização, contudo, foi considerada uma penalização/custo da queima indevida de combustível para alívio do desnivelamento do gasômetro, e é notório que o consumo otimizado tem, como consequência, uma melhor performance ambiental.

No trabalho de [hui YANG et al. \(2015\)](#), nota-se a mesma preocupação com o consumo dos coprodutos em relação ao controle do nível de gasômetros. Foi implementada uma estratégia mono-objetivo e, dentro da formulação de minimização, existe um trecho de penalização relacionado ao meio ambiente. Destaca-se que os autores modelaram o problema do tipo multiperíodo, com variáveis lineares inteiras e discretas.

O estudo de [de Oliveira Junior et al. \(2016\)](#) propõe o uso de uma heurística aliada ao modelo matemático da planta siderúrgica. A ideia principal da hibridização se dá pela necessidade de ajuste dos pesos do modelo linear inteiro misto, e se mostrou favorável, constituindo uma representação mais adequada ao estudo de caso em questão. Apesar de ser um PLIM e ser resolvido via programação matemática, essa sinergia heurística começa a se mostrar relevante para a melhoria dos modelos. Destaca-se que os autores constituíram uma otimização mono-objetivo, cujo foco é a minimização de custos operacionais, mais uma vez sem aprofundar no tema da descarbonização de forma explícita.

Em [Zeng et al. \(2018\)](#), os autores reafirmam que gases subprodutos, vapor e eletricidade desempenham um papel importante no fornecimento de energia para as unidades de produção na indústria do ferro e do aço. A distribuição ótima desses recursos em uma usina pode diminuir significativamente o custo de energia e reduzir as emissões de CO₂. No entanto, essa distribuição ótima não é trivial, pois envolve muitas unidades de produção, turbinas a vapor, unidades combinadas de calor e energia (CHP), e unidades de recuperação de calor e energia, além de várias características operacionais realistas, como mistura de gases subprodutos, controle de nível de gás em gasômetros dedicados, diferentes níveis de exigência de vapor, requisito mínimo de aquecimento e energia, e máximo permitido de comutação de queimadores, resultando em um grande e complexo problema combinatório. Os autores recorreram à programação linear inteira mista multiperíodo, a fim de modelar o sistema e minimizar o custo operacional. Apesar de se tratar de um problema mono-objetivo, a função custo abrange diversos fatores, como custos de aquisição de combustível e penalidades, como a emissão de poluentes, denotando uma mudança cultural de pensamento puramente financeiro, apesar de não ter um compromisso exclusivo com a descarbonização.

Já no trabalho de [Zhang et al. \(2019\)](#), os autores recorreram à tentativa de representação completa da planta siderúrgica, com o intuito de minimizar o consumo específico de energia total. Além disso, rastreia-se o potencial de emissão de poluentes de cada solução, porém, apenas como demonstrativo de impacto ambiental das soluções propostas. Destaca-se que os autores recorreram à programação matemática, com a finalidade de solucionar o modelo linear inteiro misto, cuja representação envolvia processar o total de energia consumida e a quantia de material produzido em cada etapa. Essa representação *Macro* é interessante para identificar o consumo distribuído, mas não descarta a necessidade de subsistemas com o foco em *Micro* modelos mais detalhados.

Na pesquisa de [Wei et al. \(2020\)](#), nota-se uma modelagem não linear, com variáveis inteiras e discretas de um complexo siderúrgico, contemplando desde os gasômetros, caldeiras, até a distribuição energética. Nota-se, também, um ponto disruptivo dentre os artigos até então mencionados, tendo em vista a necessidade de descrever o sistema mais próximo do real, com a abordagem não linear. Apesar de ser mono-objetivo, o sistema aborda três grandes aspectos, sendo o controle do nível do gasômetro, a geração energética e a emissão de poluentes. O modelo divide o gasômetro em quatro intervalos de operação e a penalidade correspondente a cada intervalo é definida. É importante citar ainda que os autores recorreram à otimização multiperíodo, considerando a flutuação da cotação energética e modelos em escala *micro*, representando as condições de performance de cada caldeira e turbina do sistema.

De acordo com [Shuai Liu \(2021\)](#), o sistema de energia dentro das usinas siderúrgicas pode ser entendido como um *Multi-Energy Systems* (MES) que consiste em diferentes tipos de fontes e dispositivos elétricos. O autor propõe a estratégia de modelagem do sistema de distribuição para dentro do ramo siderúrgico, no entanto, com uma ferramenta para linearizar a representação multicamadas do sistema. Vale destacar que o problema de otimização aborda originalmente duas funções contrastantes, o custo de operação e a emissão de CO₂, contudo, recorrem à ponderação linear, tornando o problema mono-objetivo, cuja finalidade é redistribuição de co-produtos para produção de vapor e energia, além de controlar o nível dos gasômetros associados.

Ainda no setor siderúrgico, o artigo de [Han Xi \(2021\)](#) se caracteriza pelo uso expressivo de técnicas de *machine learning* e buscas heurísticas, como árvores de decisão e *Particle Swarm Optimization* (PSO), para modelagem dos sistemas e providenciar o agendamento estratégico de recursos, respectivamente. O projeto foi desenvolvido como mono-objetivo, com o propósito central de minimização do custo de operação, porém, agregando diversos fatores, por exemplo, o custo por emissões, flutuação do nível dos gasômetros e consumo energético.

[Hu and He \(2022\)](#) apresentam dois modelos de programação matemática, um linear e outro não linear, todavia, ambos com variáveis inteiras e discretas, para otimizar o agendamento operacional de siderúrgicas com acoplamento de gás, vapor e eletricidade. Os modelos buscam minimizar custos operacionais levando em conta partidas e paradas de equipamentos, consumo energético e acoplamento energético. A formulação leva em conta uma abordagem comparativa entre otimização mono-objetivo e multiobjetivo, tendo a última abordagem alcançado melhores resultados, provavelmente pela maior capacidade de representação multicritério do problema. Uma das limitações levantadas pelos autores está na escalabilidade do modelo, que exige grande poder computacional, o que dificulta sua aplicação em tempo real. Além disso, não aprofundam nos cálculos termodinâmicos ou químicos das emissões de gases de efeito estufa.

Vale destacar o artigo de [Tingting Xu \(2023\)](#), cujo autor aborda a otimização do sistema de gás-vapor-energia em siderúrgicas, com um ponto de vista que considera tanto benefícios econômicos

quanto ambientais. O autor recorre à programação linear inteira mista multiperíodo e multiobjetivo, e busca minimizar o custo operacional e as emissões via programação matemática. No entanto, não foi observada nenhuma ferramenta de auxílio à tomada de decisão ou o levantamento da curva Pareto Ótima; os autores avaliaram apenas os extremos de cada função objetivo.

Na mesma equipe de estudo, [Xu et al. \(2024\)](#) propõem a análise abrangente de estratégias para redução de emissões de carbono em siderúrgicas integradas. O trabalho explora o desempenho na redução de carbono ao aplicar a tecnologia de alto-forno com reciclagem de gás de topo, captura e armazenamento de carbono, e sua influência na operação do sistema de cogeração de vapor e energia, mostrando o potencial do uso dos subprodutos nas operações integradas. Não se trata de um processo de otimização, mas constitui um modelo de avaliação e análise de cenários, e comprova a mudança da visão tradicional da indústria siderúrgica, que passa a investir no monitoramento e técnicas de redução de emissões de poluentes.

Já no artigo de [Neto and Batista \(2024\)](#), os autores abordam o tema de descarbonização em uma siderurgia com uma proposta de redistribuição dos gases coprodutos na central termoeletrica com foco em reduzir as emissões e reduzir gastos, mantendo a mesma relação de produção operacional. Nesse trabalho, é utilizado um modelo fenomenológico a parâmetros fixos, no intuito de representar a dinâmica das caldeiras e, via *solver Simplex*, propõem a redistribuição ótima dos combustíveis. Destaca-se que foi estruturado como uma otimização multiobjetivo, cujo propósito é maximizar a produção de vapor superaquecido e minimizar os gastos energéticos. Para isso, recorreram à estratégia de acoplamento ϵ -restrito para esboçar pontos da curva Pareto ótima. No trabalho ainda são avaliados múltiplos critérios para auxiliar na tomada de decisão via *Analytic Hierarchy Process* (AHP) ([Saaty, 2013](#)). Dentre os critérios, está em destaque a emissão de CO₂, ponderando negativamente as soluções mais poluentes.

No intuito de realizar uma análise comparativa entre as abordagens existentes na academia e a proposta do presente trabalho, foi realizada uma seleção de 16 artigos com maior correlação ao tema desta dissertação. Todos eles tratam de estudos relacionados à siderurgia e buscam otimizar o processo e o uso dos coprodutos.

É importante destacar que a escolha das metodologias e abordagens em trabalhos de otimização impacta diretamente a aplicabilidade, o realismo e a eficiência na resolução de problemas complexos. Ao analisar a literatura, é fundamental compreender as vantagens e desvantagens de cada característica para posicionar o diferencial de um novo estudo; portanto, foram extraídas 6 características que melhor traduzem essas competências.

As características dos artigos correlacionados são apresentadas na Tabela 2.1, agrupando-as em colunas.

A primeira coluna diz respeito à referência bibliográfica, com a identificação do artigo. A segunda coluna traz a informação do tipo de otimizador utilizado em cada trabalho. Esse item é

um importante discriminador da estratégia do artigo e, de modo geral, existem duas diferentes abordagens.

A Programação Matemática (PM), que envolve a formulação explícita de um problema como um modelo matemático otimizado por *solvers* dedicados, destaca-se pela capacidade de garantir a otimalidade global para classes específicas de problemas, como a Programação Linear (PL) e algumas Programações Não Lineares (PNL) convexas, além de oferecer soluções exatas e precisas. Contudo, sua escalabilidade pode ser limitada para problemas complexos, com muitas variáveis inteiras ou não linearidades não convexas, e exige uma modelagem matemática rigorosa que pode ser desafiadora.

Em contraste, as Heurísticas (HEUR), incluindo meta-heurísticas, são abordagens que buscam soluções “boas o suficiente” em um tempo razoável, sem a garantia de encontrar o ótimo global. Sua grande vantagem é a escalabilidade, permitindo o tratamento de problemas de grande porte e alta complexidade (frequentemente NP-difícil) que seriam intratáveis para métodos exatos. Além disso, oferecem flexibilidade por não dependerem de um modelo matemático e serem facilmente adaptadas para lidarem com incertezas. Exemplos notáveis incluem Algoritmos Genéticos e Otimização por Enxame de Partículas. No entanto, a principal desvantagem das heurísticas é a ausência da garantia de otimalidade global. A solução encontrada é, via de regra, um ótimo local ou uma aproximação da solução ótima. Sua performance também pode ser sensível à calibração de parâmetros específicos, e a natureza estocástica de muitas delas pode levar a variações nas soluções entre execuções.

Na terceira coluna, avalia-se o **Modelo (Tipo)**. Sobre essa característica, a distinção entre abordagens lineares e não lineares, e o uso de variáveis inteiras ou contínuas, é crucial para o realismo da representação. Modelos de Programação Linear (PL) são notáveis por sua facilidade de resolução e pela eficiência dos *solvers*, garantindo o ótimo global para problemas de grande porte. Contudo, frequentemente exigem simplificações da realidade, o que pode comprometer a representatividade e levar a soluções matematicamente ótimas, mas subótimas em condições operacionais complexas. Em oposição, a Programação Não Linear (PNL) oferece a vantagem de maior realismo, capturando relações complexas e comportamentos não lineares, o que pode resultar em soluções mais aplicáveis e eficientes. A contrapartida é a maior dificuldade de resolução, a exigência de mais recursos computacionais e o fato de que, para problemas não convexas, geralmente, só se pode garantir a obtenção de um ótimo local. A inclusão de variáveis inteiras, constituindo assim uma Programação Linear Inteira Mista (PLIM) ou Programação Não Linear Inteira Mista (PNLIM), é vital para modelar decisões discretas, como a alocação de recursos indivisíveis ou escolhas binárias (“sim/não”), conferindo realismo a diversos problemas, mas aumenta a complexidade computacional.

Nas quatro últimas colunas, utilizou-se um “X” para evidenciar a presença das características nos referidos artigos. Nesse grupo, tem-se a quarta coluna **Otimiz. Multiob.**, que indica se a abordagem de otimização se trata de um modelo multiobjetivo.

Para fins de comparação, a adoção de uma abordagem multiobjetivo é uma vantagem significativa, pois problemas reais raramente possuem um único objetivo. Ela permite a consideração simultânea de múltiplos objetivos que, frequentemente, são conflitantes (ex.: minimizar custo e emissões, enquanto maximiza o lucro). Isso oferece um conjunto de soluções de compromisso, conferindo maior flexibilidade ao tomador de decisão e proporcionando uma visão mais abrangente dos *trade-offs*. A desvantagem, porém, reside na maior complexidade computacional e no desafio de, a partir do conjunto de soluções de compromisso, escolher a opção final mais adequada sem critérios adicionais.

Destaca-se ainda, na quinta coluna **Análise Descarb.**, se há uma análise diretamente relacionada à descarbonização. Nesse caso, refere-se a uma característica de crescente importância nas indústrias e representa uma grande vantagem comparativa. Ela alinha o trabalho aos desafios ambientais globais e permite a conformidade com regulamentações. Contribui diretamente para a redução de emissões e, muitas vezes, promove maior eficiência no uso de recursos. No entanto, essa abordagem pode gerar *trade-offs* com outros objetivos (como o aumento inicial de custos) e exige dados precisos sobre emissões e tecnologias de mitigação, que nem sempre são facilmente acessíveis.

Já as duas últimas colunas, **Aux. Decisão** e **Multicrit.**, apontam respectivamente se houve a utilização de ferramentas de auxílio à tomada de decisão e se o artigo adotou uma abordagem de avaliação multicritério.

Uma ferramenta de auxílio à tomada de decisão tem a vantagem de estruturar problemas complexos, promover a transparência no processo decisório e reduzir vieses, ajudando a identificar *trade-offs* de forma clara. Suas desvantagens incluem a dependência da qualidade dos dados e o risco de não capturar nuances subjetivas. Já a avaliação multicritério se destaca por alinhar-se à natureza multifacetada das decisões reais, integrando diferentes critérios e permitindo o engajamento de múltiplos *stakeholders*. Empregar esses dois itens no trabalho confere ainda mais valor ao estudo.

Ao observar a Tabela 2.1, considerando a classificação dos artigos em ordem cronológica, do mais antigo para o mais recente, os modelos matemáticos empregados demonstram uma transição de preferência acadêmica. Os estudos mais antigos, datados entre 2003 e 2018, são, predominantemente, fundamentados em modelos de programação linear inteira mista (PLIM). Tal preferência possivelmente mostra a busca pela simplicidade e solubilidade computacional desses modelos. Contudo, em artigos mais recentes, a partir de 2019, observa-se uma considerável diversificação com a introdução de modelos não lineares. Essa evolução aponta para

TABELA 2.1: Comparativo de Artigos Correlacionados.

Referência	Otimizad.	Modelo (Tipo)	Otimiz. Multiob.	Análise Descarb.	Aux. Decisão	Multi crit.
Kim et al. (2003)	PM	PLIM				
Kong et al. (2010)	PM	PLIM				
QI et al. (2010)	PM	PLIM				
Fazlollahi et al. (2012)	HEUR	PLIM	x	x		
Kong (2015)	PM	PLIM		x		
Zhao et al. (2015)	PM	PLIM	x			
hui YANG et al. (2015)	PM	PLIM				
de Oliveira Junior et al. (2016)	PM	PLIM				
Zeng et al. (2018)	PM	PLIM				
Zhang et al. (2019)	PM	PLIM		x		
Wei et al. (2020)	PM	PNLIM		x		
Shuai Liu (2021)	PM	LP		x		
Han Xi (2021)	HEUR	NLP		x		
Hu and He (2022)	PM	PNLIM	x			
Tingting Xu (2023)	PM	PLIM	x	x		
Neto and Batista (2024)	PM	PL	x	x	x	x
Proposta	HEUR	NLP	x	x	x	x

uma crescente necessidade de formular problemas com maior aderência à complexidade inerente de sistemas reais, buscando um realismo aprimorado, ainda que isso implique maiores desafios computacionais.

Paralelamente à sofisticação dos modelos, observa-se que o foco ambiental também emergiu como uma tendência marcante. Nos trabalhos mais antigos, a avaliação direta de descarbonização era raramente considerada. No entanto, a partir de 2019/2020, percebe-se uma crescente integração dessa dimensão nos estudos. Essa mudança ratifica o que foi dito na introdução e denota a mudança de postura tanto do mercado quanto da academia frente às questões climáticas, impulsionando a pesquisa em otimização a incorporar metas explícitas de sustentabilidade.

No que tange às ferramentas de otimização, a programação matemática (PM) mantém sua dominância, sendo utilizada na vasta maioria dos artigos. Contudo, há uma tímida emergência de heurísticas em publicações mais recentes, sugerindo que a complexidade crescente dos modelos, agora mais realistas, multiobjetivo e com foco ambiental, está incentivando a busca por alternativas capazes de lidar com tamanha complexidade e de encontrar soluções viáveis em tempo hábil.

A otimização multiobjetivo, apesar de não ser muito popular nesse contexto, já era uma característica pouco presente nos trabalhos mais antigos e continua a ser adotada com menor frequência nos estudos mais recentes. No entanto, nota-se a tentativa massiva de tratamento de problemas que possuem múltiplos objetivos como se tivessem um único objetivo.

Apesar dessas importantes evoluções, a análise revela uma lacuna persistente e crucial em toda a literatura revisada no que diz respeito à integração explícita de ferramentas de tomada de decisão e à utilização de múltiplos critérios para a avaliação das soluções. Nenhum dos artigos analisados incorpora essas funcionalidades de forma destacada. Essa lacuna representa uma oportunidade significativa de contribuição para esta pesquisa, que visa desenvolver uma abordagem que não apenas enderece os desafios de modelagem e otimização contemporâneos, mas também ofereça um suporte robusto ao processo decisório, elevando a aplicabilidade prática das soluções propostas.

Portanto, ao considerar essas características, o presente trabalho busca oferecer uma contribuição que se diferencia da literatura existente. Destaca-se pelo respeito às condições operacionais, ao recorrer aos modelos não lineares e à identificação adaptativa do modelo de representação do sistema, além do fato de contar com uma maior flexibilidade para caracterizar o problema, uma vez que se trata de uma otimização multiobjetivo. Vale ressaltar a característica de ser uma abordagem multicritério e contemplar uma ferramenta de suporte à tomada de decisão pelos usuários do processo.

Capítulo 3

FUNDAMENTAÇÃO TEÓRICA

Esta seção discorre sobre detalhes do problema estudado, formulações matemáticas e apresenta referenciais teóricos usados como embasamento fundamental para a modelagem e solução propostas.

3.1 Siderurgia

O setor siderúrgico é a grande área que contempla as diversas etapas da fabricação do aço.




FIGURA 3.1: Fluxos no setor siderúrgico

Fonte: Adaptado de [CARVALHO \(2021\)](#).

A Figura 3.1 é um retrato de duas rotas siderúrgicas. Em roxo, tem-se a rota integrada e, em verde, as chamadas *Mini-Mills* ou rotas semi-integradas.

Em uma usina semi-integrada, recorre-se à sucata, ferro gusa de mercado e ligas metálicas, e esses materiais geralmente são aplicados em um Forno Elétrico a Arco (FEA), onde esses materiais de entrada são convertidos em aço líquido. A partir desse ponto, a etapa de laminação e concepção do material final é bastante similar a uma usina integrada.

A diferença entre elas se dá, basicamente, pela existência do processo inicial de redução (Coque-ria, Alto-forno e Aciaria convencional), de onde advêm os coprodutos que o presente trabalho lida.

3.2 Central Termoelétrica

Vale destacar que, em uma usina siderúrgica integrada, geralmente, se encontram as centrais termoelétricas, representadas como CTE na Figura 3.1, pois são necessárias para o fornecimento de ar soprado aos alto-fornos, por meio dos turbo-sopradadores. Além disso, elas geram energia para cargas críticas do processo, por meio dos turbo-geradores.

Essas duas máquinas supracitadas são compostas por duas partes acopladas por um eixo em comum. A parte quente, vide Figura 3.2, caracteriza-se por um conjunto de hélices que recebem o vapor superaquecido da saída das caldeiras. Ela transfere a energia recebida para o equipamento acoplado ao eixo, convertendo energia cinética em energia elétrica (no caso de um turbo-gerador), ou succionando ar atmosférico para as ventaneiras do alto-forno (no caso de um turbo-soprador).



FIGURA 3.2: Hélices da turbina a vapor de grande porte
Fonte: [Pexe \(2021\)](#).

Nas usinas de ferro e aço, as caldeiras funcionam como as termoelétricas convencionais, porém, de maneira estratégica, podem admitir os combustíveis derivados do próprio processo siderúrgico, configurando uma operação circular, lucrativa.

3.2.1 Estudo de Caso

No estudo de caso, tem-se um conjunto flexível de quatro caldeiras aquatubulares, similares à representação da Figura 3.3, cuja água desmineralizada passa por dutos que são aquecidos externamente por meio da queima de até 5 combustíveis diferentes. Desses combustíveis, 3 são subprodutos do setor siderúrgico, Gás de Alto-Forno (G_{AF}), Gás de Aciaria (G_{AC}) e Gás de Coqueria (G_{CO}), e dois recursos adquiridos externamente, sendo o Gás Natural (G_N) e Óleo Diesel ($Oleos$).

Nesse caso em específico, o objetivo das caldeiras é gerar vapor de água, superaquecido, a uma pressão superior a 64 kgF/cm^2 e cerca de 485°C , a fim de tocar as turbinas de ar soprado para alimentar os alto-fornos e favorecer a reação de redução do minério de ferro, bem como é possível gerar energia elétrica, configurando assim uma cogeração, Figura 3.4.




FIGURA 3.3: Desenho esquemático e nomenclatura de caldeira aquatubular.


Fonte: *de Souza (2020)*.

FIGURA 3.4: Diagrama de Representação do Estudo de Caso.

Fonte: *Elaborado pelo autor*.

3.2.2 Formulação Matemática

Inicialmente, vale explicitar dois conceitos úteis para avaliação de reações de combustão. O Poder Calorífico Superior (PCS) e o Poder Calorífico Inferior (PCI).

O primeiro diz respeito ao valor máximo de energia que pode ser obtido se os produtos da combustão forem resfriados à temperatura ambiente. Já o PCI é uma métrica da termodinâmica, que representa a quantidade de energia térmica liberada por uma unidade de massa ou volume de um combustível, assumindo que a água formada durante o processo permaneça no estado de vapor (Turns, 2012).

Dessa forma, pode-se dizer que o PCS será sempre superior ao PCI, uma vez que considera a quantidade de energia necessária para mudar a água do estado gasoso para o líquido (Calor Latente de Condensação), conforme (3.1):

$$PCS = PCI + Q_{vaporiz.} \quad (3.1)$$

Nesse caso, a definição do PCI é importante, pois reflete de maneira mais realista a energia útil que pode ser extraída em sistemas de conversão de energia, como motores de combustão interna e caldeiras, onde os gases de exaustão são liberados em temperaturas elevadas e a condensação da água não ocorre (Glassman, 2008).

No trabalho de Moreira (2007), mostra-se que existe uma relação direta entre a vazão de vapor produzida em uma caldeira aquatubular por volume de combustível admitido na caldeira, ponderado pelo PCI e por um dado coeficiente de desempenho, que se relaciona com a dinâmica de troca de calor do respectivo combustível na caldeira e reflete o estado de conservação da mesma, conforme (3.2):

$$Vapor_{Produzido} = Vazao_{Combustivel} \times PCI_{Combustivel} \times Coef \quad (3.2)$$

Nesse contexto, no presente trabalho pretende-se identificar a melhor alocação de combustíveis entre as caldeiras do sistema, considerando a relação presente em (3.2). Dessa forma, será possível otimizar alguns atributos de interesse prático, tais como eficiência energética, impactos ambientais e financeiros, dentre outros.

Portanto, nas próximas seções será explanado sobre a natureza desses recursos energéticos, suas características e aplicações ao longo dos processos de uma usina integrada.

3.3 Recursos Energéticos

Nesta seção são abordadas as características de cada combustível considerado no setor siderúrgico, tornando possível o uso da relação exposta em (3.2). Discute-se, também, o impacto do uso desses combustíveis nas caldeiras, bem como a contabilização do impacto ambiental ao analisar apenas as reações de combustão que geram CO_2 como produto. Essas informações são úteis na definição dos critérios usados na tomada de decisão.

Sobre os aspectos ambientais, vale ressaltar que, baseado no artigo de [Kong \(2015\)](#), a produção de NO_x ocorre em condições estritas e, nesse caso, pode-se considerar que o consumo dos gases coprodutos não emite NO_x . No mesmo artigo, assume-se, também, que os purificadores de enxofre são eficientes, de maneira que pode-se assumir o CO_2 como o balizador do custo ambiental.

Neste trabalho, usaram-se os postulados do GHG Protocol, e o balanço de CO_2 emitido é empregado para balizar o impacto de emissões do consumo dos coprodutos, como foi apresentado por [Kong \(2015\)](#), apesar de terem utilizado parâmetros da legislação chinesa para tais considerações. Tal aferição de emissões provém de uma análise estequiométrica com base na composição dos gases fornecidos pelo estudo de caso.

Contudo, além de não ter informações suficientes para estimativa de produção de NO_x e SO_2 , não é o objetivo constituir uma ferramenta de depuração dos poluentes, com foco em auditorias e declarações anuais de emissões, mas sim ser capaz de avaliar o potencial do impacto ao assumir uma ou outra solução. Para trabalhos futuros, pretende-se avaliar as condições estritas de produção de NO_x e SO_2 e, por meio da ponderação de CO_2 , conferir maior veracidade ao impacto ambiental de cada solução encontrada. Nesse quesito sobre o NO_x , é interessante destacar outro trabalho de [Franco Cotana \(2019\)](#), que busca entender e prever a relação entre a razão estequiométrica, a temperatura dentro do gaseificador e a formação de poluentes (NO_x e CO) em uma planta energética multi-combustíveis.

Por fim, vale ressaltar a importância da representação da vazão de combustível de maneira normalizada. A adoção da representação volumétrica como Metro Cúbico Normal (Nm^3) permite a simples comparação entre diversos cenários, tendo em vista que os valores estão padronizados sob uma atmosfera e zero graus Celsius. Dessa forma, a vazão dos recursos será referenciada como a taxa de volume em uma hora, dada em Nm^3/h .

3.3.1 Gás de Coqueria

Ao citar uma siderúrgica integrada, o setor da mineração e a coqueria são a porta de entrada, pois providenciam o insumo base para o início do processo.

A coqueria é responsável pela produção de coque metalúrgico a partir do carvão mineral. Destaca-se que o coque serve como agente redutor, fonte de carbono e suporte mecânico para a carga metálica dentro do alto-forno, configurando-se como um dos insumos mais críticos na rota integrada de produção de aço.



FIGURA 3.5: Bateria de Coque

Fonte: [Villaça \(2023\)](#).

O processo de coqueificação é, basicamente, aglomeração e carbonificação do carvão mineral por meio da pirólise. Esse processo ocorre em fornos de coqueria, que são câmaras de aquecimento hermeticamente fechadas, operadas em altas temperaturas e com atmosfera pobre em oxigênio.

O agrupamento desses fornos dá origem à “bateria de coque”, vide Figura 3.5, e o calor para a coqueificação geralmente provém das câmaras laterais, que aquecem o forno de maneira indireta e gradual, por mais de 15 horas, provocando a destilação seca do carvão.

De modo geral, há três fases de coqueificação, definidas conforme o aumento da temperatura do carvão. Na Figura 3.6 é possível notar os perfis de temperatura da massa de carvão enornado em diversos momentos da pirólise.

A primeira fase é caracterizada pela vaporização da água presente no carvão e pelo início da desvolatilização. Aos 350 graus Celsius, começa a segunda fase, caracterizada pela formação de alcatrão e diluição de parte do carvão pelo alcatrão produzido, criando uma mistura pastosa.

Nessa fase ocorre também a primeira contração de massa, como a quebra de moléculas maiores de hidrocarbonetos em moléculas menores (craqueamento), bem como a formação de compostos aromáticos, como o benzeno. Por fim, no patamar de 500 a 1000 graus Celsius, ainda ocorre a desvolatilização (grande parte na forma de H_2), a massa pastosa começa a endurecer e ocorre uma segunda contração de massa, dando origem ao coque.




FIGURA 3.6: Dinâmica das fases de coqueificação

Fonte: Merrick (1983).

A coleta dos gases voláteis ocorre por válvulas instaladas no topo dos fornos, e logo nessa captura há um rápido resfriamento da substância com água amoniacal. Esse resfriamento também gera um licor denso e rico, que é conduzido ao setor carboquímico, para ser beneficiado, parecido com o processo petroquímico convencional.

O tratamento do material coletado é imprescindível para torná-lo um combustível utilizável, fundamental não apenas para a recuperação energética, mas também para a proteção ambiental, uma vez que o gás bruto contém impurezas que seriam prejudiciais à saúde e aos equipamentos.

Durante o processo, são extraídos alcatrão e óleos, separados por resfriamento e decantação. Além disso, recupera-se amônia, muito usada em fertilizantes, e a tríade benzeno, tolueno e xileno (BTX), vastamente utilizada na indústria petroquímica. Destaca-se a extração do enxofre, decorrente da dessulfuração para remover compostos como o sulfeto de hidrogênio, que é corrosivo e poluente.


Como exposto, esse coproduto tem uma larga utilização no mercado, sendo útil para a fabricação de remédios, cosméticos, fertilizantes e plásticos, como também tem um alto poder calorífico, devido à alta concentração de hidrogênio e metano (Tabela 3.1).

TABELA 3.1: Composição química do G_{CO} no estudo de caso.

Componente	Nome	Percentual
H ₂	Hidrogênio	56.02%
CH ₄	Metano	26.02%
CO	Monóxido de Carbono	5.13%
CO ₂	Dióxido de Carbono	4.40%
N ₂	Nitrogênio	3.68%
O ₂	Oxigênio	2.37%
C ₂ H ₄	Eteno	1.58%
C ₂ H ₆	Etano	0.69%
C ₂ H ₂	Acetileno	0.11%

Estima-se que o gás de coqueria (G_{CO}) recuperado apresente PCI médio de 4200.0 kCal/Nm³ (Casemiro et al., 2019). Além do mais, apresenta densidade relativa de 0.498 kg/Nm³. Devido à composição rica em combustíveis, como o hidrogênio, a queima do gás de coqueria apresenta uma chama curta e de cor intensa, com pouca emissão de fumaça ou fuligem. A elevada temperatura da chama caracteriza a grande transferência de calor por radiação, sendo eficiente para o aquecimento de paredes e a carga da fornalha. Considerando esse comportamento, a performance da queima desse gás varia conforme a condição de cada caldeira, ou seja, apresentará maior rendimento em sistemas cuja fornalha estiver em melhores condições.

Em análise estequiométrica da reação de combustão dos gases que o compõem, conforme (3.3), pode-se dizer que 172.0 g dos compostos orgânicos produzem 396.0 g de CO₂. Dessa maneira, considerando a proporção desses compostos no gás de coqueria e essa proporção mássica, estima-se que, para cada 1.0 kg desse combustível, liberam-se 0.968 kg de CO₂. Ressalta-se que foi considerada, também, a quantia de dióxido de carbono presente no combustível, mas como ele não sofre queima, basta somar sua contribuição simples no resultado final.



É importante citar que, apesar de todo o tratamento realizado, o gás de coqueria é um combustível de impacto considerável na condição física da caldeira, por ser um gás mais “sujo” e com histórico de obstrução de algumas vias.

3.3.2 Gás de Alto-Forno

O alto-forno é um importante equipamento da etapa de redução em uma siderúrgica integrada. Pode ser considerado como um reator químico de grande porte, projetado para converter minério de ferro em ferro-gusa líquido, a matéria-prima básica para a produção do aço.

O processo é contínuo e opera em contracorrente. As matérias-primas sólidas (minério de ferro, coque e fundentes) são carregadas continuamente pela parte superior do forno, enquanto um fluxo de ar quente, soprado a partir da base, ascende através da carga.

A Figura 3.7 ilustra a estratégia de carregamento. Fazem-se camadas intercaladas entre coque e minério de ferro, a fim de favorecer a oxirredução do minério de ferro. Na medida em que o calor vai se propagando, os sólidos reagem entre si e configura-se a zona coesiva. Nesse ponto, o metal líquido goteja para o cadinho e, ao final da corrida, o ferro-gusa é coletado pelo carro torpedo e avança até a aciaria.




FIGURA 3.7: Representação Alto-Forno, segundo [GEERDES et al. \(2015\)](#)

Destaca-se que toda essa carga fica levitando dentro do forno, por isso é imprescindível a alimentação contínua de ar soprado para sustentação do material. Na falha do fornecimento de ar soprado na base, ou a má formação das zonas, pode ocorrer o perigoso fenômeno de arriamento de carga.

Em alto-fornos de grande porte, a aplicação de coque precisa suportar altas pressões, justificando o uso de carvão mineral, em detrimento do vegetal nas coqueiras. Além disso, o coque assume o papel de ser a fonte de calor e o agente redutor no alto-forno. Portanto, sua função é reagir com o oxigênio para produzir o monóxido de carbono (CO), que irá remover o oxigênio do minério de ferro que, por sua vez, é processado em pelotas ou sinter para otimizar o fluxo desses gases.

Vale destacar o papel dos fundentes, geralmente calcário e/ou dolomita. Esses elementos se combinam com as impurezas presentes no minério e formam um subproduto líquido chamado escória, que é mais leve que o ferro-gusa e flutua sobre ele, facilitando a separação.

A Figura 3.7 também ilustra a entrada de ar soprado, derivado dos turbo-sopradores. Essa entrada se chama ventaneira, e em alguns casos se mistura com finos de carvão, que inflamam sem a necessidade de centelhamento, devido à alta pressão interna. O uso dos finos de carvão é uma boa prática para redução do uso de coque.

TABELA 3.2: Composição química do G_{AF} no estudo de caso.

Componente	Nome	Percentual
CO	Monóxido de Carbono	23.16%
CO ₂	Dióxido de Carbono	24.75%
H ₂	Hidrogênio	3.68%
N ₂	Nitrogênio	47.41%
O ₂	Oxigênio	1.0%

Todo esse processo de redução gera gases, que saem pelo topo do forno. Esse é o gás de alto-forno (G_{AF}), um importante coproduto energético. Apesar de ser caracterizado por um baixo poder calorífico, pois tem uma alta concentração de nitrogênio (N₂) e dióxido de carbono (CO₂), vide Tabela 3.2, ele é produzido em grandes quantidades, viabilizando sua aplicação em outros processos da usina.

Devido à grande concentração de nitrogênio, a queima do gás de alto-forno é lenta, apresenta uma chama longa e de tonalização azulada. A transferência de calor ocorre basicamente por convecção, uma vez que a chama não é muito quente e pela grande quantidade de gases inertes na composição. Essa dinâmica denota que o uso de tal combustível é mais eficiente para o setor final da caldeira, como o recuperador.

Conforme Lobão et al. (2003), esse combustível apresenta um PCI médio de 777.0 kCal/Nm³, e a análise estequiométrica da reação de combustão do monóxido de carbono pode ser representada por (3.4), de onde se estima que, para cada 1.0 kg deste combustível, libera-se 0.61 kg de CO₂ dada uma combustão completa:



Cabe citar que o gás de alto-forno é considerado um combustível de poucos impactos na condição física da caldeira, diferente do gás de coqueria. Diz-se ainda que a densidade relativa desse gás é de 1.39 kg/Nm³.

3.3.3 Gás de Aciaria

Na Aciaria convencional é onde acontece a conversão de ferro em aço. Nessa etapa do processo siderúrgico, o ferro-gusa líquido (proveniente do alto-forno), bem como sucatas e outras ligas metálicas são transformados em aço líquido. Esse processo é essencialmente um refino metalúrgico, cujo principal objetivo é a redução drástica do teor de carbono e a remoção de impurezas, como silício, manganês, fósforo e enxofre.

A rota mais comum para a produção de aço primário é o processo com convertedor a oxigênio, sendo o processo *Linz-Donawitz* (LD) o mais amplamente conhecido (Figura 3.8), com vistas macro (a) e em mais detalhes (b).




FIGURA 3.8: Representação do processo da Aciaria, segundo Voraberger et al. (2022)

Neste convertedor, a mistura de ferro-gusa, juntamente com as proporções de ligas e sucata irão definir o tipo de aço que será gerado. A superfície dessa solução é então submetida ao sopro de oxigênio de alta pureza, desencadeando uma série de reações de oxidação altamente

exotérmicas. O chamado gás de aciaria é o principal subproduto gasoso derivado dessas reações químicas de refino.

O gás gerado dentro do convertedor LD é rico em monóxido de carbono (CO), portanto, altamente inflamável, além de conter dióxido de carbono (CO₂) e pequenas quantidades de nitrogênio (N₂) e oxigênio (O₂) (Pecém, 2025). A Tabela 3.3 ilustra as proporções médias da composição do gás analisado no estudo de caso.

TABELA 3.3: Composição química do G_{AC} no estudo de caso.

Componente	Nome	Percentual
CO	Monóxido de Carbono	56.63%
CO ₂	Dióxido de Carbono	18.69%
H ₂	Hidrogênio	0.85%
N ₂	Nitrogênio	23.37%
O ₂	Oxigênio	0.46%

De acordo com Rodrigues et al. (2018), este gás apresenta um PCI médio de 1800.0 kCal/Nm³ e a análise estequiométrica da reação de combustão do monóxido de carbono pode ser representada por (3.4). Destaca-se que a densidade relativa desse gás é de 1.38 kg/Nm³.

A queima do gás de aciaria apresenta uma dinâmica parecida com o gás de alto-forno, transferindo calor, principalmente, por convecção, devido à presença de menos hidrocarbonetos. Apesar de constituir uma queima estável, contém alto teor de monóxido de carbono, sendo potencialmente perigoso.

Em uma análise do balanço mássico, com base na equação de oxidação completa do CO exposta, pode-se dizer que 28.0 g de CO produzem 44.0 g de CO₂. Dessa maneira, considerando a proporção de monóxido de carbono no gás de aciaria, estima-se que, para cada 1.0 kg desse combustível, libera-se 1.0768 kg de CO₂ em uma queima completa. Ressalva-se que foi considerada, também, a quantia de dióxido de carbono presente no combustível, mas como ele não sofre queima, basta somar sua contribuição simples no resultado final. Esse valor será interessante para a contabilização do potencial de impacto ambiental da solução proposta.

É importante citar que o gás de aciaria é considerado um combustível de poucos impactos na condição física da caldeira, não sendo tão prejudicial como os óleos pesados. Na tomada de decisão, o impacto desse combustível na condição da caldeira é considerado.

3.3.4 Gás Natural

O gás natural (GN) é um produto externo ao processo siderúrgico, proveniente da aquisição sob demanda no mercado. Ele é considerado uma fonte de energia versátil e mais limpa em comparação com outros combustíveis fósseis, como o carvão e o petróleo.


A Tabela 3.4 expõe a composição química do gás natural utilizado no estudo de caso. Note a grande parcela de metano em sua composição.

TABELA 3.4: Composição química do GN no estudo de caso.

Componente	Nome	Percentual
CH ₄	Metano	89.77%
C ₂ H ₆	Etano	5.90%
C ₃ H ₈	Propano	1.80%
C ₄ H ₁₀	iso-Butano	0.57%
CO ₂	Dióxido de Carbono	0.74%
N ₂	Nitrogênio	1.22%

A queima do gás natural apresenta uma dinâmica parecida com o gás de coqueria, transferindo calor, principalmente, por radiação, devido à presença do metano. No entanto, apresenta uma chama mais estável.

De acordo com [Gasmig \(2023\)](#), pode-se aferir que esse gás apresenta um PCI médio superior a todos os demais combustíveis apresentados até então, de 8900.0 kCal/Nm³ e a análise estequiométrica da reação de combustão dos gases que o compõem pode ser representada por (3.5):



Com base na equação de oxidação completa do gás, estima-se que para cada 1.0 kg desse combustível, liberam-se 2.72 kg de CO₂ na atmosfera. Diz-se ainda que o gás natural é considerado o combustível de menor impacto na condição física da caldeira. Além disso, esse gás apresenta densidade relativa de 0.8 kg/Nm³.

3.3.5 Óleos

Os óleos podem ser obtidos via produção interna, por exemplo, os óleos leves provenientes da coqueria, mas nesse estudo de caso é um produto adquirido sob demanda no mercado, assim como o gás natural.

Para o estudo de caso, é importante destacar que se considera esse combustível e o gás natural como ativos de emergência, tendo em vista o gasto extra em aquisição, dada a possibilidade de utilizar os coprodutos da própria usina.

Para fins de simplificação, iremos considerar o óleo diesel genérico, portanto, apresenta um PCI médio de 8500.0 kCal/Nm^3 e, para cada 1.0 kg consumido, se produzem 3.2 kg de CO_2 (de Carvalho, 2011).

Geralmente, os óleos são atomizados para serem utilizados nas caldeiras. Dessa forma, a pulverização do combustível promove uma queima com dinâmica parecida à gás de coqueria, transferindo calor, principalmente, por radiação.

É importante citar que os óleos são considerados os piores combustíveis quanto ao impacto na condição física da caldeira, muito devido à alta viscosidade, tanto é que precisam ficar recirculando pela estrutura, mesmo quando não estão em uso, para evitar que o combustível encroste e obstrua os dutos.

Em resumo, apresenta-se na Tabela 3.5 a relação entre a emissão de dióxido de carbono e a queima completa de um quilograma de combustível, bem como o poder calorífico inferior de cada combustível, e um termo que compara o impacto do uso desse recurso na condição física das caldeiras.

Cabe destacar que a densidade do ar atmosférico, no nível do mar e a zero graus Celsius, é de aproximadamente $1,293 \text{ kg/Nm}^3$. Observa-se que os gases de alto-forno e gases de aciaria são mais densos, logo, denotam grande perigo no caso de vazamento em espaço confinado, pois estes irão se represar mais ao fundo.

TABELA 3.5: Resumo dos recursos energéticos

Combust.	Emissão de CO_2 por kg [kg]	PCI [kCal/Nm^3]	Fator de sujidade	Dens. [kg/Nm^3]
G_{CO}	0.968	4200.0	Alto	0.498
G_{AF}	0.61	777.0	Médio	1.392
G_{AC}	1.0768	1800.0	Médio	1.379
G_N	2.72	8900.0	Baixo	0.806
Óleos	3.2	8500.0	Muito alto	-

3.4 Representação do Sistema

Frente ao cenário das caldeiras aquatubulares e dos combustíveis admitidos, a equação esboçada em (3.2) confere uma ideia de que correlaciona as entradas com a saída do sistema, na tentativa de construir uma representação de como o sistema opera, conforme Figura 3.9.




FIGURA 3.9: Diagrama de correlação entre entradas e saída.

Para aplicação de algoritmos otimizadores, foco do presente trabalho, representar adequadamente o sistema é crucial para a máxima verossimilhança, e a natureza da representação matemática, seja ela linear ou não linear, convexa ou não, impacta tanto na definição da busca pela solução mais adequada quanto na determinação do software que pode ser utilizado.

Por exemplo, o modelo fenomenológico individual de cada caldeira representado por uma ponderação simples de um suposto coeficiente, configura um sistema linear e que pode ser solucionado por programação matemática, via algoritmos como o *Simplex*. Porém, uma vez que unem-se todas as caldeiras em um mesmo sistema, desconfigura-se tal linearidade, e o problema não pode mais ser resolvido via métodos exatos, deixando de assegurar a otimalidade da resposta.

3.4.1 Métodos Clássicos de Identificação

Para representação de um sistema, existem os métodos clássicos que se concentram em modelos lineares e em técnicas estatísticas robustas.

Em Controle e Automação, é muito comum o levantamento de modelos de resposta em frequência (Serpa, 2007). Tal modelo é a resposta em regime permanente de um sistema, quando o mesmo é submetido a uma entrada senoidal. Dado um sistema linear, submetido a uma entrada senoidal, a resposta do sistema também será senoidal e com a mesma frequência, uma vez que a saída irá diferir da entrada apenas em amplitude e fase.




FIGURA 3.10: Representação do diagrama de Bode, à esquerda sistema de primeira ordem, e à direita sistema de segunda ordem com diferentes fatores de amortecimento; adaptado de Serpa (2007).

Essa representação destaca-se por ser simples para sistemas de baixa ordem e fornecer uma representação gráfica intuitiva, conhecida como diagrama de Bode (vide Figura 3.10), apresentando o ganho em *Decibéis* e a frequência do sistema em radianos por segundo. Vale observar que em um sistema de segunda ordem com alto fator de amortecimento (ζ), assemelha-se ao sistema de primeira ordem.

Também é possível representar um modelo de resposta ao tempo (Lathi, 2006). Esse método utiliza a resposta do sistema a uma entrada em degrau, vide equação com translação temporal (3.6), conforme a representação na Figura 3.11.

$$u(t - T) = \begin{cases} 1 & \text{se } t > T \\ 0 & \text{se } t \leq T \end{cases} \quad (3.6)$$





FIGURA 3.11: Entrada Degrau unitário deslocado no tempo (Serpa, 2007).

Pode-se utilizar outras entradas padrão, por exemplo, o impulso unitário (3.7), ou Delta de *Dirac* $\delta(t)$, caracterizado por possuir duração nula, amplitude infinita e área unitária, vide Figura 3.12.

$$\delta(t) = 0 \quad \text{para} \quad t \neq 0, \quad \text{e} \quad \int_{-\infty}^{+\infty} \delta(t) dt = 1 \quad (3.7)$$

FIGURA 3.12: Entrada Delta de *Dirac* (Serpa, 2007).

Essa representação se destaca por ser simples de implementar e interpretar para sistemas de primeira ou segunda ordem, permitindo a extração de parâmetros como tempo de atraso, ganho e constante de tempo, porém, limita-se a sistemas lineares de baixa ordem e pode não capturar toda a dinâmica de sistemas complexos.

O método dos mínimos quadrados (*Least Squares*) é uma técnica popular, em que por meio de uma formulação, por exemplo os modelos autoregressivos ARX (AutoRegressive with eXogenous input), conforme (3.8), bem como outras estruturas mais complexas, como ARMAX (AutoRegressive Moving Average with eXogenous input), objetiva-se minimizar a soma dos

quadrados das diferenças entre as saídas medidas e as saídas previstas pelo modelo estimado, ajustando os parâmetros θ até alcançar a melhor representação possível, ou seja, com o menor erro (Aguirre, 2007).

Nessa ótica, pode-se dizer que essa operação nada mais é que uma otimização paramétrica, cuja função objetivo é minimizar o erro de representação.

$$\begin{aligned} y(\phi) &= \phi^T(t)\theta \\ \hat{\theta} &= (\phi^T \phi)^{-1} \phi^T y \end{aligned} \quad (3.8)$$

Apesar da robustez, simplicidade computacional e base estatística sólida, esse método apresenta muita sensibilidade a ruídos e distúrbios na saída, que podem levar a estimativas enviesadas. De forma geral, apesar de ser preciso a adoção de artifícios de linearização para conceber o modelo real, pode-se alcançar representações satisfatórias. E ao notar perda de representação, pode-se reajustar os parâmetros e adaptar o modelo linear.

No entanto, existem sistemas dinâmicos cujas relações de entrada e saída não seguem o princípio da superposição. Em outros termos, são sistemas onde a resposta não é proporcional à entrada, e/ou a soma das respostas a duas entradas separadas não é equivalente à resposta da soma dessas entradas. Este princípio é composto pelas propriedades de homogeneidade (3.10) (ou escalonamento) e aditividade (3.9), e define um sistema linear. Na falha de uma dessas propriedades, o adequado é buscar outros métodos de representação da dinâmica do sistema, classificado como não linear.

$$\textbf{Aditividade: } F(x_1 + x_2) = F(x_1) + F(x_2) \quad (3.9)$$

$$\textbf{Homogeneidade: } F(ax) = aF(x) \quad (3.10)$$

Para os casos não lineares, conforme Aguirre (2007), existem diversas estratégias, desde a série de Volterra, que se assemelha à ideia da integral de convolução, mas que necessita de muitos parâmetros para constituir o modelo, até ideias como os modelos Hammerstein e Wiener, populares na década de 70, e que voltaram à tona nos anos 90 com o controle não-linear. Eles misturam uma representação linear dinâmica com uma fração estática não linear.

No caso do modelo de Hammerstein, a não-linearidade estática precede o modelo dinâmico linear; o oposto é visto em Wiener, vide Figura 3.13, com a representação discreta dos modelos. O item (a) da figura diz respeito ao modelo de Hammerstein e o item (b) ilustra o modelo de Wiener. Diz-se ainda que em aplicações práticas não se tem acesso à variável intermediária $\nu(k)$, que é uma variável fictícia, e a função $f(\cdot)$ é desconhecida, sendo que apenas se tem acesso aos sinais de saída $y(k)$ e entrada $u(k)$.




FIGURA 3.13: Representações de blocos interconectados (Aguirre, 2007).

Na contemporaneidade, o modelo Hammerstein-Wiener unifica as duas propostas, e é aplicado na identificação do controle de motores, modelagem de sistemas de comunicação, e análise de sistemas físicos complexos.

Em um exemplo automobilístico, conforme Figura 3.14, o modelo Hammerstein-Wiener pode ser usado para modelar a dinâmica não linear do torque do motor, levando em consideração fatores como a posição da borboleta, a válvula *wastegate*, a velocidade do motor e o avanço da ignição (Center, 2025).




FIGURA 3.14: Exemplo de aplicação do modelo Hammerstein-Wiener (Center, 2025).

Existe também o NARX (Nonlinear AutoRegressive with eXogenous input), modelo discreto no tempo que explica o valor da saída $y(k)$ em função de valores prévios dos sinais de saída e de entrada. Ao inserir termos de ruído nesse modelo, converte-se em NARMAX (Nonlinear AutoRegressive Moving Average model with eXogenous variables), robusto à polarização paramétrica, geralmente assumindo representações polinomiais ou racionais (Aguirre, 2007).

3.4.2 Métodos Heurísticos de Identificação

Existem ferramentas de *Machine Learning* (ML) que demonstraram grande capacidade de detecção de padrões e classificação de informações. Especialmente para sistemas não lineares e cuja

complexidade de representação vá além de uma representação polinomial de segunda ordem, os métodos heurísticos podem ser eficazes em uma representação matemática, capturando dinâmicas sem a necessidade de uma estrutura de modelo pré-definida.

A identificação de sistemas com ML é, essencialmente, um problema de regressão, onde se busca uma função que mapeia as entradas passadas para a saída futura. A grande questão é que muitas vezes não se consegue extrair uma equação matemática intuitiva dessas regressões e, portanto, recebem o nome de modelos caixa-preta.

Existem diversas estratégias de ML capazes de conceber bons modelos, porém, assim como os diferentes métodos clássicos, cada modelo heurístico se aplica melhor em determinada situação. Existem, por exemplo, diversos tipos de redes neurais artificiais, com diferentes aplicações.

O princípio de funcionamento de uma rede neural artificial básica passa pelo entendimento de um neurônio artificial, uma vez que é composta de camadas de neurônios interconectados. De acordo com [Aguirre \(2007\)](#), um neurônio pondera e valida n entradas, conforme (3.11), sendo que b (bias) e w_j são constantes e f é chamada de função de ativação. Existem vários tipos de função de ativação, sendo que uma das mais comuns é a função sigmóide (3.12):

$$x = f \left(\sum_{j=1}^n w_j x_j + b \right) \quad (3.11)$$

$$f(z) = \frac{1}{1 + e^{-z}} \quad (3.12)$$

Normalmente, as redes neurais apresentam multicamadas, de forma que a saída de um neurônio é conectada à entrada de outro, que não precisa ter a mesma configuração do anterior.

A Figura 3.15 ilustra o funcionamento simplificado de uma rede neural. De modo geral, a grande diferença entre as estratégias de redes neurais é a seleção dos modelos de ativação, o número de camadas e de neurônios. Uma rede neural muito utilizada para modelar dinâmicas temporais é a rede neural recorrente, ou ainda as *Long Short-Term Memory* (LSTMs). Elas podem “memorizar” o histórico das entradas e saídas para prever o próximo estado, o que as tornam ideais para sistemas dinâmicos.




FIGURA 3.15: Visão explodida de um neurônio em uma rede,
Fonte: Própria.

Máquinas de vetor de suporte para regressão (SVR) configuram a técnica de aprendizado que busca encontrar um hiperplano ótimo para mapear as entradas para a saída. A SVR lida bem com dados não-lineares, demonstra robustez contra *outliers* e é eficiente em dados de alta dimensão, apesar de poder ser sensível à escolha dos hiperparâmetros.




FIGURA 3.16: Definição do hiperplano pelo SVR,
Fonte: [Hakbilen \(2022\)](#)

A Figura 3.16 exemplifica a definição do hiperplano. Conforme [Hakbilen \(2022\)](#), a margem é o intervalo entre os dois pontos mais próximos de cada classe, que é a distância do hiperplano aos pontos mais próximos (vetores de suporte). O hiperplano que melhor se ajusta aos dados, ou seja, que melhor separa as duas classes, é o hiperplano com a margem máxima possível.

Portanto, o algoritmo SVM busca o hiperplano com a margem máxima (distância aos pontos mais próximos).

Floresta Aleatória (*Random Forest*) e *Gradient Boosting* são métodos baseados em árvores de decisão. Eles constroem um conjunto de árvores para fazer a previsão. O *Gradient Boosting*, em particular, constrói as árvores sequencialmente, corrigindo os erros das árvores anteriores, mostrando alto poder preditivo, capacidade de lidar com dados não-lineares e robustez a *overfitting*.




FIGURA 3.17: Representação de uma *Random Forest*,
Adaptado de: [Kulkarni \(2023\)](#)

Cada árvore do conjunto pode representar parcelas da dinâmica do modelo, e ao uni-las em uma análise coletiva, o sistema fica bem representado. Conforme [Kulkarni \(2023\)](#), o valor de saída é a média da predição de cada parcela da floresta, vide representação na Figura 3.17.

Todos os métodos de identificação, clássicos ou heurísticos, são supervisionados. Além disso, é uma boa prática dividir o conjunto de dados em duas partes, 70% para treinamento dos parâmetros e o restante para avaliação da eficiência do modelo.

Um grande problema que pode ocorrer é a criação de um modelo que não apresenta tolerância a desvios dos dados previamente treinados. Quando isso ocorre, chama-se de *overfitting*, ou o treinamento não contemplou dados suficientes para que o modelo consiga abstrair toda a dinâmica do sistema.

Outra boa prática é a normalização dos dados, para evitar grandes amplitudes tanto na entrada quanto na saída. Recomenda-se também que nessa etapa de identificação do modelo, se utilize apenas dados condicionados, a fim de criar um modelo fiel ao sistema.

Não há um “melhor” método de identificação. Os métodos clássicos são ideais quando um modelo linear de baixa ordem é suficiente ou quando a interpretabilidade é crítica. Eles são a base teórica e oferecem garantias de estabilidade e convergência. As abordagens de *Machine Learning*, por sua vez, são poderosas para sistemas complexos, onde as dinâmicas não-lineares dominam. A tendência atual é a fusão dessas abordagens, utilizando a robustez teórica dos métodos clássicos com o poder preditivo do aprendizado de máquina, criando um novo campo de modelagem e controle híbridos.

3.5 Otimização

3.5.1 Otimização Multiobjetivo

Quando o problema de otimização apresenta mais de uma função que se deseja otimizar simultaneamente, tem-se uma otimização multi-objetivo. Para fins de ilustração, a Figura 3.18 representa o espaço de projetos com as variáveis x_1 e x_2 , com duas funções objetivo.




FIGURA 3.18: Problema de otimização multiobjetivo. Representação do espaço de projetos.
Fonte: Autoria própria.

Já a Figura 3.19 representa o espaço de objetivos, e exemplifica um caso de minimização de duas funções objetivo conflitantes. Notam-se os extremos entre os pontos ótimos individuais de cada função e, nesse caso, haverá um conjunto de soluções eficientes entre tais extremidades, cabendo

ao tomador de decisão a escolha de qual será a solução a ser implementada, configurando-se um *trade-off* de soluções.




FIGURA 3.19: Problema de otimização multiobjetivo. Representação do espaço de objetivos.
Fonte: Autoria própria.

Dado o espaço factível de soluções, há aquelas que se destacam em detrimento das demais, cabendo então a avaliação comparativa para seleção das soluções candidatas. Há diversas técnicas de avaliação, e uma das mais utilizadas na contemporaneidade foi proposta por Vilfredo Pareto, um economista italiano (Collette and Siarry, 2013).

A Dominância Pareto ocorre quando uma dada solução é melhor que a outra em pelo menos um objetivo e não é pior em nenhum dos outros. Em outras palavras, a solução S_a pareto domina a solução S_b quando a primeira oferece vantagens sem contrapartidas negativas. Quando isso for verdade, representa-se como exposto em (3.13).

$$S_a \prec S_b. \quad (3.13)$$

Essa formulação também pode ser explicada graficamente. A título de exemplo, na Figura 3.20a, considerando que ambas as funções são de minimização, o ponto rosa representa uma solução e, sobre esta, traceja-se um par de retas na cor lilás, que são representações paralelas a cada uma das duas funções objetivo. Nesse caso, a união dessas duas retas tracejadas configura uma espécie de cone de dominância, de maneira que todas as soluções dentro desse cone (pontos amarelos) são Pareto dominadas pela solução rosa em questão.

Nesses casos, a solução não é um único ponto, mas sim um conjunto de soluções de compromisso, chamado, no espaço de projetos, de Conjunto Pareto Ótimo. Esse conjunto de todas




FIGURA 3.20: Problema de otimização multiobjetivo. Representação no espaço de objetivos:
Avaliação do cone de dominância Pareto.
Fonte: Autoria própria.

essas soluções não dominadas forma, no espaço de objetivos, a Fronteira Pareto, representada na Figura 3.20b pela curva alaranjada.

Os métodos escalares ou de agregação são métodos clássicos para resolução de problemas multiobjetivo. Esses métodos mapeiam soluções na fronteira via otimizações escalares independentes.

O método ϵ -restrito se baseia na conversão do problema com múltiplos objetivos em uma série de problemas de otimização mono objetivo. Dado um problema com m objetivos, o método consiste na escolha de uma delas para ser minimizada e na transformação das demais funções em restrições de desigualdade do problema (Chankong and Haimes, 2008).

A equação (3.14) expressa a aplicação deste método em um contexto em que a primeira função objetivo foi definida como a função a ser minimizada. Nota-se que cada restrição adicionada é limitada por um escalar ϵ_k , e a geração das soluções Pareto-ótimas se dá por meio da variação desses valores.

$$\mathcal{F} = \begin{cases} \min_{\mathbf{x}} f_1(\mathbf{x}) \\ f_k(\mathbf{x}) \leq \epsilon_k; & k = 2, \dots, m \\ g_i(\mathbf{x}) \leq 0; & i = 1, \dots, p \\ h_j(\mathbf{x}) = 0; & j = 1, \dots, q \\ \mathbf{x} \in \mathcal{X} \end{cases} \quad (3.14)$$

Diferente do método soma ponderada, com o ϵ -restrito, as soluções associadas a trechos não

convexos da fronteira Pareto podem ser alcançadas. Ou seja, não é preciso garantir que o conjunto solução possua imagem convexa. Entretanto, as restrições adicionais podem conduzir a problemas infactíveis ou mesmo levar a soluções não eficientes.

3.5.2 Tomada de Decisão

A otimização multiobjetivo é capaz de fornecer um conjunto de respostas que satisfazem o problema; no entanto, isso não é suficiente na maioria dos casos. Saber qual solução é a mais adequada para cada caso é uma tarefa que está além do algoritmo otimizador, evidenciando o papel da ferramenta de suporte à tomada de decisão. A tomada de decisão é uma etapa crucial em que o usuário (ou unidade de decisão), com base em suas prioridades, é capaz de definir a solução final para o problema (Pedrycz et al., 2010).

Para uma análise do conjunto de soluções, supostamente pertencentes à fronteira Pareto, é preciso ser capaz de diferenciá-las, por meio de atributos ou critérios de decisão, que auxiliam na extração de informação e, de uma certa forma, ordenam as soluções ótimas. Dentre as técnicas mais famosas, listam-se o Analytic Hierarchy Process (AHP), Electre, Promethee, entre outras.

O método de auxílio à tomada de decisão que será empregado neste trabalho é o PROMETHEE (sigla para *Preference Ranking Organization Method for Enrichment Evaluation*). Ele é usado para classificar e selecionar alternativas em problemas complexos com múltiplos critérios, oferecendo uma abordagem diferente do AHP, pois não utiliza comparações pareadas para os critérios (Brans, 1982).

A principal característica do PROMETHEE reside em sua capacidade de modelar as preferências do tomador de decisão de forma explícita e intuitiva, com base em funções de preferência para cada critério. O método opera em uma série de etapas para construir uma relação de ordenação completa ou parcial das alternativas.

- **Definição dos Critérios e Pesos:** O processo começa com a identificação das alternativas e dos critérios. Em seguida, o decisor atribui um peso de importância a cada critério diretamente.
- **Funções de Preferência:** Esta é a característica mais distintiva do PROMETHEE. Para cada critério, o decisor deve escolher uma função de preferência que traduz a diferença na avaliação de duas alternativas em um grau de preferência. As funções mais comuns incluem a função linear, a V-shape e a função step.
 - **Função Linear:** A preferência aumenta linearmente com a diferença de desempenho.

- **Função V-shape:** A preferência é zero até um certo ponto e depois cresce linearmente.
- **Função Step:** A preferência muda em saltos, em vez de gradualmente. Essa abordagem permite que o decisor incorpore sua percepção de limites (limiares) em que uma diferença de desempenho se torna significativa.
- **Relações de Superação (*Outranking*):** O PROMETHEE calcula um índice de preferência para cada par de alternativas, medindo o quão fortemente uma alternativa é preferida sobre outra, considerando todos os critérios e seus respectivos pesos.
- **Fluxos de Preferência (ϕ^+ e ϕ^-):** A partir dos índices de preferência, dois tipos de “fluxos” são calculados para cada alternativa:
 - **Fluxo de Superação Positivo (ϕ^+):** Representa o grau em que uma alternativa supera as outras. Um alto ϕ^+ é desejável.
 - **Fluxo de Superação Negativo (ϕ^-):** Representa o grau em que uma alternativa é superada pelas outras. Um baixo ϕ^- é desejável.
- **Ordenação Final**

Expõe-se duas variações de avaliação:

 - O método **PROMETHEE I** (Ordenação Parcial): Cria uma ordenação que pode não ser completa, deixando algumas alternativas incomparáveis se seus fluxos ϕ^+ e ϕ^- forem muito similares.
 - O método **PROMETHEE II** calcula um **fluxo líquido** ($\phi_{net} = \phi^+ - \phi^-$), que fornece uma ordenação completa e clara das alternativas.

Destaca-se que existem muitas outras estratégias, bem como diferentes variantes dos métodos expostos. Porém, apesar dessa diversidade, é inegável que tais estratégias são úteis para conceber uma ferramenta de apoio à tomada de decisão, principalmente após os entregáveis de uma otimização multiobjetivo.

Após tamanha exposição de fundamentos e boas práticas, tem-se as ferramentas necessárias para o desenvolvimento da solução que irá atender ao estudo de caso.

Com base na flexibilidade de combustíveis e na possibilidade de extração de informações via modelo (3.2), pode-se esboçar um problema de otimização multiobjetivo, a fim de obter a melhor configuração de produção de vapor, com o menor gasto e impacto ambiental possível. O capítulo da metodologia aborda melhor tal proposta de solução.

Capítulo 4

METODOLOGIA

Nesta seção apresenta-se a modelagem matemática do problema alvo, bem como a estratégia de otimização a ser utilizada, a ferramenta de suporte à tomada de decisão e as etapas inerentes à concepção do algoritmo.

Cada etapa exposta no diagrama 4.1 será detalhada ao longo deste capítulo.

4.1 Coleta de Dados

É notório que a siderurgia é um ramo antigo, com muita tecnologia embarcada e, portanto, questiona-se por que, até então, são encontradas tão poucas aplicações dessa natureza de otimização em operação na literatura.

Certamente, a resposta a estes questionamentos está embasada nos desafios de conciliação entre as partes teórica e prática. A título de exemplo, destaca-se que parte dos trabalhos supracitados na revisão bibliográfica, Capítulo 2, recorre a dados simulados, e não reais. Além disso,




FIGURA 4.1: Diagrama macro da metodologia

modelos lineares propostos, como o que motivou esse estudo, Equação (3.2), assumem certas linearizações que limitam a representação das dinâmicas observadas no sistema real.

Dessa maneira, a primeira barreira para a aplicação bem-sucedida dos trabalhos é a coleta de dados adequada. Faz-se necessário um *kit* de instrumentação embarcada na área de estudo, com a devida calibração e isolamento do sistema.

No estudo de caso do presente trabalho, considerou-se a medição de vazão de entrada de cada combustível e a medição de vazão do vapor produzido por caldeira, amostrados a cada minuto, a fim de criar uma função de transferência, correlacionando entradas e saídas, vide diagrama da Figura 3.9. Ao todo, foram coletados dois meses de informações, recorrendo aos instrumentos legados, já instalados em campo, sendo eles, medidores de vazão volumétrica dos combustíveis admitidos nas caldeiras e medidores de vazão de vapor produzido em cada caldeira.

No entanto, os dados brutos não podem ser simplesmente assumidos. Todo dado está suscetível a ruídos externos, por exemplo, interferência por insolação, exposição do cabeamento à vibração e até mesmo obstrução da via de medição. Observaram-se ruídos na leitura dessas informações e trechos em que os dados ficaram estacionados em um mesmo valor.

Note, na Figura 4.2a, a medição de vazão de óleo nas quatro caldeiras. Nesse recorte, aparentemente, todos os sinais estão corretos, no entanto, ao dar um zoom na escala de medição, vide Figura 4.2b, verificam-se valores negativos presentes na leitura. Como essas informações não condizem com a realidade esperada, o primeiro tratamento realizado com o conjunto de dados foi a validação das informações, truncando os valores negativos para zero.

Provavelmente essa parcela negativa observada é proveniente de ruídos na medição. A grande questão do uso de filtros, como a média móvel, é a característica de atraso do conjunto de dados. Existe um *trade-off* entre a suavização do sinal e a perda de sincronia.

O atraso é considerado um compromisso aceitável, e até mesmo benéfico, em cenários onde o foco não é o controle em tempo real, mas a análise e a predição. Considerando a finalidade de treinar um modelo preditivo, o atraso é um compromisso válido e até mesmo necessário para mitigar o ruído e permitir que o modelo aprenda a dinâmica principal do sistema.

A fim de suavizar o conjunto de dados e mitigar a influência do ruído, preservando a tendência e a informação principal do sinal, a média móvel de Hull propõe um algoritmo capaz de mitigar atrasos e perda de sinais (Hull, 2005). Na Figura 4.3 é possível verificar a diferença de atuação entre a média móvel simples e a média móvel de Hull, ambas com janelas deslizantes de tamanho 50 amostras, aplicadas a um sinal amortecido com ruídos inseridos. É possível notar que a média móvel de Hull é mais consistente nas extremidades do conjunto e consegue se ajustar ao longo das ondulações do sinal, conservando melhor a amplitude e o defasamento.




FIGURA 4.2: Avaliação da coleta de dados brutos provenientes do monitoramento de vazão de óleo nas caldeiras do estudo de caso.

Fonte: Autoria própria.

Como o presente trabalho tem o intuito de extrair a dinâmica do processo, ao mesmo tempo que promove sugestões em tempo real para o conjunto de caldeiras, trataram-se os dados com a estratégia da média móvel proposta por Hull (2005).

No estudo de caso tem-se um conjunto de quatro caldeiras aquatubulares. Destaca-se que esse complexo térmico apresenta uma inércia considerável contra mudanças repentinas. A resposta da temperatura e da pressão a uma mudança no fluxo de combustível, por exemplo, não é imediata. Naturalmente, há um atraso entre a ação e a reação, e esse valor deve ser contemplado ao




FIGURA 4.3: Comparação entre média móvel simples e média móvel de Hull.
Fonte: Autoria própria.




FIGURA 4.4: Avaliação e tratamento de sinais
Sinais coletados da caldeira 03 do estudo de caso, durante parada para manutenção.
Fonte: Autoria própria.

parametrizar a média móvel.

Além da tratativa de ruídos, existem particularidades no conjunto de dados que devem ser expurgadas, como informações coletadas fora do período de operação da máquina. Vide recorte da caldeira 03, representada pela Figura 4.4, durante uma parada de três dias para manutenção.

4.2 Elaboração do Problema de Otimização

A elaboração do problema de otimização passa, por exemplo, pela definição das variáveis de decisão, a função objetivo e restrições. Dessa forma, o problema de otimização relacionado com o estudo de caso tem como objetivo principal otimizar a performance do conjunto de quatro caldeiras, conforme diagrama da Figura 3.4. Ao longo da Seção 4.2.1, o problema é caracterizado matematicamente.

4.2.1 Definições Matemáticas Prévias

A formalização do modelo matemático considerado neste trabalho se baseia na definição dos conjuntos explicitados na equação (4.1), em que C_γ se refere à γ -ésima caldeira. A partir de (4.1), consegue-se definir os parâmetros do sistema, conforme a equação (4.2):

$$\begin{aligned} \text{Combustiveis} &= [G_{AC}, G_{AF}, G_{CO}, GN, OLEOS] \\ \text{Caldeiras} &= [C_1, C_2, C_3, C_4] \end{aligned} \quad (4.1)$$

$$\begin{aligned} \text{PCI}_\beta & \quad \forall \beta \in \text{Combustiveis} \\ \text{Disp}_\beta & \quad \forall \beta \in \text{Combustiveis} \\ \text{Base}_{1,\beta} & \quad \forall \beta \in \text{Combustiveis} \\ \text{Base}_{2,\beta} & \quad \forall \beta \in \text{Combustiveis} \\ \text{Vp}_{min,\gamma} & \quad \forall \gamma \in \text{Caldeiras} \\ \text{Vp}_{max,\gamma} & \quad \forall \gamma \in \text{Caldeiras} \\ \text{Coef}_{\beta,\gamma} & \quad \forall \beta \in \text{Combustiveis}, \forall \gamma \in \text{Caldeiras} \\ \text{Lim}_{inf,\beta,\gamma} & \quad \forall \beta \in \text{Combustiveis}, \forall \gamma \in \text{Caldeiras} \\ \text{Lim}_{sup,\beta,\gamma} & \quad \forall \beta \in \text{Combustiveis}, \forall \gamma \in \text{Caldeiras} \\ q_\gamma & \quad \forall \gamma \in \text{Caldeiras} \\ \delta Vp & \end{aligned} \quad (4.2)$$

Em (4.2), PCI_β é o poder calorífico inferior de cada combustível e Disp_β representa a disponibilidade do combustível β . Neste estudo de caso em específico, existe uma margem que se pode manipular, admitindo mais ou menos combustível na busca de um melhor ajuste de parâmetros. Essa margem é representada pelas métricas $\text{Base}_{1,\beta}$ e $\text{Base}_{2,\beta}$.

$\text{Vp}_{max,\gamma}$ e $\text{Vp}_{min,\gamma}$ significam, respectivamente, a produção máxima e mínima de vapor pela caldeira γ . $\text{Lim}_{inf,\beta,\gamma}$ e $\text{Lim}_{sup,\beta,\gamma}$ são limites definidos via projeto de cada uma das estruturas, os quais representam limites de admissão segura de combustíveis.

Já o fator q_γ é um parâmetro de entrada do sistema, igual a 1 se a caldeira γ está em operação; e 0 caso contrário.

Por fim, têm-se os coeficientes $\text{Coef}_{\beta,\gamma}$, que representam o desempenho de cada caldeira ao utilizar determinado combustível. Já o parâmetro de equalização da produção, δV_p , valor constante igual a 30.0 Ton/h, é definido pelas regras de operação do estudo de caso abordado neste trabalho. Em outros termos, as caldeiras em operação devem estar a uma diferença de até 30.0 Ton/h de produção entre si.

Com essa parametrização é possível abordar o problema de maneira mais formal e descrever a solução proposta neste trabalho.

4.2.2 Formulação Fundamental

Inicialmente, tem-se a equação de vapor produzido (3.2); ela é representada conforme (4.3), em que V_{p_γ} é o total de vapor produzido pela caldeira γ e *Cald.* e *Comb.* são as abreviações para Caldeiras e Combustíveis, respectivamente.

$$V_{p_\gamma} = \sum_{\beta \in \text{Comb.}} \text{Vazao}_{\beta,\gamma} \times \text{PCI}_\beta \times \text{Coef}_{\beta,\gamma} \quad (4.3)$$

Essa representação diz respeito à parte linear da modelagem do problema, abordada no diagrama da Figura 4.5.

4.2.3 Variáveis de Decisão

As variáveis de decisão do sistema de otimização são definidas como a quantia de cada combustível que será atribuída a cada caldeira, conforme (4.4):

$$\text{Vazao}_{\beta,\gamma} \quad \forall \beta \in \text{Combustíveis}, \forall \gamma \in \text{Caldeiras.} \quad (4.4)$$

4.2.4 Função Objetivo

Inspirado na equação fundamental que expõe a relação fenomenológica do estudo de caso, pensou-se em um modelo compacto que represente o quanto seria demandado de energia para a produção de vapor. Essa abordagem foi definida como exposto em (4.5) e, dessa forma, observa-se uma relação de dependência direta entre o numerador e o denominador, caracterizando uma

função não linear e complexa de se resolver sem estratégias apropriadas.

$$\min \frac{\sum_{\beta \in Comb.} \sum_{\gamma \in Cald.} (Vazao_{\beta,\gamma} \times PCI_{\beta})}{\sum_{\beta \in Comb.} \sum_{\gamma \in Cald.} (Vazao_{\beta,\gamma} \times PCI_{\beta} \times Coef_{\beta,\gamma})} \quad (4.5)$$

Com o intuito de remover essa relação de dependência entre numerador e denominador exposta em (4.5), considerou-se o desmembramento da razão. Nesse caso, converteu-se tal equação em duas funções objetivo, caracterizando um problema de otimização multiobjetivo, conforme (4.6):

$$\begin{aligned} \min \quad & \sum_{\beta \in Comb.} \sum_{\gamma \in Cald.} Vazao_{\beta,\gamma} \times PCI_{\beta} \\ \max \quad & \sum_{\beta \in Comb.} \sum_{\gamma \in Cald.} Vazao_{\beta,\gamma} \times PCI_{\beta} \times Coef_{\beta,\gamma} \end{aligned} \quad (4.6)$$

Neste novo equacionamento, a primeira função representa a minimização do consumo de energia e a segunda refere-se à maximização da produção de vapor. Observa-se que inúmeras soluções eficientes podem ser obtidas, dando espaço a uma tomada de decisão estratégica aos projetistas.

4.2.5 Definição das restrições

Esse problema de otimização está sujeito às restrições definidas em (4.7)–(4.14), as quais refletem a factibilidade da aplicação siderúrgica em questão.

$$Disp_{\beta} - Base_{1,\beta} \leq \sum_{\gamma \in Cald.} Vazao_{\beta,\gamma}, \quad \forall \beta \in Comb. \quad (4.7)$$

$$\sum_{\gamma \in Cald.} Vazao_{\beta,\gamma} \leq Disp_{\beta} + Base_{2,\beta}, \quad \forall \beta \in Comb. \quad (4.8)$$

$$Vazao_{\beta,\gamma} \leq Lim_{sup,\beta,\gamma}, \quad \forall \beta \in Comb., \forall \gamma \in Cald. \quad (4.9)$$

$$Vazao_{\beta,\gamma} \geq Lim_{inf,\beta,\gamma}, \quad \forall \beta \in Comb., \forall \gamma \in Cald. \quad (4.10)$$

$$Vp_{\gamma} \geq Vp_{min,\gamma}, \quad \forall \gamma \in Cald. \quad (4.11)$$

$$Vp_{\gamma} \leq Vp_{max,\gamma}, \quad \forall \gamma \in Cald. \quad (4.12)$$

$$Vp_{\gamma} - Vp_{\gamma'} - M(1 - q_{\gamma}) - M(1 - q_{\gamma'}) \leq \delta Vp \quad (4.13)$$

$$q_{\gamma} \in \{0, 1\} \quad (4.14)$$

Em (4.7) e (4.8), limita-se a condição atual de operação dos mesmos, com base na disponibilidade de cada combustível, conforme Tabela 4.1. Já em (4.9) e (4.10) são considerados os limites operacionais relacionados às condições de projeto dos equipamentos.

TABELA 4.1: Parâmetros da instância do problema, $\text{Base}_{1,\beta}$ e $\text{Base}_{2,\beta}$.

Combustíveis	$\text{Base}_{1,\beta}$	$\text{Base}_{2,\beta}$
G_{AC} (kNm ³ /h)	0.0	0.0
G_{AF} (kNm ³ /h)	10.0	5.0
G_{CO} (kNm ³ /h)	1.0	3.0
GN (kNm ³ /h)	1.0	1.0
Óleos (Ton/h)	1.0	1.0

Além da restrição imposta pelos combustíveis, avalia-se também a produção de vapor de cada caldeira. Somente é justificável operar uma caldeira que produza, pelo menos, um valor mínimo pré-determinado de vapor (4.11), limitado à capacidade máxima de produção da mesma (4.12).

Por fim, espera-se uma determinada equalização da produção, de forma que, caso uma caldeira falhe, as demais consigam assumir a produção sem entrar em regimes críticos de operação. Para tanto, em (4.13) e (4.14) define-se que a diferença de produção de vapor entre as caldeiras deve respeitar um valor de segurança δV_p , definido por projeto, e que entra na formulação via estratégia do *BigM*; esta estratégia já foi empregada, por exemplo, em [Baker \(1974\)](#), [Ravindran et al. \(1987\)](#), [Liao and You \(1992\)](#).

Assim, o problema consiste em otimizar o rendimento do sistema de caldeiras da Central Termoelétrica, por meio do levantamento de um conjunto de soluções eficientes que caracterizem diferentes *trade-offs* entre produção de vapor e gasto energético. Em outros termos, a partir de um retrato instantâneo que representa a condição atual das caldeiras e a quantidade de combustível disponível para queima, buscam-se as melhores distribuições de combustíveis que permitam, simultaneamente, a maximização da produção de vapor e a minimização do consumo energético.

4.2.6 Método de Agregação ϵ -Restrito

Considerando a natureza multiobjetivo do problema, optou-se pela utilização da estratégia ϵ -restrito, proposta por [Ritzel et al. \(1994\)](#). Essa técnica permite transformar um problema multiobjetivo em escalar, ao definir um dos objetivos como principal, e as demais funções como restrições adicionais de desigualdade.

Nesse contexto, para a obtenção do modelo mono-objetivo via estratégia ϵ -restrito, adotou-se a maximização da produção de vapor como o objetivo principal e definiu-se a informação da

energia como restrição em múltiplos processos de otimização, conforme indicado em (4.15). Dessa maneira, é possível obter diferentes soluções Pareto-ótimas (Batista and Batista, 2018).

$$\begin{aligned}
& \text{Maximizar} \quad \sum_{\beta \in \text{Comb.}} \sum_{\gamma \in \text{Cald.}} \text{Vazao}_{\beta,\gamma} \times \text{PCI}_{\beta} \times \text{Coef}_{\beta,\gamma} \\
& \text{sujeito a:} \quad \sum_{\beta \in \text{Comb.}} \sum_{\gamma \in \text{Cald.}} \text{Vazao}_{\beta,\gamma} \times \text{PCI}_{\beta} \leq \epsilon \\
& \quad \text{Disp}_{\beta} - \text{Base}_{1,\beta} \leq \sum_{\gamma \in \text{Cald.}} \text{Vazao}_{\beta,\gamma}, \quad \forall \beta \in \text{Comb.} \\
& \quad \sum_{\gamma \in \text{Cald.}} \text{Vazao}_{\beta,\gamma} \leq \text{Disp}_{\beta} + \text{Base}_{2,\beta}, \quad \forall \beta \in \text{Comb.} \\
& \quad \text{Vazao}_{\beta,\gamma} \leq \text{Lim}_{\text{sup},\beta,\gamma}, \quad \forall \beta \in \text{Comb.}, \forall \gamma \in \text{Cald.} \\
& \quad \text{Vazao}_{\beta,\gamma} \geq \text{Lim}_{\text{inf},\beta,\gamma}, \quad \forall \beta \in \text{Comb.}, \forall \gamma \in \text{Cald.} \\
& \quad \text{Vp}_{\gamma} \geq \text{Vp}_{\text{min},\gamma}, \quad \forall \gamma \in \text{Cald.} \\
& \quad \text{Vp}_{\gamma} \leq \text{Vp}_{\text{max},\gamma}, \quad \forall \gamma \in \text{Cald.} \\
& \quad M = \max(\text{Vp}_{\text{max},\gamma}) \\
& \quad \text{Vp}_{\gamma} - \text{Vp}_{\gamma'} - M(1 - q_{\gamma}) - M(1 - q_{\gamma'}) \leq \delta \text{Vp} \\
& \quad q_{\gamma} \in \{0, 1\}, \quad \gamma \text{ e } \gamma' : \forall \gamma \text{ e } \gamma' \in \text{Cald.}, \gamma \neq \gamma'
\end{aligned} \tag{4.15}$$

4.3 Criação do Modelo de Identificação

A criação de um modelo capaz de representar o funcionamento do sistema é uma etapa fundamental para o desenvolvimento da otimização. Além disso, destaca-se que qualquer erro de representação será propagado para as demais etapas do projeto, como otimização e tomada de decisão. Portanto, a viabilidade da solução está intimamente ligada ao modelo bem ajustado e alimentado com informações confiáveis.

Após a garantia de coleta de dados e a devida extração de informações, ainda falta um parâmetro para compor a fórmula estacionária exposta inicialmente em (3.2). Sabe-se que é um grande equívoco tentar representar um modelo dinâmico com parâmetros fixos, uma vez que tal coeficiente de performance do combustível varia conforme cada caldeira, cada combustível, além de variar conforme cada regime operacional. Esse último parâmetro, inclusive, é uma característica que inviabiliza muitas aplicações que linearizam o sistema, pois negligenciam as nuances operacionais presentes no cotidiano, sendo necessária a criação de um modelo tolerante e adaptativo.

No trabalho de Wei et al. (2020), os autores realizaram uma regressão quadrática para ajuste dos modelos, inclusive com correlação satisfatória para representação dos mesmos. Na coleta de

dados do presente trabalho, enfrentou-se grande amplitude de temperatura ambiente, problemas de encrustação de dutos, performance de caldeiras variáveis com o tempo e diferentes *setpoints* operacionais.

Portanto, utilizou-se um método de identificação caixa-cinza, composto por uma base linear, como definido na função objetivo da formulação (4.15), e uma parte residual a ser tratada via rede neural, cuja adaptação é realizada a cada iteração, com faixa temporal $t - 100 \text{ min}$, a fim de se utilizar o modelo mais representativo possível no instante da otimização, conforme ilustração da proposta na Figura 4.5. Dessa maneira, o modelo híbrido resultante dessa estratégia de identificação irá substituir a função objetivo da formulação (4.15).




FIGURA 4.5: Diagrama de criação do modelo de identificação

A rede neural construída contém três etapas básicas, vide equação (4.16). O processamento inicial recorre à função de base radial Gaussiana, ajustando os centros dos 50 neurônios de entrada. A saída dessa camada inicial alimenta uma rede neural tradicional totalmente conectada de 32 neurônios, com função de ativação *ReLU* e regularização ativa, aplicando *Dropout* com uma taxa de 0.1 para evitar *overfitting*. Por fim, as informações são linearizadas na camada de saída, projetando os 32 neurônios em apenas um. Essa arquitetura ainda conta com 5000 épocas de treinamento e taxa de aprendizagem de 0.001.

$$\text{Entrada} \rightarrow 50 \text{ Neurônios RBF} \rightarrow 32 \text{ Neurônios (ReLU)} \rightarrow 1 \text{ Neurônio de Saída} \quad (4.16)$$

4.4 Ferramenta Otimizadora

Tendo em vista a característica não linear do modelo de identificação criado para representar o sistema de caldeiras, bem como a necessidade de resposta em um curto período de tempo, optou-se por resolver o problema de otimização recorrendo a um algoritmo meta-heurístico.

Uma variante do algoritmo *Particle Swarm Optimization* (PSO) será responsável por explorar o ambiente de factibilidade, em busca de soluções que otimizam a função objetivo. Nesse caso, atrelado ao ϵ -restrito, a estratégia será mapear pelo menos oito soluções de compromisso para cada perfil energético, conforme problema de otimização definido em (4.15).

Vale destacar que essa abordagem não garante otimalidade, mas a entrega ágil de uma solução melhor que a inicial já é satisfatória no ponto de vista do estudo de caso. Para cada mudança de patamar energético, especificada pelo parâmetro ϵ_i , a solução inicial adotada será a solução alternativa encontrada na iteração anterior ($i - 1$).

O método QPSO (*Quantum-behaved Particle Swarm Optimization*), [Sun et al. \(2004\)](#), é uma variação do enxame de partículas original, contemplando adaptações na maneira de evolução das partículas. Em vez de usar vetores de posição e velocidade, o QPSO modela cada partícula como uma “nuvem de probabilidade” em um poço de potencial quântico, cujo centro é definido pela média das melhores soluções do enxame.

No que se refere ao processo de otimização heurística, existem preocupações atreladas à escolha dos algoritmos, principalmente quando se refere ao *trade-off exploration e exploitation*. O QPSO, com uma filosofia focada em tratar a situação descobrindo soluções potencialmente melhores ou mais eficientes que as conhecidas pelas partículas vigentes, está sujeita a necessitar de mais tempo e o esforço para satisfazer a exploração, e portanto, pode resultar em pequeno aprofundamento da solução. Dependendo da natureza do problema, pode não ser capaz de convergir e aprofundar nas buscas, como o código PSO original.

Destaca-se que a evolução da partícula é desvinculada da trajetória anterior, podendo assumir posições completamente distintas, devido à natureza probabilística. Em comparação com o PSO convencional, esse comportamento permite a exploração do espaço de busca de maneira mais ampla e mitiga a estagnação em mínimos locais.

No Algoritmo 1, tem-se a representação de um pseudocódigo que detalha o funcionamento do QPSO.

Primeiramente, estabelecem-se os parâmetros do algoritmo: define-se o tamanho da população $N_{particulas}$, o número de iterações de busca $N_{iteracoes}$ e o fator de controle α que determina a velocidade de busca. No estudo de caso, recorrem-se a 10 partículas, que farão a busca em no máximo 100 iterações com coeficiente de evolução α igual a 0.96. Vale explicitar que cada

Algorithm 1 Método QPSO

```

1: Parâmetros:  $N_{particulas}, N_{iteracoes}, \alpha$ 
2: Inicialização:
3: for  $i = 1$  to  $N_{particulas}$  do
4:    $x_i(0) = \text{posição aleatória}$ 
5:    $pbest_i(0) = x_i(0)$ 
6:  $gbest(0) = \text{melhor posição entre todos os } pbest_i(0)$ 
7: for  $t = 0$  to  $N_{iteracoes} - 1$  do
8:   ▷ Loop Principal
9:   for  $i = 1$  to  $N_{particulas}$  do
10:    ▷ Atualiza a posição da partícula
11:     $u_1 = \text{random}(0, 1)$ 
12:     $u_2 = \text{random}(0, 1)$ 
13:     $u_3 = \text{random}(0, 1)$ 
14:    if  $\text{random}(0, 1) > 0.5$  then
15:       $rSign = 1$ 
16:    else
17:       $rSign = -1$ 
18:     $c_i(t) = \left( (u_1 \cdot pbest_i(t)) + (u_2 \cdot gbest(t)) \right) / (u_1 + u_2)$ 
19:     $L(t) = (1/\alpha) \cdot |c_i(t) - x_i(t)|$ 
20:     $x_i(t+1) = c_i(t) + rSign \cdot L(t) \cdot \ln(1/u_3)$ 
21:    ▷ Atualiza pbest e gbest
22:    if  $f_{obj}(x_i(t+1)) - f_{restr}(x_i(t+1)) < f_{obj}(pbest_i(t)) - f_{restr}(pbest_i(t))$  then
23:       $pbest_i(t+1) = x_i(t+1)$ 
24:    if  $f_{obj}(pbest_i(t+1)) - f_{restr}(pbest_i(t+1)) < f_{obj}(gbest(t)) - f_{restr}(gbest(t))$  then
25:       $gbest(t+1) = pbest_i(t+1)$ 
26: Retornar:  $gbest(N_{iteracoes})$ 

```

solução apresenta 20 dimensões, tendo em vista que representa as informações dos 5 combustíveis referentes às 4 caldeiras.

Destaca-se que, inicialmente, cada membro da população é alocado em uma posição aleatória no espaço de busca do problema. Além disso, considera-se que a melhor posição que cada partícula já visitou, $pbest_i(0)$, é a sua própria posição inicial e, dentre essas, o melhor global inicial, $gbest(0)$, assume aquela que resulta na melhor posição para o problema.

Na linha 7, inicia-se o *loop* principal. Nesse trecho, tem-se a repetição da heurística de busca e evolução da população até o limite de iterações definido. Pode-se, também, definir um critério de parada além do número de iterações.

A nova posição da partícula é baseada em um “ponto de atração”. Este ponto (c_i) é um local aleatório entre a melhor posição pessoal da partícula ($pbest_i$) e a melhor posição global ($gbest$). Isso garante um equilíbrio entre a exploração de novas áreas e a exploração de áreas de sucesso.

Já o poço de potencial (L) é um conceito quântico que define o “tamanho da área de busca” da partícula. Ele é calculado com base na definição do parâmetro α e na diferença entre a posição inicial e o ponto de atração c_i .

Por fim, a atualização da posição ($x_i(t + 1)$) é calculada a partir do seu ponto de atração c_i e do poço de potencial L . Vale ressaltar que a partícula pode se mover para “frente” ou “trás” desse ponto de atração, com uma probabilidade de 50% para cada direção, devido ao parâmetro de sinal $rSign$. Isso permite que a partícula explore a vizinhança do ponto de atração, o que ajuda a evitar que ela fique presa em um mínimo local.

Observa-se que o processo de otimização ocorre de forma irrestrita a cada iteração, com as restrições sendo avaliadas apenas ao final do ciclo. Ao se detectar violações, aplica-se uma penalidade proporcional à função objetivo da respectiva partícula. Para que a punição seja relevante sem romper o processo evolutivo, um fator de ponderação, na escala de milhar, ajusta a violação para a mesma ordem de grandeza da função objetivo. Dessa forma, a busca é consistentemente guiada para longe de soluções inviáveis, penalizando cada violação de acordo com sua gravidade.

Ao final, avalia-se se há atualizações dos melhores valores individuais $pbest_i$, bem como o melhor global $gbest$.

4.5 Tomada de Decisão Assistida

Após obter um conjunto estimado de soluções Pareto-ótimas para o problema, deve-se escolher qual dessas soluções caracteriza a alternativa de melhor *trade-off* para se implementar na prática.

Nesse contexto, emprega-se neste trabalho uma estratégia amplamente difundida na literatura de teoria da decisão, conhecida como PROMETHEE II, (Brans, 1982).

O método PROMETHEE sugere uma alternativa de projeto a partir da comparação das soluções disponíveis, considerando-se a avaliação das mesmas em um conjunto de critérios/atributos. Os critérios usados neste estudo incluem a eficiência energética, as emissões de CO₂, bem como o balanço financeiro e o impacto nas caldeiras pelo uso de determinado combustível. A Tabela 4.2 expõe os atributos e seus respectivos pesos, definidos em conjunto com profissionais do setor da Central Termoelétrica do estudo de caso.

TABELA 4.2: Atributos e Pesos usados no PROMETHEE

Atributo	Descrição	Peso
C_1	Eficiência (Vapor/Energia)	0.3
C_2	Emissões de GEE	0.4
C_3	Nota de Sujidade	0.2
C_4	Impacto Financeiro / Geração	0.1

Para calcular o indicador de impacto financeiro, obtém-se a diferença de produção total de vapor da solução proposta em relação ao cenário inicial. Essa diferença, se positiva, pode ser utilizada para geração de energia e, com base nos geradores à disposição deste estudo, sabe-se que, para cada 4.2 Ton de vapor, se produz 1.0 MWh de energia elétrica. Em contrapartida, se tal diferença de produção for negativa, ou seja, menos vapor é produzido na solução proposta, desconta-se a quantidade de potencial que poderia ser convertida em energia elétrica.

A quantidade de combustível utilizada também contribui para o indicador balanço financeiro. Nesse caso, se for poupado o uso de energia proveniente da queima de combustíveis, então faz-se a conversão em quantidade de Gás Natural que, supostamente, seria adquirida no mercado para suprir a demanda anterior não otimizada. Dessa maneira, consegue-se contabilizar o impacto financeiro. Notavelmente, quanto maior o valor deste indicador, melhores serão os retornos financeiros da solução proposta. Destaca-se que o mesmo vale para a razão *Vapor/Energia*.

A eficiência, por sua vez, pode ser entendida como a quantidade de vapor produzido utilizando 1.0 Mcal de energia. Ou seja, quanto maior esse indicador, mais eficiente será a solução.

Foi realizada uma ponderação simples a respeito do uso dos combustíveis e do impacto na manutenção das caldeiras, considerando as características de cada um, como registrado de forma qualitativa na Tabela 3.5.

A equação (4.17) representa o vetor de sujidade dos combustíveis (considera-se a mesma sequência de combustíveis apresentada em (4.1)); quanto maior o valor adotado, mais prejudicial ele é para a integridade do sistema. Dessa forma, uma nota é atribuída a cada solução estimada, a qual é dada pela soma ponderada dos combustíveis utilizados.

$$\text{Coef}_{Sujidade} = \begin{bmatrix} 1 & 1 & 3 & 0 & 4 \end{bmatrix} \quad (4.17)$$

Empregou-se uma ideia similar para o cálculo da emissão de CO₂. Utilizando as relações estequiométricas percorridas anteriormente, pode-se contabilizar a taxa de emissão desse Gás de Efeito Estufa (GEE). Quanto maior o valor desse indicador, mais poluente é a solução proposta. Essas informações estão sintetizadas na Tabela 3.5.




FIGURA 4.6: Visão geral da metodologia proposta

Vale destacar que alguns dados foram disponibilizados na íntegra e outros não, por se tratarem de informações sigilosas. Dessa forma, para não se perder poder de comparação e não haver exposição de dados sensíveis deste estudo de caso, as informações de cada atributo foram descharacterizadas via normalização e convertidas em notas, de 0 a 1, de maneira que quanto maior a nota, melhor.

De maneira geral, propõe-se em avaliar os 100 *min* anteriores e extrair o modelo de identificação. Após isso, otimiza-se via QPSO e as possíveis soluções são analisadas pela ferramenta de tomada de decisão. Repete-se este processo a cada minuto, configurando um algoritmo de apoio à operação da Central Termoelétrica. Vide um fluxograma que apresenta a proposta metodológica ilustrado na Figura 4.6.

No próximo capítulo abordam-se os resultados obtidos, validando desde a fase de identificação do sistema até a tomada de decisão final.

Capítulo 5

RESULTADOS E DISCUSSÕES

Neste capítulo, o intuito é a apresentação dos resultados obtidos em cada etapa de aplicação da solução proposta. Destaca-se que toda a programação foi realizada em Python, usando o Jupyter Notebook, em um computador com *Ryzen 7* e 16 GB de memória RAM.

A proposta do sistema consiste em avaliar os 100 *min* anteriores e extrair o modelo de identificação. Após isso, deve-se rodar o algoritmo QPSO e otimizar o sistema com base na modelagem mais recente e propor as possíveis soluções que serão analisadas ao final, pela ferramenta de tomada de decisão. Todo esse processo deve ser realizado a cada minuto, quando novos dados são coletados do sistema.

Vale destacar que a parte da identificação dos modelos de cada uma das quatro caldeiras pode ser realizada em ambientes distintos (de maneira paralela), e ao final alimentar o otimizador para análise conjunta. É notório que essa estratégia pouparia tempo de processamento; no entanto, todas as tarefas foram realizadas de maneira sequencial neste estudo.

Para identificação do sistema, estima-se que se gastaram 15*seg* em cada caldeira. Originalmente, o algoritmo está plotando os resultados obtidos. Em caso de omissão dessa geração de gráficos e valores intermediários, o fluxo básico gasta em torno de 10*seg* para cada caldeira. Já para obtenção das 8 soluções do conjunto e tomada de decisão final, demanda-se em torno de 70*seg*. Dessa maneira, é certo que o computador utilizado no estudo de caso não é capaz de integrar ao sistema real, tendo em vista que demandará em torno de 2*min* em cada execução completa.

Neste capítulo são apresentados os resultados referentes ao primeiro turno de trabalho de um dia arbitrário da coleta de dados, bem como duas simulações horárias em cenários distintos. Cabe enfatizar que, no conjunto de dados coletados, não houve registro do uso de gás de aciaria. O gasômetro deste coproduto estava fora de operação.




FIGURA 5.1: Avaliação e tratamento de sinais
Vazão de vapor da Caldeira 01 do estudo de caso.
Fonte: Autoria própria.

5.1 Modelo de Identificação

O modelo de identificação recebe, a priori, os dados tratados, conforme dito no capítulo anterior. Empiricamente, alcançaram-se resultados suaves e sem atraso excessivo, considerando janela de 10 amostras para média móvel de Hull. Na Figura 5.1 é possível verificar a diferença entre o sinal de vazão de vapor com e sem o tratamento, na Caldeira 01. De uma forma geral, é perceptível que os grandes picos e vales são amenizados.

Como dito, a proposta do sistema de identificação é constituir um modelo adaptativo que captura a dinâmica dos últimos $100min$ de operação. Em um recorte destes $100min$ amostrados, a Figura 5.2 ilustra a diferença entre o sinal ruidoso e o sinal tratado. Nota-se que, apesar da capacidade de suavização e conservação das amplitudes, há um pequeno defasamento entre os sinais. Contudo, cabe ressaltar que todos os sinais são submetidos ao mesmo tratamento, de forma que entradas e saídas permanecem sincronizadas.

A Figura 5.3 ilustra a performance do sistema de representação proposto. Cabe lembrar que o modelo híbrido é composto por uma parcela linear e um termo não linear referente ao tratamento dos resíduos pela rede neural. Observa-se que o modelo linear, linha verde, não é suficiente para representar o sistema. No entanto, em conjunto com a correção proveniente do modelo neural, o modelo híbrido alcança uma representação mais ajustada.

A Tabela 5.1 mostra os erros médios obtidos ao longo da simulação. De maneira geral, é válido destacar que a hibridização alcançou resultados duas vezes mais assertivos do que a representação linear sozinha.




FIGURA 5.2: Avaliação e tratamento de sinais: Conjunto de treinamento
Vazão de vapor da Caldeira 01 do estudo de caso.
Fonte: Autoria própria.


TABELA 5.1: Erros médios de representação registrados ao longo da simulação

Modelo	MAE: Linear	MSE: Linear	MAE: Híbrido	MSE: Híbrido
Caldeira 01	0.877	1.157	0.543	0.595
Caldeira 02	0.522	0.464	0.114	0.031
Caldeira 03	0.376	0.302	0.127	0.031
Caldeira 04	0.749	0.724	0.228	0.093


5.2 Fronteira Pareto Estimada

A fim de ilustrar a consistência da ferramenta, a Figura 5.4 apresenta os resultados de 10 execuções do algoritmo para a mesma instância. O ponto principal é que o conjunto de execuções alcançaram soluções melhores que a condição inicial, próximas entre si, e configurando uma fronteira estimada convexa. Sendo o QPSO uma metaheurística, é esperado que se alcance respostas diferentes em cada execução, pois sua natureza estocástica não garante a otimalidade global. Além disso, a configuração adotada (10 partículas, 100 iterações) não visa a saturação da solução, mas sim um balanço que satisfaz a melhora da condição inicial em tempo hábil, atendendo à demanda operacional, Figura 5.4a. Testou-se também uma configuração mais poderosa, com 40 partículas e 400 iterações, vide na Figura 5.4b, uma convergência mais aparente, em detrimento de maior esforço computacional.


Essas análises mostram que o sistema proposto tem a capacidade de encontrar resultados consistentemente superiores em comparação com a solução inicial. Dessa maneira, assume-se que uma resolução é suficiente para representar o problema, e está alinhado à proposta de aplicação em tempo real.




(A) Modelagem Caldeira 01



(B) Modelagem Caldeira 02




(C) Modelagem Caldeira 03




(D) Modelagem Caldeira 04

FIGURA 5.3: Avaliação do modelo de identificação da produção de vapor.
Fonte: Autoria própria.



(A) Configuração QPSO com 10 Partículas e 100 Iterações.



(B) Configuração QPSO com 40 Partículas e 400 Iterações.

FIGURA 5.4: Avaliação de consistência do algoritmo em 10 execuções

5.2.1 Avaliação pontual : uma aplicação prática

A solução inicial parte pelo cenário representado pela Tabela 5.2. Nessas circunstâncias, o total de vapor produzido é, aproximadamente, 349.7 Ton, e o total de energia demandado é 249.9 Mcal. Nesse caso, faz-se a análise de disponibilidade e é avaliado o range energético que se pode excursionar.

TABELA 5.2: Fluxos de Combustível por Caldeira (em unidades de vazão)

Caldeira	G_{AF} (kNm ³ /h)	G_{CO} (kNm ³ /h)	G_{AC} (kNm ³ /h)	GN (kNm ³ /h)	Óleos (Ton/h)
1	50.50	3.68	0.00	0.00	0.00
2	29.18	1.2	0.00	0.00	4.25
3	44.77	7.22	0.00	0.00	0.00
4	55.12	3.51	0.00	0.97	0.00

TABELA 5.3: Vetor de energia admitida - limites de operação

	G_{AF} (kNm ³ /h)	G_{CO} (kNm ³ /h)	G_{AC} (kNm ³ /h)	GN (kNm ³ /h)	Óleos (Ton/h)
max	189.57	16.62	0.0	1.97	5.25
atual	179.57	15.62	0.0	0.97	4.25
min	174.57	12.62	0.0	0.0	3.25

A Tabela 5.3 indica os vetores máximo e mínimo de admissão de energia nas caldeiras, considerando os fatores $Base_{1,\beta}$ e $Base_{2,\beta}$, explicitados na seção 4.1. Dessas configurações, o máximo de energia admissível é 279.26 Mcal e o mínimo é definido como 216.28 Mcal. Por meio desses limites, extraem-se os oito patamares energéticos que definirão as restrições ϵ_i para as sucessivas otimizações, conforme Tabela 5.4.

TABELA 5.4: Valores de ϵ para o problema de otimização

Valores de ϵ
236.48
241.77
247.06
252.36
257.65
262.94
268.24
273.53

Considerando a metodologia proposta, otimizou-se cada instância do problema via algoritmo QPSO. Para fins de análise e discussões, expõem-se, na Figura 5.5, as soluções sumarizadas ao longo da fronteira Pareto estimada. Perceba que a fronteira foi obtida considerando uma única execução.




FIGURA 5.5: Relação entre Energia e Vapor Produzido - Fronteira Pareto Estimada.
Fonte: Autoria própria.

É importante destacar que algumas alternativas podem contemplar energias um pouco superiores ao respectivo valor de ϵ , apontado na Tabela 5.4. Essa infração é caracterizada pela estratégia de tratamento das restrições usada em conjunto com o QPSO. Diferente do que ocorre com as restrições de operação do sistema, os patamares de energia definidos pelos valores de ϵ foram configurados como restrições flexíveis. Portanto, esses resultados são devidamente penalizados, mas não descartados.

Na Figura 5.6, com o auxílio dos cones de dominância, é possível observar que a solução inicial é Pareto-dominada pelas três primeiras alternativas (à esquerda). Apesar das demais alternativas não dominarem a solução inicial, elas exprimem uma relação de compromisso entre produção de vapor e consumo de recursos energéticos mais interessante. Perceba ainda que nenhuma das soluções estimadas é Pareto-dominada entre si e juntas mapeiam toda a extensão da fronteira, sugerindo uma aproximação adequada da fronteira de soluções do problema. Apesar do otimizador não garantir a otimalidade, a ferramenta proposta se mostrou ágil (no contexto do problema) e capaz de encontrar soluções de compromisso tão boas ou melhores que a inicial.

Caso o sistema fosse mono-objetivo, como proposto em (4.5), a análise do sistema seria denotada pela razão entre os valores dos eixos da Figura 5.6, obtendo assim a Figura 5.7, dada pela razão entre vapor produzido e energia consumida. Ou seja, no cenário mono-objetivo, a segunda alternativa encontrada (cuja razão equivale a 1.578) seria indicada como solução do problema. Essa alternativa é claramente melhor que a solução inicial do sistema; no entanto, a partir de uma abordagem multiobjetivo e multicritério, conforme proposta deste trabalho, pode-se chegar




FIGURA 5.6: Análise dos cones de dominância - Fronteira Pareto Estimada.
Fonte: Autoria própria.

a uma tomada de decisão mais assertiva e apropriada para o sistema, uma vez que inúmeros atributos são considerados simultaneamente.




FIGURA 5.7: Avaliação da performance das soluções propostas - Pseudo Pareto Ótima.
Fonte: Autoria própria.

5.3 Seleção da Solução Interesse

Para a aplicação do PROMETHEE II, inicialmente é necessário levantar a performance das soluções alternativas considerando cada atributo. A Tabela 5.6 expõe tais informações, encontradas com base na metodologia definida. Nota-se a extração de informação de cada solução, bem como a composição dos critérios normalizados, para posterior análise da ferramenta de auxílio à decisão.

O PROMETHEE II é caracterizado pela avaliação do fluxo de sobreclassificação par a par entre as soluções. Essa avaliação considera a soma ponderada da performance dos atributos. Na Figura 5.8, é possível observar no eixo das ordenadas a discriminação das notas negativas obtidas por cada alternativa, e na abscissa, o somatório dos pontos positivos.

De forma visual, as soluções mais próximas do canto inferior direito do gráfico são as que melhor performaram na ótica do decisor. Dessa maneira, as alternativas 01 a 04 estão bem posicionadas em detrimento das demais, e a alternativa 02 é reconhecida como a melhor configuração pelo tomador de decisão, devido ao melhor saldo entre fluxos positivos e negativos. Neste caso, coincide com a solução ótima se o problema fosse mono-objetivo, no entanto, a depender do contexto, a tomada de decisão poderá levar a soluções distintas da otimização escalar, pois considera diferentes atributos e suas ponderações.

O fluxo líquido, responsável por sumarizar as notas obtidas e dar o suporte final à decisão, está representado na Figura 5.9 e valida toda a discussão anterior. Nota-se que, na perspectiva de análise da ferramenta de decisão, as alternativas 07 e 08 são inferiores à solução original, mas não significa que serão descartadas em outras óticas estratégicas.




FIGURA 5.8: Avaliação PROMETHEE II
Fonte: Autoria Própria




FIGURA 5.9: Avaliação PROMETHEE II - Fluxo líquido
Fonte: Autoria Própria

Considerando essas análises, para o estudo de caso em questão, a alternativa 02 é a que melhor se encaixa nas diretrizes definidas. Essa solução é caracterizada pelo seguinte perfil de combustíveis, exposto na Tabela 5.5.

TABELA 5.5: Fluxos de Combustível por Caldeira (em unidades de vazão) - Alternativa 02.

Caldeira	G_{AF} (kNm ³ /h)	G_{CO} (kNm ³ /h)	G_{AC} (kNm ³ /h)	GN (kNm ³ /h)	Óleos (Ton/h)
1	52.26	6.09	0.0	0.57	0.06
2	28.41	0.53	0.0	0.07	2.91
3	45.0	4.98	0.0	0.15	0.12
4	50.95	4.79	0.0	0.1	0.13

É importante destacar que, em relação à solução inicial, a alternativa 02 entrega 31 Ton/h de vapor a mais, equivalente a 9% de melhoria. Associado a isso, houve a redução de consumo energético em cerca de 3%. Com esses 3% de redução, tem-se a taxa de emissão de GEE, que, em valores absolutos, representa 7211.7 kg/h a menos de emissões.

A alternativa 02 ainda foi capaz de gerar, aproximadamente, 7.41 MWh com o vapor extra produzido e apresenta uma eficiência 13% superior à solução original. Destaca-se também que, tal proposta de solução alcança todos esses resultados sendo menos agressiva aos próprios equipamentos, uma vez que apresenta menor nota de sujeidade, pois optou-se por consumir menos recursos como óleo.

O algoritmo proposto apresentou uma busca pela redução do consumo de óleo, totalizando 1 Ton/h a menos. Essa redução dá suporte à menor nota de sujeidade alcançada pela alternativa 02. A solução inicial concentra o uso de óleo apenas na caldeira 02, e na solução proposta, nota-se uma sutil redistribuição deste ativo e redução pontual de 1.34 Ton/h, somente na caldeira 02.

O modelo adaptativo, ao avaliar os dados amostrados, deve ter notado um certo saturamento da performance da caldeira 02 na região da fornalha, o que justifica a redução expressiva do consumo de óleo e gás de coqueria. O oposto pode ser observado com o comportamento da caldeira 04. Nota-se a redução do consumo de gás de alto-forno e o aumento do consumo de gás de coqueria. Sabe-se que esses combustíveis exprimem comportamentos distintos e, portanto, o carregamento energético para o setor de recuperação provavelmente não estava performando tão bem quanto a troca de calor na fornalha.

A mudança de comportamento proposta para as caldeiras 02 e 04 tem o reflexo em performance exposto na Figura 5.11. Nota-se que a mudança do perfil de troca de calor é um indício de necessidade de manutenção preventiva nas respectivas áreas que foram evitadas. De certo modo, o resultado da ferramenta proposta pode ser empregado para avaliar a integridade física dos ativos.




FIGURA 5.10: Avaliação comparativa - distribuição de recursos

Fonte: Autoria Própria

Já a caldeira 03 mostra um equilíbrio entre solução original e a alternativa 02. Aparentemente, as duas grandes zonas de transferência de calor, fornalha e recuperador, performam similarmente, fato que pode ser observado pela pequena diferença de eficiência na Figura 5.11.

Por fim, observa-se que a caldeira 01 foi submetida a grande carga energética, em comparação com a solução original, vide Figura 5.10. Contudo, registrou-se perda de performance, vide Figura 5.11. Pela redistribuição de combustíveis, a alta concentração de gás de alto-forno pode ter carreado parcela da energia extra injetada pelo gás de coqueria e gás natural para o setor de recuperação. No entanto, registrou-se grande produção de vapor, conforme Figura 5.12.

Nota-se ainda que o otimizador poupou a entrada de energia nas caldeiras 02, 03 e 04, e elevou o fornecimento de recursos para a caldeira 01, vide Figura 5.10.




FIGURA 5.11: Avaliação comparativa - performance das caldeiras

Fonte: Autoria Própria

Já na Figura 5.11, pode-se observar que se fez mais com menos recursos. Destaca-se ainda, na Figura 5.12, que os níveis de produção não destoam entre si acima do fator de 30 ton/h, denotando operação dentro da margem de segurança.




FIGURA 5.12: Avaliação comparativa - produção de vapor
Fonte: Autoria Própria

5.4 Simulação Horária

Foram realizadas duas análises horárias de aplicação do algoritmo de otimização. Considerando que, dentro deste período de uma hora, a estratégia de operação mude e impacte na ação do tomador de decisão, recorreu-se ao estimador média, a fim de considerar o potencial de melhora das soluções propostas em cada iteração e comparar com o modo de operação real, com exceção das discussões de emissões de GEE e notas de sujidade, que são intrínsecos de cada avaliação.




FIGURA 5.13: Retrato de produção do mês coletado
Fonte: Autoria Própria

Escolheram-se dois cenários para esta avaliação. O primeiro cenário de desafio é caracterizado pela operação de apenas três das quatro caldeiras em funcionamento. Nesse caso, a caldeira 03

está parada para manutenção, e as outras três precisaram assumir a produção. Veja os dias 12 a 15 da Figura 5.13. Observa-se que a faixa de operação das caldeiras mudou para suprir a falta de uma fonte geradora. Já o segundo cenário é um retrato horário de um período sem notificações de anomalias, a fim de avaliar se a ferramenta de otimização também é útil no cotidiano.

5.4.1 Três Caldeiras em Funcionamento

Ao analisar a média das soluções propostas e o retrato real do período, observou-se que a produção de vapor foi superior ao praticado. Note na Figura 5.14 que em nenhum momento obteve-se uma proposta de produção inferior à produção real, significando que as propostas estão aderentes aos princípios de operação.

Ao final desse período de análise, a produção devida da solução otimizada está em torno de 394.25 Ton, enquanto o retrato real esteve na casa dos 362.14 Ton.




FIGURA 5.14: Análise comparativa de produção de vapor - Simulação de três caldeiras em operação

Fonte: Autoria Própria

Já pela Figura 5.15, observa-se que o consumo energético nesse período totalizou 280.77 Mcal para a solução proposta, enquanto a operação real consumiu 275.4 Mcal.




FIGURA 5.15: Análise comparativa de consumo de energia - Simulação de três caldeiras em operação

Fonte: Autoria Própria

Essa diferença de produção na ordem de 32.11 Ton representa cerca de 9% de melhora em produção, tendo como base o aumento de 2% do consumo de recursos. Destaca-se ainda que o sistema saiu de um patamar de performance de 1.31 para 1.40 em uma condição de operação crítica, tendo em vista que o sistema estava operando com apenas três caldeiras, mas entregando a produção equivalente ao conjunto completo. Além de garantir o fornecimento de vapor, a diferença de produção gera 7.64 MWh de energia elétrica para a usina.

Ao considerar que a parada da caldeira 03 durou 4 dias, e que essa margem de operação crítica se manteve durante esse período, o potencial de geração de energia elétrica extra alcança um patamar acumulado de 733,4 MWh, equivalente a trinta minutos da produção da Usina Hidrelétrica de Furnas, se operar com sua capacidade total de 1216 MW (Furnas, 2023).

5.4.2 Operação Convencional

No cenário convencional, ao analisar a média das soluções propostas e o retrato real do período, observa-se que a produção de vapor foi superior ao praticado. Note na Figura 5.16 que em nenhum momento obteve-se uma proposta de produção inferior à produção real, significando que as propostas estão aderentes aos princípios de operação. Ao final desse período de análise, a produção devida da solução otimizada está em torno de 311.74 Ton, enquanto o retrato real esteve na casa dos 270.56 Ton.




FIGURA 5.16: Análise comparativa de produção de vapor - Simulação todas as caldeiras em operação

Fonte: Autoria Própria

Já pela Figura 5.17, observa-se que o consumo energético nesse período totalizou 202.1 Mcal para a solução proposta, enquanto a operação real consumiu 195.1 Mcal.




FIGURA 5.17: Análise comparativa de consumo de energia - Simulação todas as caldeiras em operação

Fonte: Autoria Própria

Essa diferença de produção na ordem de 41.2 Ton representa cerca de 15% de melhora em produção, tendo como base o aumento de 4% do consumo de recursos. Destaca-se ainda que o sistema saiu de um patamar de performance de 1.38 para 1.54, além de possibilitar a produção de 9.8 MWh de energia elétrica para a usina.

Por se tratar de operação convencional, pode-se estimar que ao longo de um mês, caso esse perfil se mantenha, o potencial de geração de energia elétrica extra fica na casa dos 7000 MWh. Se comparado a Furnas, equivalem a quase 6h de operação contínua, em plena carga.

TABELA 5.6: Resultados do Processo de Otimização - avaliação das soluções

Opção	Vapor [ton/h]	Energia [MCal/h]	Emissão [kg/h]	Sujidade	Geração [MWh]	Eficiência	C1	C2	C3	C4
Sol. Orig.	349.69	249.89	262433.49	243.42	0.00	1.40	0.00	0.66	0.67	0.00
Altern. 01	354.68	236.35	253657.79	235.20	1.19	1.50	0.57	1.00	1.00	0.09
Altern. 02	380.82	241.36	255221.80	238.67	7.41	1.58	1.00	0.94	0.86	0.55
Altern. 03	389.74	247.08	259305.10	242.08	9.53	1.58	1.00	0.78	0.73	0.70
Altern. 04	396.48	252.31	261907.29	243.87	11.14	1.57	0.96	0.68	0.65	0.82
Altern. 05	400.22	257.42	266917.91	248.88	12,03	1,55	0,87	0,49	0,45	0,89
Altern. 06	403.20	262.99	275599.06	255.62	12,74	1,53	0,75	0,15	0,19	0,94
Altern. 07	404.80	268.33	277383.46	257.75	13,12	1,51	0,61	0,08	0,10	0,97
Altern. 08	406.65	273.63	279542.36	260.29	13,56	1,49	0,49	0,00	0,00	1,00

Capítulo 6

CONCLUSÕES

Conforme exposto, a postura observada nas grandes empresas vem mudando, demonstrando maior preocupação com o meio ambiente e os impactos relacionados às respectivas operações. Considerando o cenário ambiental, é certo que a academia tem um importante papel na construção de ferramentas que dão suporte ao desenvolvimento sustentável.

Tendo em vista o nicho de conversões energéticas e, com foco maior em siderúrgicas, fica nítida a oportunidade cercada pelo presente trabalho. O projeto desenvolvido foi capaz de explorar uma brecha até então existente na academia, ao tratar o problema de cogeração no setor de Ferro e Aço, concebendo um otimizador multiobjetivo associado à ferramenta de auxílio à tomada de decisão multicritério, desvinculado do viés exclusivamente financeiro.

A modelagem matemática proposta representa o problema fenomenológico de conversão calorífica para um sistema multicomcombustível baseado em dados. Para o estudo de caso exposto na Seção 5.1, foi possível representar a dinâmica do sítio de caldeiras com erro absoluto médio de 0.253 Ton/h, o que representa cerca de 0,28% do valor nominal praticado no conjunto (89.25 Ton/h). Além do ajuste satisfatório proveniente da modelagem híbrida não linear, a estratégia abordada não se limita a um tipo exclusivo de caldeiras, ou está definida sob parâmetros fixos. A proposta de identificação promove uma modelagem genérica, capaz de se adaptar a mudanças inerentes ao processo e representar outros tipos de sistemas multicomcombustíveis.

Cabe destacar o tratamento abrangente do problema de otimização ao contemplar múltiplos objetivos. Com o apoio do QPSO, foi possível levantar candidatos da fronteira Pareto estimada. Destaca-se que o recurso heurístico viabiliza o uso da ferramenta, permitindo a entrega de soluções que não violam as limitações operacionais em tempos compatíveis com a dinâmica do processo real, apesar de não ter garantias de otimalidade.

Já a ferramenta de suporte à decisão multicritério PROMETHEE II avalia cada alternativa encontrada e ordena com base nos atributos específicos do problema, alinhados com a unidade de

decisão. Havendo mudança estratégica no plano de produção, caberá ajuste de tal ponderação dos atributos, no entanto, todo o conjunto à montante se mantém sem modificações. Foi possível definir atributos consistentes com o problema siderúrgico e conflitantes entre si. Com isso, o algoritmo consegue analisar cada cenário, considerando impacto ambiental, dano ao próprio ativo, eficiência energética e balanço financeiro. Em geral, após a aplicação nos dois cenários de desafio, permitiu-se notar a adoção de soluções não triviais que, em comparação com a solução inicial, refletem em ganho de performance, redução de emissões e aumento de produção, com consequente retorno financeiro pela produção extra de energia elétrica.

Além do atendimento às expectativas originais, a discussão dos resultados evidenciou que as respostas fornecidas pela ferramenta podem constituir um diagnóstico de performance para o sistema. Dessa maneira, os *stakeholders* podem planejar manutenções com mais acurácia e até remediar, preventivamente, a indisponibilidade do equipamento.

Destaca-se que o estudo se limitou ao atendimento do cenário inicial, ou seja, respeita as condições mínimas definidas pela operação. Portanto, as respostas apresentadas apontavam sempre para uma geração positiva de energia, devido à produção extra de vapor. No entanto, para projetos futuros, pode-se constituir o problema de maneira distinta, ao contemplar mais informações, como demanda das cargas associadas, vazão de entrada de ar, temperatura de admissão, disponibilidade das malhas de controle e condição operacional dos gasômetros.

Vale ressaltar que, apesar de serem dados reais, os experimentos foram realizados em ambiente computacional. Além disso, todo o processamento foi delegado a apenas um computador, gastando aproximadamente $2min$ para uma análise completa. A modularidade do projeto permite a distribuição das tarefas, de maneira que, em trabalhos futuros, a identificação do sistema de cada caldeira pode ser responsabilidade de um computador dedicado, enquanto outro processa as iterações da otimização, permitindo a garantia do respeito às diretrizes temporais e, com isso, viabilizando a aplicação em ambientes reais.

Considerando apenas a divisão de tarefas, a aplicação modular da identificação de sistema gastaria em torno de $10seg$ em cada computador. Já a resolução do otimizador e tomada de decisão assumiriam mais $70seg$ de execução. Ao todo, utilizando cinco computadores do mesmo modelo do estudo de caso, demandam-se em torno de $80seg$ para uma análise completa. Contudo, em trabalhos futuros, pode-se recorrer a uma configuração mais avançada de hardware, na tentativa de entregar resultados ao controlador dentro do *deadline* de $60seg$, e viabilizar a aplicação prática na indústria siderúrgica. Outro fator que pode contribuir para a redução do tempo de execução é o uso de linguagens de programação compiladas, como *C/C++* e *Fortran*.

Como trabalho de continuidade, tem-se em mente, também, conceber um modelo de desempenho dos turbo-geradores e integrar ao escopo deste estudo. Além do mais, pretende-se representar as condições adversas de combustão, considerando os efeitos de pressão e temperatura

da fornalha, a fim de possibilitar a contabilização estequiométrica das emissões de NO_x , contribuindo para uma avaliação mais assertiva dos impactos da solução no aquecimento global. Por fim, cabe destacar a oportunidade de utilizar modelos mais complexos de otimização multiobjetivo, como abordagens MOPSO, NSGA-II e SPEA2, capazes de tratar o problema sem a necessidade de modularizar a solução, ou recorrer aos métodos de agregação.

BIBLIOGRAFIA

- LORENA SOUZA VALADARES DE CARVALHO. Análise de diferentes medidas de mitigação para neutralização da emissão de carbono em uma siderúrgica integrada. *Departamento De Engenharia De Produção, Administração E Economia - Universidade Federal de Ouro Preto*, 2021.
- Ronaldo Pexe. A maior turbina a vapor do mundo, 2021. URL <https://turbivap.com.br/a-maior-turbina-a-vapor-do-mundo/>.
- Luiz Antônio Moschini de Souza. Inspeção de caldeiras. *Instituto Brasileiro de Petróleo e Gás, Guias de inspeção*, 5, page 72, 2020.
- Luis Alberto Villaça. Características Físicas e Químicas, 2023. URL <https://pt.linkedin.com/pulse/processo-de-produ%C3%A7%C3%A3o-coque-e-seus-principais-desafios-villa%C3%A7a>.
- D. Merrick. *Mathematical models of the thermal decomposition of coal*, volume 62. Fuel, 1983.
- M. GEERDES, C. V. D. VLIET, and F. T. TOXOPEUS, H.and MEDEIROS. *Modern Blast Furnace Ironmaking*. Delft University Press, 2015.
- B. Voraberger, G. Wimmer, U. Dieguez Salgado, E. Wimmer, K. Pastucha, and A. Fleischanderl. Green ld (bof) steelmaking—reduced co2 emissions via increased scrap rate. *Metals*, 12:466, 2022. doi: <https://doi.org/10.3390/met12030466>.
- Alberto Luiz Serpa. Controle de sistemas em tempo contínuo, 2007. UNICAMP.
- L.A. Aguirre. *Introdução à Identificação de Sistemas – Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais*. Editora UFMG, 2007.
- MATLAB Help Center. Hammerstein-wiener model of si engine torque dynamics, 2025. https://www.mathworks.com/help/ident/ug/hammerstein-wiener-model-of-si_engine_torque_dynamics.html.
- Berk Hakbilen. O que é uma Máquina de Vetores de Suporte?, 2022. URL <https://hackernoon.com/lang/pt/o-que-%C3%A9-uma-m%C3%A1quina-de-vetores-de-suporte>.

- Ishika Kulkarni. Random Forest in R Programming, 2023. URL <https://www.scaler.com/topics/random-forest-in-r/>.
- Roberto Peixoto. Cop 28 começa nesta quinta; saiba o que está em jogo e o que esperar da conferência sobre a crise do clima., 2024. URL <https://shorturl.at/gpzOX>.
- PactoGlobal.org. ESG, 2000. URL <https://www.pactoglobal.org.br/esg/>.
- Anselmo Lázaro Branco. Revoluções industriais, 2024. URL <https://shorturl.at/yBLNU>.
- L. A. Tavares. Matriz elétrica brasileira e as tendências futuras. *RECIMA21 - Revista Científica Multidisciplinar*, 2023.
- Carlos Eduardo Machado Paletta, Pedro Lo Giudice, Antonio Marcos Furco Junior, and Leonardo Buranello. Tecnologia aplicada a geração de energia elétrica utilizando unidades termoeletricas. *34º Seminário de Balanços Energéticos e 28º Seminário de Gases Industriais - ABM*, pages 56–64, 2013.
- Sophie Knöttner and René Hofmann. Assessment and conceptualization of industrial energy flexibility supply in mathematical optimization in a competitive and changing environment. *Energy Conversion and Management*, 304, 2024.
- consilium.europa.eu. Poluição atmosférica na UE: factos e números, 2025. URL <https://www.consilium.europa.eu/pt/infographics/air-pollution-in-the-eu/>.
- gov.br. Rumo à COP30, 2025. URL <https://www.gov.br/planalto/pt-br/agenda-internacional/missoes-internacionais/cop28/cop-30-no-brasil>.
- FGVces. Programa brasileiro ghg protocol, 2024. URL <https://shorturl.at/crzDJ>.
- Sudhansu S. Mishra, Taraprasad Mohapatra, Sudhansu Sekhar Sahoo, and Prasheet Mishra. Overall performance investigation and optimization of a multi-fuel operated compression ignition engine using coupled taguchi and grey relational analysis. *ACS Omega*, 7(37):33216–33232, 2022. doi: 10.1021/acsomega.2c03566. URL <https://doi.org/10.1021/acsomega.2c03566>.
- Nicolas Walter, Michael Guenther, Matthias Thees, and Jonas Fuhrmeister. Optimization of the dpf-regeneration strategy for the use of vegetable oil in a multi-fuel-engine concept. *University of Kaiserslautern*, 2023.
- M. Krishnamoorthi and R. Malayalamurthi. Combined effect of compression ratio, injection pressure, and injection timing on performance and emission of a di compression ignition engine fueled with diesel–aegle marmelos oil–diethyl ether blends using response surface methodology, 2017.

- Yiwei Wu, Hongyu Zhang, Fei Li, Shuaian Wang, and Lu Zhen. Optimal selection of multi-fuel engines for ships considering fuel price uncertainty. *Mathematics*, 11(17), 2023. ISSN 2227-7390. doi: 10.3390/math11173621. URL <https://www.mdpi.com/2227-7390/11/17/3621>.
- Pierluigi Mancarella. Mes (multi-energy systems): An overview of concepts and evaluation models, 2013.
- Samira Fazlollahi, Pierre Mandel, Gwénaëlle Becker, and François Maréchal. Methods for multi-objective investment and operating optimization of complex energy systems, 2012.
- Hrvoje Dorotić, Tomislav Pukšec, and Neven Duić. Multi-objective optimization of district heating and cooling systems for a one-year time horizon. *Energy*, 169:319–328, 2019.
- Xu Chen. Novel dual-population adaptive differential evolution algorithm for large-scale multi-fuel economic dispatch with valve-point effects. *Energy*, 203:117874, 2020. ISSN 0360-5442. doi: <https://doi.org/10.1016/j.energy.2020.117874>. URL <https://www.sciencedirect.com/science/article/pii/S0360544220309816>.
- Ana María Sarmiento Alejandro Aragón-Zavala Fernando Lezama Gerardo Castañón, Alberto F. Martínez-Herrera. Comparative analysis of nature-inspired algorithms for optimal power flow problem: A focus on penalty-vanishing terms and algorithm performance, 2024.
- Monica Secui Dinu Călin Secui. Social small group optimization algorithm for large-scale economic dispatch problem with valve-point effects and multi-fuel sources, 2024.
- Chintalapudi V. Suresh and Sirigiri Sivanagaraju. Analysis and effect of multi-fuel and practical constraints on economic load dispatch in the presence of unified power flow controller using udtppo. *Ain Shams Engineering Journal*, 6(3):803–817, 2015. ISSN 2090-4479. doi: <https://doi.org/10.1016/j.asej.2014.12.011>. URL <https://www.sciencedirect.com/science/article/pii/S2090447915000039>.
- Xu Chen and Kangji Li. Collective information-based particle swarm optimization for multi-fuel chp economic dispatch problem. *Knowledge-Based Systems*, 248:108902, 2022. ISSN 0950-7051. doi: <https://doi.org/10.1016/j.knosys.2022.108902>. URL <https://www.sciencedirect.com/science/article/pii/S0950705122004324>.
- Jiahua Ni Farzad Ghayoor Pierluigi Siano Hassan Haes Alhelou Arman Goudarzi, Shah Fahad. A sequential hybridization of etlbo and ipso for solving reserve-constrained combined heat, power and economic dispatch problem, 2022.
- M. Basu. Bee colony optimization for combined heat and power economic dispatch. *Expert Systems with Applications*, 38:13527–13531, 2011.

- Lavinia Marina Paola Ghilardi, Alessandro Francesco Castelli, Luca Moretti, Mirko Morini, and Emanuele Martelli. Co-optimization of multi-energy system operation, district heating/cooling network and thermal comfort management for buildings. *Applied Energy*, 302:117480, 2021. ISSN 0306-2619. doi: <https://doi.org/10.1016/j.apenergy.2021.117480>. URL <https://www.sciencedirect.com/science/article/pii/S0306261921008680>.
- Georgios I. Tsoumalis, Zafeirios N. Bampos, Georgios V. Chatzis, Pandelis N. Biskas, and Stratos D. Keranidis. Minimization of natural gas consumption of domestic boilers with convolutional, long-short term memory neural networks and genetic algorithm. *Applied Energy*, 299:117256, 2021. ISSN 0306-2619. doi: <https://doi.org/10.1016/j.apenergy.2021.117256>. URL <https://www.sciencedirect.com/science/article/pii/S0306261921006760>.
- Lygin M.M. Varganova A.V. Optimization of the composition of the fuel mixture of industrial thermal power plants. *International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon)*, 2019.
- Majid Majidi, Behnam Mohammadi-Ivatloo, and Amjad Anvari-Moghaddam. Optimal robust operation of combined heat and power systems with demand response programs. *Applied Thermal Engineering*, 149:1359–1369, 2019.
- Viknesh Andiappan Wei Jen Lok, Lik Yin Ng. Optimal decision-making for combined heat and power operations: A fuzzy optimisation approach considering system flexibility, environmental emissions, start-up and shutdown costs, 2020.
- Sebastian Goderbauer, Björn Bahl, Philip Voll, Marco E. Lübbecke, André Bardow, and Arie M. C. A. Koster. An adaptive discretization MINLP algorithm for optimal synthesis of decentralized energy supply systems. *Computers & Chemical Engineering*, 95:38–48, 2016.
- Tohid Nasiri, Moein Moeini-Aghaie, Mehdi Foroughi, and Meisam Azimi. Energy optimization of multi-carrier energy systems to achieve a low carbon community. *Journal of Cleaner Production*, 390:136154, 2023. ISSN 0959-6526. doi: <https://doi.org/10.1016/j.jclepro.2023.136154>. URL <https://www.sciencedirect.com/science/article/pii/S0959652623003128>.
- Grzegorz Bartnicki, Marcin Klimczak, and Piotr Ziembicki. Evaluation of the effects of optimization of gas boiler burner control by means of an innovative method of fuel input factor. *Energy*, 263:125708, 2023. ISSN 0360-5442. doi: <https://doi.org/10.1016/j.energy.2022.125708>. URL <https://www.sciencedirect.com/science/article/pii/S0360544222025944>.

- Ibrahim Kshanh and Makoto Tanaka. Comparative analysis of mcdm for energy efficiency projects evaluation towards sustainable industrial energy management: Case study of a petrochemical complex. *Expert Systems with Applications*, 255:124692, 2024. ISSN 0957-4174. doi: <https://doi.org/10.1016/j.eswa.2024.124692>. URL <https://www.sciencedirect.com/science/article/pii/S0957417424015598>.
- M. Abdul Quader, Shamsuddin Ahmed, Raja Ariffin Raja Ghazilla, Shameem Ahmed, and Mahidzal Dahari. A comprehensive review on energy efficient co2 breakthrough technologies for sustainable green iron and steel manufacturing. *Renewable and Sustainable Energy Reviews*, 50:594–614, 2015. ISSN 1364-0321. doi: <https://doi.org/10.1016/j.rser.2015.05.026>. URL <https://www.sciencedirect.com/science/article/pii/S1364032115004852>.
- J.H. Kim, H.-S. Yi, and C. Han. A novel milp model for plantwide multiperiod optimization of byproduct gas supply system in the iron- and steel-making process. *Chemical Engineering Research and Design*, 81(8):1015–1025, 2003. ISSN 0263-8762. doi: <https://doi.org/10.1205/026387603322482248>. URL <https://www.sciencedirect.com/science/article/pii/S0263876203723909>. Particle Technology.
- Haining Kong, Ershi Qi, Hui Li, Gang Li, and Xing Zhang. An milp model for optimization of byproduct gases in the integrated iron and steel plant. *Applied Energy*, 87(7):2156–2163, 2010. ISSN 0306-2619. doi: <https://doi.org/10.1016/j.apenergy.2009.11.031>. URL <https://www.sciencedirect.com/science/article/pii/S0306261909005182>.
- Ershi QI, Haining Kong, Shuguang HE, and Gang LI. Milp model for plant-wide optimal by-product gas scheduling in iron and steel industry. *Journal of Iron and Steel Research, International*, 17(7):34–37, 2010. ISSN 1006-706X. doi: [https://doi.org/10.1016/S1006-706X\(10\)60153-7](https://doi.org/10.1016/S1006-706X(10)60153-7). URL <https://www.sciencedirect.com/science/article/pii/S1006706X10601537>.
- Haining Kong. A green mixed integer linear programming model for optimization of byproduct gases in iron and steel industry, 2015.
- Xiancong Zhao, Hao Bai, Xin Lu, Qi Shi, and Jiehai Han. A milp model concerning the optimisation of penalty factors for the short-term distribution of byproduct gases produced in the iron and steel making process. *Applied Energy*, 148:142–158, 2015. ISSN 0306-2619. doi: <https://doi.org/10.1016/j.apenergy.2015.03.046>. URL <https://www.sciencedirect.com/science/article/pii/S030626191500330X>.
- Jing hui YANG, Jiu ju CAI, Wen qiang SUN, and Jing yu LIU. Optimization and scheduling of byproduct gas system in steel plant. *Journal of Iron and Steel Research, International*, 22(5):408–413, 2015. ISSN 1006-706X. doi: <https://doi.org/10.1016/j.apenergy.2015.03.046>.

- 1016/S1006-706X(15)30020-0. URL <https://www.sciencedirect.com/science/article/pii/S1006706X15300200>.
- Valter B. de Oliveira Junior, João G. Coelho Pena, and José L. Félix Salles. An improved plant-wide multiperiod optimization model of a byproduct gas supply system in the iron and steel-making process. *Applied Energy*, 164:462–474, 2016. ISSN 0306-2619. doi: <https://doi.org/10.1016/j.apenergy.2015.11.043>. URL <https://www.sciencedirect.com/science/article/pii/S0306261915014932>.
- Yujiao Zeng, Xin Xiao, Jie Li, Li Sun, Christodoulos A. Floudas, and Hechang Li. A novel multi-period mixed-integer linear optimization model for optimal distribution of byproduct gases, steam and power in an iron and steel plant. *Energy*, 143:881–899, 2018. ISSN 0360-5442. doi: <https://doi.org/10.1016/j.energy.2017.10.122>. URL <https://www.sciencedirect.com/science/article/pii/S0360544217318285>.
- Qi Zhang, Ziqing Wei, Jialin Ma, Ziyang Qiu, and Tao Du. Optimization of energy use with co2 emission reducing in an integrated iron and steel plant. *Applied Thermal Engineering*, 157:113635, 2019. ISSN 1359-4311. doi: <https://doi.org/10.1016/j.applthermaleng.2019.04.045>. URL <https://www.sciencedirect.com/science/article/pii/S1359431118369795>.
- Ziqing Wei, Xiaoqiang Zhai, Qi Zhang, Gan Yang, Tao Du, and Junqing Wei. A minlp model for multi-period optimization considering couple of gas-steam-electricity and time of use electricity price in steel plant. *Applied Thermal Engineering*, 168:114834, 2020. ISSN 1359-4311. doi: <https://doi.org/10.1016/j.applthermaleng.2019.114834>. URL <https://www.sciencedirect.com/science/article/pii/S1359431119359460>.
- Qi Zhang Shuai Liu, Xie Sheng. Multi-energy synergistic optimization in steelmaking process based on energy hub concept, 2021.
- Xianhao Chen Sha Peng Han Xi, Xiao Wu. Artificial intelligent based energy scheduling of steel mill gas utilization system towards carbon neutrality, 2021.
- Zhengbiao Hu and Dongfeng He. Operation scheduling optimization of gas–steam–power conversion systems in iron and steel enterprises. *Applied Thermal Engineering*, 206:118121, 2022. ISSN 1359-4311. doi: <https://doi.org/10.1016/j.applthermaleng.2022.118121>. URL <https://www.sciencedirect.com/science/article/pii/S1359431122000850>.
- Tong Wang Jiawei Lv Yixuan Han Lin Mu Tingting Xu, Zhaoyi Huo. Multi-objective optimization of gas-steam-power system for an integrated iron and steel mill considering carbon emission reduction and cost, 2023.

- Tingting Xu, Zhaoyi Huo, Wenjing Wang, Ning Xie, Lili Li, Yingjie Liu, and Lin Mu. Evaluation of by-product-gas utilization options for carbon reduction at an integrated iron and steel mill, 2024.
- L. Neto and L. Batista. Otimização energética em sistemas de combustão multicomcombustível. *Congresso Brasileiro de Automática*, 4, 2024.
- T. L. Saaty. *Fundamentals of Decision Making and Priority Theory with the Analytic Hierarchy Process*. RWS Publications, 2013.
- S. R. Turns. *An Introduction to Combustion: Concepts and Applications (3rd ed.)*. McGraw-Hill Education, 2012.
- & Yetter R. A. Glassman, I. *Combustion. (4th ed.)*. Academic Press., 2008.
- José Geraldo da Silva Moreira. Desenvolvimento de uma metodologia para determinação contínua do consumo específico por combustível e priorização da distribuição de combustíveis entre caldeiras. *Programa De Pós-Graduação Em Engenharia De Energia - Universidade Federal De São João Del-Rei*, 2007.
- Guido Marseglia Carlo Maria Medaglia Valentina Coccia Alessandro Petrozzi Andrea Nicolini Gianluca Cavalaglio Franco Cotana, Sabrina Vittori. Pollutant emissions of a biomass gasifier inside a multifuel energy plant, 2019.
- Renata Lima Casemiro, Neyda de la Caridad Om Tapanes, Ana Isabel de Carvalho Santana, and Roberta Gaidzinski. Balanço energético de um forno de fabricação de coque em uma coqueria heat recovery. *ABM*, 2019.
- Diniz Lobão, Paulo Eduardo Rodrigues, José Ramon Martinez Pontes, and Patrícia Alcântara Cardoso. Aproveitamento de características físicas dos gases de alto forno para geração de energia elétrica em uma siderúrgica: O caso da companhia siderúrgica de tubarão (cst). *XXIII Encontro Nac. de Eng. de Produção*, 2003.
- ArcelorMittal Pecém. Quem somos., 2025. URL <https://brasil.arcelormittal.com/a-arcelormittal/quem-somos/arcelormittal-pecem>.
- Marcos Antonio Rodrigues, Rafael Cesar de Souza, Leonardo Benevides Etrusco, Elmo Coelho Sobrinho, Ricardo da Silva Rodrigues, and Francis Wellington Moraes. Otimização da recuperação e distribuição do gás de aciaria. *ABM*, 2018.
- Gasmig. Características Físicas e Químicas, 2023. URL <https://https://gasmig.com.br/caracteristicas-fisicas-e-quimicas/>.
- Carlos Henrique Ribeiro de Carvalho. *Emissões Relativas De Poluentes Do Transporte Motorizado De Passageiros Nos Grandes Centros Urbanos Brasileiros*. Instituto de Economia Aplicada, 2011.

- B.P. Lathi. *Sinais e Sistemas Lineares - 2.ed.* Bookman, 2006. ISBN 9788560031139. URL <https://books.google.com.br/books?id=ySxoo2TVeeYC>.
- Y. Collette and P. Siarry. *Multiobjective Optimization: Principles and Case Studies*. Decision Engineering. Springer Berlin Heidelberg, 2013.
- V. Chankong and Y.Y. Haimes. *Multiobjective Decision Making: Theory and Methodology*. Dover Publications, 2008.
- W. Pedrycz, P. Ekel, and R. Parreiras. *Fuzzy Multicriteria Decision-Making: Models, Methods and Applications*. Wiley, 2010.
- J. P. Brans. L'ingénierie de la décision: Elaboration d'instruments d'aide à la décision. *European Journal of Operational Research*, 1982.
- Alan Hull. How to reduce lag in a moving average - hull moving average (hma): The indicator explained, 2005. URL <https://alanhull.com/hull-moving-average>.
- K. R. Baker. Introduction to sequencing and scheduling. *Operations Research*, 23:62–73, 1974.
- A. Ravindran, D. T. Phillips, and J. J. Solberg. Operations research: principles and practice. *New York: John Wiley & Sons*, 1987.
- C. J. Liao and C. T. You. An improved formulation for the job shop scheduling problem. *Operational Research Society*, 11:1047–1054, 1992.
- B. J. Ritzel, J. W. Eheart, and S. Ranjithan. Using genetic algorithms to solve a multiple objective groundwater pollution containment problem. *Water Resources Research*, 30:1589–1603, 1994.
- André Costa Batista and Lucas S. Batista. Demand side management using a multi-criteria ϵ -constraint based exact approach. *Expert Systems with Applications*, 99:180–192, 2018.
- Jun Sun, Bin Feng, and Wenbo Xu. Particle swarm optimization with particles having quantum behavior. 1:325–331 Vol.1, 2004. doi: 10.1109/CEC.2004.1330875.
- Eletrobras Furnas. Usina de furnas, 2023. URL <https://www.furnas.com.br/subsecao/120/usina-de-furnas---1216-mw>.